

Segmentación de mercado basada en las preferencias: aplicación de las Escalas de Máximas Diferencias y las Clases Latentes como estrategia para predecir el comportamiento del mercado. Una aplicación al Marketing de bebidas no alcohólicas.

Hernán Talledo

e-mail: pccmotal@upc.edu.pe

Universidad Peruana de Ciencias Aplicadas

<https://orcid.org/0000-0002-4484-9845>

Joaquín Sánchez Herrera

e-mail: joaquins@ucm.es

Universidad Complutense de Madrid

<https://orcid.org/0000-0003-0737-1210>

Resumen

El estudio de las preferencias del consumidor y su proceso de decisión ha sido una de las áreas de estudio más activas en la última década. La elevada tasa de fracasos en los productos de consumo frecuente, así como el aumento de la heterogeneidad de la demanda, han hecho que tanto académicos como profesionales busquen modelos y técnicas que sean capaces de entender la complejidad de los mercados, y desvelar las intenciones de los consumidores. En este trabajo se propone la combinación de las escalas de máximas diferencias o “best-worst scaling” con el análisis de Clases Latentes. La primera de ellas permite extraer el valor o “utilidad” que tiene una determinada alternativa de compra para el consumidor, mientras que la segunda usa esa información para detectar grupos de consumidores de forma eficiente. Para ilustrar el procedimiento se ha aplicado a una muestra de 575 individuos en el mercado de las bebidas no alcohólicas, en el que se revela la utilidad y eficiencia de este tipo de modelos de análisis de segmentación.

Palabras clave: Best Worst Scaling, Segmentación, Clases Latentes, Análisis Clúster, Modelos de elección.

Abstract

The study of consumer preferences and their decision process has been one of the most active areas of research in the last decade. The high failure rate of products of frequent consumption, as well as the increasing heterogeneity of demand, have led both academics and practitioners to search for models and techniques that are able to understand the complexity of markets and to unveil consumers' purchase intentions. This paper proposes the combination of "best-worst scaling" with latent class analysis. The former makes it possible to extract the value or "utility" that a given purchase alternative has for the consumer, while the latter uses this information to detect groups of consumers efficiently. To illustrate the procedure, it has been applied to a sample of 575 individuals in the soft drinks market, which reveals the usefulness and efficiency of this type of segmentation models.

Keywords: Best Worst Scaling, Segmentation, Latent Class, Cluster Analysis, Choice Models.

Introducción

De acuerdo con Nielsen, cerca del 80% de los productos nuevos lanzados al mercado fracasan en el primer año, y ese porcentaje puede ser aún mayor en las categorías de gran consumo. Estudios de la misma compañía indican que la causa más común del fracaso está en una comprensión insuficiente de las necesidades y preferencias del consumidor (Nielsen, 2020). Nielsen apunta, además, que en buena parte de los fracasos se han llevado a cabo investigaciones de mercado, y que los resultados tras el lanzamiento no han sido los que se esperaban según dichas investigaciones. Es posible, por tanto, que las herramientas de investigación de las que disponemos no sean suficientes, y que sea necesario desarrollar metodologías nuevas que sean capaces de desvelar de forma más fiable el comportamiento esperado del consumidor.

Este trabajo tiene como objetivo principal ser una investigación aplicada para poder realizar una segmentación orientada a las preferencias. En este sentido, no es una investigación sobre bebidas no alcohólicas sino una contribución empírica mediante la metodología de las Clases Latentes y las Escalas de Máximas Diferencias o "Best Worst Scaling", conocido comercialmente por el acrónimo de MaxDiff. Las aportaciones en este sentido supondrán una contribución que ayudaría a elegir, con mayor consistencia, la estrategia de segmentación de las compañías. Concretamente, desde un punto de vista metodológico, se propone aplicar las Clases Latentes junto con las Escalas de Máximas Diferencias como herramientas de investigación que desvelan la estructura de preferencias del consumidor de un modo más fiable y con mayor exactitud que otras aproximaciones alternativas.

Este estudio está estructurado del siguiente modo: (i) en primer lugar se realiza un breve recorrido a través de las aportaciones teóricas más relevantes en esta área de estudio, (ii) se desarrollan las bases técnicas de la metodología aportada, y (iii) se aplican los procedimientos descritos a una muestra de consumidores en el mercado de las bebidas no alcohólicas.

Bases teóricas de las escalas de Máximas Diferencias y Clases Latentes

Desvelar la estructura de preferencias de los consumidores supone un reto técnico (elección de las métricas más adecuadas) y también conceptual (cómo entender e interpretar las evaluaciones de los consumidores). En este sentido, Böckenholt (2006) afirma que muchos de los modelos de elección psicométrica están basados en la noción de utilidad de decisión. Desde este punto de vista, la utilidad de las elecciones observadas es empleada para explicar las elecciones. En una situación cualquiera si una persona elige una opción a y rechaza una opción b, se interpreta en el sentido de que a tiene una utilidad mayor que b para esta persona. No obstante, existen otras condiciones posibles para caracterizar las decisiones, como la transitividad, en la que una preferencia de a sobre b, y b sobre c implica una preferencia de a sobre c.

Los precedentes teóricos de las Escalas de Máximas Diferencias tienen hitos muy interesantes, como el aportado por Thurstone (1928). Böckenholt (2006) hace una excelente recopilación de algunas de las ideas de Thurstone, ya que describe y comenta la “ley del juicio comparativo” de este autor, en la que, a lo largo de un continuo de utilidad, las opciones de elección pueden ser representadas por variables aleatorias que describen los efectos de las opciones en nuestro sistema cognitivo.

Añadido a la versión probabilística de la utilidad de decisión, Thurstone observó lo que más tarde se conoció como “preferencia declarada” y “preferencia revelada”, es decir, que la posibilidad de obtener información sobre las preferencias de una persona puede no estar disponible al observar las opciones en su entorno cotidiano. Thurstone (1927) concibió el método de comparaciones pareadas como una versión de opción múltiple que luego se constituyó como el caso básico de las “Escalas de Máximas Diferencias”, que cuantifica el valor relativo de cada uno de los elementos de un conjunto de indicadores. En el mismo sentido, Chrzan y Orme (2019) afirman que, modelando las respuestas de una muestra de entrevistados, se pueden obtener sus utilidades (part worths).

Finn y Louviere (1992) mencionan el desarrollo de las escalas BW (Best-Worst) de Louviere y Woodworth (1990), basándose en una extensión de opción múltiple del método de comparaciones por pares de Thurstone (1927). Argumentan que la escala Best-Worst (BW) modela el proceso cognitivo mediante el cual los encuestados eligen repetidamente entre dos objetos dispuestos en distintos conjuntos de alternativas posibles. Estos dos objetos pueden tener mayor o menor importancia para el encuestado, de modo que preguntar por ambos brinda la oportunidad de obtener más información. Cohen, (2003) también aporta estudios sobre las preferencias, bajo la denominación de “escalamiento de diferencias máximas” haciendo referencia al mismo concepto. En suma, un conjunto de disyuntivas de elección recoge elevada información sobre componentes que el encuestado considera pertinentes o no pertinentes. Al elegir la mejor y la peor opción se eliminan los problemas relacionados con la propensión a caer dentro del entorno de la media. Esta modalidad invita a hacer poco esfuerzo por parte del sujeto que está respondiendo y las respuestas tienden a ser más sólidas o congruentes. En esta línea, Marley y Louviere, (2005) recopilaron los aspectos positivos de la utilización de las escalas de máximas diferencias, también mencionadas por Sánchez y Talledo (2007).

Las Escalas de Máximas Diferencias están teniendo un auge importante en la investigación de mercados y otras disciplinas utilizándose en diversos campos como sustituto de las escalas tradicionales, tipo Likert o similares, para la medida de importancia de características de productos, marcas, frases publicitarias, diseño de empaques, y en general como reemplazo de los problemas de las escalas de puntuación (Orme, 2014). Desde el punto de vista aplicado, las Escalas Best-Worst, o escalas de Máximas Diferencias (MaxDiff) están siendo utilizadas

en diversos campos, siendo uno de los más interesantes la aplicación a la segmentación de mercados a través de los resultados de estos análisis de preferencias combinados con la técnica de Clases Latentes. El análisis de Clases Latentes contribuye a descubrir grupos ocultos en los datos mediante la agrupación de sujetos con características multifactoriales preespecificadas o variables manifiestas en variables latentes, o dicho de otro modo, desvela subgrupos con características similares basándose en agrupaciones que no son observables directamente. Estos grupos, formados por indicadores observables, forman un conjunto limitado de conglomerados (no observables o latentes) donde las características individuales tienen una probabilidad específica de ocurrencia (Naldi y Cazzaniga, 2020). Por tanto, las Clases Latentes se enfocan en el agrupamiento probabilístico de los individuos de una muestra. Se asume que los datos se generan mediante una combinación de distribuciones de probabilidad subyacentes, y una de las aportaciones más interesantes es que no es necesario tomar decisiones sobre la escala de los indicadores o variables observadas, ya que los resultados serán los mismos si las variables tienen o no una distribución normal. Por consiguiente, se pueden utilizar variables de diferentes tipos de escala: variables nominales, ordinales, continuas, recuentos, etc., haciendo más realista el modelo de segmentación (Vermunt y Magidson, 2002).

Por ejemplo, DeSarbo et al (1992) llevan a cabo un estudio sobre un control remoto para automóviles mediante la técnica Análisis Conjunto y Clases Latentes utilizando 16 tareas con combinaciones de 5 atributos cada una. A partir de la minimización AIC (Akaike Information Criterion) eligieron los cuatro segmentos óptimos. Además, compararon el resultado de la segmentación con Clases Latentes con siete técnicas diferentes de análisis clúster: (i) K-Medias, (ii) Método de Ward, (iii) Average Linkage, (iv) Complete Linkage, (v) Método del Centroide, (vi) Método de la Mediana, y (vii) Single Linkage. Por medio de una tabulación cruzada construyeron una ratio de congruencia entre el resultado proporcionado por el método de Average Linkage y el número de grupos obtenidos a partir del análisis de Clases Latentes, utilizando el mismo número de segmentos para ambas técnicas, siendo el más elevado (66,7%). No obstante, con el método Average Linkage se encontraron pequeños segmentos que mejoraron en su tamaño al utilizar el método de Ward, si bien es cierto que obtuvo el segundo mejor ratio de congruencia (60,4%) al ser comparado con los resultados de las Clases Latentes. En esta misma línea, Cohen y Ramaswamy (1998) hacen un recorrido por diversos casos aplicados de Clases Latentes en estudios con datos de Análisis Conjunto, concluyendo que la potencia de las Clases Latentes era superior a las herramientas de segmentación tradicionales, además de no requerir ninguna transformación métrica de las escalas originales para hacer la segmentación y brindar simultáneamente una segmentación y una predicción. Coincidiendo con las aportaciones descritas, DeSarbo, Ramaswamy y Cohen, (1995); Cohen y Ramaswamy, (1998) defienden el uso de los datos de las escalas de Máximas Diferencias (MaxDiff) con un modelo de clase latente que conduzcan a segmentos fácilmente identificables con diferentes estructuras de necesidades, sin los sesgos que producen las escalas convencionales.

Además, Cohen, (2003) traza las principales ventajas de utilizar las Clases Latentes para modelar segmentaciones teniendo como entrada de datos, los resultados de las escalas Best-Worst. En este sentido, al igual que Vermunt y Magidson (2002) y Cohen y Ramaswamy (1998) argumentan que los datos se utilizan con su forma original de medida, o con datos de medidas mixtas, y cumplen con todas las exigencias de estimación necesarias. Los encuestados se asignan a cada segmento con una probabilidad de pertenencia, a diferencia de los modelos de análisis clúster tradicionales, que actúan con aparente certeza. En suma, invita a utilizar los resultados de las Escalas de Máximas Diferencias para el uso de la segmentación por preferencias con Clases Latentes, para superar a las tradicionales escalas de puntuación y llegar a una segmentación más precisa. Una de las aportaciones más

interesantes de Cohen (2003) es la utilización de las funciones de utilidad, que resultan de las Escalas Best-Worst o de Máximas Diferencias, para la realización de una segmentación que mejore la precisión de los segmentos basándose en las preferencias, pero utilizando las Clases Latentes como herramienta de segmentación.

En este sentido, Lockshin y Cohen (2009) llevaron a cabo un estudio sobre vino en once países: Australia, Austria, Brasil, Francia, Alemania, Israel, Italia, Nueva Zelanda, Taiwán, Reino Unido, y Estados Unidos. Dicho estudio se hizo con escalas de Máximas Diferencias (Best Worst Scaling) y Clases Latentes, y los resultados mostraron diferencias significativas entre algunos países y se segmentó la muestra en tres grupos. Al ser la muestra heterogénea, no hubo una clara solución en cuanto a elegir el número de segmentos por el BIC (Bayesian Information Criterion) y, por tanto, se optó por la solución que ofrecía una interpretación más consistente, comparando la solución con 3, 4 y 5 grupos. Finalmente, la solución en tres grupos fue la elegida, dado que las cargas de cada uno de los trece ítems escogidos no se solapaban.

En otro trabajo similar, Mueller y Rungie (2009), analizaron el estudio sobre vino de Lockshin y Cohen (2009), pero focalizado su análisis en el Reino Unido. Al igual que en estudios anteriores, se utilizaron las utilidades del Best-Worst Model como entrada de datos para las Clases Latentes como método de segmentación. No obstante, en este trabajo se utiliza la matriz de varianzas-covarianzas con las puntuaciones originales agregadas de los atributos para medir su heterogeneidad (varianza) y las correlaciones entre atributos (covarianza). Posteriormente se utilizaron las Clases Latentes para modelizar la heterogeneidad de las puntuaciones individuales, encontrándose una solución con cuatro grupos, aunque los autores no especifican con qué valores de BIC y/o AIC eligieron esa solución, pero se han basado en un valor de verosimilitud $LL=-7463.25$, en la potencia de clasificación ($R^2=0.89$), y en el error de clasificación ($e=0.048$).

Aunque nuestro trabajo es de índole empírica, se ha considerado conveniente formular dos premisas generales a partir de las aportaciones teóricas y los resultados de la literatura previa:

Premisa 1: En mercados de consumo frecuente, cuyos individuos tienen preferencias muy diferentes, el modelo planteado asume que el encuestado elige el producto que le proporcione mayor utilidad.

Premisa 2: En un mercado cuyos individuos tienen preferencias muy diferentes, la probabilidad de elegir un producto viene dada por la utilidad de ese producto sobre el promedio de las utilidades de cada producto, según la premisa anterior.

Metodología

Tal y como se ha expuesto con anterioridad, la aplicación del modelo de segmentación se realiza en dos etapas. La primera etapa consiste en la estimación de las utilidades de los individuos mediante una escala de máximas diferencias, y en la segunda etapa se calculan los distintos segmentos por medio del algoritmo de Clases Latentes, a partir de las utilidades individuales estimadas en la primera etapa. A continuación, se detalla el proceso de cálculo, la descripción de la muestra, y el método de recogida de información.

Best-Worst Scaling o Escalas de Máximas Diferencias (MaxDiff)

A diferencia de la forma de preguntar en las escalas monádicas, en las Escalas de Máximas Diferencias, Best-Worst Scaling o MaxDiff, la forma de preguntar es como se observa en la Figura 1.

Figura 1: Ejemplo forma de preguntar en MaxDiff

Por favor, considera cuán importantes son para ti las diferentes bebidas que te presentamos si las tuvieras en cuenta para comprarlas y consumirías.
 De estas bebidas, sólo considera aquella que sea, la que **Más** te guste y la que **Menos** te guste

(1 of 16)

La bebida que Más me gusta		La bebida que Menos me gusta
<input type="radio"/>	Aloe Vera (solo y con sabores)	<input type="radio"/>
<input type="radio"/>	Té verde	<input type="radio"/>
<input type="radio"/>	Maltin Power	<input type="radio"/>
<input type="radio"/>	Mix de Camu Camu	<input type="radio"/>

[Click aquí para continuar](#)

Fuente: elaboración propia

Chrzan y Patterson (2004) concluyen que los ítems por combinación deben ser entre cuatro y cinco. Orme (2005) muestra que se pueden utilizar aproximadamente entre quince y veinte tareas para cuatro combinaciones. Para calcular el número de tareas, cuya propuesta es entre $3K/k$ y $5K/k$, donde K =total número de ítems y k =número de ítems por tarea. Una ilustración en este sentido se puede observar en la Figura 2.

Figura 2: Ejemplo número de tareas MaxDiff

Por favor, considera cuán importantes son para ti las diferentes bebidas que te presentamos si las tuvieras en cuenta para comprarlas y consumirías.
 De estas bebidas, sólo considera aquella que sea, la que **Más** te guste y la que **Menos** te guste

(1 of 16)

La bebida que **Más** me gusta

Por favor, considera cuán importantes son para ti las diferentes bebidas que te presentamos si las tuvieras en cuenta para comprarlas y consumirías.
 De estas bebidas, sólo considera aquella que sea, la que **Más** te guste y la que **Menos** te guste

(1 of 16)

La bebida que **Más** me gusta

Por favor, considera cuán importantes son para ti las diferentes bebidas que te presentamos si las tuvieras en cuenta para comprarlas y consumirías.
 De estas bebidas, sólo considera aquella que sea, la que **Más** te guste y la que **Menos** te guste

(1 of 16)

La bebida que **Más** me gusta

Por favor, considera cuán importantes son para ti las diferentes bebidas que te presentamos si las tuvieras en cuenta para comprarlas y consumirías.
 De estas bebidas, sólo considera aquella que sea, la que **Más** te guste y la que **Menos** te guste

(1 of 16)

La bebida que **Más** me gusta

Por favor, considera cuán importantes son para ti las diferentes bebidas que te presentamos si las tuvieras en cuenta para comprarlas y consumirías.
 De estas bebidas, sólo considera aquella que sea, la que **Más** te guste y la que **Menos** te guste

(1 of 16)

La bebida que **Más** me gusta

La bebida que Más me gusta		La bebida que Menos me gusta
<input type="radio"/>	Aloe Vera (solo y con sabores)	<input type="radio"/>
<input type="radio"/>	Té verde	<input type="radio"/>
<input type="radio"/>	Maltin Power	<input type="radio"/>
<input type="radio"/>	Mix de Camu Camu	<input type="radio"/>

[Click aquí para continuar](#)

Fuente: elaboración propia

El cálculo de las utilidades de las escalas Best-Worst se realiza mediante el modelo de estimación Logit Multinomial (MNL) Jerárquico Bayesiano (HB) (Orme y Chrzan, 2017) aunque el modelo ha sido descrito por numerosos autores, habiendo sido desarrollado por Allenby et al. (1995). El resultado previo de las utilidades calculadas para Best-Worst Scaling, se reescalan para conocer su probabilidad en tanto por ciento. Esto es posible, dado que inicialmente el algoritmo MNL calcula la predicción para cada selección de Best o Worst, según:

$$P_i = \frac{e^{U_i}}{\sum_1^k e^{U_i} + \dots + e^{U_k}} \quad (1)$$

donde:

P_i = probabilidad de elegir la alternativa i^{th}

U_i = utilidad de la alternativa i^{th}

e^{U_i} = antilogaritmo de la utilidad para el ítem i

Exponenciando las utilidades fruto del logit, se convierten en probabilidades que son proporcionales y suman 100% (Chrzan y Orme, 2019). De esta forma, se obtiene un ranking de los elementos utilizados (productos, frases, actitudes, etc).

Para convertir las utilidades originales a una escala de 0-100 puntos, la transformación se realiza mediante la siguiente expresión:

$$\frac{e^{U_i}}{e^{U_i} + a - 1} \quad (2)$$

dónde:

U_i = peso logit en utilidades originales centrado a cero para el ítem i

e^{U_i} es equivalente a tomar el antilog de U_i

a = Número de elementos mostrados por tarea

Las puntuaciones reescaladas siguen una escala de proporción y se puede decir que un ítem con puntuación de 10 es dos veces más preferido que un ítem con una puntuación de 5 (The MaxDiff System Technical Paper, 2020).

Clases Latentes

El modelo de Clases Latentes básico tiene la siguiente forma, con variables o indicadores continuos, Vermunt y Magidson (2002):

$$f(y_i | \theta) = \sum_{k=1}^K \pi_k f_k(y_i | \theta_k) \quad (3)$$

donde:

y_i = puntuaciones de un objeto en un conjunto de variables observadas,

K = número de conglomerados,

π_k = probabilidad previa de pertenecer a una clase o grupo latente k o, de manera equivalente el tamaño del conglomerado k .

Las etiquetas alternativas para las y 's son indicadores, variables dependientes, resultados de las variables, productos, variables endógenas o ítems, y la distribución de y_i , dados los parámetros del modelo, θ , $f(y_i|\theta)$, se asume que es una mezcla de densidades específicas de clases, $f_k(y_i|\theta_k)$.

Para la formación de grupos con variables de diferentes tipos de escala, toma la siguiente forma, Vermunt y Magidson (2002):

$$f(y_i|\theta) = \sum_{k=1}^k \pi_k \prod_{j=1}^J f_k(y_{ij}|\theta_{jk}) \quad (4)$$

donde:

J = número total de indicadores

y_j = indicador particular.

En lugar de especificar la distribución conjunta de y_i dada la pertenencia a una clase utilizando una única distribución multivariante, ahora se especifica la función de distribución univariante apropiada para cada elemento y_{ij} de y_i .

Criterios de selección del número óptimo de segmentos

¿Cómo poder elegir el número de segmentos o de subconjuntos de elementos, productos, atributos, escalas, etc., que hayan sido fruto del análisis de preferencias con las Escalas Best-Worst y las Clases Latentes? Para elegir el número de segmentos se utilizan, con más frecuencia, los criterios de información bayesiano BIC (Bayes Information Criterion), (Schwarz, 1978) y el criterio de información de Akaike AIC (Akaike Information Criterion), (Akaike, 1987). El Criterio de Información de Bayes (BIC), se define como:

$$\text{BIC} = -2\text{LogLikelihood} + (nk + k - 1)(\ln N) \quad (5)$$

La expresión formal del Criterio de Información de Akaike (AIC) es la siguiente:

$$\text{AIC} = -2\text{LogLikelihood} + 2(nk + k - 1) \quad (6)$$

donde:

k = número de grupos,

n = número de parámetros independientes estimados por grupo

N = número total de tareas en la muestra

Muestra y recogida de datos

El tipo de muestreo utilizado fue no probabilístico y la selección de la muestra fue por conveniencia. Los datos disponibles para la aplicación del modelo son de carácter cuantitativo con una muestra de 575 casos. La muestra estuvo compuesta por consumidores de bebidas no alcohólicas, del género masculino y femenino, entre los 18 y 30 años y

residentes en Lima Metropolitana. Previamente, los encuestados pasaron por un filtro a fin de cumplir con las características de representación muestral. El trabajo de campo se realizó entre el 6 y el 20 de noviembre de 2017.

El número total de ítems (bebidas) fue de 21 y el de versiones de MaxDiff fue de 900. Las tareas o combinaciones presentadas a cada encuestado fueron 16. Al ser la muestra de 575 individuos, a cada encuestado se le asignó una combinación diferente, con lo cual el sesgo de contestar siempre la misma combinación se redujo ostensiblemente. El diseño final constó de 4 ítems por combinación. El cuestionario fue administrado a través de internet mediante el programa Lighthouse Studio, versión 9.5.3 (Sawtooth Software, 2020) y el alojamiento de la encuesta se hizo en los servidores del mismo proveedor.

Resultados

Los resultados de las Escalas de Máximas Diferencias (Best-Worst Model) se utilizaron como entrada de datos para construir una segmentación. En la primera columna de la Tabla 1, se detallan los productos (bebidas) utilizados.

Tabla 1: Recuentos de Best y Worst

Label	Best			Worst		
	1.Mostrados	2.Seleccionados	3.Proporción %	4.Mostrados	5.Seleccionados	6.Proporción %
Agua con sabores	1750	304	17,4	1750	585	33,4
Agua embotellada sin gas	1752	860	49,1	1752	127	7,2
Agua embotellada con gas	1754	230	13,1	1754	781	44,5
Jugos de frutas naturales (100%)	1751	1166	66,6	1751	71	4,1
Jugos envasados con 10-20% de frutas naturales	1751	443	25,3	1751	367	21,0
Jugos de frutas naturales envasadas	1753	769	43,9	1753	169	9,6
Té helado	1751	601	34,3	1751	233	13,3
Té verde	1752	529	30,2	1752	269	15,4
Mezcla de hierbas	1755	336	19,1	1755	435	24,8
Red Bull	1753	363	20,7	1753	624	35,6
Energy Drink	1751	193	11,0	1751	617	35,2
Maltin Power	1751	170	9,7	1751	994	56,8
Gatorade	1754	617	35,2	1754	231	13,2
Power Edge	1751	198	11,3	1751	590	33,7
Sporade	1755	629	35,8	1755	254	14,5
Agua vitaminizada	1753	311	17,7	1753	460	26,2
Jugo de guanábana con chía	1753	294	16,8	1753	518	29,5
Jugo de chía y mora	1751	285	16,3	1751	419	23,9
Mix de Camu Camu	1755	292	16,6	1755	425	24,2
Té verde con ginseng	1750	240	13,7	1750	512	29,3
Aloe Vera (solo y con sabores)	1754	370	21,1	1754	519	29,6

Fuente: Elaboración propia

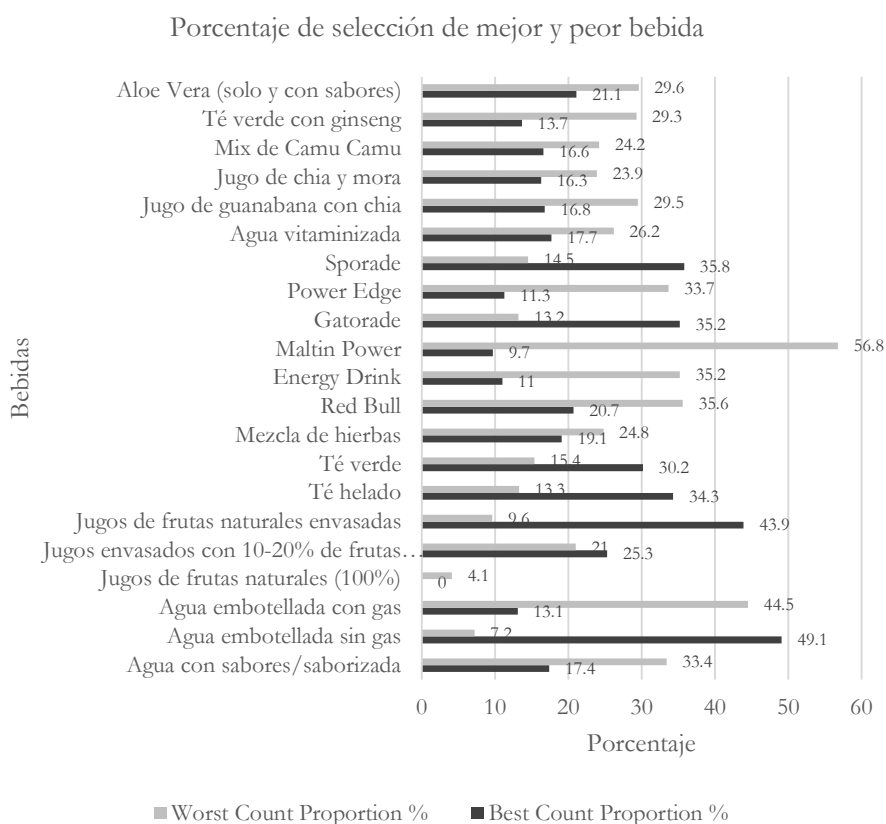
En la misma tabla se encuentran, además, las veces que han sido mostradas tanto las opciones “Best” (1. Mostrados), así como para las opciones “Worst” (4. Mostrados). “Best” equivale a la opción que más gusta y “Worst” a la que menos gusta. Para la opción que más gusta (Best)

se muestra el número de veces que cada producto (bebida) ha sido seleccionada (2. Seleccionados), así como la proporción que representa el número de veces que se han seleccionado con respecto al total de veces mostradas (3. Proporción%). De la misma forma se presentan los resultados para las bebidas que menos gustan en las columnas 5 y 6.

En total los “Best” se han mostrado entre 1,750 y 1,754 veces y los “Worst”, igualmente, entre 1,750 y 1,754 veces, (diseño balanceado). Cada encuestado ha seleccionado las bebidas según la columna 2 o 5, alternativamente, de modo que dividiendo los seleccionados entre los mostrados y multiplicándolos por 100 da como resultado la proporción en las que cada bebida ha sido seleccionada como “Best” o “Worst” (ver Figura 3). Por ejemplo, Maltin Power ha sido seleccionada 56,8% como la Worst (la que menos gusta), mientras que agua embotellada sin gas (49,1%) y jugos de frutas naturales en el 43,9% han sido seleccionadas como la bebida que más gusta (Best).

Con los datos descriptivos anteriores, ya se puede vislumbrar algunos de los resultados que se encontrarán a continuación. Los datos anteriores son recuentos de las respuestas de los encuestados, de las preferencias de las bebidas, tal y como se muestra en la Tabla 2. En dicha tabla se encuentran los resultados de aplicar las ecuaciones (1) y (2). Los productos que más gustan ocuparán los primeros lugares, por ejemplo, Jugos de frutas naturales 100% en primer lugar (10,99%) y en último lugar Maltin Power (1,82%).

Figura 3: Recuento en porcentaje de Best y Worst



Fuente: elaboración propia

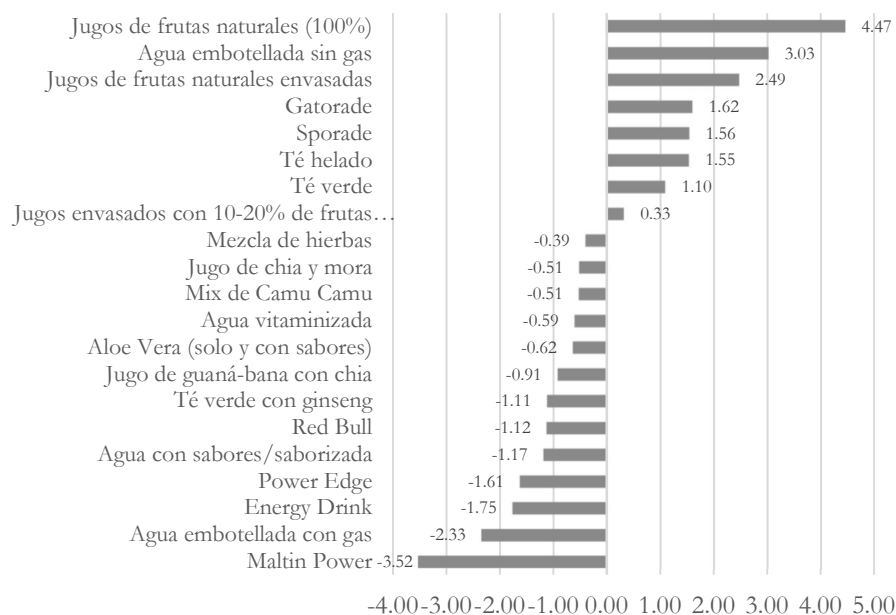
Tabla 2: Resultados totales en porcentajes

Label	Average %
Jugos de frutas naturales (100%)	10,99
Agua embotellada sin gas	9,21
Jugos de frutas naturales envasadas	8,36
Gatorade	6,98
Sporade	6,93
Té helado	6,78
Té verde	6,1
Jugos envasados con 10-20% de frutas naturales	4,97
Red Bull	3,93
Aloe Vera (solo y con sabores)	3,81
Mezcla de hierbas	3,78
Jugo de chía y mora	3,63
Mix de Camu Camu	3,6
Agua vitaminizada	3,48
Jugo de guanábana con chía	3,34
Té verde con ginseng	2,81
Agua con sabores/saborizada	2,78
Agua embotellada con gas	2,31
Energy Drink	2,23
Power Edge	2,16
Maltin Power	1,82
Total	100

Fuente: elaboración propia

Estandarizamos los recuentos de “Best” y “Worst”, tal y como se muestra en la Figura 4, se evidencian aún mejor los resultados obtenidos. Por ejemplo, los “jugos de frutas naturales 100%” son preferidos o gustan aproximadamente tres veces más que “Gatorade”, “Sporade” o “Té Helado”, y cuatro veces más que “Té Verde”. De la misma forma, “Maltin Power” gusta nueve veces menos que “Jugos de Frutas envasados con 10-20% de frutas naturales”.

Figura 4: Diferencias estandarizadas Best (la bebida que más gusta) menos Worst (la bebida que menos gusta)



Fuente: elaboración propia

Anteriormente se han descrito los resultados primarios sin tener en cuenta el cálculo de las utilidades que proporcionan las escalas Best-Worst. Previamente se han calculado estas utilidades (part worths) y se han convertido a tanto por ciento, siguiendo las ecuaciones (1) y (2) para tener una visión distinta, referida a la elección de cada bebida, teniendo en cuenta la conversión de sus utilidades. Posteriormente se ha llevado a cabo una segmentación con Clases Latentes, pero antes de describir los segmentos, es necesario cuantificar el número de segmentos que se deben tener. Para la elección de dicho número de segmentos, se extrajeron entre 2 y 20 segmentos con Clases Latentes (ver Tabla 3) para valorar cuál podría ser la elección del número de segmentos óptimo. Para ambos criterios, generalmente se establece que el valor de cada uno de ellos (BIC o AIC) debe ser el de menor valor.


Tabla 3: AIC y BIC según número de segmentos

Número de Segmentos	Log-likelihood	AIC	BIC
2	-2.110.892.049	4.229.984.098	4.262.046.532
3	-2.066.431.481	4.145.262.962	4.193.747.619
4	-2.034.716.804	4.086.033.609	4.150.940.488
5	-2.006.811.118	4.034.422.237	4.115.751.339
6	-1.983.307.637	3.991.615.273	4.089.366.597
7	-1.965.560.459	3.960.320.919	4.074.494.465
8	-1.950.085.298	3.933.570.597	4.064.166.366
9	-1.937.577.080	3.912.754.159	4.059.772.151
10	-1.924.781.653	3.891.363.306	4.054.803.520
11	-1.911.109.126	3.868.218.253	4.048.080.690
12	-1.899.930.595	3.850.061.191	4.046.345.850
13	-1.890.644.587	3.835.689.175	4.048.396.056
14	-1.882.361.167	3.823.322.334	4.052.451.438
15	-1.871.537.495	3.805.874.989	4.051.426.316
16	-1.863.114.307	3.793.228.615	4.055.202.164
17	-1.861.590.442	3.794.380.884	4.072.776.655
18	-1.850.163.537	3.775.727.073	4.070.545.067
19	-1.845.077.506	3.769.755.012	4.080.995.229
20	-1.836.242.179	3.756.284.358	4.083.946.797

Fuente: elaboración propia

Sin embargo, hay ocasiones en los que este criterio no es el más idóneo puesto que según se van creando más segmentos los valores de ambos criterios tienden a disminuir sin que se encuentre un punto de inflexión claro. Por tanto, conviene utilizar aquel valor que ofrezca un valor pequeño y que en sucesivos valores no haya una dramática disminución de los valores. Para poder determinar con más facilidad la evolución de los índices AIC y BIC, la Figura 5 muestra dichos índices de forma gráfica.

Figura 5: curva AIC y BIC según número de segmentos (de 2 a 20 segmentos)



Fuente: elaboración propia

Ambos indicadores presentan una disminución progresiva de sus valores, pero no muestran un punto de inflexión donde el valor siguiente sea mayor que el anterior. Este punto de inflexión es el señalado por la mayoría de los autores para fijar el número de segmentos y en este caso eso sucede en el segmento 16, si es que se toma en consideración el concepto exacto. Sin embargo, puede ser poco operativo en términos gerenciales tomar como referencia tal número de segmentos. No siempre es posible aplicar esta idea y hay casos en los que los valores de BIC y AIC decrecen constantemente si se incrementa el número de segmentos. En estas situaciones se puede utilizar la técnica del codo, que determina en qué momento el decrecimiento de BIC o AIC ya no es tan pronunciado. En la Figura 5, se puede observar que esto sucede con 5 segmentos aproximadamente. Es por esta razón que los resultados se presentan finalmente con cinco segmentos.

En la Tabla 4 se visualiza el tamaño de cada uno de los segmentos, su nombre y con qué bebidas están más identificados. Los valores de cada producto y segmento son los reescalados a 100% de las puntuaciones originales. La descripción de cada uno de los cinco segmentos podría resumirse del siguiente modo:

- a) Segmento 1: Energéticos (17,3%%), amantes de las bebidas energéticas y del agua con gas, quizás al margen de los beneficios de otros tipos de bebidas.
- b) Segmento 2: Naturalistas (22,3%), con tendencia a preferir bebidas con hierbas y té de distintos tipos.
- c) Segmento 3: Fronterizos (19,3%) por un lado, prefieren las bebidas con frutas, envasadas y naturales y por otro también prefieren alguna bebida rehidratante.
- d) Segmento 4: Clásicos (23,5%), son en realidad consumidores heterogéneos en sus gustos pues tienen preferencia los jugos envasados con 10-20% de frutas naturales y bebidas rehidratantes. Son muy parecidos a los Fronterizos, pero se diferencian en que estos últimos, prefieren jugos de frutas, bien naturales o envasados, mientras que a los Clásicos prefieren jugos con 10-20% de frutas naturales
- e) Segmento 5 (17,4%) Sofisticados: prefieren bebidas con las frutas menos comunes y mezcla de hierbas.

Tabla 4: segmentos de bebidas no alcohólicas

Puntuaciones reescaladas	Energéticos	Naturalistas	Fronteros	Clásicos	Sofisticados
Tamaño del segmento	17.3%	22.3%	19.4%	23.5%	17.4%
Agua con Sabores	3,23	4,19	4,08	1,67	1,15
Agua sin Gas	5,81	11,19	9,72	9,36	9,10
Agua con Gas	4,62	1,28	2,08	1,10	1,21
Jugo Frutas 100% Naturales	5,95	12,53	13,61	11,90	13,42
Jugos Envasados 10-20% Frutas Naturales	3,60	4,26	6,13	6,33	2,32
Jugo de Frutas Naturales Envasados	5,43	7,67	10,63	9,60	6,82
Té Helado	6,00	9,35	2,90	7,86	6,13
Té Verde	5,87	9,11	2,07	5,30	7,66
Mezcla de Hierbas	3,35	4,07	2,86	1,96	7,44
Red Bull	5,39	1,56	1,51	9,84	0,40
Energy Drink	5,12	1,12	1,85	3,80	0,72
Maltin Power	5,13	0,25	1,83	0,47	1,02
Gatorade	6,13	4,14	9,89	10,12	2,77
Power Edge	4,76	0,93	3,34	2,83	1,08
Sporade	7,17	3,17	10,38	9,00	3,28
Agua Vitaminizada	3,38	4,95	4,80	1,79	2,51
Jugo Guanábana con Chía	3,76	2,07	3,20	0,98	8,90
Jugo de Chía y Mora	3,65	3,20	2,75	1,33	9,51
Mix de Camu Camu	4,42	3,11	2,78	1,65	7,03
Té verde con Ginseng	3,68	4,40	1,40	1,55	4,37
Aloe Vera (Solo y con Sabores)	3,54	7,47	2,21	1,55	3,15
Total	100,00	100,00	100,00	100,00	100,00

Fuente: elaboración propia

Se puede también hacer un aporte específico con respecto a los resultados que muestra la Tabla 4, ya que es posible diseñar mercados específicos con solo seguir la ecuación (1). Por ejemplo, eliminando las bebidas rehidratantes, dejando solo las bebidas a base de hierbas o jugos, podemos diseñar ese mercado específico haciendo abstracción de las demás bebidas y simular qué pasaría si solo existieran estas bebidas en el mercado. De esta forma las utilidades originales de la escala MaxDiff, muestran un escenario diferente al de estudiar el total de un mercado. La restricción es que ya no es posible utilizar la segmentación que muestra la Tabla 4 porque los resultados de la Tabla 5 corresponden a un mercado teórico particular, y se tendrían que recalcular los segmentos y el resultado sería confuso. En este mercado específico los “jugos de frutas naturales 100%” pasarían a tener un mayor protagonismo, siendo preferidos casi tres veces más que a los “jugos de frutas naturales envasados”, y más de cuatro veces con respecto al “té helado”.

Tabla 5: mercado específico de bebidas

Label	Average %
Jugos de frutas naturales (100%)	36,29
Jugos de frutas naturales envasadas	13,53
Té helado	8,68
Té verde	7,11
Jugos envasados con 10-20% de frutas naturales	5,79
Jugo de chía y mora	4,07
Mix de Camu Camu	3,98
Mezcla de hierbas	3,83
Jugo de guanábana con chía	3,67
Aloe Vera (solo y con sabores)	3,6
Agua vitaminizada	3,54
Té verde con ginseng	3,03
Agua con sabores/saborizada	2,87
Total	100

Fuente: elaboración propia

Conclusiones

La utilización de la combinación Escalas de Máximas Diferencias con Clases Latentes manifiesta, una vez más, que, la sinergia entre ambas técnicas da una visión diferente y útil para la segmentación de mercados. Por un lado, las Escalas de Máximas Diferencias (Best Worst Model o MaxDiff) son de singular ayuda para las personas entrevistadas ya que evitan la valoración o el orden que implica contestar a las escalas convencionales. Todos sabemos elegir y BW facilita la labor de elicitar las preferencias al estar libre de la elección de una puntuación en una escala cuyos atributos o productos no son comparados sino valorados antes de expresar una preferencia.

Por otro lado, las Clases Latentes tienen un importante papel en la segmentación, ya que se apoyan en una teoría más sólida si se les compara con la segmentación tradicional con Clúster Análisis. La conjunción de Escalas de Máximas Diferencias (Best Worst Model) y Clases Latentes proporcionan una segmentación a través de las funciones de utilidad de BW y el cálculo de la probabilidad de pertenencia de un individuo a un grupo. En este sentido se mejora la idea de pertenencia a un grupo de forma precisa al considerar las medidas de distancia del Clúster Análisis en vez de las probabilidades de pertenencia, que se entienden más acordes con la realidad.

Desde coincidentes puntos de vista, así lo han manifestado autores como Vermunt y Magidson, 2002, Cohen, (2003), Lockshin y Cohen (2009), Chrzan y Patterson (2004). Las importantes ayudas para poder seleccionar con precisión el número de segmentos, fueron propuestos por Schwarz, (1978) BIC (Bayes Information Criterion) y por Akaike (1987) con AIC (Akaike Information Criterion). Estos criterios facilitan la toma de decisiones de la elección del número de segmentos construidos desde las funciones de utilidad, pasando por el tratamiento de estos con las Clases Latentes.

Referencias bibliográficas

- Akaike, H. (1987). Factor Analysis and AIC. *Psychometrika*--vol. 52, no. 3, 317-332 September 1987
- Allenby, G. M., Arora, N., and Ginter, J. L. (1995) "Incorporating Prior Knowledge into the Analysis of Conjoint Studies," *Journal of Marketing Research*, 32 (May) 152-62.
- Böckenholt, Ulf (2006). "Thurstonian-based analyses: past, present, and future utilities", *Psychometrika*—Vol. 71, No. 4, pgs 615–629. DOI: 10.1007/s11336-006-1598-5
- Chrzan, K. y Patterson, M (2006) Testing for the Optimal Number of Attributes in MaxDiff Questions, disponible en <https://sawtoothsoftware.com/resources/technical-papers/testing-for-the-optimal-number-of-attributes-in-maxdiff-questions> recuperado el 27-05-2021
- Chrzan, K y Orme, B. (2019) "Applied MaxDiff: A Practitioner's Guide to Best-Worst Scaling". *Sawtooth Software Inc.* 3210 N Canyon Rd Ste 202 Provo, UT 84604-6508 USA. ISBN 978-0-9993677-2-8 (full text, paper) ISBN 978-0-9993677-3-5 (full text, electronic) pag 5-8.
- Chrzan, K y Orme, B. (2019) "Applied MaxDiff: A Practitioner's Guide to Best-Worst Scaling". *Sawtooth Software Inc.* 3210 N Canyon Rd Ste 202 Provo, UT 84604-6508 USA. ISBN 978-0-9993677-2-8 (full text, paper) ISBN 978-0-9993677-3-5 (full text, electronic). pag 49 a 53
- Cohen, S.H. Maximum difference scaling: Improved measures of importance and preference for segmentation In *Proceedings of the Sawtooth Software Conference Proceedings*, Sequim, WA, USA, 15–17 April 2003.
- Cohen, S. H., & Ramaswamy, V. (1998). Latent segmentation models. *Marketing Research*, 10(2), 14-21. Retrieved from disponible en <https://search.proquest.com/scholarly-journals/latent-segmentation-models/docview/202690069/se-2?accountid=43860>, 15-22.
- DeSarbo, W., Wedel, M., Vriens, M., Ramaswamy, V., Latent Class Metric Conjoint Analysis *Marketing Letters* 3:3, (1992): 273-288
- DeSarbo, W., Ramaswamy, V., and Cohen, S. (1995) "Market Segmentation with choice-based conjoint analysis." *Marketing Letters*, 6 (2), 137-47.
- Elrod, Terry; Kumar, Krishna: "Bias in the First Choice Rule for Predicting Share". *Proceedings of the Sawtooth Software Conference Vol 1 1989*, pag 259-71
- Finn, A y Louviere, J: Determining the Appropriate Response to Evidence of Public Concern: The Case of Food Safety. *Journal of Public & Policy & Marketing, Vol 11(1), 1992*
- Green, Paul E. Srinivasan, V.:" Conjoint Analysis in Marketing: New Developments with Implications for Research and Practice", *Journal of Marketing*, October 1990.
- Lockshin, L., Cohen, E., Using product and retail choice attributes for cross-national segmentation. *European Journal of Marketing* 2009
- Louviere, J.J.;Woodworth, G. Design and Analysis of Simulated Consumer Choice or Allocation Experiments: An Approach Based on Aggregate Data. *J. Mark. Res.* 1983, 20, 350–367
- Louviere, J.J.;Woodworth, G. (1990), "Best-Worst Scaling: A Model for Largest Difference Judgments," *working paper, Faculty of Business, University of Alberta.*
- The Latent Class Technical Paper Version 4.8, *Sawtooth Software, Inc*, disponible en <https://sawtoothsoftware.com/resources/technical-papers/latent-class-technical-paper>
- Lighthouse Studio, disponible en <https://sawtoothsoftware.com/lighthouse-studio>
The MaxDiff System Technical Paper Version 9 *Sawtooth Software, Inc.* disponible en

<https://sawtoothsoftware.com/resources/technical-papers/maxdiff-technical-paper>

- Mueller, S., y Rungie, C. Is there more information in best-worst choice data?. Using the attitude heterogeneity structure to identify consumer segments. *International Journal of Wine Business Research* Vol. 21 No. 1, 2009 pp. 24-40.
- Naldi1, L and Cazzaniga S., Research Techniques Made Simple: Latent Class Analysis. *Journal of Investigative Dermatology* (2020) 140, 1676e1680; <https://doi.org/10.1016/j.jid.2020.05.079>
- Nielsen (2018) “Setting the record straight on innovation failure”. The Nielsen Company.
- Orme, Bryan: “Getting Started with Conjoint Analysis, Strategies for Product Design and Pricing Research”. 2014, pag 111
- Orme, Bryan: “Getting Started with Conjoint Analysis, Strategies for Product Design and Pricing Research”. 2014, pag 93-109
- Orme, B. y Chrzan, K; *Become an Expert in Conjoint Analysis. Choice Modeling for Pros.* Sawtooth Software, 2017, pag 207-212
- Orme, B. y Chrzan, K; *Become an Expert in Conjoint Analysis. Choice Modeling for Pros.* Sawtooth Software, 2017, pag 144-155
- Marley, A. A. y Louviere, J. J. (2005). “Some Probabilistic Models of Best- Worst and Best-Worst Choices”, *Journal of Mathematical Psychology*, 49, pgs. 464-480.
- Sánchez Herrera, J; Talledo, H.: “Del Análisis Conjunto a las Escalas de Máximas Diferencias: un Estudio Comparativo entre Maxdiff y Escalas Monádicas, desde la Validez Convergente y Discriminante”, 2007, disponible en <http://www.aemarkcongresos.com/congreso2007/investigacion/IM04-P.pdf> recuperado el 25 de abril de 2020.
- Shaosheng Jin, Rao Yuan, Yan Zhang, ay Xin Jin (2019) “Chinese Consumers’ Preferences for Attributes of Fresh Milk: A Best–Worst Approach” *International Journal of Environmental Research and Public Health*
- Schwarz, G. E. (1978): Estimating the dimension of a Model. *Annals of Statistics*. 6(2): 461-464.
- Thurstone, L. L. (1928). “Attitudes can be Measured”, *American Journal of Sociology*, Vol. 33, pgs. 529-554.
- Vázquez Casielles, Rodolfo:” Investigación de las Preferencias del Consumidor Mediante “Análisis Conjunto” Importancia para el Diseño de Nuevos Productos., *ICE*, págs. 149-163, Julio 1990
- Vermunt, J.K., and Magidson, J. (2002). Latent class cluster analysis. In: J. A. Hagenaars and A. L. McCutcheon (Eds.), *Applied Latent Class Analysis*, 89-106. *Cambridge: Cambridge University Press*.