



UN ENFOQUE BAYESIANO DE PLANEACIÓN AGREGADA ORIENTADO AL RETAIL MARKETING

José Antonio Taquía Gutiérrez
Corporación Yanbal International. Lima, Perú

Recibido: 16 de julio de 2015 / Aprobado: 7 de agosto de 2015

Resumen

La necesidad de generar eficiencias en las compras por volumen, o de mejorar la exactitud de los pronósticos de venta, crea un esfuerzo de integración en las organizaciones que buscan tener presencia en el canal comercial para ganar cuota de mercado. La planeación de largo plazo queda restringida a una planeación estratégica de lineamientos, escenarios prospectivos o políticas comerciales que debido a la incertidumbre sobre el comportamiento de las diversas variables influyentes en un plan de nivel táctico reducen la posibilidad de incrementar los horizontes de planeación. En el presente artículo se describe el aporte del enfoque bayesiano para mejorar la exactitud de los pronósticos ante un incremento de la periodicidad de los consumos, en un entorno altamente dinámico debido a la influencia de los cambios de estrategias comerciales de mediano y corto plazo, como ocurre usualmente en el retail marketing.

Palabras clave: cadena de abastecimiento / gestión de demanda / marketing cuantitativo / pronósticos bayesianos

A Bayesian Approach to Aggregate Planning Oriented to Retail Marketing

Summary

The need to generate efficiencies in volume purchases or improve the accuracy of sales forecasts is based on integration efforts within organizations competing in retail channel pursuing gain market share. Long-term planning is usually restricted to a strategic planning guidelines, foresight scenarios or trade policies where the uncertainty of different variables generates little influence on tactical level planning. This article discusses the contribution of the Bayesian approach used to improve tactical planning in a highly dynamic environment due to the influence of changes in business strategies of medium and short term as usually occurs in retail marketing environment.

Key words: supply chain / demand planning / quantitative marketing / bayesian forecasting

Introducción

En los procesos de operaciones de manufactura, la visibilidad de los consumos futuros determina el desempeño de una cadena de abastecimiento, siendo mayor el impacto en productos con demanda volátil. Por este motivo, muchas empresas hacen esfuerzos por gestionar la demanda futura con la mayor periodicidad posible. Este horizonte futuro, también denominado visibilidad, es dinámico y cambiante.

En el presente trabajo se abordará el problema de la falta de visibilidad táctica en empresas con procesos de abastecimiento complejo, buscando un método que permita incrementar el horizonte de estimación de la demanda. El horizonte de estimación táctica varía según el correspondiente sector comercial, debido a las estructuras de abastecimiento que cada categoría puede tener en función a la complejidad de la gestión de los proveedores (Lapide, 2014), conviviendo en una misma empresa diversos horizontes de planificación de demanda. Por experiencia del autor, el horizonte de planificación más utilizado para un análisis táctico es el período mensual, y la propuesta de este caso es obtener una proyección agregada por trimestre.

Está demostrado que la ruptura de los tiempos de abastecimiento en los proveedores tiene, como una de sus causas principales, la falta de la visibilidad en el horizonte de los consumos que se requieren comprar (Chopra y Meindl, 2013). En mercados maduros de productos básicos los modelos estadísticos tradicionales aportan mucho en la obtención de estas proyecciones (Simchi-Levi, 2010; Valencia, Correa, Díaz y Ramírez, 2014), pero la complejidad se incrementa cuando el consumo es influenciado por estrategias de *marketing* para impulsar las ventas; esto se muestra de manera más evidente cuando el modelo del negocio no toma contacto con el cliente final, a diferencia de los productos de consumo masivo. Modelos de negocio basados en venta por Internet, por campañas de suscripción, por catálogo, entre otros, son altamente dinámicos en asignar ofertas.

Para mejorar la proyección de un estimado utilizando métodos bayesianos se requiere conocer *a priori* la influencia de información empírica en el escenario por proyectar. Los métodos bayesianos son considerados un aporte de la teoría condicional de la probabilidad, siendo utilizados especialmente en series estacionarias de datos secuenciales (Gamerman y Lopes, 2006).

Como una intuición del aporte de información no estructurada en un proceso estocástico, esta técnica ha aumentado las posibilidades de investigación en temas como salud (Gelman, Carlin, Stern, Vehtari y Rubin, 2014), *marketing* (Rossi y Allenby, 2003), operaciones (Lunn, Jackson, Best, Thomas y Spiegelhalter, 2013), por mencionar solo algunos. En este sentido, las variables nominales, categóricas y escalares pueden construir indicadores y establecer patrones o tendencias partiendo de una confirmación posterior, en la medida en que la información enriquezca los estimadores de los parámetros asociados a las distribuciones de probabilidad utilizadas.



1. Situación problemática

Entre los problemas que aparecen en una cadena de abastecimiento sin una gestión de demanda equilibrada se encuentran el exceso de inventario y la pérdida de ventas. Estos son dos de los efectos más notorios de una inadecuada previsión del consumo futuro. Asimismo, otra consecuencia de una cadena de abastecimiento desbalanceada es el efecto látigo (Simchi-Levi, 2010), descrito como el exceso de materiales y componentes ante cambios en la información del proceso de demanda, efecto estudiado en detalle por Forrester (2007) como un caso clásico de dinámica de sistemas. Por estas razones, la gestión de la demanda en cadenas de abastecimiento requiere incrementar la visibilidad de los consumos que le permita a la empresa planificar y organizarse en estos escenarios.

En este artículo se describe el caso de una empresa que comercializa y repara calzado, en la cual se tiene una gran variabilidad en el proceso de recepción de demanda, y dificultades en la predicción del comportamiento futuro de dicha demanda. Entre los efectos del proceso de gestión de demanda sin equilibrio táctico-operativo se tiene a la gran cantidad de actividades de respuesta, la falta de seguimiento de una planificación agregada y el impacto negativo en la percepción del servicio al cliente.

El modelo de negocio de la empresa de calzado es similar al de las tiendas *retail*, ya que dispone de locales en diversas ubicaciones geográficas, y uno solo donde se realiza la manufactura y funciona el taller de reparación (Euromonitor, 2014). Debido a que una gran variedad de productos requieren insumos que son abastecidos por proveedores que atienden a múltiples clientes, la coordinación de compras capta mayor protagonismo, puesto que se busca obtener beneficios de compra por volumen, en la medida en que diversos productos requieren de materiales comunes que pueden agregarse.

2. Marco referencial

La modelación y la optimización bayesianas de pronósticos de la demanda es una técnica que ha tomado mayor interés en la comunidad académica vinculada a las cadenas de abastecimiento. Valencia, Correa, Díaz y Ramírez (2014) proponen aplicar técnicas bayesianas y técnicas de optimización, utilizando el error porcentual de un pronóstico como una variable del modelo. El trabajo de Wagner (2010) muestra la utilidad de los métodos ARIMA ante la información de demanda diaria para un producto típico de consumo masivo. Tomando como referencia estudios de oportunidades de investigación en el campo de cadenas de abastecimiento (Stock, Boyer y Harmon, 2010), los métodos de planeación agregada utilizados en contexto de cadenas de abastecimiento se pueden encontrar como reglas de operación (Simchi-Levi, 2010). El aporte bayesiano en cadenas de abastecimiento se observa

en los trabajos de uso de información *a priori* en experimentos de simulación (Muñoz y Muñoz, 2008); además de métodos de series de tiempo usando Holt-Winters (Bermúdez, Segura y Vercher, 2010).

Como la gestión del abastecimiento es consecuencia de la medición del pronóstico de demanda, se utilizará la medición del pronóstico futuro como una fuente de información que, gestionada con un enfoque predictivo, se convierte en una herramienta táctica para atenuar las naturales fluctuaciones del proceso de estimación. Existe material referencial que aborda este tipo de enfoque (Gaur, Kesavan, Raman y Fisher, 2007; Fildes y Kingsman, 2011; Chase, 2014), pero hay diferencias en la práctica local de aspectos vitales debido a que en el mercado *retail* peruano existe un uso limitado de técnicas cuantitativas para estimar la demanda y establecer una periodicidad adecuada de abastecimiento.

3. Marco teórico

3.1 Gestión de la demanda

La evaluación de la gestión de la demanda se puede realizar a través de diversas métricas e indicadores, entre los que se menciona la exactitud del pronóstico, la calidad del consenso comercial, el nivel de cobertura del inventario, la cantidad de ventas perdidas, la proporción de pedido completo que se entrega, entre otros. Muchas de estas medidas del proceso pueden estar poco enlazadas, configurándose escenarios operativos aislados, es decir, sin un contexto particular que soporte las métricas del proceso.

En la mayoría de empresas la propuesta del consumo futuro, obtenido a partir de un pronóstico, pasa por una secuencia de consensos organizacionales tomando en cuenta variables del mercado y restricciones de la operación comercial. La periodicidad táctica y operativa no requiere coincidir con el planeamiento agregado, lo que abre una oportunidad para desarrollar el balance entre la demanda y el abastecimiento, subiendo el nivel de la agregación de la serie (Rossi y Allenby, 2003).

Para los empresarios del rubro *retail*, que desarrollan sus negocios con tiendas que reciben pedidos y centralizan sus operaciones, la agregación de la demanda es una buena estrategia de operación porque les permite mejorar eficiencias en el aprovisionamiento, y si adicionalmente se implementan tácticas de preparación previa, podrán mejorar su nivel de servicio a la demanda.



Tabla 1
Origen de la variabilidad en los componentes del proceso de gestión de abastecimiento

Origen Proveedores	Foco en la gestión de proveedores	Inestabilidad en los tiempos de abastecimiento
Origen interno	Relacionado con la manufactura y la distribución	Inconsistencia del rendimiento operativo
		Ratios inestables de producción
		Alta variabilidad en los niveles de inventario
		Inconsistencia en la calidad de los productos
	Tiempos inestables de entrega	
Relacionado con la gestión de <i>marketing</i>	Inestabilidad en las políticas, lineamientos y estrategias de <i>marketing</i>	
Relacionado con la estimación	Modelos de pronósticos inadecuados	
Origen contexto	Foco en las restricciones de distribución	Asignación de rutas Ventanas de tiempo de entrega y distribución Normativas municipales cambiantes
Origen en el cliente	Foco en los clientes	Cambios atribuidos al cliente

Elaboración propia

3.2 Exactitud de los pronósticos

La exactitud del pronóstico es una métrica bastante estudiada, pero poco utilizada; esta medición se incluye como parte de los informes sobre el comportamiento de la demanda en un periodo comercial ya cerrado. Para realizar el cálculo de una métrica de exactitud del pronóstico a través de un grupo de productos, se puede utilizar el cálculo promedio del error porcentual (*MAPE - mean absolute percentage error*).

$$MAPE = \frac{\sum_{t=1}^n \left(\frac{|Y_t - \hat{Y}_t|}{Y_t} \right)}{n}$$

Donde:

Y_t : Unidades reales observadas en el periodo t .

\hat{Y}_t : Valor ajustado para el periodo t .

Nota: el valor obtenido se expresa en forma porcentual.

Tabla 2
Cálculo del error del pronóstico por el MAPE

	Producto 1	Producto 2	Producto 3	Producto 4	Total
Pronóstico	75	0	25	75	175
Real	25	50	75	74	224
Error	50	50	50	1	151
% Error	200	100	66,7	1,3	67,4
% Exactitud	0	0	33,3	98,7	32,6

Elaboración propia

El MAPE es la métrica más utilizada en diversas industrias debido a su facilidad de interpretación administrativa y de procesamiento computacional (Chase, 2014). Lo que usualmente no se analiza en las empresas es la diferencia entre la exactitud operativa, que utiliza las unidades vendidas como denominador en el cálculo del error, y la exactitud comercial, donde el error se obtiene al utilizar el pronóstico en denominador. Esta diferencia representa directamente un incremento en las unidades de inventario.

$$\text{Exactitud operativa} = 1 - \frac{\sum_{t=1}^n \left(\frac{|Y_t - \hat{Y}_t|}{Y_t} \right)}{n}$$

$$\text{Exactitud comercial: } 1 - \frac{\sum_{t=1}^n \left(\frac{|Y_t - \hat{Y}_t|}{\hat{Y}_t} \right)}{n}$$

Usualmente, las proyecciones muestran tendencia sistemática a seguir una dirección. La mayoría de los sesgos en una serie pueden ocurrir debido a un incremento del estimado para alcanzar un objetivo comercial, ajustar el valor futuro para reducir la exposición al riesgo de tener venta perdida debido a la falta de producto, adicionando efectos que atenúen la incertidumbre (*stock* de protección), el ciclo de vida del producto en clara tendencia de crecimiento, etc. Este tipo de sesgo puede generar directamente un innecesario incremento del inventario y un mayor riesgo de productos obsoletos, si fuera el caso.




Figura 1. Seguimiento operativo de la estimación
Elaboración propia

3.3 Enfoque bayesiano

Por otro lado, el enfoque bayesiano está en sintonía con los estudios cuasi experimentales de la práctica empresarial donde se requiere tomar decisiones, haciendo que el objetivo de la investigación se oriente en conocer la probabilidad de que ocurra un evento o una secuencia de eventos, dados los datos iniciales o indicios que se observan y desean analizar (Cea, 2012). Este tipo de análisis se puede aplicar en variables con comportamiento continuo o discreto que intervienen en los problemas de la gestión empresarial (Lunn, et al., 2013).

3.3.1 Teorema de Bayes

Por el teorema de Bayes se tiene que:

$$P(\theta | f(x)) = \frac{P(\theta)P(f(x)|\theta)}{\int f(x)dx}$$

Como el denominador $\int f(x)dx$ es independiente de θ , entonces el teorema se puede escribir con la notación de proporcionalidad:

$$P(\theta | f(x)) \propto P(\theta)P(f(x)|\theta)$$

Donde $f(x)$ se puede obtener por:

$\sum_{\theta} f(x|\theta)f(\theta)$, si x es una variable aleatoria discreta.

$\int_{\theta} f(x|\theta)f(\theta)$, si x es una variable aleatoria continua.

Los resultados de un análisis bayesiano se expresan como una función de la probabilidad posterior de los diferentes valores de un parámetro (θ), por ejemplo; la media o la dispersión, que se desea utilizar para describir un comportamiento. El análisis bayesiano empieza especificando distribuciones *a priori* de un parámetro desconocido, buscando obtener la función posterior que permita determinar un intervalo de confianza que incluya el verdadero valor de θ

3.3.2 Distribución *a priori*

De acuerdo con González (2009), al realizar inferencias sobre un parámetro generalmente se cuenta con alguna información acerca de su valor. La distribución *a priori* $\pi(\theta)$ representa lo que se conoce, antes de observar dato alguno, sobre el parámetro desconocido θ .

A. Determinación subjetiva de la distribución *a priori*

Un aspecto importante que se debe considerar es la información *a priori* acerca del parámetro de interés θ . La información disponible debe ser cuantificada a través de medidas de probabilidad sobre el espacio paramétrico Θ , ya que $\theta \in \Theta$; si Θ es un espacio discreto, se determina una probabilidad subjetiva para cada elemento de Θ , y si Θ es un espacio continuo, la determinación de la distribución *a priori* $\pi(\theta)$ es más laboriosa (González, 2009).

B. Distribución *a priori* no informativa

Cuando el conocimiento inicial sobre el valor del parámetro θ es muy vago, se utiliza un tipo de distribuciones *a priori* denominadas 'distribuciones *a priori* no informativas', las cuales consideran el bajo nivel de conocimiento sobre el parámetro. Una distribución sobre el parámetro θ será del tipo no informativa si no determina que unos valores de θ son más o menos favorables que otros. A modo de ejemplo, "si se establecen dos hipótesis simples sobre el valor de θ y asignamos una probabilidad 1/2 a cada una de ellas, se tiene una situación no informativa" (González, 2009, p. 12).



3.3.3 Modelo clásico y bayesiano de regresión lineal múltiple

A. Modelo clásico de regresión

Al considerar un modelo clásico de regresión lineal múltiple, donde la variable de respuesta Y está relacionada a una o más variables predictoras, X_1, X_2, \dots, X_{n-1} para una muestra aleatoria de n casos donde X_{i1} es el valor del modelo en un momento temporal:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_{K-1} X_{i,K-1} + \varepsilon_i, \quad \varepsilon \sim N(0, \sigma^2)$$

Este modelo en forma matricial se denota como:

$$Y = X\beta + \varepsilon, \quad \varepsilon \sim (0, \sigma^2)$$

Donde

$$Y = \begin{bmatrix} Y_1 \\ \dots \\ Y_n \end{bmatrix}, \quad X = \begin{bmatrix} 1 & X_{11} & \dots & X_{1,K-1} \\ 1 & X_{21} & \dots & X_{2,K-1} \\ \dots & \dots & \dots & \dots \\ 1 & X_{n1} & \dots & X_{n,K-1} \end{bmatrix}, \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \dots \\ \varepsilon_n \end{bmatrix}, \quad \beta = \begin{bmatrix} \beta_1 \\ \dots \\ \beta_{K-1} \end{bmatrix}$$

Donde los vectores de X , las observaciones $Y_i = 1, \dots, T$, tienen función de densidad $N(y_i, X_i, \beta, \sigma^2)$ similar a la función normal de los errores junto a los vectores β y σ^2 la función de verosimilitud sería:

$$l(\beta, \theta^2 | X, y) = (2\pi\sigma^2)^{-T/2} \exp\left\{-\frac{1}{2\sigma^2}(Y - X\beta)'(Y - X\beta)\right\}$$

B. Modelo bayesiano de regresión lineal múltiple

El modelo bayesiano es similar al modelo clásico, con la diferencia de que en el modelo bayesiano se incluye la distribución *a priori* de los parámetros (González, 2009). Para la distribución *a posteriori* del modelo bayesiano, con información *a priori* no informativa, se tiene el modelo:

$$Y = X\beta + \varepsilon,$$

En donde $\varepsilon_1, \dots, \varepsilon_n$ son independientes, entonces $\varepsilon \sim N_n(0, \sigma^2 I)$. Así la función de verosimilitud queda definida como:

$$l(\beta, \sigma^2 | Y) = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} \exp\left[-\frac{1}{2\sigma^2}(Y - X\beta)'(Y - X\beta)\right]$$

Dado que: $\tilde{\beta} = (X'X)^{-1} X'Y$ y $\tilde{Y} = X\tilde{\beta}$, se tiene:

$$l(\beta, \sigma^2 | Y) = \frac{1}{(2\pi)^{n/2} \sigma^n} \exp\left[-\frac{1}{2\sigma^2}\left[vS^2 + (\beta - \tilde{\beta})' X'X(\beta - \tilde{\beta})\right]\right]$$

Como β es un parámetro de localización, el cual desplaza la distribución hacia los valores menores o mayores, mientras σ^2 es parámetro de escala, el

cual define la dispersión de la distribución, entonces, las distribuciones *a priori* no informativas son:

$$\pi(\beta) \propto 1$$

$$\pi(\sigma^2) \propto 1/\sigma^2$$

3.3.4 Validación de modelo bayesiano

El modelo bayesiano se puede validar obteniendo el coeficiente de ajuste bayesiano para analizar la distribución *a posteriori* obtenida, para lo cual se simulan muestras y_1, \dots, y_n con la mencionada distribución, a partir de los vectores de las variables independientes. Asimismo, para verificar un valor puntual se puede observar la posición relativa de y_i con respecto a la distribución de los valores simulados de \tilde{y}_i , si este valor se encuentra en alguno de los extremos entonces significa que es un potencial *outlier*.

4. Caso aplicado

El presente artículo sugiere un marco de análisis posible de ser aplicado a cualquier entorno *retail* que tenga como característica principal la gestión de productos con tiempo de abastecimiento, que requieran compromisos de consumos futuros. La empresa donde se aplicó el análisis comercializa y repara calzado para damas y varones¹. Como se observa en la serie existen patrones de tendencia y estacionalidad.




Figura 2. Demanda mensual de órdenes de trabajo

Fuente: Calzados Murga EIRL

1 La empresa Calzados Murga cuenta con tres locales comerciales: dos ubicados en Lima (San Juan de Lurigancho y Miraflores) y uno en Trujillo. La data de esta empresa fue gestionada por Anabel Murga y Diandra Curich, de agosto de 2014 a julio de 2015.



El objetivo del análisis es determinar una proyección trimestral de órdenes de trabajo, utilizando el método de series de tiempo y el método de regresión bayesiana con información *a priori* de variables consideradas no informativas.

La información mensual de los consumos determina la cantidad de material de inventario requerido para su atención. Materiales comunes para distintos servicios no pueden faltar nunca para evitar demoras en la ejecución del servicio y pérdida de eficiencia en la gestión del proceso de abastecimiento (menor costo por adquirir volumen, etc.). La proyección de la información histórica se puede hacer de manera mensual o trimestral. La serie de datos es de corto plazo, tal como se observa en la tabla 3 correspondiente a la proyección mensual.

Para la obtención de los pronósticos se utilizó el método de suavización exponencial Holt-Winter con los siguientes parámetros: nivel ($\alpha = 0.5$), tendencia ($\beta = 0.5$) y estacionalidad ($\gamma = 0.5$); con lo cual se obtuvo un valor del MAPE de 8,12 %, valor que se encuentra considerado dentro del rango aceptable, de acuerdo a la dirección de la organización.

Tabla 3
Detalle de proyección mensual

Mes	Total mensual	Pronóstico	Error porcentual (%)
sep-13	865		
oct-13	868	823	5,18
nov-13	769	814	5,85
dic-13	842	771	8,43
ene-14	670	767	14,48
feb-14	627	650	3,67
mar-14	758	625	17,55
abr-14	595	674	13,28
may-14	681	610	10,43
jun-14	690	655	5,07
jul-14	833	712	14,53
ago-14	866	840	3,00
sep-14	814	883	8,48
oct-14	860	861	0,12
nov-14	793	861	8,58
dic-14	881	832	5,56
ene-15	746	811	8,71
feb-15	692	723	4,48
mar-15	781	713	8,71
abr-15	696	713	
may-15	802	740	
jun-15	946	753	

Elaboración propia

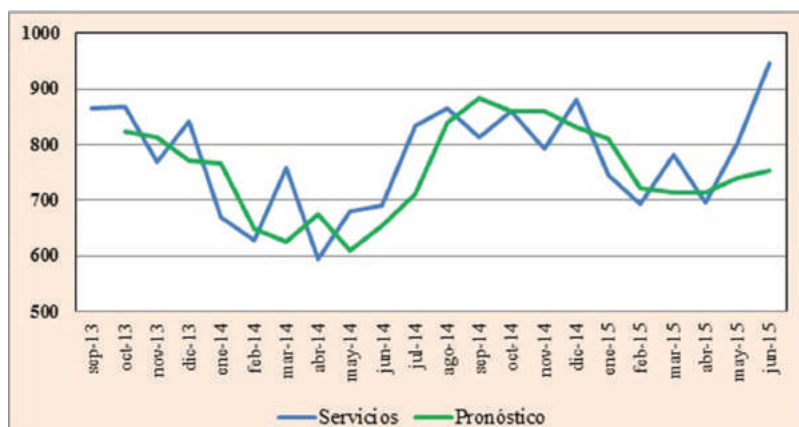


Figura 3. Proyección mensual de tres periodos²
Elaboración propia

La proyección a tres meses para los periodos de abril, mayo y junio de 2015 muestra una mayor variación en junio de 2015, mientras que la de abril es de solamente 2,4 %, debido a que los métodos de series de tiempo usualmente explican la tendencia y estacionalidad, pero no responden a comportamientos donde los picos (*outliers*) se explican por factores externos a la serie. Esto motiva la agregación de los periodos para estabilizar la serie y obtener un mejor pronóstico. Es factible considerar adicionalmente la agregación temporal, la agregación de productos similares y las regiones geográficas de venta (Simchi-Levi, 2010). Se agregó trimestralmente la información, obteniéndose los resultados mostrados en la tabla 4, donde los valores trimestrales consecutivos presentan mejor exactitud porcentual debido a la reducción de diferencias, cuando ocurre la agregación de los meses.

Tabla 4
Pronóstico del trimestre 2-2015 con serie de tiempo y demanda agregada trimestral

Año	Trimestre	Servicios	Pronóstico	Exactitud (%)
2013	4	2479	2530	98
2014	1	2055	2106	98
2014	2	1966	2298	83
2014	3	2513	2808	88
2014	4	2534	2357	93
2015	1	2219	2081	94
2015	2	2444	2568	95

Elaboración propia

2 Se consideraron los meses de abril a junio como data de validación de la proyección univariable.

Con el ánimo de incorporar al pronóstico información basada en la experiencia de los responsables de gestionar el negocio, se ha utilizado la lógica de regresión bayesiana adicionando dos variables explicativas: la venta en moneda local y la exactitud del pronóstico. Esta segunda variable es un indicador de cercanía al plan de ventas, al que denominamos exactitud. Para el futuro estas variables se considerarán como no informativas *a priori*.

Para la aplicación del modelo bayesiano se utilizó el *software* de código abierto Winbugs (*Bayesian inference using gibbs sampling*)³, que utiliza un muestreo estocástico obteniendo intervalos de confianza para los parámetros del modelo de regresión utilizando cadenas de Markov (Ntzoufras, 2011). A continuación se presenta el modelo especificado, de acuerdo a la sintaxis del Winbugs:

```
# Función de verosimilitud
Model { for ( i in 1 : N) {
Cantidad[i] ~ dnorm(mu[i], tau)
Cantidad.rep[i] <-beta0+beta1*mean(venta[i])+beta2*mean(exactitud[i])
mu[i] <- beta0+beta1*venta[i] +beta2*exactitud[i] }
s2<- 1/tau
s<-sqrt(s2)
# Cálculo de la varianza
for (i in 1:N) {
resid[i]<- Cantidad[i]-mean(Cantidad[]) }
Sy2<- inprod(resid[],resid[])/(N-1)
R2B <- 1- s2/Sy2

# Valores a priori : no informativos
beta0~dnorm(500,300)
beta1~ dnorm(.00001,.0001)
beta2~dnorm(2000,200)
tau~dgamma(20,10) }

INITS
list(beta0=500, beta1 = .00001, beta2 = 2200, tau = 150)
# Data

DATA list(N=6,Cantidad=c(2479,2055,1966,2513,2534,2219),venta
=c(47968,41418,40020,48479,48820,43943), exactitud = c(0.98,0.98,0.83,0.88,0.93,0.94))
```

Para probar el ajuste del modelo se considera que si la precisión es alta, entonces la varianza de los errores (σ^2) es baja. Para este fin se busca cuantificar la varianza de la variable dependiente S_y^2 , utilizando un R_b^2 , definido como:

3 The Bugs Project. Medical Research Council Biostatistics Unit, 2015.

$$R_b^2 = 1 - \frac{r^{-1}}{s_{y'}}^2 = 1 - \frac{\sigma^2}{s_y^2}$$

La métrica de ajuste (R_b^2) explica la variación total en el modelo, a semejanza de un coeficiente de determinación ajustado obtenido en los modelos de regresión lineal por mínimos cuadrados (Ntzoufras, 2011). El ajuste obtenido brinda el siguiente intervalo para la métrica de ajuste: $R_b^2 \in <0.82, 0.92>$, tal como se aprecia en la figura 4.

node	mean	sd	MC error	2.5%	median	97.5%	start	sample
R2B	0.8819	0.02656	2.674E-4	0.819	0.8854	0.9229	1000	9001

Figura 4. Estimación de la métrica de ajuste
Elaboración propia

Este modelo será de utilidad en la medida en que se asocie con las políticas de inventario, la configuración del abastecimiento, el tipo de proveedor, entre otros. Los errores en los resultados obtenidos en la estimación de los parámetros, con el muestreo de la cadena Markov y la media de los parámetros de los coeficientes de regresión, se muestran en la figura 5:

node	mean	sd	MC error	2.5%	median	97.5%	start	sample
Cantidad.rep[1]	2421.0	36.72	0.3957	2349.0	2421.0	2491.0	1000	9001
Cantidad.rep[2]	2426.0	31.71	0.3417	2364.0	2426.0	2487.0	1000	9001
Cantidad.rep[3]	2127.0	30.64	0.3302	2067.0	2127.0	2186.0	1000	9001
Cantidad.rep[4]	2220.0	37.11	0.4	2147.0	2220.0	2292.0	1000	9001
Cantidad.rep[5]	2320.0	37.37	0.4028	2247.0	2320.0	2392.0	1000	9001
Cantidad.rep[6]	2344.0	33.64	0.3625	2278.0	2344.0	2409.0	1000	9001
R2B	0.8819	0.02656	2.674E-4	0.819	0.8854	0.9229	1000	9001
beta0	500.0	0.05768	5.457E-4	499.9	500.0	500.1	1000	9001
beta1	-8.164E-4	7.655E-4	8.249E-6	-0.002322	-8.155E-4	6.529E-4	1000	9001
beta2	2.0E+3	0.07014	7.168E-4	2.0E+3	2.0E+3	2.0E+3	1000	9001
resid[1]	184.7	0.0	1.054E-12	184.7	184.7	184.7	1000	9001
resid[2]	-239.3	0.0	1.054E-12	-239.3	-239.3	-239.3	1000	9001
resid[3]	-328.3	0.0	1.054E-12	-328.3	-328.3	-328.3	1000	9001
resid[4]	218.7	0.0	1.054E-12	218.7	218.7	218.7	1000	9001
resid[5]	239.7	0.0	1.054E-12	239.7	239.7	239.7	1000	9001
resid[6]	-75.33	0.0	1.054E-12	-75.33	-75.33	-75.33	1000	9001
s	85.08	9.357	0.09349	69.16	84.29	105.9	1000	9001
s2	7327.0	1648.0	16.58	4783.0	7105.0	11230.0	1000	9001

Figura 5. Resultados parámetros en Winbugs
Elaboración propia



Tabla 5
Data y resultados con regresión bayesiana

Año	Trimestre	Servicios	Venta ML	Exactitud	Reg bayesiana
2013	4	2479	47968	0.980	2420
2014	1	2055	41418	0.975	2417
2014	2	1966	40020	0.831	2129
2014	3	2513	48479	0.883	2226
2014	4	2534	48820	0.930	2321
2015	1	2219	43943	0.938	2340
2015	2	2444	42422	0.949	2364

Elaboración propia

El proceso de estimación bayesiano simula una cadena de Markov que presenta estabilidad de los parámetros, considerando un rango de calentamiento (1/100) de la longitud total de iteraciones. El algoritmo del muestreo *Gibbs* utiliza la aleatoriedad para partir las iteraciones y encontrar valores estables de los parámetros. La interfaz de monitoreo, implementada en *Winbugs*, se muestra en la figura 6.

Adicionalmente a la proyección bayesiana, la variación del error histórico puede servir como un control de calidad del error futuro en el valor proyectado. Asumiendo la premisa de que todo pronóstico futuro es, por naturaleza, erróneo, y que todo proceso comercial de estimación de demanda estable es consecuencia del nivel de madurez organizacional para realizar consensos entre diversas áreas funcionales, se puede obtener una función de distribución de ocurrencia de errores en un valor estimado futuro basándonos en la historia de éxitos esperados.

Si el ideal es que esta discrepancia tienda a cero, en la medida de un tamaño de muestra cada vez mayor, se puede utilizar la función de Poisson como una aproximación a la distribución binomial de dicho error.

Al registrar los errores de la medición del pronóstico, estos se pueden utilizar para establecer una escala de "calidad de la estimación". El objetivo de esta información es determinar riesgos ante posibles desviaciones, como consecuencia de discrepancias en el consenso de estimación (véase la tabla 6).

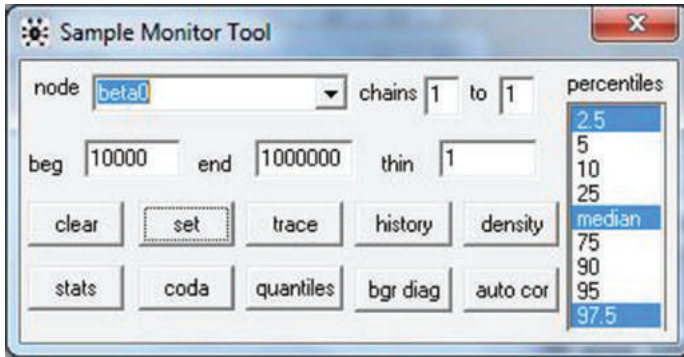


Figura 6. Interfaz de monitoreo
Elaboración propia

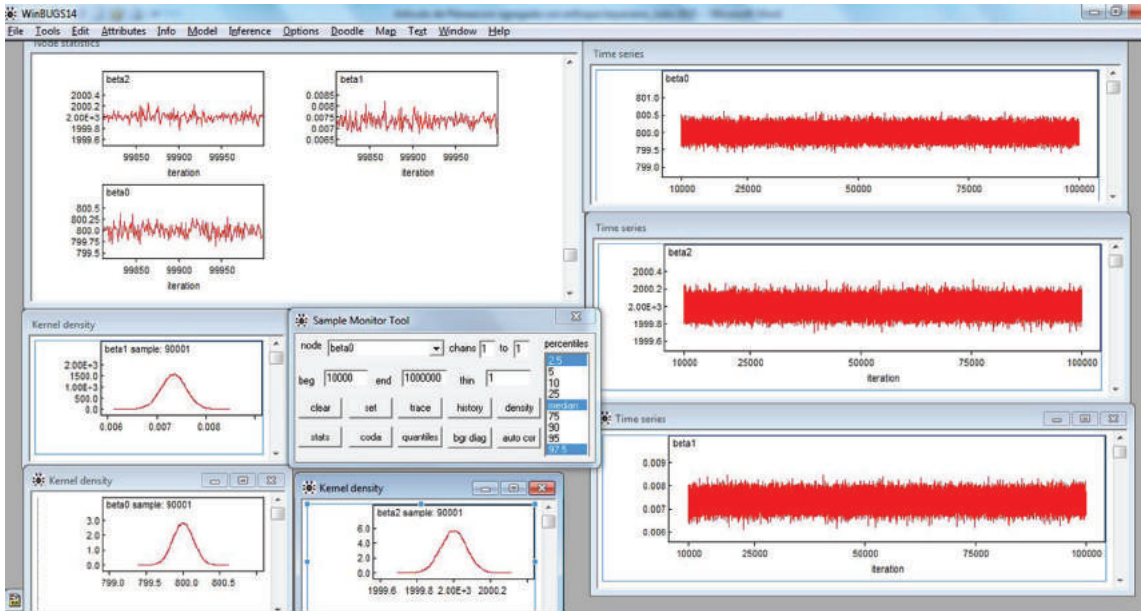


Figura 7. Resultado de parámetros del modelo
Elaboración propia



Tabla 6
Relación exactitud y calidad de la estimación

Exactitud	Error	Probabilidad
0.712	0.288	0.01
0.702	0.298	0.02
0.687	0.313	0.03
0.671	0.329	0.04
0.661	0.339	0.05
0.569	0.431	0.06
0.495	0.505	0.07
0.454	0.546	0.08
0.424	0.576	0.10

Elaboración propia

La lógica de las figuras 8, 9 y 10 requiere de dos parámetros: el valor por estimar futuro "P" y el valor "d" de las diferencias en el consenso de estimación, considerando las diversas opiniones entre los involucrados del proceso, a partir de los cuales se construye una función de distribución Poisson, que permite tomar una decisión sobre aceptar o rechazar el valor de la proyección, teniendo en cuenta la historia de las diferencias. Como todo período comercial tiene sus particulares características, se cree probable que esta función discreta ayudará a calcular una probabilidad de ocurrencia de la media en el total de la estimación.

En la figura 8 se muestran los valores de los parámetros para el estimado futuro bayesiano con valor P: 2311 en unidades, p: 0.01; y diferencia entre consenso de 50 unidades.

En la figura 9 se muestran los valores de los parámetros para P: 2311 unidades, p: 0.01; y diferencia entre consenso de 100 unidades.

En la figura 10 se muestran los valores de los parámetros para P: 2311 unidades, p: 0.01; y diferencia entre consenso de 200 unidades.

Las figuras elaboradas muestran una manera práctica de encontrar acuerdos para reducir diferencias en el valor de un estimado en reuniones de consenso, con presencia de roles funcionales de las áreas comercial, finanzas, operaciones y compras, entre otras, que tienen objetivos funcionales distintos y debido a estas diferencias, el abastecimiento de materiales e insumos puede verse perjudicado.




Figura 8. Resultado de decisión sobre el estimado - Diferencia 50
Elaboración propia




Figura 9. Resultado de decisión sobre el estimado - Diferencia 100
Elaboración propia

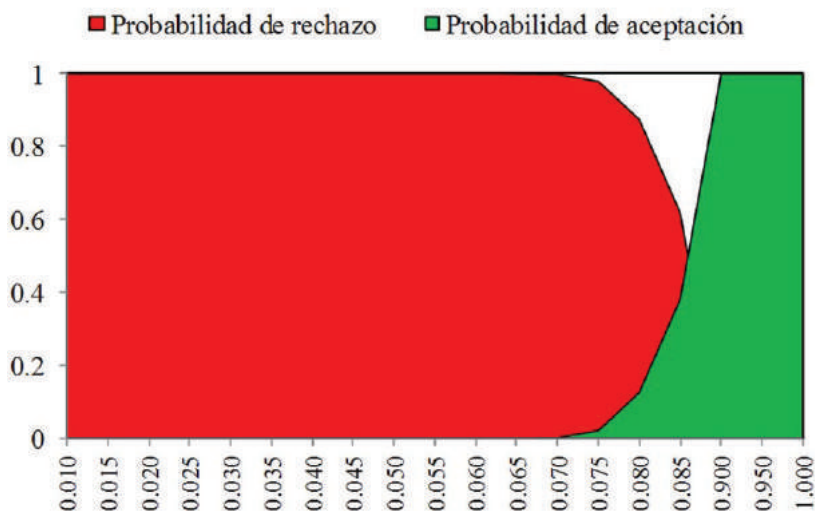


Figura 10. Resultado de decisión sobre el estimado - Diferencia 200
Elaboración propia

5. Conclusiones

En este artículo se muestra la utilidad de proyectar una serie histórica que sea estabilizada con la agregación de períodos de tiempo. El método de pronóstico puede ser el de serie de tiempo o las técnicas de regresión bayesiana, las cuales, junto con el muestreo Gibbs, son de utilidad para situaciones empresariales donde se cuenta con poca cantidad de data histórica, debido a la posibilidad de incorporar información *a priori*, como la experiencia de la dirección en el negocio, que es de suma importancia para un buen pronóstico.

La utilidad de cuantificar el proceso de coordinación entre diversos interesados en pronosticar un volumen futuro de consumo puede mejorarse, utilizando la función de Poisson como una distribución discreta sensible a las discrepancias. De esta manera, se proporciona a este proceso un mecanismo de control factible de ser sistematizado para cualquier estructura comercial que agregue productos en categorías, con el objetivo de hacer seguimiento y darle mayor madurez a este proceso organizacional.

Referencias

Bermúdez, J. D., Segura, J. V., y Vercher, E. (2010). *Bayesian forecasting with the Holt-Winters model*. *Journal of the Operational Research Society*, 61(1), 164-171.

- Cea, M. Á. (2012). *Fundamentos y aplicaciones en metodología cuantitativa*. Madrid: Síntesis.
- Chase, C. (2014). Innovations in business forecasting: predictive analytics. *The Journal of Business Forecasting*, 33(1), 29-34.
- Chopra, S., y Meindl, P. (2013). *Supply chain management: Strategy, planning, and operation*. Boston: Pearson.
- Euromonitor International. (Mayo de 2014). *Retailing in Peru*. Recuperado de <http://www.euromonitor.com/>
- Fildes, R., y Kingsman, B. (2011). Incorporating demand uncertainty and forecast error in supply chain planning models. *The Journal of the Operational Research Society*, 62(3), 483-500.
- Forrester, J. W. (2007). System dynamics a personal view of the first fifty years. *System Dynamics Review*, 23(2-3), 345-358.
- Gamerman, D., y Lopes, H. F. (2006). *Markov chain Monte Carlo: stochastic simulation for Bayesian inference*. Boca Ratón, FL: Chapman & Hall/CRC.
- Gaur, V., Kesavan, S., Raman, A., y Fisher, M. L. (2007). Estimating demand uncertainty using judgmental forecasts. *Manufacturing & Service Operations Management*, 9(4), 480-491.
- Gelman, A., Carlin, J. B., Stern, B. D., Vehtari, A., y Rubin, D. B. (2014). *Bayesian data analysis*. Boca Ratón, FL: Chapman & Hall/CRC.
- González, E. (2009). *Análisis bayesiano del modelo de regresión lineal con una aplicación a datos astronómicos*. (Tesis de pregrado). Universidad Tecnológica de la Mixteca, México.
- Lapide, L. (2014). Looking over the visible planning horizon. *Supply Chain Management Review*, 18(5), 4-5.
- Lunn, D., Jackson, C., Best, N., Thomas, A., y Spiegelhalter, D. J. (2013). *The BUGS book: a practical introduction to bayesian analysis*. Florida: Chapman & Hall/CRC.
- Muñoz, D. F., y Muñoz, D. G. (2008). A bayesian framework for the incorporations of priors and sample data in simulation experiments. *The Open Operational Research Journal*, 2, 44-51.
- Ntzoufras, I. (2011). *Bayesian modeling using win BUGS*. New Jersey: John Wiley & Sons.
- Rossi, P. E., y Allenby, G. M. (2003). Bayesian statistics and marketing. *Marketing Science*, 22(3), 304-328.
- Simchi-Levi, D. (2010). *Operations rules: delivering customer value through flexible operations*. Massachusetts: MIT Press.



- Stock, J. R., Boyer, S. L., y Harmon, T. (2010). Research opportunities in supply chain management. *Journal of the Academy of Marketing Science*, 38(1), 32-41.
- Valencia, M., Correa, J. C., Díaz, F. J., y Ramírez, S. (2014). Bayesian modeling application and optimization to demand forecasting. *Ingeniería y Desarrollo*, 32(2), 179-199.
- Wagner, M. (2010). Forecasting daily demand in cash supply chains. *American Journal of Economics and Business Administration*, 2(4), 377-383.

