

# Estimación bayesiana del parámetro de decepción en modelos de elección discreta bajo el paradigma RRM (Random Regret Minimization): aplicación al diseño de exhibiciones en grandes superficies

**Bayesian Estimation of the Disappointment Parameter in Discrete Choice Models under the RRM (Random Regret Minimization) Paradigm: Application to Display Design in Large Retail Stores.**

Carlos Gabriel Contreras Serrano<sup>a</sup>  
carloscontrerass@usantotomas.edu.co

## Resumen

El presente estudio compara dos enfoques metodológicos para analizar experimentos de elección discreta con el fin de identificar la estrategia óptima de organización de productos en góndolas de supermercados y reducir la complejidad cognitiva para el comprador durante el proceso de compra. Se contrastan el modelo Logit Multinomial Mixto basado en la Maximización de la Utilidad Aleatoria (RUM) y el Modelo Logit Multinomial Mixto con estimación bayesiana de parámetros bajo el enfoque de Minimización del Arrepentimiento Aleatorio (RRM). El experimento, diseñado de manera factorial fraccionada y realizado con la participación de 748 compradores colombianos en la categoría de crema dental, revela que el modelo RRM bayesiano ofrece predicciones más sensibles en comparación con el MNL RUM, especialmente en productos con participaciones de mercado medianas o pequeñas. Asimismo, la obtención de distribuciones posteriores de los parámetros que impactan variables como precio, beneficios, marca y posición en la góndola permite realizar simulaciones precisas de diversos escenarios. Estas simulaciones capturan la heterogeneidad no observada en las preferencias individuales de los compradores, lo que favorece la toma de decisiones en la negociación de estrategias de exhibición con grandes superficies. Además, las distribuciones posteriores ofrecen ventajas adicionales al contar con densidades empíricas conocidas, superando las limitaciones de los métodos estándar de estimación de parámetros en términos de optimización estadística. **Palabras clave:** Palabras claves: Elección discreta, Modelo logit multinomial mixto, RUM (Random Utility Maximization), RRM (Random Regret Minimization), estrategia de exhibición, Trade marketing

<sup>a</sup>Estudiante, Maestría en Estadística Aplicada

### Abstract

This study compares two methodological approaches for analyzing discrete choice experiments aimed at identifying the optimal product organization strategy in supermarket shelves, while reducing cognitive complexity for buyers during the purchasing process. The study contrasts the Mixed Multinomial Logit model based on Random Utility Maximization (RUM) with the Bayesian parameter estimation approach of the Mixed Multinomial Logit model under the Random Regret Minimization (RRM) framework. The experiment, structured as a fractional factorial design and conducted with the participation of 748 Colombian shoppers in the toothpaste category, reveals that the Bayesian RRM model provides more sensitive predictions compared to the standard MNL RUM model, particularly for products with medium or small market shares. Additionally, the posterior distributions of parameters affecting variables such as price, benefits, brand, and shelf position enable precise simulations of various scenarios. These simulations capture unobserved heterogeneity in individual consumer preferences, facilitating decision-making in negotiations regarding shelf display strategies with major retailers. Moreover, the posterior distributions offer additional advantages by providing known empirical densities, overcoming the limitations of standard parameter estimation methods in terms of statistical optimization.

**Keywords:** Discrete Choice Models, Mixed Multinomial Logit Model, RUM, RRM, Display strategy, Trade Marketing.

## 1. Introducción

El planograma es un diagrama que ilustra detalladamente el plan de disposición de productos en una góndola de supermercado y constituye una de las principales herramientas de negociación entre marcas y minoristas (Bianchi-Aguiar, Hübner, Carravilla, & Oliveira, 2001). La ubicación de productos en góndolas para optimizar su competitividad ha sido abordada principalmente por ingenieros y economistas mediante métodos numéricos y de optimización (Hübner & Kuhn, 2024). Estos enfoques consideran el potencial de rentabilidad, el espacio disponible del retail para la negociación con las marcas, el número de caras que un producto ocupa en la góndola y la rotación, entre otras variables operativas. Sin embargo, debido a las modas, los constantes lanzamientos de nuevos productos por parte de las marcas, las tendencias de consumo y la estacionalidad de ciertas categorías, los esfuerzos que ignoran las variables contextuales y comportamentales del comprador, junto con sus procesos cognitivos durante la elección (diferencias individuales / heterogeneidad), han tendido a reportar bajas eficiencias en la predicción del surtido óptimo y en la participación de las marcas en las elecciones de los consumidores. (Pietrini, Paolanti, Mancini, Frontoni & Zingaretti, 2024)

La cantidad de alternativas en una góndola es elevada y cada una de ellas presenta información detallada sobre el producto, como marca, beneficios funcionales, ingredientes, principios activos, sabores, tamaños, precio y promociones, lo que dificulta

al consumidor encontrar el producto deseado (Shankar, Inman, Mantrala, Kelley & Rizley, 2011). Por esta razón, los investigadores han centrado su atención en definir procedimientos y algoritmos para priorizar los beneficios que el comprador considera al enfrentarse a la góndola y en cuantificar el impacto de cada elemento del producto para definir un árbol de decisión. Esta herramienta permite la creación de planogramas profesionales (Robinson, Feufel, Shalin, Steele-Johnson & Springer, 2020) sin embargo las referencias publicadas hasta el momento no contemplan la posición del producto en la góndola como un factor de elección.

## 2. Modelos de elección discreta

A nivel experimental, el análisis conjunto (conjoint análisis) en general y los métodos de elección discreta en particular son la herramienta por excelencia para estudiar comportamiento de elección (Oppewal, Louviere & Timmermans, 1994), en investigación de mercados, las aplicaciones son extensas para fijación de precios (Ancarani & Shankar, 2004), desarrollo de productos (Contreras, 2020), mejora de empaques (Silayoi & Speece, 2007) e innovación (Farley, Thompson, Hanbury & Chambers, 2013) por lo que se considera una herramienta sensible para estudiar procesos de elección (Ben-Akiva, y otros, 2002), esta investigación propone demostrar la utilidad de esta metodología para lograr un objetivo doble: 1. Establecer el árbol de decisión de categoría del shopper y 2. Simular el planograma con mejores posibilidades de simplificar el proceso cognitivo del comprador al elegir entre las opciones en góndola.

Hasta el momento, los experimentos de elección discreta descomponen el producto en factores como marca, precio, promoción, presentación, beneficios etc., para poder aislar el impacto de cada una de estas variables en el proceso de decisión del comprador, la utilidad calculada de cada variable ayuda a configurar el árbol de decisión del comprador y posterior planograma. No se ha integrado la posición del producto en la góndola como una de las variables en los escenarios experimentales del conjoint.

Se ha demostrado que, con un mayor número de opciones, la función clásica de maximización de utilidad tiende a no converger estadísticamente, aumentando la influencia de la función de decepción (Chorus, 2010). Dado que una góndola ofrece una amplia gama de alternativas, asumir que el consumidor maximiza la utilidad de su decisión resulta estadísticamente cuestionable, lo que invalida la aplicabilidad de los modelos clásicos RUM (Random Utility Maximization) en el análisis de la conducta de elección. Esto sugiere la necesidad de explorar este fenómeno mediante modelos RRN (Random Regret Minimization).

### 3. Modelos RUM y RRM

Los modelos de Maximización Aleatoria de Utilidad (RUM) hipotetizan que los compradores toman decisiones buscando maximizar su utilidad. En estos modelos, se asume que la utilidad de una alternativa  $i$ ,  $U_i$ , se descompone en dos: un componente sistemático,  $V_i$ , que es una función lineal de las características del producto,  $\beta_m * X_{im}$ ; y un componente aleatorio,  $\varepsilon_i$ . Este último representa la porción estocástica de la función de utilidad, asumida como idénticamente distribuida e independiente (ver ecuación 1).

$$U_i = V_i + \varepsilon_i = \sum_m \beta_m * X_{im} + \varepsilon_i \quad (1)$$

Considerando la distribución del error y asumiendo que el consumidor selecciona las alternativas que maximizan su utilidad, las probabilidades de elección,  $P_i$ , se determinan mediante la formulación logit. (ver ecuación 2).

$$P(i) = \frac{\exp(V_i)}{\sum_{j=1 \dots J} \exp(V_j)} \quad (2)$$

El enfoque de Minimización Aleatoria del Arrepentimiento (RRM) se centra en reducir la decepción asociada con la elección, en lugar de maximizar la utilidad. La evidencia sobre la minimización del arrepentimiento ha sido presentada en diversos estudios teóricos y empíricos desde hace más de dos décadas (Bell, 1982) y ha sido validada recientemente mediante novedosos mecanismos investigativos (Muller, Kroll & Vogt, 2012).

Los modelos de Minimización Aleatoria del Arrepentimiento (RRM) postulan que, dado que una góndola se compone de diversos atributos (como la posición del producto, posición del rival directo, marca, precio, promoción, beneficios, empaque, etc.), y cada atributo presenta diferentes niveles, resulta improbable que todos los atributos de un producto maximicen la utilidad simultáneamente. Por lo tanto, se acepta que algunos atributos puedan tener niveles subóptimos, siempre que la totalidad de los atributos proporcione una experiencia de optimización. Desde esta perspectiva, el arrepentimiento del comprador surge cuando una alternativa no elegida supera en al menos un atributo importante a la alternativa seleccionada (Chorus, 2012). La estructuración matemática del arrepentimiento por parte del comprador se puede formular como muestra la ecuación 3.

$$RR_i = R_i + \varepsilon_i = \sum_{j \neq i} \sum_m \ln(1 + \exp[\beta_m * (x_{jm} - x_{im})]) + \varepsilon_i \quad (3)$$

En esta concepción, el arrepentimiento asociado a una alternativa  $i$ ,  $RR_i$ , se descompone en dos partes: una componente explicativa, formada por la suma de los efectos de los atributos del producto no elegido  $x_{jm}$  en comparación con el producto elegido  $x_{im}$  y un componente estocástico de error  $\varepsilon_i$  que sigue una distribución

negativa, idéntica e independiente con valores extremos tipo I. Dada esta distribución del componente aleatorio y asumiendo que el consumidor elige la alternativa que le genere menos arrepentimiento, la probabilidad de elección se determina mediante la expresión logit presentada en la ecuación 4.

$$P(i) = \frac{\exp(-V_i)}{\sum_{j=1 \dots J} \exp(-V_j)} \quad (4)$$

El término  $\ln(1 + \exp[\beta_m * (x_{jm} - x_{im})])$  cuantifica el arrepentimiento al comparar la alternativa  $i$  con la alternativa  $j$  en relación a un atributo particular  $x_m$ ; Esta formulación implica que el arrepentimiento tiende a cero cuando la alternativa no elegida  $j$  tiene un desempeño inferior al de la alternativa  $i$ ; cuando el caso contrario ocurre y la alternativa elegida presenta un peor desempeño en el atributo en comparación con la no elegida, el arrepentimiento tiende a 1. El parámetro  $\beta_m$  representa la forma de la función de arrepentimiento para el atributo  $x_m$ .

Desde la economía del comportamiento, los modelos RUM y RRM difieren en dos perspectivas clave: el comportamiento compensatorio y el efecto compromisorio (Chorus, 2010), RUM asume un comportamiento completamente compensatorio, donde un bajo desempeño en un atributo puede ser totalmente compensado por un buen desempeño en otros. RRM propone un comportamiento semi-compensatorio, donde el desempeño mejorado de un atributo que ya es superior tiene poco efecto, mientras que un mal desempeño en comparación con la alternativa no elegida acelera el arrepentimiento a uno. Aquí, un bajo desempeño puede ser compensado por un alto desempeño en otro atributo, siempre que ambos sean igualmente importantes.

El efecto compromisorio surge debido a las limitaciones cognitivas del comprador. La memoria limitada del consumidor hace que sea más económico almacenar atributos de bajo desempeño, ya que ocupan menos espacio mnemónico. Esto implica que el modelo RUM requiere más recursos de memoria en comparación con el modelo RRM, que es más eficiente en términos cognitivos cuando hay múltiples atributos (Simonson, 1992)

## 4. Retos en la estimación de parámetros

El diseño de planogramas basados en el comportamiento de elección del comprador requiere un manejo preciso de las diferencias individuales, lo que presenta varios desafíos:

- Los enfoques frecuentistas típicos en modelos de elección discreta asumen que todos los individuos comparten los mismos coeficientes de preferencia (Train K. , Discrete Choice Methods with simulation, 2009). Esta suposición implica que no se permite variación en las preferencias entre los individuos, lo cual puede no ser realista en muchas aplicaciones prácticas.

- En observación de autores en paradigma RUM (McFadden & Train, 2000) para modelar adecuadamente las diferencias individuales, es necesario capturar la heterogeneidad de las preferencias, tratándolas como una variable aleatoria. Sin embargo, los modelos logit convencionales consideran estos coeficientes como fijos y uniformes para toda la población, limitando su capacidad para reflejar la diversidad de comportamientos entre los individuos (Revelt & Train, 1998)
- La falta de incorporación de información previa sobre la distribución de los coeficientes de preferencia puede conducir a estimaciones sesgadas (Greene & Hensher, 2010), especialmente en presencia de alta variabilidad no capturada en las preferencias individuales. Además, los modelos frecuentistas estándar no pueden aprovechar de manera efectiva la información jerárquica o de grupo para mejorar la estimación de los coeficientes individuales.
- Si se intentara capturar la heterogeneidad mediante variables dummy o interacciones en modelos frecuentistas, el número de parámetros a estimar aumentaría significativamente, lo que pondría en riesgo la eficiencia del modelo y podría generar problemas de sobreajuste o identificabilidad (Train & Sonnier, 2005) particularmente en muestras con un gran número de individuos y una alta variabilidad en las preferencias.

Los modelos mixtos, como el Multinomial Logit Mixto (MMNL), permiten capturar la heterogeneidad no observada entre individuos mediante la introducción de coeficientes aleatorios en las variables explicativas (Revelt & Train, 1998). Aunque esto mejora la representatividad del modelo al reconocer diferencias individuales o grupales, también introduce complejidad adicional. La función de verosimilitud de estos modelos se vuelve altamente no lineal y puede presentar múltiples máximos locales, complicando su evaluación y optimización debido a la necesidad de integrar sobre distribuciones complejas, como las normales multivariadas (McFadden & Train, 2000). Este proceso, generalmente abordado mediante métodos numéricos como la cuadratura de Gauss-Hermite o simulaciones de Monte Carlo, puede ser computacionalmente intensivo y propenso a errores (Bhat, 2001).

En contraste, los métodos bayesianos ofrecen una solución más robusta y flexible para manejar estas complejidades (Rossi, Allenby & McCulloch, 2005). A través de técnicas de muestreo como Monte Carlo con Cadenas de Markov (MCMC), es posible generar muestras de la distribución posterior de los parámetros, lo que permite una exploración más exhaustiva del espacio de parámetros, incluso en presencia de múltiples máximos locales (Train K. , 2001). Al no depender de la optimización de una función de verosimilitud singular, estos métodos mitigan el riesgo de convergencia en máximos locales y proporcionan estimaciones más completas que incorporan tanto incertidumbre como variabilidad (Robert & Castella, 2004). Además, los métodos bayesianos permiten utilizar distribuciones a priori informadas por conocimiento previo, lo que facilita un muestreo más eficiente y estable en modelos complejos (Lenk, 2009).

## 5. Enfoque bayesiano para la estimación de parámetros.

Se evidencia un elevado aumento del uso de enfoques bayesianos para resolver problemas de comportamiento del consumidor. Es notorio el trabajo en modelos probit de elección propuestos por (Albert & Chib, 1993) y (McCulloch & Rossi, 1994) (Train K. , 2009) y la forma como amplifica el trabajo bayesiano de modelos logit mixtos para incluir distribución lognormal y triangular a trabajos que ya incluía efectos aleatorios con distribución normal (Allenby G. , 1997) son un ejemplo de este esfuerzo.

Idealmente, para capturar una representación completa de las preferencias individuales y su influencia en el proceso de elección, sería necesario exponer al sujeto a un gran número de escenarios. Sin embargo, esto compromete la validez de la investigación debido a la fatiga del participante. (Rossi, McCulloch, & Allenby, 1996) demuestran cómo es posible extraer información a nivel individual utilizando la variación aleatoria en las preferencias dentro de un modelo. La escasez de datos individuales, sumada a la necesidad de capturar las diferencias entre sujetos en lugar de tratarlos de manera homogénea, plantea desafíos en la investigación de mercados. En este contexto, los enfoques bayesianos resultan particularmente adecuados.

Los modelos de elección con efectos aleatorios generalizan los modelos de elección estándar para incorporar efectos a nivel individual siempre enfocados en el paradigma RUM (McFadden & Train, 2000) donde el coeficiente es una utilidad. En esta propuesta de investigación la decepción sustituye la utilidad como parámetro a estimar. Sea  $D_{ijt}$  la decepción que el individuo  $i$  minimiza al elegir la alternativa  $j$  en la situación de elección  $t$  (ver ecuación 5)

$$\begin{aligned} D_{ijt} &= x'_{ijt}\beta + z'_{ijt}\gamma_i + \epsilon_{ijt} \\ Y_{ijt} &= \begin{cases} 1 & \text{si } D_{ijt} \geq \max(D_{i1t}, D_{i2t}, \dots, D_{iLt}) \\ 0 & \text{en otros casos} \end{cases} \end{aligned} \quad (5)$$

Donde  $Y_{ijt}$  es la elección observada para el individuo  $i$  y la alternativa  $j$  en la situación de elección  $t$ ;  $x_{ijt}$  es el vector de diseño fijo para el individuo  $i$  y la alternativa  $j$  en la situación de elección  $t$ ;  $\beta$  son los coeficientes fijos;  $z_{ijt}$  es el vector de diseño aleatorio para el individuo  $i$  y la alternativa  $j$  en la situación de elección  $t$ ; y  $\gamma_i$  son los coeficientes aleatorios correspondientes al individuo  $i$  alineados con  $z_{ijt}$ .

A partir del trabajo de (Allenby & Rossi, 1999) Se asume que cada  $\gamma_i$  se extrae de una superpoblación y que esta sigue una distribución normal,  $\gamma_i \sim N(0, \Omega_\gamma)$ . Se añade una etapa adicional al modelo en la que se especifica una distribución previa para  $\Omega_\gamma$  con condiciones tales que se pueden ver a continuación:

$$\begin{aligned}\pi(\gamma) &= N(\gamma', \Omega_\gamma) \\ \pi(\Omega_\gamma) &= \text{Whishart inversa}(v_0, V_0)\end{aligned}$$

La matriz de covarianza  $\Omega_\gamma$  caracteriza el grado de heterogeneidad entre los individuos. La diagonal de la matriz indica una heterogeneidad sustancial en las decepciones parciales. Los elementos fuera de la diagonal indican la evaluación de los niveles de los atributos en pares.  $\gamma'$  es el vector medio de los coeficientes en la regresión.

El modelo logit con efectos aleatorios está compuesto por los coeficientes de los parámetros de efectos fijos  $\beta$ , los coeficientes de los parámetros de efectos aleatorios  $\gamma_i$  y la covarianza de los parámetros para los coeficientes de efectos aleatorios  $\Omega_\gamma$ . La estrategia de muestreo de Metropolis – Hasting bajo el enfoque Gamerman (Gamerman, 1997) será útil para proponer muestras bajo condiciones tales que:

$$\begin{aligned}1 &\rightarrow (\beta|\gamma_i, Y) \\ 2 &\rightarrow (\gamma_i|\beta, \Omega_\gamma, Y), \quad i = 1, \dots, N \\ 3 &\rightarrow (\Omega_\gamma|\gamma_i, Y)\end{aligned}$$

En propuesta de Gamerman todas las cadenas se inician con los efectos aleatorios en 0 y matriz de covarianza identidad. La actualización se realiza primero para los efectos fijos  $\beta$  como un bloque para ubicar las cadenas en la región correcta del espacio de parámetros. Luego se actualiza para los efectos aleatorios  $\gamma_i$  y finalmente la matriz de covarianza de los efectos aleatorios  $\Omega_\gamma$  (Gamerman, Sampling from the Posterior Distribution in Generalized Linear Models, 1997)

La propuesta de (Allenby & Rossi, 1999) de modelos bayesianos jerárquicos contiene parámetros de coeficientes aleatorios  $\gamma_i$ , la media poblacional de los parámetros de los coeficientes aleatorios  $\bar{\gamma}$  y la covarianza de los parámetros para efectos aleatorios  $\Omega_\gamma$ . La estrategia de muestreo se realizaría mediante las siguientes condicionales:

$$\begin{aligned}1 &\rightarrow (\gamma_i|\bar{\gamma}, \Omega_\gamma, Y), \quad i = 1, \dots, N \\ 2 &\rightarrow (\bar{\gamma}|\gamma_i, \Omega_\gamma) \\ 3 &\rightarrow (\Omega_\gamma|\gamma_i, \bar{Y})\end{aligned}$$

La posterior para los parámetros de las diferencias individuales  $\bar{\gamma}$  proviene de una distribución normal con media de  $\sum_{i=1}^N \gamma_i/N$  y una covarianza de  $\Omega_\gamma/N$ .

La posterior de la matriz de covarianza  $\Omega_\gamma$  es una inversa de Wishart  $(v_0 + N, V_0 + S)$  donde  $S = \sum_{i=1}^N (\gamma_i - \bar{\gamma})(\gamma_i - \bar{\gamma})'/N$ .

La posterior condicional para el parámetro de decepción no está definida. El muestreo de Metrópolis – Hastings bajo en método de Gamerman es el algoritmo de muestreo propuesto para tal fin.

## 6. Problema de investigación

¿Qué ventajas ofrece un modelo RRN (Random Regret Minimization) con efectos mixtos y estimación bayesiana de parámetros en comparación a un modelo de RUM estimado con MNL (Multinomial Logit Mixto) estándar en términos de MAPE si comparamos la predicción de share de mercado conocido vs predicciones de los modelos?

### 6.1. Método.

#### 6.1.1. Diseño de estudio:

Diseño experimental intra-sujeto factorial anidada (Ato, López, & Benavente, 2013). En este diseño experimental cada sujeto se expone a 20 escenarios experimentales que combinan ortogonalmente los productos de la categoría de pasta de dientes.

#### 6.1.2. Muestra:

748 compradores frecuentes de productos para cuidado bucal, incluidos pasta de dientes, cepillos dentales, enjuagues bucales y ceda de dientes. 55 % mujeres, 45 % hombres seleccionados aleatoriamente de un marco muestral ad-hoc construido para este estudio. La edad promedio de los participantes fue de 28,5 años (desviación estándar: 4,3).

El experimento se desarrolló en Bogotá, Medellín, Cali y Barranquilla, cada ciudad contó con 187 sujetos que se presentaron en hora y fecha establecida a cabina experimental para participar del estudio. La información de las cuatro ciudades se levantó durante 15 días calendario.

Para asegurar calidad en el reclutamiento de los participantes, cada uno de estos fue cotejado contra la base de datos inter-agencia de la asociación colombiana de empresas de investigación de mercados y opinión pública (ACEI, 2024). Ningún participante en el estudio estuvo registrado en la base indicando que no han participado en estudios de mercado y opinión pública desde la construcción de la base de datos.

### 6.1.3. Instrumentos:

Como es propio en los diseños de elección discreta, las variables independientes son factores que se combinan ortogonalmente en estímulos conjuntos, en este caso imágenes de góndolas que emulan la presentación de la categoría de pastas de dientes en un supermercado como se muestra en la figura 1:

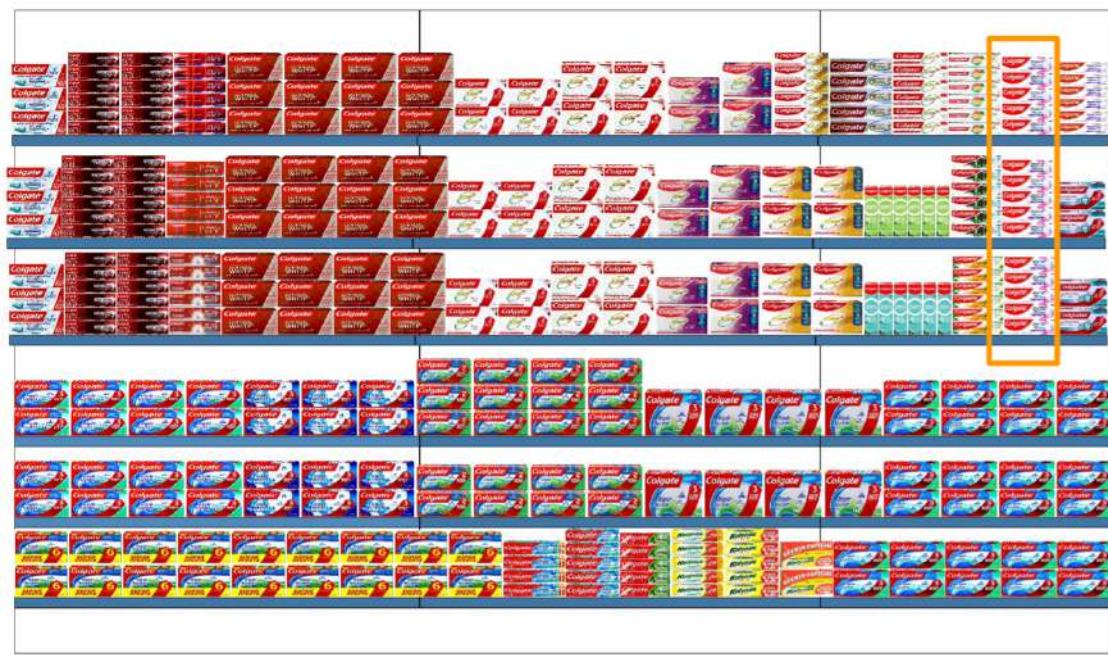


Figura 1: Ejemplo de escenario experimental ortogonal

Las variables independientes se resumen en la tabla 1. La estrategia de presentación de los estímulos fue MBCA Menu Based Adaptative Conjoint Analysis (Bauer, Menrad, & Decker, 2015) esto significa que, según los hábitos de compra del participante, sus marcas favoritas, y sus beneficios predilectos, el algoritmo adaptativo presenta configuraciones personalizadas de la góndola (Figura 1) respetando principios de ortogonalidad en la presentación factorial fraccionada de las variables independientes. Cada participante se expuso a 20 góndolas experimentales personalizadas según sus hábitos.

El diseño experimental se desarrolló con la librería DOE en Python, (ver anexo 1) (Tang, Luo, Cheng, Yang, & Ran, 2014). Los estímulos experimentales o góndolas resultaron ser una combinación factorial fraccionada de los niveles de los factores expuestos en la tabla 1. Esto permite analizar el efecto marginal de cada nivel, no los efectos interactivos.

Las góndolas experimentales personalizadas a cada participante se presentaron proyectadas a escala real, tamaño pared simulando condiciones naturales de super-

Tabla 1: Atributos y Niveles

Atributo	Niveles
Marca	6 marcas que representan el 80 % de participación de mercado en volumen
Beneficios	Sin beneficio Blanqueamiento dental Sensibilidad Aliento fresco prolongado
Precio	Sin precio 30 % por debajo de mercado 15 % por debajo de mercado Precio mercado 15 % por encima de mercado 30 % por encima de mercado
Promoción	Sin promoción Pack 2 * 1 20 % de descuento Pack 3 * 2 30 % de descuento
Distribución	Agotado (El estímulo no aparece) Conforme mercado (El estímulo aparece conforme distribución ponderada de mercado) -15 % distribución ponderada (menos caras de producto en góndola) 15 % distribución ponderada (más caras del producto en góndola)
Posición en anaquel	El anaquel se dividió en cuatro bandejas horizontales y seis columnas verticales para un total de 24 espacios en góndola. Cada coordenada es un nivel de la variable

mercado, usando un proyector de video de alta definición Samsung 2022 SP-LSP3B 4k HD

La tarea experimental consistía en que para cada uno de los 20 escenarios (góndolas) el participante tendría que escoger los productos que mejor dieran satisfacción a su necesidad. La respuesta es binaria por escenario.

#### 6.1.4. Análisis estadístico

Aunque la librería Apollo en R (Hess & Palma, 2019) cuenta con un abanico grande de opciones para programar modelos de elección, el enfoque RRN que es objeto de esta investigación no está habilitado para estimación bayesiana de parámetros y de la matriz de covarianza de efectos aleatorios.

Se hizo uso de SAS STAT 15.2, particularmente PROC NL MIXED para programar

el modelo multinomial logit bajo minimización de función de decepción el cual sería gold standard RUM, RUM MNL. Para la estimación de parámetros de manera bayesiana se hizo uso del Proc MCMC donde se desarrolló el RUM Bayesiano.

Los parámetros de simulación usados para el RUM Bayesiano fue bajo estrategia Gamerman-Metrópolis, tomando como distribución previa para la matriz de covarianza de efectos aleatorios la distribución inversa de Wishart. Todos los demás parámetros iniciaron con previas no informativas de Jeffreys. Se programaron 30.000 iteraciones. La convergencia de las cadenas de Markov se evaluaron mediante tiempos de autocorrelación y diagnóstico de Geweke. Se estimaron intervalos de credibilidad para los parámetros de forma simétrica y de alta densidad (Ver anexo 2 para el código)

## 6.2. Resultados

El mercado mide mediante empresas como Nielsen la participación oficial de cada marca en formatos de tienda como canal moderno, gracias a esto, se conoce el desempeño de las diferentes marcas en la exhibición actual. Para validar el modelo se simula la exhibición estándar actual en el canal y se obtienen las probabilidades estimadas del modelo Logit. El MAPE entre el modelo clásico RUM, el RRM frecuentista y el RRM bayesiano y la métrica de participación de mercado oficial.

La tabla 2, muestra las predicciones de los tres modelos en comparación con la participación oficial de mercado mostrando que el RRM bayesiano tiene mejor capacidad de predecir la participación de mercado, sobre todo en marcas pequeñas ( $Q: 0,84, p:0,03$ ) en comparación con RRM estimado por multinomial logit mixto que parece eficiente en marcas grandes dejando de ser sensible para capturar la variabilidad de participación de mercado para marcas que pesan menos en la masa ( $Q:0,67, p:0,04$ ).

Tabla 2: Comparativo de la eficiencia predictiva RUM vs RNN vía share de mercado

	<b>Participación oficial</b>	<b>RUM</b>	<b>RRM MNL</b>	<b>RRM Bayesiano</b>
Marca 1	51 %	25 %	48 %	50 %
Marca 2	19 %	26 %	20 %	18 %
Marca 3	14 %	19 %	8 %	15 %
Marca 4	9 %	12 %	11 %	12 %
Marca 5	5 %	9 %	7 %	4 %
Marca 6	2 %	9 %	6 %	1 %
MAPE		81,8 %	36,5 %	6,1 %

Tomando como referencia el RRM Bayesiano, se procedió a analizar las decepciones extrayendo unas importancias relativas estimadas tomando el HPD de cada atributo sobre el HPD de todos los atributos de manera similar como se extraen las importancias sobre las utilidades en modelos RUM estándar. La tabla 3, muestra

las importancias de cada uno de los componentes dentro del proceso de elección.

Tabla 3: Importancia relativa sobre el parámetro de decepción (RRM Bayesiana) en la elección durante el experimento

	<b>RUM</b>	<b>RRM MNL</b>	<b>RRM Bayesiano</b>
Beneficio	18 %	23 %	30 %
Posición en el anaquel	14 %	23 %	23 %
Precio	21 %	18 %	17 %
Marca	30 %	17 %	13 %
Promoción	11 %	12 %	10 %
Distribución	5 %	8 %	6 %

Para disminuir la potencial decepción de elegir mal, el consumidor tiende a analizar tres variables fundamentalmente: el beneficio del producto con un peso del 30 %, la posición en el anaquel 23 % y el precio 17 %. Los modelos clásicos que vienen por defecto en paquetes como SAS y SPSS que usan RUM, y que en este experimento sale desfavorecido en el MAPE (ver tabla 1), hubiesen afirmado que el principal motivo de elección del comprador en góndola es la marca, seguido por el precio y en tercer lugar el beneficio.

Dado que la posición en el anaquel pesa cerca del 23 % en la dinámica de elección de crema de dientes, la tabla 4 muestra los parámetros específicos de cada posición en el anaquel y su impacto en la decisión extraídos como descriptivos de la distribución posterior.

Los resultados indican que las cadenas de Markov generadas para las 30 posiciones posibles en la góndola experimental, utilizando el muestreo de Gamerman-Metropolis con 50,000 iteraciones y un tiempo de procesamiento computacional promedio de 800 minutos (aproximadamente 13 horas), convergen de acuerdo con el diagnóstico de Geweke a un nivel de significancia  $\alpha$  de 0.05.

Los productos ubicado en las filas 2 y 3 del anaquel en interacción con las columnas 3 y 4, tienden a disminuir la decepción del consumidor. Por el contrario, cualquier producto ubicado en la columna 1 o columna 5 o en la celda F1C5 tiende a elevar de forma significativa la decepción del comprador haciendo menos posible la elección. La tabla 5 muestra la media de la posterior para cada uno de los efectos de las posiciones en el anaquel organizado como una exhibición estándar de supermercado.

La tabla 5 es fundamentalmente un mapa de calor que muestra el chance que tiene un producto de ser elegido si se ubica en esta posición de la góndola en comparación de ubicarse en la celda F5/C1 teniendo en cuenta las diferencias individuales de los participantes. Teniendo en cuenta que cualquier producto de esta categoría ubicado en la celda F2/C4 tiene una probabilidad de ser elegido del 95 %, la figura 2 muestra la densidad posterior para este parámetro y su diagnóstico vía autocorrelograma.

El costo computacional puede ser elevado, aun trabajando en paralelo como se

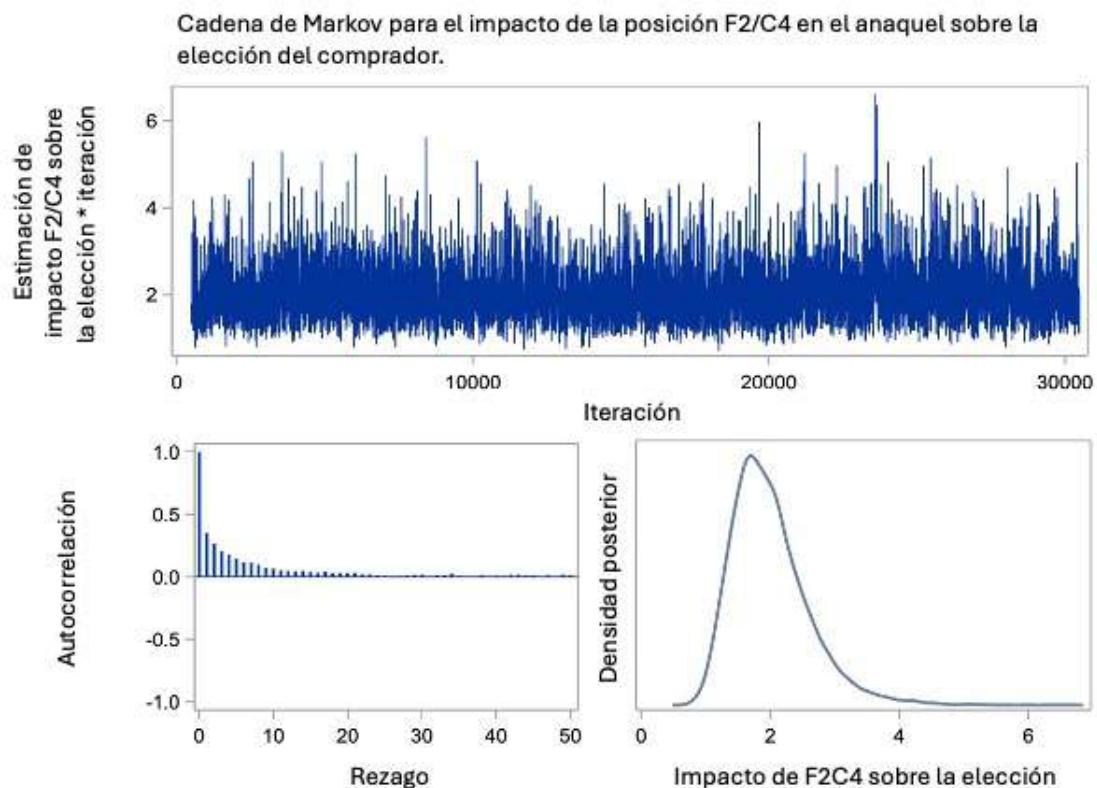


Figura 2: Evaluación de convergencia del parámetro de impacto de la posición f2/c4 para minimizar la decepción del comprador

Tabla 4: Parámetros de la distribución posterior para las posiciones en el anaquel bajo RMM Bayesiano

Fila F / Columna C	Media	Desv estándar	Intervalos de confianza				Diagnóstico de Geweke		Tamaños de muestra efectivos		
			ETI 95 %		HPD 95 %		Z	Pr >  z	ESS	AutCor. Time	Eficc
			Mín	Máx	Mín	Máx					
F1/C1	-1,53	1,36	1,11	-4,30	1,0	-4,42	-3,04	0,05	32,3	774,1	0,0013
F1/C2	-1,42	1,26	1,41	-3,81	1,1	-3,94	-1,98	0,07	35,8	699,1	0,0014
F1/C3	0,60	1,03	3,03	-1,17	2,7	-1,39	-2,80	0,06	30,6	815,8	0,0012
F1/C4	1,52	0,93	3,89	-0,04	3,4	-0,31	-2,80	0,06	30,7	814,1	0,0012
F1/C5	-3,01	1,74	0,18	-6,75	-0,1	-6,98	-1,42	0,15	33,3	750,5	0,0013
F1/C6	-0,76	1,10	1,76	-2,80	1,5	-3,00	-2,17	0,30	31,5	793,9	0,0013
F2/C1	1,54	0,95	3,93	-0,06	3,5	-2,87	-2,44	0,15	30,7	814,2	0,0012
F2/C2	1,86	0,94	4,21	0,32	3,8	0,10	-3,32	0,13	30,8	812,8	0,0012
F2/C3	2,58	0,91	4,99	1,07	4,4	0,80	-3,24	0,12	30,4	821,9	0,0012
F2/C4	3,09	0,90	5,54	1,61	4,9	1,30	-3,14	0,17	30,1	829,4	0,0012
F2/C5	-0,11	1,00	2,22	-1,91	1,9	-2,10	-1,71	0,09	33,6	743,5	0,0013
F2/C6	0,29	1,01	2,62	-1,60	2,2	-1,86	-1,64	0,10	33,8	740	0,0014
F3/C1	1,38	0,95	3,78	-0,26	3,2	-0,58	-2,22	0,07	31,9	783,1	0,0013
F3/C2	0,51	1,00	2,99	-1,24	2,5	-1,52	-2,20	0,08	31,2	802,1	0,0012
F3/C3	2,95	0,90	5,37	1,47	4,8	1,19	-2,95	0,06	30	832,3	0,0012
F3/C4	2,61	0,91	5,07	1,11	4,4	0,74	-3,01	0,06	30,1	831,8	0,0012
F3/C5	0,93	0,96	3,27	-0,72	2,8	-0,97	-2,32	0,07	31	805,2	0,0012
F3/C6	-1,99	1,32	0,44	-4,92	0,6	-4,72	0,18	0,86	33,4	747,7	0,0013
F4/C1	-1,46	1,25	1,20	-3,91	1,1	-4,01	-2,94	0,04	34,3	729,2	0,0014
F4/C2	-1,37	1,27	1,50	-3,74	1,2	-4,00	-0,84	0,40	34,1	732,3	0,0014
F4/C3	2,35	0,91	4,81	0,83	4,1	0,48	-2,99	0,08	30,1	830,1	0,0012
F4/C4	2,74	0,92	5,18	1,23	4,6	1,00	-2,77	0,08	30	834,5	0,0012
F4/C5	0,67	1,02	3,21	-1,15	2,7	-1,39	-3,23	0,09	31,6	792	0,0013
F4/C6	-2,30	1,32	0,41	-4,82	0,3	-4,92	-1,32	0,19	33,8	740,5	0,0014
F5/C1	-1,80	1,30	0,91	-4,52	0,9	-4,55	-2,54	0,06	36	695,2	0,0014
F5/C2	-1,08	1,12	1,60	-3,14	1,2	-3,41	-1,34	0,18	32,7	765,1	0,0013
F5/C3	1,46	0,96	3,91	-0,13	3,4	-0,43	-2,65	0,08	30,7	815,6	0,0012
F5/C4	2,45	0,91	4,81	0,97	4,4	0,74	-3,15	0,08	30,5	820	0,0012
F5/C5	-0,22	1,03	2,28	-2,03	1,7	-2,30	-3,61	0,09	35,6	701,7	0,0014

evidencia en el código empleado, esto se debe al planteamiento de modelos de efectos aleatorios para el parámetro de cada posición en la góndola. Si se emplearan modelos estándar de efectos fijos, a pesar de las múltiples iteraciones sería difícil lograr convergencia como se muestra en la figura 3.

Tabla 5: Odds Ratio estimados sobre la media posterior del impacto de la posición en anaquel sobre la elección del consumidor

	<b>C1</b>	<b>C2</b>	<b>C3</b>	<b>C4</b>	<b>C5</b>	<b>C6</b>
F1	0,22	0,24	1,81	4,58	0,05	0,47
F2	4,68	6,45	13,19	22,00	0,89	1,34
F3	3,96	1,67	19,11	13,61	2,53	0,14
F4	0,23	0,25	10,49	15,48	1,96	0,10
F5	0,17	0,34	4,33	11,57	0,80	Referencia

Lo anterior aporta evidencia de la conveniencia en el uso de métodos de efectos aleatorios que contengan la heterogeneidad no observada de las diferencias individuales de los participantes del experimento para hacer inferencias con mejor validez con respecto al impacto del parámetro de posición en anaquel sobre la elección del comprador.

## 7. Conclusiones

Este estudio ha demostrado que el impacto de la posición en el anaquel sobre la elección del comprador puede representarse a través de distribuciones empíricas, lo que permite simular distintas configuraciones de exhibición. Además, se ha evidenciado que parámetros clave como la marca, el nivel de promoción y el precio, entre otros, tienen distribuciones propias. Esto facilita simulaciones realistas, considerando las variaciones individuales de los perfiles de los participantes, lo cual posibilita segmentaciones por género, edad, características actitudinales, y el desarrollo de estrategias de exhibición en función de las propiedades demográficas y psicográficas de la audiencia.

Los enfoques bayesianos presentan ventajas teóricas significativas frente a los métodos tradicionales de máxima verosimilitud en modelos logit con efectos aleatorios. Mientras que la optimización de la función de verosimilitud enfrenta dificultades numéricas, como la convergencia a máximos locales y la necesidad de simulación con un gran número de parámetros, los modelos bayesianos no requieren optimización directa y mantienen consistencia incluso con un número fijo de simulaciones. Este enfoque, por tanto, es más robusto y eficiente, especialmente en situaciones donde el número de simulaciones no crece rápidamente con el tamaño de la muestra.

A lo largo del experimento, se observó que los modelos convencionales basados en RUM (Random Utility Maximization), comunes en paquetes estadísticos estándar, no capturan de manera adecuada las realidades observadas en el mercado, particularmente en categorías con múltiples opciones de elección. Asimismo, los enfoques RUM tienden a subestimar el comportamiento de marcas pequeñas, innovaciones o productos con baja participación de mercado, lo que limita la precisión de sus

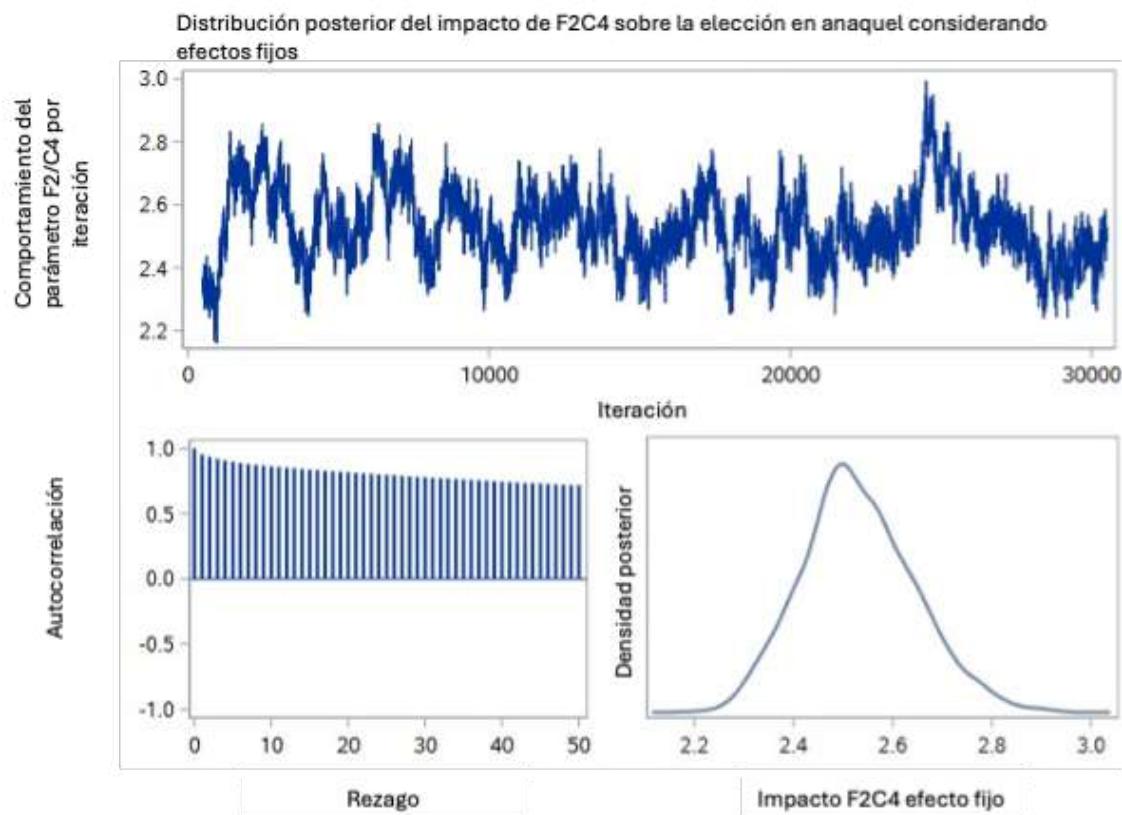


Figura 3: Proceso de estimación de efecto fijo para F2C4

predicciones.

Por otro lado, aunque la estimación bayesiana en modelos de RRM (Random Regret Minimization) presenta mejoras, su implementación puede ser riesgosa si no se emplean efectos fijos. Si se asume que la elección del individuo es simplemente la minimización de las decepciones acumuladas en cada parámetro, se corre el riesgo de subestimar la heterogeneidad no observada de las diferencias individuales, lo que puede llevar a una sobreestimación de los parámetros y problemas de convergencia. En consecuencia, es esencial integrar adecuadamente las variaciones individuales en las estimaciones para obtener modelos más precisos y representativos del comportamiento del consumidor.

Dada la prioridad del presente trabajo por concentrarse en el efecto específico de la posición del producto en la góndola sobre la elección del comprador, se optó por no discutir la distribución empírica y el aporte que hacen variables como la promoción, el precio, la marca, los beneficios de producto y la distribución sobre la elección. La discusión individual y conjunta de estos parámetros junto con las observaciones estadísticas del comportamiento de las distribuciones posteriores será objeto de otros trabajos.

**Recibido: Diciembre de 2024**

**Aceptado: Mayo de 2025**

## Referencias

- ACEI (2024), ‘Listado de participantes de estudios de mercado en colombia’, Obtenido de Base de datos inter agencia: [www.acei.com](http://www.acei.com). Fecha de consulta: 4 de Abril de 2024.
- Albert, J. & Chib, S. (1993), ‘Bayesian analysis of binary and polychotomous response data’, *Journal of the American Statistical Association* .
- Allenby, G. (1997), ‘An introduction to hierarchical bayesian modeling’, Advanced Research Techniques Forum. Tutorial Notes: American Marketing Association.
- Allenby, G. & Rossi, P. (1999), ‘Marketing models of consumer heterogeneity’, *Journal of Econometrics* .
- Ancarani, F. & Shankar, V. (2004), ‘Price levels and price dispersion within and across multiple retailer types: Further evidence and extension’, *Journal of the academy of marketing Science* .
- Ato, M., López, J. & Benavente, A. (2013), ‘Un sistema de clasificación de los diseños de investigación en psicología’, *Anales de psicología* .
- Bauer, R., Menrad, K. & Decker, T. (2015), ‘Adaptive hybrid methods for choice-based conjoint analysis: a comparative study’, *International Journal of Marketing Studies* .

- Bell, D. E. (1982), ‘Regret in decision making under uncertainty’, *Operational Research* .
- Ben-Akiva, M., McFadden, D., Train, M., Walker, J., Bhat, C., Bierlaire, M. & Munizaga, M. (2002), ‘Hybrid choice models: Progress and challenges’, *Marketing Letters* .
- Bhat, C. (2001), ‘Quasi-random maximum simulated likelihood estimation of the mixed multinomial logit model’, *Transportation research part B: Methodological* .
- Bianchi-Aguiar, T., Hübner, A., Caravilla, M. A. & Oliveira, J. (2001), ‘Retail shelf space planning problems: A comprehensive review and classification framework’, *European Journal of Operational Research* .
- Chorus, C. G. (2010), ‘A new random regret minimization’, *European Journal of Transport Infrastructure* .
- Chorus, C. G. (2012), *Random Regret-Based Discrete Choice Modelling: A Tutorial*, Springer, Heidelberg.
- Contreras, G. (2020), ‘Modelos estadísticos de elección desde la economía del comportamiento: Modelamiento de elección discreta basada en costo emocional aleatorio-aplicación a la industria agroquímica colombiana’, *Comunicaciones en Estadística* .
- Farley, K., Thompson, C., Hanbury, A. & Chambers, C. (2013), ‘Exploring the feasibility of conjoint analysis as a tool for prioritizing innovations for implementation’, *implementation science* .
- Gamerman, D. (1997), ‘Sampling from the posterior distribution in generalized linear models’, *Statistics and Computing* .
- Greene, W. H. & Hensher, D. A. (2010), *Modeling Ordered Choices: A Primer*, Cambridge University Press, Cambridge.
- Hess, S. & Palma, D. (2019), ‘Apollo: a flexible, powerful and customisable free-software package for choice model estimation and application’, *Journal of Choice Modelling* .
- Hübner, A. & Kuhn, H. (2024), ‘Decision support for managing assortments, shelf space, and replenishment in retail’, *Flexible Services and Manufacturing Journal* .
- Lenk, P. (2009), ‘Simulation of pseudo-bias correction to the harmonic mean estimator of integrated likelihoods’, *Journal of Computational and Graphical Statistics* .
- McCulloch, R. & Rossi, P. (1994), ‘An exact likelihood analysis of the multinomial probit model’, *Journal of Econometrics* .

- McFadden, D. & Train, K. (2000), 'Mixed mnl models for discrete response', *Journal of Applied Econometrics* .
- Muller, H., Kroll, E. B. & Vogt, B. (2012), 'Do real payments really matter? a re-examination of the compromise effect in hypothetical and binding choice settings', *Marketing Letters* .
- Oppewal, H., Louviere, J. & Timmermans, H. (1994), 'Modeling hierarchical conjoint processes with integrated choice experiments', *Journal of Marketing Research* .
- Pietrini, R., Paolanti, M., Mancini, A., Frontoni, E. & Zingaretti, P. (2024), 'Shelf management: A deep learning-based system for shelf visual monitoring', *Expert Systems with Applications* .
- Revelt, D. & Train, K. (1998), 'Mixed logit with repeated choices: Households' choices of appliance efficiency level', *Review of Econometrics and Statistics* .
- Robert, C. & Castella, G. (2004), *Monte Carlo Statistical Methods*, 2nd edn, Springer.
- Robinson, F., Feufel, M., Shalin, V., Steele-Johnson, D. & Springer, B. (2020), 'Rational adaptation: contextual effects in medical decision making', *Journal of Cognitive Engineering and Decision Making* .
- Rossi, P., Allenby, G. & McCulloch, R. (2005), *Bayesian Statistics and Marketing*, John Wiley & Sons.
- Rossi, P., McCulloch, R. & Allenby, G. (1996), 'The value of purchase history data in target marketing', *Marketing Science* .
- Shankar, V., Inman, J., Mantrala, M., Kelley, E. & Rizley, R. (2011), 'Innovations in shopper marketing: Current insights and future research issues', *Journal of Retailing* .
- Silayoi, P. & Speece, M. (2007), 'The importance of packaging attributes: a conjoint analysis approach', *European journal of marketing* .
- Simonson, I. (1992), 'The influence of anticipating regret and responsibility on purchasing decision', *Journal of Consumer Research* .
- Tang, L., Luo, X., Cheng, Y., Yang, F. & Ran, B. (2014), 'Constructing an optimal orthogonal choice design with alternative-specific attributes for stated choice experiments', *Transportation Research Record* .
- Train, K. (2001), 'A comparison of hierarchical bayes and maximum simulated likelihood for mixed logit', *Journal of Choice Modelling* .
- Train, K. (2009), *Discrete Choice Methods with simulation*, Cambridge University Press, Cambridge.

Train, K. & Sonnier, G. (2005), ‘Mixed logit with bounded distributions of correlated partworths’, *Bayesian Analysis* .