ECUACIONES ESTRUCTURALES NO LINEALES PARA MEDIR LA INTENCIÓN DE COMPRA A TRAVÉS DEL CAPITAL DE MARCA DE PRODUCTOS DE CONSUMO MASIVO

Jesús Tapia López
Maestría y Especialista en Estadística Aplicada
Escuela Politécnica Nacional

Resumen

En este trabajo se realiza un análisis de las variables que describen los atributos que se relacionan con la intención de compra de productos de consumo masivo de las encuestas de imagen y posicionamiento realizadas por la empresa de investigación de mercados Habitus S.A., a través del capital de marca y con la construcción de un modelo de ecuaciones estructurales no lineales usando la estimación Bayesiana, midiendo el aporte del capital hacia la intención de compra.

Se calcularon las cuantificaciones asociadas a cada relación entre variables latentes y observables que están disponibles en las encuestas de imagen y posicionamiento.

Las cuantificaciones calculadas sirven como una herramienta para la toma de decisiones al momento de manejar una marca o la implementación de un nuevo producto.

Se determino que existen interacciones de relevancia entre atributos que aportan al capital de marca y consecuentemente a la intención de compra, que no han sido cuantificadas con otra técnica estadística.

Además los resultados del modelo de ecuaciones estructurales no lineales se comparan con los obtenidos usando un modelo de ecuaciones estructurales lineal y se encontró que el aporte hacia la intención de compra a través del capital de marca es más significativo en el modelo de ecuaciones estructurales no lineales que toma en cuenta interacciones entre variables.

Abstract

This paper undertakes an analysis of the variables that describe the attributes relate with the purchase intent of consumer products, of the tracking surveys conducted by Habitus SA research company , through brand equity and building a structural equation model using nonlinear Bayesian estimation, was measured the contribution of brand equity to purchase intent.

The associated quantifications were calculated to each ratio between latent variables and observable those are available in the image and positioning surveys.

The calculated quantifications serve as a tool for decision making when managing a brand or the implementation of a new product.

It was determined that there are important interactions between attributes that contribute to brand equity and consequently towards purchase intent, which have not been quantified with another statistical technique.

In addition the results of nonlinear structural equations model were compared with those obtained using a linear structural equation model and found that the contribution to the purchase intent through the brand equity is more significant in nonlinear structural equations which take into account interactions between variables.

1. ESTIMACIÓN BAYESIANA DE ECUACIONES ESTRUCTURALES NO LINEALES.

Consideremos el siguiente modelo de ecuaciones estructurales no lineales **(MEEN)** con un vector px1 de variables observables aleatorias $y = (y_1, ..., y_p)^T$.

$$y = \mu + \Lambda w + \varepsilon \tag{1.1}$$

Donde, μ es el vector de interceptos, Λ es la matriz de pesos factoriales de dimensión $p_x q$; $w = (w_1, ..., w_q)^T$ es un vector aleatorio de factores latentes con q<p y ε: es el vector de errores de dimensión px1, que se encuentra distribuido con $\mathrm{N}(\mathrm{O}, \Psi_\varepsilon)$, donde Ψ_ε es diagonal y w es independiente de ε.

En situaciones más complejas se puede utilizar w como una partición de la forma (η^T, ξ^T), con lo que a más del modelo, contamos con el vector latente que define el siguiente modelo estructural no lineal:

$$\eta = \Pi \eta + \Gamma H(\xi) + \delta \tag{1.2}$$

Donde, η y ξ son subvectores de variables latentes de w, de dimensión q_1x1 y q_2x1 respectivamente.

$H(\xi) = (h_1(\xi), ..., h_t(\xi))^T$ es un vector no nulo de las funciones h_j evaluadas en valores distintos a cero de dimensión tx1, con t≥q2.

$\Pi_{(q_1 x q_1)}$ y $\Gamma_{(q_1 x t)}$ son las matrices de los coeficientes de regresión para η y $H(\xi)$ respectivamente.

Se asume que δ y ξ son independientes y distribuidas con $\mathrm{N}(\mathrm{O}, \Phi)$ y $\mathrm{N}(\mathrm{O}, \Psi_\delta)$, respectivamente y Ψ_δ es una matriz de covarianza diagonal.

Si algunas $h_j(\xi)$ no son lineales la distribución del vector de variables aleatorias observadas y no es lineal. Dado que en ξ pueden existir relaciones no lineales la ecuación (1.2) puede escribirse como:

$$\eta = \Lambda_w G(w) + \delta \tag{1.3}$$

Donde $\Lambda_w = (\Pi, \Gamma)$ y $G(w) = (\eta^T, H(\xi)^T)^T$.

Los componentes de $H(\xi)$ son funciones diferenciables de cualquier clase, por lo tanto pueden plantearse varios tipos de relaciones entre variables latentes, pero claro está la elección de $H(\xi)$ no puede ser completamente arbitraria, por ejemplo el siguiente caso, $H_1(\xi) = (\xi_1, \xi_2, \xi_1^2, \xi_1^2)$ y $H_2(\xi) = (\xi_1, \xi_2, \xi_{12}, 0)$ no es

permitido al ser relevante; en su lugar debemos escoger $H_1(\xi) = (\xi_1, \xi_2, \xi_1^2)$ y $H_2(\xi) = (\xi_1, \xi_2, \xi_{12}),$ un ejemplo de una ecuación estructural sería el siguiente:

$$\begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} = \begin{pmatrix} 0 & \pi \\ 0 & 0 \end{pmatrix} \begin{pmatrix} \eta_1 \\ \eta_2 \end{pmatrix} + \begin{pmatrix} \gamma_{11} & \gamma_{12} & 0 & 0 & 0 \\ \gamma_{21} & \gamma_{22} & \gamma_{23} & \gamma_{24} & \gamma_{25} \end{pmatrix} \begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_1^2 \\ \xi_1\xi_2 \\ \xi_2^2 \end{pmatrix} + \begin{pmatrix} \delta_1 \\ \delta_2 \end{pmatrix} \qquad (1.4)$$

El propósito es encontrar los parámetros del modelo no lineal cuando no se cuentan suficientes condiciones de identificación.

Por ejemplo, un modelo equivalente al de la ecuación (1.1) es $y = \mu + \Lambda^* w^* + \varepsilon$ donde $\Lambda^* = \Lambda R$ y $w^* = R^{-1} w$ para cualquier matriz *R* no singular.

Un método común para resolver el problema de identificación de estimación de la ecuación estructural consiste en fijar elementos apropiados para Λ bajo cierto criterio de conocimiento de modo que *R* sea la matriz identidad; así mismo pueden fijarse valores para Λ_w.

En el contexto de los modelos de ecuaciones estructurales no lineales debemos tener mucho cuidado al interpretar la esperanza del vector y. Si Λ_k^T es la k-ésima fila de Λ para k=1,…, p de la ecuación (1.1) tenemos que $E(y_k) = \mu_k + \Lambda_k^T E(w),$ si bien $E(\xi) = 0$ tenemos de la ecuación (1.2) que $E(\eta) \neq 0,$ como $H(\xi)$ es un función no lineal de $\xi;$ por lo tanto $E(w) \neq 0$ y $E(y_k) \neq \mu_k$.

Ahora bien, sea $\Lambda_k^T = (\Lambda_{k\eta}^T, \Lambda_{k\xi}^T)$ la partición de Λ_k^T correspondiente a $w = (\eta^T, \xi^T)^T,$ como $E(\xi) = 0$ y tomando $\eta = (I - \Pi)^{-1}\left[\Gamma H(\xi)\right],$ de la ecuación (1.2) tenemos que:

$$E(y_k) = \mu_k + \Lambda_{k\eta}^T E(\eta) + \Lambda_{k\xi}^T E(\xi) = \mu_k + \Lambda_{k\eta}^T \left[(I - B)^{-1}\Gamma\right] E(H(\xi)) \qquad (1.5)$$

Donde la matriz *B* corresponde a los puntajes factoriales obtenidos a partir del análisis factorial confirmatorio de $x = B(\Lambda\xi + \varepsilon) + \delta$.

Como en general la forma de $H(\xi)$ no es demasiada complicada, la $E(H(\xi))$ y $E(y_k)$ no presentan dificultades de cálculo.

Para un MEE lineal definido por $y = \mu + \varepsilon^*,$ el vector ε^* está distribuido con $\mathrm{N}(\mathrm{O}, \Sigma),$ donde Σ es una matriz de covarianzas sin ninguna estructura en particular, pero en este caso como existen términos no lineales la distribución

de ε^* no es normal; por lo que para medir la significancia de los términos no lineales se necesita un tratamiento especial.

1.1 MUESTREO DE GIBBS PARA LA SIMULACIÓN A POSTERIORI

Sea $Y=(y_1,...,y_n)$ la matriz de datos observados y θ el vector que contiene los parámetros desconocidos $\mu,\Lambda,\Lambda_w,\Phi,\Psi_\varepsilon$ y Ψ_δ; dada la no linealidad de $H(\xi)$ el objetivo es encontrar las estimaciones Bayesianas a partir de Y (Lee, 2007).

Usamos el muestreo de Gibbs para generar una secuencia de observaciones de la distribución a posterior $[\theta,\Omega\,|\,Y]$, donde la j-ésima iteración con valores iniciales de θ^j y Ω^j está dada por:

$$Paso\,(a):\ \ \theta^{(j+1)}\ de\ p(\theta\,|\,\Omega^{(j)},Y)$$
$$Paso\,(b):\ \ \Omega^{(j+1)}\ de\ p(\Omega\,|\,\theta^{(j+1)},Y)$$

En el paso (a), θ contiene los parámetros desconocidos $\mu,\Lambda,\Lambda_w,\Phi,\Psi_\varepsilon$ y Ψ_δ. Como Ω está dado el MEEN por las ecuaciones (1.1) y (1.2) se reduce a un modelo de regresión simultánea y sus distribuciones condicionales no son difíciles de encontrar.

1.2 DISTRIBUCIÓN CONDICIONAL TOTAL

Sea θ_y que contiene los parámetros en μ,Λ y Ψ_ε asociados a la ecuación de medida y dado θ_w el vector de parámetros de Λ_w,Φ y Ψ_δ; asociados a la ecuación estructural, si no fijamos parámetros iniciales y como las distribuciones de θ_y y θ_w son independientes se cumple que $p(\theta)=p(\theta_y)p(\theta_w)$, más aún como $p(Y,\Omega\,|\,\theta)=p(Y\,|\,\Omega,\theta_y)p(\Omega\,|\,\theta_w)$, se cumple que:

$$p(\theta_y,\theta_w\,|\,Y,\Omega)=\left[p(y\,|\,\Omega,\theta_y)p(\theta_y)\right]\left[p(\Omega\,|\,\theta_w)p(\theta_w)\right] \qquad (1.2.1)$$

Para encontrar las estimaciones se usan las siguientes distribuciones a priori, con k=1,…, p.

$$\mu\overset{D}{=}\mathrm{N}\left[\mu_0,\Sigma_0\right],$$
$$\Psi_{\varepsilon k}^{-1}\overset{D}{=}\mathrm{Gamma}\left[\alpha_{0\varepsilon k},\beta_{0\varepsilon k}\right],$$
$$\left[\Lambda_k\,|\,\Psi_{\varepsilon k}\right]\overset{D}{=}\mathrm{N}\left[\Lambda_{0k},\Psi_{\varepsilon k}\mathrm{H}_{0yk}\right]$$

Donde Λ_k^T es la k-ésima fila de Λ; $\alpha_{0\varepsilon k},\beta_{0\varepsilon k},\mu_0,\Lambda_{0k},\mathrm{H}_{0yk}$ y Σ_0 son hiperparámetros cuyos valores se supone deben ser dados. Para k≠h asumimos que $(\Psi_{\varepsilon k},\Lambda_k)$ y $(\Psi_{\varepsilon h},\Lambda_h)$ son independientes (Lee, 2007)..

La distribución condicional de Λ esta dada para el caso en el que todos los elementos son desconocidos; por lo que la distribución condicional con elementos fijos puede ser obtenida a través de la siguiente modificación:

Dados $\mathrm{A}_k = (\mathrm{H}_{0yk}^{-1} + \Omega\Omega^T)^{-1}$, $Y_k^* = (y_{1k}^*, ..., y_{nk}^*)^T$ con $y_{ik}^* = y_{ik} - \mu_k$,
$a_k = \mathrm{A}_k(\mathrm{H}_{0yk}^{-1}\Lambda_{0k} + \Omega Y_k^*)$ y
$\beta_{\varepsilon k} = \beta_{0\varepsilon k} + 2^{-1}(Y_k^{*T}Y_k^* - a_k^T\mathrm{A}_k^{-1}a_k + \Lambda_{0k}^T\mathrm{H}_{0yk}^{-1}\Lambda_{0k})$;
se puede demostrar que:

$$p(\Psi_{\varepsilon k}^{-1} \mid Y, \Omega, \mu) \overset{D}{=} \mathrm{Gamma}\left[\frac{n}{2} + \alpha_{0\varepsilon k}, \beta_{\varepsilon k}\right]$$

$$p(\Lambda_k \mid Y, \Omega, \Psi_{\varepsilon k}^{-1}, \mu) \overset{D}{=} \mathrm{N}\left[a_k, \Psi_{\varepsilon k} A_k\right]$$

$$p(\mu \mid Y, \Omega, \Lambda, \Psi_\varepsilon) \overset{D}{=} \mathrm{N}\left[(\Sigma_0^{-1} + n\Psi_\varepsilon^{-1})^{-1}(n\Psi_\varepsilon^{-1}\overline{Y} + \Sigma_0^{-1}\mu_0), (\Sigma_0^{-1} + n\Psi_\varepsilon^{-1})^{-1}\right]$$

Donde $\overline{Y} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \Lambda w_i).$

Consideremos ahora la distribución condicional de θ_w que es proporcional a la $p(\Omega \mid \theta_w)p(\theta_w)$; dados $\Omega_1 = (\eta_1, ..., \eta_n)$, $\Omega_2 = (\xi_1, ..., \xi_n)$ y $\mathrm{G} = \left[\mathrm{G}(w_1), ..., \mathrm{G}(w_n)\right]$; si suponemos que la distribución de ξ_i solo involucra a Φ, podemos entonces verificar que $p(\Omega_2 \mid \theta_w) = p(\Omega_2 \mid \Phi)$.

Más aún si asumimos que la distribución a priori de Φ es independiente de la distribución a priori de Λ_w y Ψ_δ; se sigue que:

$$p(\Omega \mid \theta_w)p(\theta_w) \propto \left[p(\Omega_1 \mid \Omega_2, \Lambda_w, \Psi_\delta)p(\Lambda_w, \Psi_\delta)\right]\left[p(\Omega_2 \mid \Phi)p(\Phi)\right] \qquad (1.2.2)$$

Por lo tanto las densidades condicionales marginales de (Λ_w, Ψ_δ) y Φ pueden ser analizadas por separado.

Consideremos ahora una distribución a priori para Φ con $\Phi^{-1} \overset{D}{=} W_{q2}\left[\mathrm{R}_0, \rho_0\right]$, dónde ρ_0 y la matriz definida positiva R_0 son hiperparámetros dados; donde se verifica que:

$$p(\Phi \mid \Omega_2) \overset{D}{=} \mathrm{I}W_{q2}\left[(\Omega_2\Omega_2^T + \mathrm{R}_0^{-1}), n + \rho_0\right] \qquad (1.2.3)$$

Usando distribuciones a priori para θ_w, tenemos que:

$$\Psi_{\delta k}^{-1} \overset{D}{=} \text{Gamma}\left[\alpha_{0\delta k}, \beta_{0\delta k}\right],$$
$$\left[\Lambda_{wk} \mid \Psi_{\delta k}\right] \overset{D}{=} N\left[\Lambda_{0wk}, \Psi_{\delta k} \text{H}_{0wk}\right]$$

Donde Λ_{wk}^{T} es la k-ésima fila de Λ_{w}; $\alpha_{0\delta k}, \alpha_{0\delta k}, \Lambda_{0wk}$ y H_{0wk} son los hiperparámetros dados, si k≠h tenemos que $(\Psi_{\delta k}, \Lambda_{wk})$ y $(\Psi_{\delta h}, \Lambda_{wh})$ son independientes.

Ahora dado $\text{E}_{k}^{*} = (\eta_{1k}, ..., \eta_{nk})^{T}$ con k=1,…, q_1; dados π_{kj} y γ_{lj} que son elementos de Π y Γ respectivamente se puede demostrar que para k=1,…, q_1 se cumple:

$$p(\Psi_{\delta k}^{-1} \mid \Omega) \overset{D}{=} \text{Gamma}\left[\frac{n}{2} + \alpha_{0\delta k}, \beta_{\delta k}\right],$$
$$p(\Lambda_{wk} \mid \Omega, \Psi_{\delta k}^{-1}) \overset{D}{=} \text{N}\left[a_{wk}, \Psi_{\delta k} \text{A}_{wk}\right]$$

Donde $\text{A}_{wk} = (\text{A}_{0wk}^{-1} + \text{GG}^{T})^{-1}$, $a_{wk} = \text{A}_{wk}(\text{H}_{0wk}^{-1}\Lambda_{0wk} + \text{GE}_{k}^{*})$; y
$\beta_{\delta k} = \beta_{0\delta k} + 2^{-1}(\text{E}_{k}^{*T}\text{E}_{k}^{*} - a_{wk}^{T}\text{A}_{wk}^{-1}a_{wk} + \Lambda_{0wk}^{T}\text{H}_{0wk}^{-1}\Lambda_{0wk})$

Así, las distribuciones condicionales asociadas con la ecuación (1.2.3) en el paso (a) del muestreo de Gibbs, pueden ser distribuciones Gamma, normal y Wishart invertida; si consideramos el paso (b) tendríamos que:

$$p(\Omega \mid \theta, Y) = \prod_{i=1}^{n} p(y_i \mid w_i, \theta) p(\eta_i \mid \xi_i, \theta) p(\xi_i \mid \theta) \tag{1.2.4}$$

Como los w_i son mutuamente independientes, de la misma manera que los y_i la $p(w_i \mid y_i, \theta)$ es proporcional a:

$$\exp\left\{-\frac{1}{2}\xi_i^{T}\Phi^{-1}\xi_i - \frac{1}{2}(y_i - \mu - \Lambda w_i)^{T}\Psi_{\varepsilon}^{-1}(y_i - \mu - \Lambda w_i) - \frac{1}{2}\left[\eta_i - \Lambda_w G(w_i)\right]^{t}\Psi_{\delta}^{-1}\left[\eta_i - \Lambda_w G(w_i)\right]\right\} \tag{1.2.5}$$

Esta es la distribución condicional requerida en el paso (b); como se ve esta distribución no es estándar y a la vez es algo compleja: el algoritmo de Metropolis-Hasting (MH) se usa para generar observaciones de $p(w_i \mid y_i, \theta)$ a partir de (1.2.5).

Los componentes de la distribución condicional $\left[\theta \mid \Omega, Y\right]$ que involucran el método de Gibbs para analizar modelos no lineales son muy similares al de los modelos lineales; mientras que la distribución condicional $\left[\Omega \mid \theta, Y\right]$ presenta ligeras dificultades teóricas y de implementación. Por lo tanto la generalización

de estimación Bayesiana para modelos no lineales no presenta mayores dificultades.

1.3 CRITERIO DE INFORMACIÓN BAYESIANA Y DE AKAIKE.

Se basa en una aproximación del valor $2\log B_{12}$ que no depende de la densidad a priori, sino en el llamado criterio de Schwarz (SW) (Lee, 2007).

$$2\log B_{12} \cong 2SW = 2\left[\log p(Y \mid \tilde{\theta}_1, E_1) - \log p(Y \mid \tilde{\theta}_2, E_2)\right] - (d_1 - d_2)\log n \qquad (1.3.1)$$

Donde $\tilde{\theta}_1$ y $\tilde{\theta}_2$ son estimadores de Máxima Verosimilitud en los modelos E_1 y E_2 respectivamente, d_1 y d_2 son las dimensiones de θ_1 y θ_2, n el tamaño muestral, entonces el Criterio de Información Bayesiana (CIB) para contrastar los modelos E_1 y E_2 es:

$$CIB_{12} = -2SW \cong -2\log B_{12} = 2\log B_{21} \qquad (1.3.2)$$

Los criterios de interpretación del CIB_{12} es el mismo que se utiliza para el factor de Bayes. Para cada modelo E_k con k=1,2 definimos:

$$CIB_k = -2\log p(Y \mid \tilde{\theta}_k, E_k) + d_k \log n \qquad (1.3.3)$$

Se escoge el modelo con menor valor del CIB_k.

El criterio de información de Akaike (CIA) asociado al modelo E_k esta definido por:

$$CIA_k = -2\log p(Y \mid \tilde{\theta}_k, E_k) + 2d_k \qquad (1.3.4)$$

Como se observa en (1.3.4) este criterio de comparación no depende del tamaño muestral n; la selección se la realiza de la misma manera que se la hace cuando usamos el CIB.

1.4 CRITERIO DE INFORMACIÓN DE DESVIACIÓN.

El criterio de información de desviación (CID) es una generalización del CIA que incorpora las simulaciones θ_k^j del parámetro desconocido θ_k, con j=1,…, J; basados en la distribución a posteriori, definimos entonces:

$$CID_k = -\frac{2}{J}\sum_{j=1}^{J}\log p(Y \mid \theta_k^j, E_k) + 2d_k \qquad (1.4.1)$$

Al igual que los criterios presentados, se selecciona el modelo con menor valor de de CID_k (Lee, 2007).

2. APLICACIÓN.

La estimación Bayesiana permite identificar interacciones entre variables endógenas o exógenas; para esto partimos de un modelo teórico que se presenta a continuación, en el cuál se toman en cuenta las posibles interacciones teóricas presentadas en el capítulo tres, el modelo toma en consideración adicionalmente a todos los atributos con los que se dispone:

$X_2=a_2*Y_2+e_{12}$
$X_3=a_3*Y_2+e_{13}$
$X_4=a_4*Y_3+e_{14}$
$X_5=a_5*Y_3+e_{15}$
$X_6=a_6*Y_3+e_{16}$
$X_7=a_7*Y_3+e_{17}$
$X_8=a_8*Y_3+e_{18}$
$X_9=a_9*Y_4+e_{19}$
$X_{10}=a_{10}*Y_4+e_{20}$
$X_{11}=a_{11}*Y_5+e_{21}$
$X_{12}=a_{12}*Y_5+e_{22}$
$X_{13}=a_{13}*Y_5+e_{23}$
$X_{14}=a_{14}*Y_5+e_{24}$
$X_{15}=a_{15}*Y_5+e_{25}$
$X_{16}=a_{16}*Y_5+e_{26}$
$X_{17}=a_{17}*Y_5+e_{27}$
$X_{18}=a_{18}*Y_5+e_{28}$
$X_{19}=a_{19}*Y_5+e_{29}$
$X_{20}=a_{20}*Y_6+e_{30}$
$X_{21}=a_{21}*Y_6+e_{31}$
$X_2*X_{13}=a_{22}*Y_7+e_{32}$
$X_{13}*X_{19}= a_{23}*Y_7+e_{33}$
$X_{19}* X_3= a_{24}*Y_7+e_{34}$
$X_2*X_3= a_{25}*Y_7+e_{35}$
$X_{13}*X_{17}= a_{26}*Y_7+e_{36}$
$X_{13}*X_{16}= a_{27}*Y_7+e_{37}$
$X_9*X_{11}= a_{28}*Y_8+e_{38}$
$X_9*X_{10}= a_{29}*Y_8+e_{39}$
$X_6*X_7= a_{30}*Y_8+e_{40}$
$X_9*X_{19}= a_{31}*Y_9+e_{41}$
$X_2*X_9= a_{32}*Y_9+e_{42}$
$X_9*X_{13}= a_{33}*Y_9+e_8$
$X_{11}*X_{19}= a_{34}*Y_9+e_7$
$X_9*X_{15}= a_{35}*Y_9+e_6$
$X_9*X_{17}= a_{36}*Y_9+e_5$
$X_{10}*X_{13}= a_{37}*Y_9+e_4$
$X_{12}*X_{13}= a_{38}*Y_9+e_3$
$Z=b_1*Y_2+b_2*Y_3+b_3*Y_4 +b_4*Y_5+b_5*Y_6+b_6*Y_7+ b_7*Y_8+b_8*Y_9+e_2$
$X1=c*Z+e1$

(X1): Intención de Compra
(X2): Ha probado
(X3): La busco en otra parte
(X4): Natural
(X5): Sabor
(X6): Ofrece algo diferente
(X7): A la moda
(X8): Moderna
(X9): Para alguien como yo
(X10): Se ajusta al momento
(X11): Satisfacción
(X12): Mejor marca
(X13): Marca favorita
(X14): Marca que admiro
(X15): Marca que respeto
(X16): Marca de calidad
(X17): Marca líder
(X18): Vale lo que cuesta
(X19): Escala odio-amor
(X20): Recomendaría a mis amigos
(X21): Pagaría más por ella
(Z): Capital de marca
(Y2): Familiaridad
(Y3): Diferenciación
(Y4): Relevancia
(Y5): Respeto
(Y6): Reconocimiento
(Y7): Estatura de la marca
(Y8): Fuerza de la marca
(Y9): Hallazgo.

Donde los coeficientes a_i, b_i y c son los parámetros a estimar, los e_i son los correspondientes errores asociados.

En la figura 2.1 se presenta el modelo final donde se observa que la variable latente que más aporta al capital de marca es la familiaridad que en gran parte se relaciona con la variable observable “Para alguien como yo”.

En nuestro modelo el respeto aporta en menor medida que la estatura de la marca; donde la interacción entre marca favorita con la escala de amor y odio es la más relevante seguida por relación entre marca líder con marca favorita y finalmente marca favorita con marca de calidad, no debemos dejar de lado que

existe el supuesto de que una de las variables presenta una relación directa con cada variable latente.

En la tabla 2.2 se presentan adicionalmente los interceptos de la ecuación de medida obtenidos en la estimación, mientras que la tabla 2.4 muestra las varianzas de la medición, donde todas son positivas lo que indica que el modelo está bien definido.

Adicionalmente debemos señalar que podrían existir efectos de multicolinealidad, especialmente entre las variables latentes que explican el capital de marca, a pesar de que la base del modelo que estamos analizando no contempla dicha posibilidad, sin embargo para descartar esa posibilidad se presenta en la tabla 2.3 las covarianzas entre las variables latentes donde, con un nivel de confianza del 95%, estas no son significativas.

Debemos recordar que el modelo se construyo usando la técnica de análisis exploratorio, por lo tanto se deja de lado el análisis confirmatorio que es uno de los objetivos en los MEE, cuando se cuenta con un modelo previo.

Figura 2.1. Modelo con interacciones final

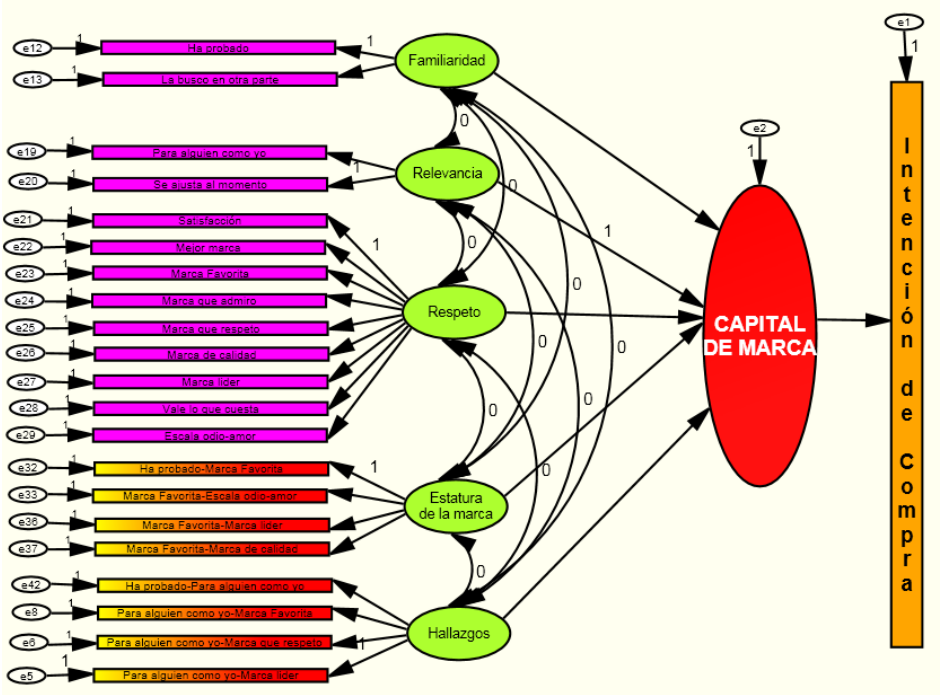

Tabla 2.1. Estimaciones de los parámetros en el modelo con interacciones

Coeficientes	Mean	S.E.	S.D.	C.S.	Median
La busco en otra parte<--Familiaridad	2,359	0,004	0,273	**1**	2,342
Para alguien como yo<--Relevancia	1,755	0,013	0,209	**1,002**	1,758
Marca que reséto<--Respeto	0,864	0	0,033	**1**	0,864
Marca de calidad<--Respeto	0,916	0	0,033	**1**	0,916
Marca líder<--Respeto	0,604	0	0,028	**1**	0,604
Vale lo que cuesta<--Respeto	0,736	0	0,032	**1**	0,735
Para alguien como yo_Marca que reséto<--Hallazgos	0,826	0	0,016	**1**	0,826
Ha probado_Para alguien como yo<--Hallazgos	1,046	0	0,014	**1**	1,046
Para alguien como yo_Marca favorita<--Hallazgos	0,758	0	0,017	**1**	0,758
Marca favorita_Marca líder<--Estatura_de la marca	0,86	0	0,01	**1**	0,86
Marca favorita_Odio-amor<--Estatura_de la marca	1,007	0	0,004	**1**	1,007
Marca favorita_Marca de calidad<--Estatura_de la marca	0,71	0	0,012	**1**	0,71
Odio-amor<--Respeto	0,255	0	0,016	**1**	0,255
Mejor marca<--Respeto	0,935	0	0,033	**1**	0,934
Marca favorita<--Respeto	0,745	0	0,032	**1**	0,745
Marca que admiro<--Respeto	0,839	0	0,032	**1**	0,839
int_compra<--CAPITAL_DE MARCA	0,967	0,015	0,191	**1,002**	0,967
CAPITAL_DE MARCA<--Respeto	0,098	0,001	0,037	**1**	0,095
CAPITAL_DE MARCA<--Familiaridad	3,331	0,069	0,899	**1,002**	3,181
CAPITAL_DE MARCA<--Estatura_de la marca	0,136	0,002	0,033	**1,002**	0,131
CAPITAL_DE MARCA<--Hallazgos	-0,26	0,003	0,038	**1,002**	-0,263
CONVERGENCIA					

Tabla 2.2. Estimaciones de los parámetros en el modelo con interacciones

Interceptos	Mean	S.E.	S.D.	C.S.	Median
Ha probado	0,949	0	0,004	**1**	0,949
La busco en otra parte	0,353	0	0,009	**1**	0,353
Para alguien como yo	0,54	0	0,009	**1**	0,54
Se ajusta al momento	0,503	0	0,009	**1**	0,503
Satisfacción	0,471	0	0,009	**1**	0,471
Mejor marca	0,484	0	0,009	**1**	0,484
Marca favorita	0,452	0	0,009	**1**	0,452
Marca que admiro	0,448	0	0,009	**1**	0,448
Mejor que respeto	0,534	0	0,009	**1**	0,534
Mejor de calidad	0,541	0	0,009	**1**	0,541
Marca líder	0,746	0	0,008	**1**	0,746
Vale lo que cuesta	0,494	0	0,009	**1**	0,494
Odio_amor	0,93	0	0,005	**1**	0,93
Ha probado_Marca favorita	0,446	0	0,009	**1**	0,446
Marca favorita_Odio_amor	0,45	0	0,009	**1**	0,45
Marca favorita_Marca líder	0,382	0	0,009	**1**	0,382
Marca favorita_Mejor de calidad	0,315	0	0,009	**1**	0,315
Ha probado_Para alguien como yo	0,534	0	0,009	**1**	0,534
Para alguien como yo_Marca favorita	0,346	0	0,009	**1**	0,346
Para alguien como yo_Mejor que respeto	0,374	0	0,009	**1**	0,374
Para alguien como yo_Marca líder	0,46	0	0,009	**1**	0,46
int_compra	0,807	0	0,008	**1**	0,807
CONVERGENCIA					

Tabla 2.3. Estimaciones de las covarianzas en el modelo con interacciones

Covarianzas	Estimate	Significancia Bilateral
Relevancia<-->Respeto	0,056	0,12
Familiaridad<-->Respeto	0,012	0,089
Estatura_de la marca<-->Familiaridad	0,013	0,99
Familiaridad<-->Hallazgos	0,006	0,59
Estatura_de la marca<-->Relevancia	0,054	0,987
Relevancia<-->Hallazgos	0,116	0,069
Respeto<-->Hallazgos	0,109	0,888
Familiaridad<-->Relevancia	0,007	0,125
Estatura_de la marca<-->Respeto	0,107	0,72
Estatura_de la marca<-->Hallazgos	0,11	0,67

Tabla 2.4. Estimaciones de las varianzas en el modelo con interacciones

Varianzas	Mean	S.E.	S.D.	C.S.	Median
Familiaridad	0,006	0	0,001	**1**	0,006
Relevancia	0,046	0	0,007	**1,002**	0,045
Respeto	0,117	0	0,006	**1**	0,117
Hallazgos	0,2	0	0,007	**1**	0,199
Estatura_de la marca	0,242	0	0,007	**1**	0,242
e1	0,06	0	0,011	**1,001**	0,061
e5	0,049	0	0,002	**1**	0,049
e6	0,098	0	0,003	**1**	0,098
e8	0,112	0	0,003	**1**	0,112
e12	0,043	0	0,001	**1**	0,043
e13	0,198	0	0,007	**1**	0,197
e20	0,205	0	0,008	**1,001**	0,205
e19	0,109	0,001	0,017	**1,002**	0,109
e29	0,058	0	0,002	**1**	0,057
e21	0,132	0	0,004	**1**	0,132
e22	0,148	0	0,005	**1**	0,148
e23	0,183	0	0,005	**1**	0,183
e24	0,166	0	0,005	**1**	0,166
e25	0,162	0	0,005	**1**	0,162
e26	0,151	0	0,005	**1**	0,151
e27	0,147	0	0,004	**1**	0,147
e28	0,187	0	0,005	**1**	0,187
e37	0,094	0	0,003	**1**	0,094
e36	0,057	0	0,002	**1**	0,057
e33	0,002	0	0	**1**	0,002
e32	0,005	0	0	**1**	0,005
e42	0,031	0	0,002	**1**	0,031
CONVERGENCIA					

Figura 2.2. Iteraciones de las estimaciones de los coeficientes

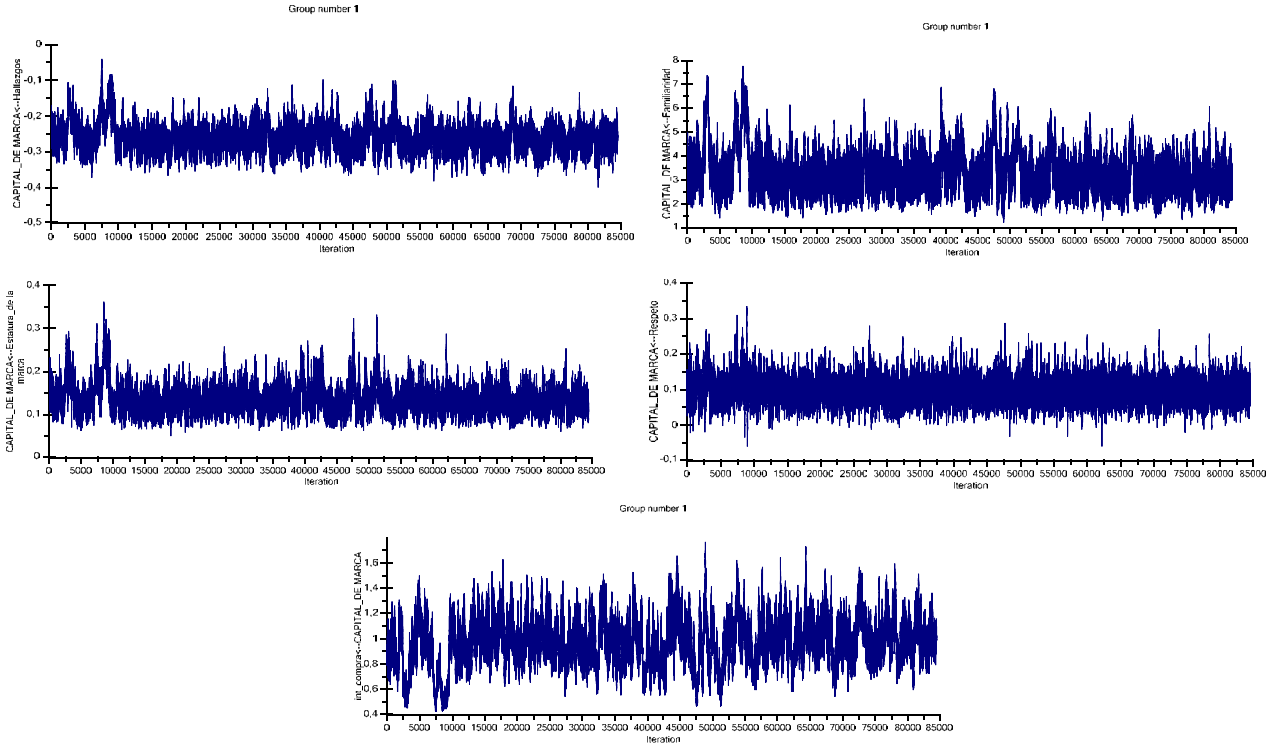

Para analizar si las interacciones muestran algún aporte en medición de la intención de compra se presenta el modelo que no toma en cuenta a dichas interacciones, donde, existe un aporte del capital de marca hacia la intención de compra de apenas 0,12; la variable familiaridad es la que más aporta al capital de marca, seguida en menor medida por relevancia la figura 2.3 muestra el modelo.

Figura 2.3. Modelo sin interacciones final

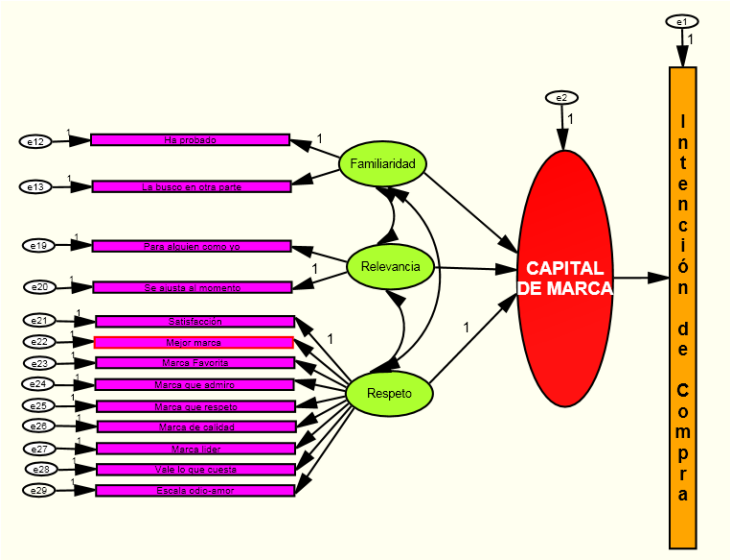

Tabla 2.5. Estimaciones de los parámetros en el modelo sin interacciones

Coeficientes	Mean	S.E.	S.D.	C.S.	Median
La busco en otra parte<--Familiaridad	2,541	0,003	0,285	**1**	2,522
Para alguien como yo<--Relevancia	1,059	0,001	0,133	**1**	1,051
Marca que respeto<--Respeto	0,863	0	0,033	**1**	0,862
Marca de calidad<--Respeto	0,915	0	0,033	**1**	0,914
Marca líder<--Respeto	0,602	0	0,028	**1**	0,602
Vale lo que cuesta<--Respeto	0,736	0	0,032	**1**	0,735
Odio-amor<--Respeto	0,255	0	0,016	**1**	0,255
Mejor marca<--Respeto	0,932	0	0,033	**1**	0,931
Marca favorita<--Respeto	0,75	0	0,032	**1**	0,749
Marca que admiro<--Respeto	0,837	0	0,032	**1**	0,837
CAPITAL_DE MARCA<--Relevancia	3,883	0,063	1,329	**1,001**	3,639
int_compra<--CAPITAL_DE MARCA	0,118	0,001	0,028	**1,001**	0,117
CAPITAL_DE MARCA<--Familiaridad	30,223	0,497	9,887	**1,001**	28,385
CONVERGENCIA					

Tabla 2.6. Estimaciones de los parámetros en el modelo sin interacciones

Interceptos	Mean	S.E.	S.D.	C.S.	Median
tp2a	0,949	0	0,004	**1**	0,949
tp7_1	0,353	0	0,009	**1**	0,353
tp4_1	0,54	0	0,009	**1**	0,54
tp13_4	0,503	0	0,009	**1**	0,503
tp8_9	0,471	0	0,009	**1**	0,471
tp8_2	0,484	0	0,009	**1**	0,484
tp3_1_2	0,452	0	0,009	**1**	0,452
tp8_10	0,448	0	0,009	**1**	0,448
tp8_4	0,534	0	0,009	**1**	0,534
tp8_5	0,541	0	0,009	**1**	0,541
tp8_1	0,746	0	0,008	**1**	0,746
tp5c	0,494	0	0,009	**1**	0,494
tp3_1a	0,93	0	0,005	**1**	0,93
int_compra	0,807	0	0,007	**1**	0,807
CONVERGENCIA					

Tabla 2.7. Estimaciones de las varianzas en el modelo con interacciones

Varianzas	Mean	S.E.	S.D.	C.S.	Median
Familiaridad	0,005	0	0,001	1	0,005
Relevancia	0,076	0	0,011	1	0,075
Respeto	0,117	0	0,006	1	0,117
e1	0,07	0	0,01	1	0,071
e12	0,044	0	0,001	1	0,044
e13	0,195	0	0,007	1	0,195
e20	0,175	0	0,011	1	0,175
e19	0,166	0	0,011	1	0,166
e29	0,058	0	0,002	1	0,057
e21	0,132	0	0,004	1	0,132
e22	0,149	0	0,005	1	0,149
e23	0,183	0	0,005	1	0,183
e24	0,166	0	0,005	1	0,166
e25	0,162	0	0,005	1	0,162
e26	0,151	0	0,005	1	0,151
e27	0,147	0	0,004	1	0,147
e28	0,187	0	0,005	1	0,187
CONVERGENCIA					

Se puede observar que la principal diferencia entre los dos modelos se ve manifestada en el aporte del capital de marca hacia la intención de compra, en el modelo con interacciones el aporte es de 0,967, mientras que en el modelo sin interacciones es de apenas 0,118; es decir que existiría una variación porcentual del 88%. Más aún se comprueba que existe evidencia estadística a través de una prueba de hipótesis de que existe diferencia entre los coeficientes con un nivel de significancia del 5%.

Se puede observar en la figura 4.4.1 que en general los coeficientes de las relaciones en común entre los dos modelos no varían demasiado de uno a otro aunque en general existe evidencia estadística de que si son diferentes, con excepción de los coeficientes asociados a Marca que respeto←Respeto, Marca de calidad←Respeto, Vale lo que cuesta←Respeto y Odio-amor←Respeto, siendo la diferencia más evidente en el caso de la variable familiaridad donde se ve un crecimiento de 27 puntos, lo que indicaría que en un modelo sin interacciones lo único que en definitiva aportaría al capital de marca sería la familiaridad con el producto, que tiene sentido con el capital de marca; pero en términos prácticos podría ser muy arriesgado depender de un solo factor.

Para realizar una comparación global de los dos modelos se utiliza el CID, visto en el capítulo uno, donde se observa en cambio que el modelo sin interacciones esta mejor adaptado ya que valores pequeños de CID muestran un mejor ajuste, aunque el número de coeficientes efectivos es menor, los resultados se presentan a continuación:

Tabla 2.8. Indicadores de ajuste de los modelos con y sin interacciones

	CID	**Número efectivo de parámetros**	**P-valor predictivo a posteriori**
Modelo con interacciones	2971,15	61,98	0,00007
Modelo sin interacciones	2547,83	33,15	0,00001

En conclusión se observa que existe un mayor aporte del capital de marca hacia la intención de compra en el modelo con interacciones, lo que comprueba la hipótesis de este trabajo que existen relaciones de relevancia entre atributos que aporten al capital de marca y consecuentemente hacia la intención de compra de productos de consumo masivo.

3. BIBLIOGRAFÍA.

- Hair J. F., Jr., Anderson R. E., Tatham R. I., Black W. C., “Análisis Multivariante”, Prentice Hall Iberia, Madrid, 1999.

- Byrne Barbara M., “Structural Equation Modelling with AMOS”, second edition, 2001.

- Joreskog, K. G., “Factor analysis by least-squares and maximum likelihood methods”. In K. Enslein, A. Ralston and H. S. Wilf (eds), Statistical Methods for Digital Computers. New York: John Wiley & Sons, Inc, 1977.

- Wiley, D., “The identification problem for structural equation models with unmeasured variables”. In A. S. Goldberger and O. D. Duncan (eds), Structural Equation Models in the Social Sciences pp. 69–83. New York: Academic Press, 1973.

- Browne, M. W., “Asymptotically distribution-free methods in the analysis of covariance structures”. British Journal of Mathematical and Statistical Psychology, 37, 62–83, 1984.

- Bentler, P. M., “Some contributions to efficient statistics for structural models: specification and estimation of moment structures”. Psychometrika, 48, 493–517, 1983.

- Bentler, P. M., “EQS: Structural Equation Program Manual”. Los Angeles: BMDP Statistical Software, 1992.

- Donald R. Lehmann-Sunil Gupta-Joel H. Steckel, “Marketing Research”, first edition, 1998.

- Lee Sik-Yum, “Structural Equation Modelling A Bayesian Approach”, 2007.

- Congdon Meter, “Applied Bayesian Modelling”, 2003

- Bazán Jorge, Calderón Arturo, Valdivieso Luis, “Modelos de teoría de respuesta al ítem bajo enfoque bayesiano”, Sociedad Matemática Peruana, XXVII Coloquio, 2009.

- Steinmetz Holger, Davidov Eldad, Schmidt Peter, “Three Approaches to Estimate Latent Interaction Effects: Intention and Perceived Behavioral”, 2011.

- Aaker David, Building Strong Brands, USA, 1993.

- AMOS versión 18