



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

ESTUDIO DEL USO DE REGLAS DE DECISIÓN LEXICOGRÁFICAS UTILIZANDO
HERRAMIENTAS DE EYE TRACKING

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERA CIVIL INDUSTRIAL

PAULA JAVIERA URRUTIA MOREIRA

PROFESOR GUÍA:
RICARDO MONTOYA MOREIRA

MIEMBROS DE LA COMISIÓN:
ANDRÉS MUSALEM SAID
DENIS SAURE VALENZUELA

SANTIAGO DE CHILE
JUNIO 2014

Resumen

Bajo un contexto de compras y ventas, los procesos de decisión comienzan desde el momento en que una persona adquiere información sobre algún producto o servicio que se tenga interés en adquirir. De esta manera, la forma en la que se recopila la información, los juicios y las razones de cada consumidor que influyen en la toma de decisión, son interesantes de estudiar porque permiten comprender parte del comportamiento individual de los consumidores.

Cuando un consumidor se ve enfrentado a una decisión, tiene múltiples caminos a seguir para dar con alguna elección. Estos caminos suelen estar condicionados por las preferencias y los gustos de los tomadores de decisión, y son denominados como *reglas de decisión*. Por lo tanto, las reglas de decisión son un conjunto de condiciones bajo las cuales se puede elegir o rechazar una determinada alternativa.

Conocer las reglas de decisión que utilizan los individuos puede ser de gran interés para los investigadores porque, de esta forma, se podría predecir las futuras elecciones de los consumidores. Hasta el momento, los estudios relacionados a comprender los procesos de decisión han combinado diversas técnicas del tipo cualitativas y cuantitativas. En particular, esta investigación utiliza técnicas cuantitativas para poder comprender, diferenciar y predecir el comportamiento de individuos que participaron en dos experimentos de simulación de compras.

Los experimentos mencionados, simulan la oferta de un producto (o servicio), en donde los participantes deben escoger una alternativa. Durante estos procesos de elección, los individuos utilizan herramientas de *Eye tracking*, las que permiten registrar todo el comportamiento visual. Esta información adicional es la base de este trabajo de investigación y su importancia radica en que permite comprender *qué* es lo que buscan los participantes y *el camino recorrido* para dar con su elección a través de la información visual.

A partir de los datos visuales recopilados del primer experimento, se construyen modelos matemáticos que permiten predecir el tipo de regla de decisión usada por los encuestados, acertando en el 95 % de los casos. Las restricciones impuestas en los modelos utilizados para esta predicción, configuran un escenario *ideal* que no representa correctamente una situación real. Por este motivo se realiza un análisis sobre los datos del segundo experimento, en cuyo caso se busca predecir la alternativa elegida por los encuestados, lográndolo correctamente en un 61 % de los casos. En función de estos análisis, se demuestra que la información visual puede ser muy útil para entender el comportamiento de los consumidores. Finalmente, se propone para futuras investigaciones, adaptar los modelos aquí propuestos, incluyendo nuevas variables que permitan acercar el estudio a un escenario cada vez más real.

Para mis más cercanos que me han apoyado siempre :-)

Agradecimientos

Haber llegado hasta este punto es un logro muy importante para mí, y no habría sido posible sin todas y cada una de las personas que han aparecido en mi camino. Y es por la forma en que me han marcado, que los quiero mucho. Quiero agradecer a mis padres, Sergio y Jacqueline, a quienes quiero mucho y me dieron las herramientas necesarias para desarrollarme en la persona que soy. Me inculcaron los estudios, me dieron los ánimos y su apoyo para cumplir mi meta de ser una profesional. A mi hermano Javier, por escuchare y aconsejarme cada vez que lo necesité, tus consejos siempre me han mostrado un nuevo camino para sobreponerme. A mis abuelitas, tíos, tías, primos y primas. Si bien no alcanzo a nombrarlos a cada uno de ustedes, deben saber que valoro mucho el cariño que siempre me han dado, porque me han hecho sentir feliz y querida. Así que si alguna vez necesitan contar conmigo, háganlo, porque estaré ahí para ustedes siempre que Dios me lo permita. En especial a mi madrina, Elisa, que ha sido como una segunda mamá, por su incondicionalidad, preocupación y cariño hacia mi persona.

A Mauricio, quien ha sido una de las personas más importantes en mi vida, un amigo, compañero y mi pololo, quien tuvo la paciencia de acompañarme en este periodo lleno de estrés, brindarme su amor y apoyo inquebrantable, sin ti, definitivamente mi vida no sería la misma. Agradezco también a su familia, quienes me han recibido siempre con los brazos abiertos y me han querido como soy.

A mis amigos de la Universidad que se encargaron de hacer que mi paso por esta escuela haya sido la mejor época de mi vida. A mi mejor amiga, Andrea, que siempre explota mi lado más creativo, no sé cómo lo haces pero logras siempre que me ponga feliz y nos divirtamos juntas, eres la mejor y gracias por estar siempre ahí para mí. A mis amigos Roberto, Sebastián (Chino), Ignacio, Eduardo y Juan Luis, porque simplemente han sido geniales, los quiero mucho y estoy muy orgullosa de ser amiga de ustedes. También agradezco a la *Comunidad de los Lerus*, Bayron, Antonio, Marco, Camilo, Nicolás y Rodrigo, que me acompañaron gran parte durante el tiempo del plan común; cómo olvidar las tardes de mario kart, los partidos de taca donde el tío taca, las improvisaciones culinarias y muchos otros momentos geniales. Muchas gracias a todos ustedes.

A mis profesores, Ricardo quien fue mi profesor guía y me ayudó mucho en este proceso, toleró mis frustraciones y me enseñó que con esfuerzo y paciencia puedo ser capaz de lograr muchas cosas. Y a mi profesor Andrés, cuya preocupación, interés y participación en esta investigación siempre fue muy útil e importante para mí.

Muchas gracias a todos por haberme acompañado a cumplir esta gran meta, los quiero mucho, y espero que esta nueva etapa de mi vida venga con tantos aprendizajes y éxitos como lo ha sido hasta ahora. Muchas gracias a la vida.

Tabla de contenido

1. Introducción	1
1.1. Motivación	2
1.2. Objetivos	3
1.2.1. Objetivo General	3
1.2.2. Objetivos Específicos	3
1.3. Metodología	3
1.4. Alcances	4
1.5. Resultados Esperados	5
1.6. Estructura de la Memoria	5
2. Antecedentes Generales	7
2.1. Análisis Conjunto	8
2.2. Reglas de Decisión	8
2.2.1. Estrategia Lexicográfica	9
2.2.2. Estrategia Conjuntiva	9
2.3. Métodos de Rastreo	9
2.3.1. Eye Tracking	9
2.3.2. Otros Métodos de Rastreo Computarizados	11
2.4. Métodos de Estimación y Caracterización de Reglas de Decisión ya Existentes . . .	11
2.4.1. Métricas que Caracterizan el Comportamiento del Encuestado	12
2.4.2. Modelo de Predicción	15
3. Experimento Visual de Análisis Conjunto	16
3.1. Captura y Almacenamiento de los Datos	18
3.2. Estructura y Diseño de Datos	19
4. Análisis Descriptivo	21
4.1. Fijaciones	21
4.2. Fijaciones y Elecciones	22
4.2.1. Dinámica de Fijaciones	25
4.2.2. Fuentes de Variabilidad	26
4.3. Análisis y Tipos de Transiciones	26
4.4. Resultados de los Tests	28
4.4.1. Caso 1: Sin Normalizar	28
4.4.2. Caso 2: Normalizado	29
4.5. Comparación <i>Equivalente</i>	30

4.6.	Conclusiones del Capítulo	32
5.	Análisis Multivariado	33
5.1.	Modelo Logit Binomial	33
5.2.	Variables Propuestas	33
5.2.1.	Número de fijaciones ($N_{fijaciones}$)	34
5.2.2.	Primer Atributo más Observado ($AtributoTop^1$)	34
5.2.3.	Segundo Atributo más Observado ($AtributoTop^2$)	34
5.2.4.	Primera Opción más Observada ($OpcionTop^1$)	34
5.2.5.	Segunda Opción más Observada ($OpcionTop^2$)	35
5.2.6.	Algún Atributo Observado Completamente para la Primera Mitad de la Serie de Fijaciones ($AtributoCompleto^{Inicio}$)	35
5.2.7.	Algún Atributo Observado Completamente para la Segunda Mitad de la Serie de Fijaciones ($AtributoCompleto^{Fin}$)	35
5.2.8.	Variables derivadas de la <i>Serie Ideal</i>	36
5.3.	Evaluación de las Variables en el Modelo Logit Binomial	37
5.4.	Selección de Variables y Resultados	40
5.4.1.	Test de Muestras Independientes	40
5.4.2.	Análisis Factorial	42
5.5.	Análisis de Correlación entre las Reglas y lo Observado	43
5.6.	Conclusiones del Capítulo	44
6.	Heurísticas de Predicción de Órdenes e Información Visual	45
6.1.	Utilidad Lexicográfica	45
6.2.	Heurística Greedy	46
6.3.	Modelo de Fijaciones No Compensatorio	46
6.4.	Comparación de la Heurística Greedy con la Información Visual	47
6.4.1.	Consistencia de los Distintos Órdenes de Importancia de Atributos	47
6.4.2.	Comparación por Atributo Independiente	48
6.4.3.	Hit Rate	49
6.4.4.	Hit Rate Según Dificultad	50
6.4.5.	Heurística Greedy sin los Casos de Respuestas Erroneas	51
6.5.	Conclusiones del Capítulo	51
7.	Aplicación en una Base de Datos Experimental de Cafeteras	53
7.1.	Descripción del Experimento	53
7.2.	Heurística Greedy	55
7.3.	Modelo Compensatorio: Mixed Logit	56
7.3.1.	Aplicación del Modelo Mixed Logit a los Datos Experimentales	57
7.4.	Modelo No Compensatorio: Lexicographic Elimination By Attributes (LBA)	57
7.4.1.	Incertidumbre en el orden de los atributos	57
7.4.2.	Descripción del Modelo Jerárquico Bayesiano	58
7.4.3.	Lexicographic Elimination By Aspects con Fijaciones	59
7.5.	Modelo de Fijaciones	60
7.5.1.	Modelo de Fijaciones No Compensatorias	60
7.5.2.	Modelo de Fijaciones Compensatorias	61
7.6.	Conclusiones del Capítulo	66

8. Conclusiones	67
8.1. Trabajos Futuros	68
A. Otras reglas de decisión	69
A.1. Additive difference strategy (ADD)	69
A.1.1. Equal wieghts strategy (EQW)	69
A.1.2. Least important heuristic (LIM)	69
A.1.3. Least variance heuristic (LVA)	69
A.1.4. Multiattribute utility model (MAU)	70
A.1.5. Majority of confirming dimensions strategy (MCD)	70
A.1.6. Recognition heuristic (REC)	70
B. Otros Métodos de Rastreo utilizados en el estudio de las reglas de Decisión	71
C. Resultados del Análisis Factorial	73
D. Resultados del Test Cohen Kappa	76
E. Resultados Test de Medias	77
F. Fijaciones y Elecciones	79
G. Valores de los Parámetros β del Modelo de Fijaciones Compensatorio	80
G.1. Estadísticos para los parámetros β	80
G.2. Hitogramas para los parámetros β	81
Bibliografía	89

Índice de tablas

3.1.	Posibles valores para cada atributo.	17
4.1.	Valores de media y desviación estándar para los datos agregados.	22
4.2.	Número promedio de fijaciones considerando el 2,5 % , 50 % y 97,5 % de los valores de la distribución por pregunta.	23
4.3.	Significado del valor del orden de opciones.	23
4.4.	Significado del valor del orden de opciones.	24
4.5.	Resultados Test de Medias, sin Normalizar.	28
4.6.	Resultados Test de Medias, Normalizado.	30
4.7.	Resultados Test de Medias, Equivalente sin Normalizar.	31
4.8.	Resultados Test de Medias, Equivalente Normalizado.	31
5.1.	Estadísticos básicos de las variables propuestas.	37
5.2.	Coeficientes del modelo Logit Binomial.	39
5.3.	Valores de los ratios para el conjunto de entrenamiento y de prueba.	39
5.4.	Resultados Test de Diferencias de Medias.	40
5.5.	Ratios para el conjunto de entrenamiento, prueba y variables significativas.	42
5.6.	Resumen de los ratios para el conjunto de entrenamiento, prueba, Análisis Factorial y las variables significativas.	42
6.1.	Coincidencias por grupo de atributos.	47
6.2.	Resultados de la comparación de atributos independientes.	48
6.3.	Resultados de los casos del <i>hit rate</i> tipo 1 y tipo 2.	49
6.4.	Resumen de resultados para un <i>hit rate</i> 1, en los tres niveles de dificultad.	50
6.5.	Resumen de resultados para un <i>hit rate</i> 2, en los tres niveles de dificultad.	51
6.6.	Resumen de resultados para el <i>hit rate</i> sin considerar las respuestas erróneas en los tres niveles de dificultad.	51
7.1.	Tabla con los posibles valores para cada atributo.	54
7.2.	Hit Rate para la Heurística Greedy.	55
7.3.	Hit Rate para el modelo Mixed Logit y la Heurística Greedy.	57
7.4.	Variables utilizadas en la estimación de v_{ij} en el modelo LBA.	59
7.5.	Hit Rate para el modelo LBA con fijaciones, LBA tradicional, Mixed Logit y Heurística Greedy.	60
7.6.	Hit Rate para el modelo de Fijaciones no Compensatorio, LBA con fijaciones, LBA tradicional, Mixed Logit y Heurística Greedy.	60

7.7. Hit Rate para el modelo de Fijaciones Compensatorio, Fijaciones no Compensatorias, LBA con fijaciones, LBA tradicional, Mixed Logit y Heurística Greedy.	63
C.1. Total de varianza explicada.	73
C.2. Resultados Test de Medias, Equivalente sin Normalizar (Parte 1).	74
C.3. Resultados Test de Medias, Equivalente sin Normalizar (Parte 2).	75
D.1. Resultados del Test Cohen Kappa	76
D.2. Resumen de las medidas de ajuste para cada una de las posiciones en el ranking. . .	76
E.1. Resumen de estadísticos básicos, sin Normalizar.	77
E.2. Resumen de estadísticos básicos, Normalizados	77
E.3. Resumen de estadísticos básicos, Equivalente sin Normalizar	77
E.4. Resumen de estadísticos básicos, Equivalente Normalizado	78
F.1. Tabla de estadísticos capítulo 5.	79
G.1. Tabla de estadísticos para los valores de los parámetros β	80

Índice de figuras

2.1.	Dispositivo de eye tracking. <i>Eye tracking glasses reading laptop</i> [Fotografía]. Extraído de http://www.asleyetracking.com/Site/Portals/0/Mobile-eye-tracking-glasses-reading-laptop.JPG	10
2.2.	Dispositivo eye tracker montado en la cabeza. <i>Eye Tracker</i> [Fotografía]. Extraído de http://www.profissionaldeecommerce.com.br/eye-tracking-para-onde-vao-os-olhos-do-visitante-em-uma-loja-virtual/	10
2.3.	Tipo de transiciones descritas por Riedl, Brandstätter y Roithmayr (2008).	12
2.4.	Esquema explicativo Métrica 3.	14
3.1.	Diseño de una pregunta donde se exige seguir una estrategia lexicográfica. Se le indica al encuestado el orden de importancia de los atributos.	17
3.2.	Muestra de una serie de fijaciones registrada durante un proceso de respuesta	18
3.3.	Ejemplo de casilla o Área de Interés (AOI) en la posición (2,3), dentro de la matriz atributos-opciones.	19
4.1.	Histograma de la distribución del número de fijaciones.	22
4.2.	Matriz de Transiciones generada según el orden de las opciones durante el 1° y 2° período.	24
4.3.	Resultados para el orden de fijaciones por período, condicionado a la elección.	24
4.4.	Matriz de Transición entre Opciones	25
4.5.	Matriz de Transición entre Atributos.	25
4.6.	Ejemplo de los tipos de transiciones.	26
4.7.	Diagramación que resume el origen de las ocho variables propuestas.	27
4.8.	Número de Fijaciones y su Desviación Estándar, sin normalizar. La información numérica está en Apéndices E.	28
4.9.	Número de Fijaciones y su Desviación Estándar, Normalizado. La información numérica está en Apéndices E.	29
4.10.	Caso Equivalente: Número de Fijaciones y su Desviación Estándar, sin normalizar. La información numérica está en Apéndices E.	30
4.11.	Caso Equivalente: Número de Fijaciones y su Desviación Estándar, Normalizado. La información numérica está en Apéndices E.	31
5.1.	Matriz de confusión.	38
5.2.	Matriz de confusión para el conjunto de entrenamiento.	38
5.3.	Matriz de confusión para el conjunto de prueba.	39
6.1.	Distribución gráfica de los resultados de la Tabla 6.1.	48

6.2. Distribución gráfica de los resultados de la Tabla 6.2.	49
7.1. Diseño de un conjunto de opciones para un análisis conjunto basado en opciones, Martin Meißner and Reinhold Decker (2009).	54
7.2. Dispersión entre el Modelo de fijaciones compensatorio y el Mixed Logit.	63
7.3. Dispersión entre el Modelo de fijaciones compensatorio y el Mixed Logit.	65
G.1. Histograma que muestra la distribución del parámetro $\beta_{1,1}$	81
G.2. Histograma que muestra la distribución del parámetro $\beta_{1,2}$	82
G.3. Histograma que muestra la distribución del parámetro $\beta_{1,3}$	82
G.4. Histograma que muestra la distribución del parámetro $\beta_{1,4}$	83
G.5. Histograma que muestra la distribución del parámetro $\beta_{2,1}$	83
G.6. Histograma que muestra la distribución del parámetro $\beta_{2,2}$	84
G.7. Histograma que muestra la distribución del parámetro $\beta_{2,3}$	84
G.8. Histograma que muestra la distribución del parámetro $\beta_{3,1}$	85
G.9. Histograma que muestra la distribución del parámetro $\beta_{3,2}$	85
G.10. Histograma que muestra la distribución del parámetro $\beta_{4,1}$	86
G.11. Histograma que muestra la distribución del parámetro $\beta_{4,2}$	86
G.12. Histograma que muestra la distribución del parámetro $\beta_{4,3}$	87
G.13. Histograma que muestra la distribución del parámetro $\beta_{4,4}$	87
G.14. Histograma que muestra la distribución del parámetro β_5	88
G.15. Histograma que muestra la distribución del parámetro β_6	88

Capítulo 1

Introducción

A diario los consumidores se ven enfrentados a una gran cantidad de decisiones que pueden ser de todo tipo, en cualquier momento o lugar y abarcando diversas situaciones de la vida diaria. Todas estas elecciones son afectadas por diversos estímulos que conforman un contexto de decisión específico, en donde los consumidores tienen un amplio abanico de posibilidades para comparar un producto o servicio con otro hasta encontrar alguna alternativa que los satisfaga. Esta elección, también dependerá exclusivamente del tomador de decisión, puesto que entran en juego sus gustos, necesidades, preferencias, estado anímico, género y edad, entre muchos otros factores.

Las ventajas tecnológicas con las que se cuenta actualmente, como el masivo acceso a internet y rápido desarrollo de las redes sociales, permiten a los consumidores gozar de otros beneficios que están relacionado con la toma de decisiones, como es el aumento de los canales de venta, publicidad, mayor información sobre productos, foros de opiniones y más. Así, el mercado otorga a los consumidores la posibilidad de tomar decisiones, pero, bajo un escenario de mayor oferta y conocimiento.

Entonces, surge el interés de comprender las preferencias de los consumidores y a la vez cómo son utilizadas estas preferencias (por medio de las reglas de decisión) para comparar alternativas. Con esta información, se puede mejorar la oferta hacia los consumidores y en consecuencia, potenciar el aumento de las ventas para cada uno de los diferentes escenarios. Actualmente esta necesidad está cubierta gracias a la aplicación de técnicas clásicas de investigación de mercado, incluyendo el uso de encuestas del tipo análisis conjunto.

Una de las convenciones que existen actualmente para ordenar las distintas formas de escoger un determinado bien o servicio, son las llamadas *reglas de decisión*, las que pueden ser definidas como un conjunto de condiciones bajo las que se elige o rechaza una determinada alternativa. En la práctica, poder descifrar el tipo de regla de decisión que utiliza un determinado consumidor permite inferir los productos o servicios que tienen mayor probabilidad de ser escogidos, por lo que en el futuro se podría generar una oferta cada vez más personalizada, adecuada a las necesidades y preferencias de cada consumidor.

Para poder deducir el tipo de regla de decisión que maneja un determinado consumidor, es necesario analizar su comportamiento durante el proceso de elección y por supuesto, la elección misma.

Estudiar el comportamiento de los individuos durante el proceso de elección es útil para entender las reacciones frente a variados estímulos, los cuales pueden estar dados por las diferentes marcas, materiales, diseños, precios, entre otras características (Riedl et al., 2008b). El resultado de este proceso es la alternativa, las que suelen utilizarse para validar la coherencia entre el comportamiento y la decisión tomada.

En la literatura se ha descrito variados procesos para estudiar el comportamiento del proceso de decisión, entre ellos destacan procesos de elección en computadores, como MouseLab (Johnson et al., 1989) y MouseTrace (Jasper and Shapiro, 2002), que registran los movimientos del mouse realizados por los individuos durante todo el tiempo que se extiende el estudio. Metodologías de esta índole son combinadas con experimentos del tipo análisis conjunto, en donde los encuestados expresan sus preferencias directamente en un computador. Aún así, ninguna de estas técnicas se aplica de manera estándar en la industria, lo que da pie para la investigación de nuevos métodos que puedan inferir las llamadas *reglas de decisión*.

Otra arista interesante, señala que la atención de las personas se refleja en el lugar donde posicionan su vista (Pieters and Warlop, 1999) y (Stattgen et al., 2012). Para medir dicha actividad se utilizan herramientas de eye tracking, las que consisten en un dispositivo que sigue el movimiento de los ojos a través de una cámara, capturando los puntos observados, el tiempo destinado en cada uno y la secuencia realizada. La utilidad del eye tracking ha sido probada en distintos estudios (tales como en el desarrollo de las interfaces web, la *usabilidad* de los sitios web y avisos publicitarios, entre otros), cuyos resultados han sido bastante alentadores. Actualmente, el uso de las herramientas de eye tracking goza de los avances tecnológicos que cada vez la presentan como una técnica más exacta y precisa en la captura del movimiento de la vista (Jacob and Karn, 2003).

Al considerar todas estas ideas en conjunto, nace la propuesta de utilizar las herramientas de eye tracking para registrar el comportamiento de los individuos, a partir de datos recolectados mediante un experimento de análisis conjunto en donde se evalúan las características de un servicio, para luego comparar la efectividad de esta información visual, con la efectividad de los métodos tradicionales.

1.1. Motivación

Durante años los investigadores han anhelado comprender y predecir el comportamiento, gustos y decisiones de los consumidores para diseñar productos o servicios que tengan la mejor aceptación y éxito dentro del mercado. Sin embargo, en muchas ocasiones las decisiones tomadas por los consumidores se escapan de lo esperado dada la información disponible, dejando en evidencia la existencia de otras variables que puedan afectar la elección.

Para comprender esto último resulta esencial descubrir en qué centran la atención los consumidores, ya que es un buen indicio de sus gustos. Algunos estudios entregan evidencias empíricas de que la atención visual es un indicador clave de las preferencias de un individuo (Shimojo et al., 2003).

La presente investigación tiene por objetivo estimar las preferencias de los consumidores a nivel

individual para un conjunto de atributos evaluados en un análisis conjunto, en donde además se utilizan herramientas de eye tracking que permiten integrar información del comportamiento previo a la toma de decisión de los participantes. Todo esto, con la finalidad de predecir las elecciones para un tipo de regla en particular.

Problemas como estos resultan ser complejos y de alto impacto, pues las decisiones relativas al diseño de un producto suelen ser estratégicas, provocando que una mala decisión signifique el fracaso de un producto o servicio en el mercado.

1.2. Objetivos

1.2.1. Objetivo General

Estudiar el uso de herramientas de eye tracking para identificar el orden de importancia de los atributos de un producto (o servicio) al realizar una elección en una regla de decisión lexicográfica.

1.2.2. Objetivos Específicos

- Analizar la consistencia entre el comportamiento visual de los participantes y sus elecciones.
- Estudiar las diferencias entre dos tipos de reglas de decisión no compensatorias (lexicográfica y conjuntiva) para caracterizar el comportamiento de los participantes.
- Comparar el comportamiento visual con otras técnicas de estimación de ordenes de atributos.
- Proponer una integración de los datos del comportamiento visual en un modelo de estimación no compensatorio y compensatorio para mejorar la predicción.
- Evaluar las ventajas y desventajas de la aplicación de esta nueva metodología.

1.3. Metodología

Los datos trabajados corresponden a la información visual obtenida del eye tracking y las respectivas elecciones de cada participante. Se procede con la aplicación de Modelos Econométricos y Métodos Bayesianos, bajo un contexto de análisis conjunto basado en elecciones.

- **Analizar la consistencia entre el comportamiento visual de los participantes y sus elecciones.**

El proceso inicial corresponde al análisis exploratorio de los datos, en donde se trabaja con el software Matlab para estudiar las distribuciones de manera agregada y desagregada por regla.

Además, se desarrollan matrices de transición para estudiar la dinámica de los movimientos de la vista.

- **Estudiar las diferencias entre dos tipos de reglas de decisión no compensatorias (lexicográfica y conjuntiva) para caracterizar el comportamiento de los participantes.**

Se construyen variables que puedan caracterizar a cada una de las reglas en cuestión para descubrir patrones en el comportamiento de la vista. Se trabaja con un Modelo Logit para estudiar la clasificación y el ajuste de las variables a los datos.

- **Comparar el comportamiento visual con otras técnicas de estimación de reglas.**

Sobre los datos del experimento se aplica una heurística para predecir el orden de importancia de los atributos, y a la vez se genera el mismo orden pero con la información visual. Así se puede estudiar el comportamiento de ambas técnicas y proponer un análisis que permita fusionar la información visual con algún método de estimación ya existente.

- **Proponer una integración de los datos del comportamiento visual en un modelo de estimación no compensatorio y compensatorio para mejorar la predicción.**

Se describe el modelo escogido para una estimación de preferencias lexicográficas, y se propone una integración de los valores derivados del comportamiento de la vista.

- **Demostrar las ventajas y desventajas de la aplicación de esta nueva metodología.**

Se comprueba la validez del modelo en otra base de datos experimental en donde no se les indica a los participantes el tipo de regla de decisión que deben utilizar para escoger. Además se contrasta con modelos del tipo Compensatorios.

1.4. Alcances

Algunas consideraciones de la investigación son presentadas a continuación:

- Dentro del amplio abanico de las reglas de decisión, se trabajará principalmente con la regla *lexicográfica*, que es del tipo no compensatoria.
- En la investigación no se incluyen las diferencias demográficas o físicas entre los individuos (como la edad o el género). Solo se considera la *heterogeneidad no observada*, y se aborda trabajando los datos de manera individual a través de un modelo Jerárquico Bayesiano.
- Se asumirá que un individuo utiliza la misma regla de decisión para todas las preguntas que responde.
- El modelo generado durante esta memoria no pretende llegar a ser implementado en la industria durante el transcurso del trabajo de título.

1.5. Resultados Esperados

- Descripción de la situación actual de los métodos de estimación de reglas de decisión y eye tracking.
- Diagramas matriciales con los resultados porcentuales y estadísticos derivados del análisis exploratorio aplicados a los datos derivados del eye tracking.
- Variables para la caracterización de las reglas no compensatorias.
- Variables que capturen los movimientos de cada regla y la evaluación en un modelo Logit de regresión para la clasificación entre reglas.
- Comparación de los órdenes de importancia obtenidos con la información visual y los derivados de una heurística ya existente.
- Parámetros estimados del modelo Jerárquico Bayesiano al integrar información del comportamiento visual.
- Comparación entre el modelo Jerárquico Bayesiano original y el modificado.
- Resultados de la aplicación del modelo Jerárquico Bayesiano modificado en una base de datos de prueba.

1.6. Estructura de la Memoria

- **Capítulo 1. Introducción:** Establece el contexto del trabajo de título, describe las características generales y los pasos principales de la investigación, motivación, objetivos, alcances, además del valor que genera dentro del área de investigación.
- **Capítulo 2. Antecedentes Generales:** Se muestra una revisión de la literatura relativa al tema de las reglas de decisión, eye tracking y los modelos jerárquicos Bayesianos desarrollados en reglas no compensatorias.
- **Capítulo 3. Experimento Visual de Análisis Conjunto:** Se describen las características del experimento y cómo se llevó a cabo para capturar la información visual.
- **Capítulo 4. Análisis Descriptivo:** Se explica cómo fue abordado el análisis exploratorio, su justificación y los resultados obtenidos en él.
- **Capítulo 5. Análisis Multivariado:** Se describen los patrones descubiertos en el análisis exploratorio y como pueden ser capturados con variables en una regresión Logit. Además de los resultados y las conclusiones obtenidas.
- **Capítulo 6. Heurísticas de Predicción de Órdenes e Información Visual:** Se explican los resultados y conclusiones de probar con otros métodos de estimación de orden de preferen-

cias, y se compara con los obtenidos de la información visual.

- **Capítulo 7. Aplicación en una Base de Datos Experimental de Cafeteras:** Se propone la integración de la información visual a través modelos compensatorio y no compensatorios, además de los resultados y conclusiones.
- **Capítulo 8. Conclusiones:** Conclusiones finales del trabajo realizado y futuros caminos de investigación.

Capítulo 2

Antecedentes Generales

Enfrentarse ante una decisión conlleva una serie de actos que caracterizan el proceso en sí, los cuales son interesantes de analizar para posteriormente comprender parte del comportamiento de las personas, y por ende, sus decisiones tomadas. Uno de estos procesos es el de adquisición de información, que abarca muchas variables siendo algunas de ellas dependientes exclusivamente de los individuos, como lo son la *habilidad de adquirir información* y la *dificultad percibida en el proceso* mismo (Murray, 1991). Debido a esto último, la forma en que se le despliega la información a los consumidores puede afectar el proceso de elección, razón por la cual es fundamental encontrar la mejor manera de hacerlo.

Actualmente se han propuesto métodos que utilizan la información desplegada en conjunto con las elecciones, para inferir la estrategia de decisión de los consumidores. Sin embargo, esta metodología ha sido criticada principalmente por dos problemas (Harte and Koele, 2001):

- Los estudios consideran como información conocida las opciones que se despliegan a un encuestado. Por lo que la investigación puede verse limitada en caso de no hacer un estudio directo de los procesos de decisión.
- Los modelos compensatorios y no compensatorios¹

Lo anterior da paso a considerar nuevas ideas para mejorar estos problemas. Es acá donde los métodos de rastreo, que permiten capturar el comportamiento de los individuos durante todo el proceso de decisión han tomado gran relevancia en la investigación actual, puesto que integran información nueva a los modelos ya existentes. Estos métodos se describen con mayor detalle en la sección 2.3.

¹Métodos compensatorios: Aquellos en que la carencia de algún atributo puede ser compensado por el exceso de otro. Métodos no compensatorios: Las elecciones no compensatorias no consideran un *trade-off* en las utilidades entre atributos de una misma opción, pues el individuo debe descartar alternativas comparando entre un mismo atributo, basado en criterios establecidos previamente. En caso de empate, continúa con el proceso en el siguiente atributo más relevante (Foerster, 1979).

2.1. Análisis Conjunto

El análisis conjunto es una metodología que se utiliza para medir las preferencias de los consumidores frente a productos o servicios con múltiples atributos a través de una encuesta. Con la información de las preferencias y gracias a métodos de optimización, es posible encontrar la combinación más adecuada de los diferentes atributos que conforman el producto con mejor aceptación.

El análisis conjunto también es utilizado en la realización de simulaciones de marketing, para el ingreso al mercado de nuevas marcas o productos, y para segmentar a los consumidores según las utilidades que les produce el bien o servicio en cuestión. Existen diferentes tipos de análisis conjunto dependiendo de las necesidades de los investigadores. En este caso, se trabajará con el análisis conjunto basado en elecciones (Choice Based Conjoint - CBC), pues esta herramienta es muy popular en las investigaciones dentro del área del marketing porque simula procesos de selección de opciones individuales (Haaijer and Wedel, 2007).

Las ventajas de este tipo de análisis son variadas, entre ellas se destaca que los datos recolectados simulan decisiones de compra, lo que es más realista y simple de entender para los encuestados. También, los niveles de los atributos para los productos (o servicios) pueden acomodarse fácilmente para estimar las utilidades. Y a diferencia de los Análisis Conjunto tradicionales, el CBC es más flexible en los diseños ya que abarca una amplia gama de de elección incluyendo productos alternativos, de la competencia y la opción de *No Comprar*, entre otras variantes (DeSarbo et al., 1995) y (Louviere and Woodworth, 1983).

2.2. Reglas de Decisión

Las reglas de decisión corresponden a un conjunto de condiciones bajo las cuales se evalúan alternativas de productos o servicios. En general, estas reglas responden a un enfoque estructural, que describe una relación entre la información desplegada (que funciona como estímulo) y las opciones escogidas (Riedl et al., 2008b).

Cuando se hace una elección, según las prioridades del elector se puede escoger siguiendo diferentes caminos. Sin embargo, esta investigación se enfoca en los modelos de elección, donde los que toman gran importancia son los métodos compensatorios y no compensatorios.

Los *métodos compensatorios* son aquellos en que la carencia de algún atributo puede ser compensado por el exceso de otro. Los *métodos no compensatorios*, no consideran un *trade-off* en las utilidades, es decir que la carencia de un atributo no puede ser compensada por el exceso de otro, debido a que en el proceso de elección, el individuo debe descartar alternativas mientras evalúa solo un atributo a la vez. Todo esto basado en criterios establecidos previamente. En caso de empate, continúa con el proceso en el siguiente atributo más relevante (Foerster, 1979).

Por lo tanto, según el tipo de método empleado existen diferentes estrategias para evaluar y escoger una alternativa, pero solo algunas de ellas toman relevancia para esta investigación. En particular, se trabajará con reglas de decisión lexicográfica y conjuntiva, que son del tipo no compensatorias (En el Apéndice A puede encontrarse la descripción de otras reglas de decisión).

2.2.1. Estrategia Lexicográfica

Esta regla cuenta con un orden de importancia de los atributos. De este modo, se comienza por evaluar el atributo más importante en todas las alternativas, para luego escoger la (o las) opción (opciones) que tenga el mejor valor en dicho atributo. En caso de que se produzca un empate, es decir, si dos o más opciones toman el mejor valor en el atributo más relevante, se procede a evaluar el siguiente atributo según la escala de importancia establecida. Se continúa de esta manera hasta quedar con una única opción (Fishburn, 1974).

2.2.2. Estrategia Conjuntiva

En esta estrategia el tomador de decisión tiene un *umbral* individual, el cual es el valor mínimo exigido para cada atributo en donde la persona está dispuesta a aceptar una opción si cumple con ser igual o mejor que el valor del umbral. En esta estrategia, la opción que supere los umbrales establecidos en todos sus atributos es la ganadora. (Dawes, 1964).

A diferencia de la regla lexicográfica que necesita un orden de importancia de los atributos, no es necesario tenerlo en el caso de esta estrategia. Sin embargo, el individuo que utilice la regla puede variar el número de atributos a evaluar, considerando todos los atributos o solo un subconjunto de ellos. Cabe recalcar que no hay una preferencia explícita en el orden en que se evalúan los atributos, lo cual queda a criterio del individuo.

Se esperaría que en un contexto experimental, la opción correcta sea solo una, pero en caso de obtener dos o más opciones correctas se puede asumir que el encuestado escoge de manera aleatoria entre las opciones candidatas, ya que entran en juego otras variables que no son posibles de cuantificar (como los juicios personales del encuestado)(Coombs, 1951).

2.3. Métodos de Rastreo

Son metodologías que permiten rastrear los movimientos y/o acciones de las personas. En general, se utilizan bajo un contexto particular y experimental, como en la aplicación de alguna encuesta. Pueden ser de diferentes tipos, en este caso se trabaja con *eye tracking* que es utilizado para rastrear la visión.

2.3.1. Eye Tracking

Este método funciona registrando el movimiento de los ojos de un individuo. Comúnmente, los participantes utilizan algún accesorio que registra el movimiento de la vista, como anteojos o cintillos con cámara incorporada que enfoca hacia los ojos del participante. Estos experimentos con eye tracking suelen llevarse a cabo frente a una pantalla de un computador en donde los encuestados deben realizar alguna actividad.



Figura 2.1: Dispositivo de eye tracking. *Eye tracking glasses reading laptop* [Fotografía]. Extraído de <http://www.asleyetracking.com/Site/Portals/0/Mobile-eye-tracking-glasses-reading-laptop.JPG>




Figura 2.2: Dispositivo eye tracker montado en la cabeza. *Eye Tracker* [Fotografía]. Extraído de <http://www.profissionaldeecommerce.com.br/eye-tracking-para-onde-vao-os-olhos-do-visitante-em-uma-loja-virtual/>.

Los datos recolectados con estas herramientas pueden ser de dos tipos:

- **Fijaciones:** Cuando el individuo posiciona su vista en un determinado lugar y la información adquirida puede ser procesada por el cerebro. Son los periodos en los cuales el ojo está inmóvil, y cuya duración suele estar entre los 200 y 500 milisegundos (Riding and Rayner, 1998).
- **Transiciones:** Movimiento desde una fijación a otra, pero a diferencia de las fijaciones, la información vista en este movimiento no alcanza a ser procesada (Buswell, 1935). La velocidad es alrededor de 20 - 40 milisegundos, dejándolo como el movimiento más rápido que hay en el cuerpo humano. Una persona, realiza en promedio 170 mil transiciones por día (Wedel and Pieters, 2008).

Debido a que el tiempo de las fijaciones es significativamente mayor al de las transiciones, es posible realizar distinciones claras entre un movimiento y otro. Si bien este trabajo se basa en la aplicación de herramientas con eye tracking, es interesante establecer la diferencia con otras herramientas para explicar las ventajas de eye tracking sobre el resto (Una descripción de estas otras metodologías puede encontrarse en el Apéndice B).

2.3.2. Otros Métodos de Rastreo Computarizados

En un estudio realizado en 1996, se indica que las principales desventajas del eye tracking se deben a la falta de precisión de las herramientas en aquel entonces y al costo monetario de adquirir de los equipos, en comparación con otros métodos computarizados (como MouseLab, en donde se realiza un rastreo de los movimientos del mouse) (Lohse and Johnson, 1996a).

No obstante, los instrumentos actuales que capturan los movimientos de la vista han sido constantemente mejorados y hoy gozan de exactitud en la captura de información, su costo de adquisición ha disminuido significativamente por lo que permite a los usuarios desenvolverse bajo condiciones cada vez más naturales (Wedel and Pieters, 2008).

2.4. Métodos de Estimación y Caracterización de Reglas de Decisión ya Existentes

Para estimar las reglas de decisión que utilizan los consumidores se han realizado variados estudios, cuya metodología consiste en aplicar una encuesta del tipo análisis conjunto, donde los encuestados deben responder las preguntas en un computador. Al mismo tiempo, se registra el comportamiento del encuestado por medio de algún método de rastreo.

Finalmente con los datos obtenidos y la información de la encuesta, se proponen modelos para predecir las elecciones, reglas de decisión, orden de importancia de atributos, entre otras cosas. Algunos de los modelos propuestos intentan caracterizar el comportamiento de los encuestados en base a los datos recolectados por los métodos de rastreo, otros consideran además las elecciones tomadas y la información de la encuesta para la predicción de las reglas.

A continuación se describen brevemente algunas técnicas planteadas en la literatura, cuya finalidad es predecir las reglas de decisión. Las metodologías utilizadas en cada una es muy diferente, porque la primera de ellas pretende caracterizar las reglas a través de métricas basadas en los movimientos ideales, y la segunda técnica trabaja información de la encuesta y la aplicación de modelos matemáticos. Cada uno de estos caminos distintos son de inspiración para el posterior trabajo de investigación.

2.4.1. Métricas que Caracterizan el Comportamiento del Encuestado

En el estudio publicado por Riedl, Brandstätter y Roithmayr en el año 2008 (Riedl et al., 2008b), se trabajó con datos de un experimento de análisis conjunto que fue rastreado con Mouselab. Los investigadores definieron tres posibles transiciones, que se pueden representar según lo mostrado en la Figura 2.3




Figura 2.3: Tipo de transiciones descritas por Riedl, Brandstätter y Roithmayr (2008).

- **Transición por Opción (OT):** El orden para adquirir información es vertical, puede ser de ascendente o descendente, e incluso entre atributos que no estén consecutivos.
- **Transición por Atributo (AT):** Las transiciones son horizontales, ya sea de izquierda a derecha o viceversa, y también puede ser para atributos no consecutivos.
- **Transiciones Mixtas (MT):** El resto de las transiciones diagonales.

Siguiendo esta terminología se proponen métricas para inferir la estrategia cognitiva de manera individual bajo una situación de no riesgo de decisión y múltiples atributos.

Métrica 1: Barrido por Opción, Atributo y Transiciones Mixtas.

Esta métrica es para distinguir reglas compensatorias de las no compensatorias. Se genera un valor ideal para las transiciones del tipo *OT*, *AT* y *MT*, a través de las siguientes ecuaciones:

$$OT_{ideal} = (a - 1) * o$$

$$AT_{ideal} + MT_{ideal} = o - 1$$

Donde *a* es equivalente al número de atributos y *o* al número de opciones que aparecen en la encuesta. El ratio ideal asume que la persona recorre la matriz de opciones-atributos (como la representada en la Figura 2.3) una sola vez, pasando por todas las posiciones y sin retroceder. El ratio que relaciona los tres tipos de transiciones está dado por:

$$OT_{ideal} / (AT_{ideal} + MT_{ideal}) = ((a - 1) * o) / ((o - 1))$$

Al comparar el valor de este cociente ideal, con el cociente estimado a partir de las transiciones encontradas en los datos del método de rastreo, se tienen dos casos:

- Si el valor real es mayor que el ideal: se esperaría que en su mayoría las transiciones fueran por opción y puede tratarse de un comportamiento compensatorio.
- Si el valor real es menor que el ideal: Análogo al caso anterior, se esperaría que la mayoría de las transiciones fuera por atributo y se tratase de un comportamiento no compensatorio.

Lo anterior se puede concluir a partir de que en una regla del tipo compensatoria es necesario comparar los atributos dentro de una misma opción, ya que existe un *trade-off* entre la utilidad que generan los atributos. Por lo tanto se espera que el tipo de comparación se vea reflejado en transiciones por opción. Por otro lado, en una regla no compensatoria los atributos importantes deben compararse en primera instancia, en todas las opciones para poder descartar aquellas opciones que no cumplen el criterio establecido. Así, se esperaría tener comparaciones con transiciones por atributo.

Métrica 2: Tiempo Destinado en Opciones.

Consistente con reglas compensatorias. Para explicar la lógica de esta métrica se considera el siguiente ejemplo: En una góndola de supermercado existen tres productos, A, B y C. La forma de escoger uno de estos productos siguiendo la métrica, sería comparar el producto A con el B en todos sus atributos, para luego escoger un ganador entre ellos, que pudo haber sido el producto B que ahora compite con C.

En este caso es evidente que el producto B es mirado el doble de lo que es mirado el producto A y C, por lo tanto el tiempo invertido en observar los productos seguirá una razón del tipo 1:2:1. Esta es la razón base y se produce en la circunstancia en que el encuestado sigue la regla de manera perfecta. Es importante mencionar que independiente del producto por el que se comience comparando la razón sería en una misma proporción (2:1:1, 1:1:2 o 1:2:1). Por lo tanto se contabilizan el tipo de comparaciones para estimar cuan cercanas están a la razón base.

Métrica 3: Correlación entre el Ranking de Atributos y el Número de Cajas Visitadas

Útil para las reglas no compensatorias, como es el caso de la regla lexicográfica y la conjuntiva. Trabaja buscando información de transiciones en su mayoría por atributo; además utiliza el *umbral* como información conocida. Para poder explicar esta métrica, se utiliza el ejemplo de la Figura 2.4.

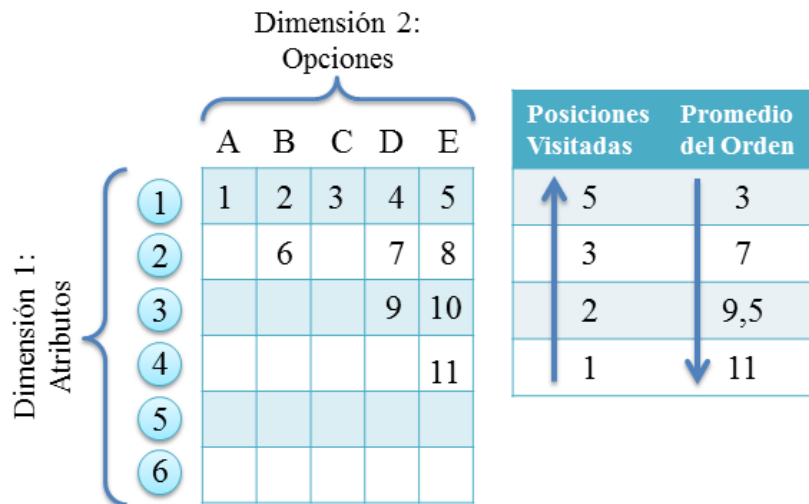


Figura 2.4: Esquema explicativo Métrica 3.

Acá se asume que la matriz de opciones y atributos tiene ordenado de manera descendente los atributos desde el más al menos importante según las preferencias de cada encuestado (la importancia se representa por los números que están encerrados en círculos).

La matriz se recorre según la secuencia de números que están en las casillas interiores. Por lo tanto en el primer atributo se miran todas las opciones disponibles en un orden de izquierda a derecha. Suponiendo que se generan tres empates en las columnas B, D y E, luego entran en competencia para ser evaluados en el segundo atributo más importante. Se continúa de esta manera hasta dar con una sola alternativa, que en este caso corresponde a la columna E.

Con esta serie al interior de la matriz, se pueden estimar dos tipos de métricas:

- **Posiciones Visitadas:** Número de posiciones de la matriz que se visitaron por atributo. En el atributo 1 se visitaron las 5 opciones, en el 2 solo 3 opciones.
- **Promedio del Orden:** Valor promedio simple de la secuencia de visita, considerando los números de un mismo atributo.

Por lo tanto, se esperaría que la correlación entre las *Posiciones Visitadas* y el *Promedio del Orden* para un encuestado que siga de manera perfecta la regla lexicográfica, sea negativa.

Esto sucede porque en una regla del tipo no compensatoria se eliminan opciones a medida que se evalúan atributos. Además, las opciones que son eliminadas, no vuelven a ser visitadas nuevamente y se reduce paulatinamente el conjunto de evaluación. El *Promedio del Orden*, representa el número de la secuencia en que se realizó la visita a una casilla. Es de esperar que aquellas casillas que se visitaron primero tengan una posición menor que las que se visitaron al final. Esta diferencia es lo que genera la correlación negativa.

2.4.2. Modelo de Predicción

Uno de los modelos de predicción interesantes de mencionar para esta investigación, corresponde al publicado por Allenby, Rossi y McCulloch en el año 2005 (Allenby et al., 2005), en donde proponen un modelo Jerárquico Bayesiano que permite a los investigadores estimar modelos del comportamiento de los consumidores más complejos y realistas, con menores limitaciones computacionales debidas a la modelación planteada.

Los modelos Jerárquicos Bayesianos también cuentan con la ventaja de ser *versátiles* y no lineales por lo que pueden usarse muy ampliamente en variadas situaciones. Estos modelos están escritos en forma modular o en términos de sub-modelos. Es decir, que para realizar o llevar a cabo su análisis, se debe tener en cuenta qué tipo de modelo se utiliza para estimar la unidad o problemática principal, y los sub-modelos que corren a través de ella.

Los sub-modelos se combinan para formar el Modelo Jerárquico, para posteriormente ser trabajados con la metodología Bayesiana que incluye la incertidumbre. Para calcular un modelo de esta índole, se trabaja en conjunto con métodos de Markov Chain Monte Carlo (MCMC) que permiten la estimación en base a la simulación. En particular en el estudio de Allenby, Rossi y McCulloch, la combinación de los modelos Jerárquicos Bayesianos con MCMC se utiliza para explorar los extremos de distribuciones multivariantes, los que proporcionan información sobre las acciones que se pueden tomar para aumentar la rentabilidad base de una empresa.

Un modelo Jerárquico Bayesiano similar a este, será utilizado en el desarrollo de esta investigación para estimar las preferencias individuales de los encuestados, por lo que en posteriores capítulos será explicado con mayor detalle.

Capítulo 3

Experimento Visual de Análisis Conjunto

Los procesos de decisión de los consumidores pueden llegar a ser de alta complejidad, debido a que en su desarrollo entra en juego mucha información intrínseca de la persona (gustos, necesidades, limitaciones, juicio, entre otros), además de la información extrínseca que puede ser adquirida en el momento de la toma de decisión. Y es precisamente en este último punto, en donde es posible analizar a los consumidores de manera cuantitativa, basándose solamente en sus acciones a partir de la información adquirida en el instante mismo de la toma de decisión.

Para trabajar con el comportamiento de los individuos, se utilizó la herramienta de eye tracking durante un experimento de análisis conjunto, con la finalidad de capturar el comportamiento visual. En esta oportunidad se encuestó a un total de 60 personas, todas ellas estudiantes universitarios alemanes. Los participantes de este experimento debían responder un total de 24 preguntas, de las cuales en 12 de ellas se les indicó seguir un tipo de regla lexicográfica, y en las 12 preguntas restantes un tipo de regla conjuntiva (estas reglas fueron explicadas en 2.2.1 y 2.2.2). La temática abordada en la encuesta alude a la elección de un hotel, donde el participante debe escoger una alternativa pensando en las preferencias de un *amigo hipotético*, las que son dadas en las instrucciones de la encuesta.

El objetivo del experimento es descubrir patrones en el comportamiento visual de los encuestados, comparar dos tipos reglas y evaluar rasgos que más tarde generen un aprendizaje en el desarrollo de la información visual y puedan ser puestos a prueba en otro experimento visual. La particularidad en esta ocasión, es imponer dos tipos regla de decisión no compensatorias que deben seguir los participantes.

La dificultad se estima a partir del número mínimo de atributos necesarios para contar con la información suficiente para escoger. En base a esto, el nivel de dificultad impuesto es diferente para cada una de las reglas en juego. Las preguntas con reglas del tipo lexicográficas pueden ser de dificultad fácil, media o difícil. No obstante, en la regla conjuntiva se trabaja solo con dificultades fáciles ya que siempre se deben evaluar dos atributos distintos. Aún así, los participantes no están al tanto de estas medidas, por lo que se puede asumir que los encuestados estaban en igualdad de condiciones antes comenzar a responder.

Respecto a la diagramación de las alternativas, se presentaron de forma matricial en donde

las columnas corresponden a las opciones y las filas representan los atributos de cada opción. Se contó con un total de cuatro opciones diferentes entre si, todas ellas siendo posibles hoteles puesto que no se incluyó una opción de *No arriendo de hotel*. Por otro lado, los atributos considerados ascienden a un total de seis y son: *Recomendación de Clientes*, *Precio*, *Distancia al centro de la Ciudad*, *Calidad de la Comida*, *Vista al Mar* y *Categoría de la Habitación*. Estos atributos fueron mostrados siempre en el mismo orden durante todo el experimento y para todos los encuestados. En la Figura 3.1, se muestra un ejemplo de la diagramación de una pregunta que exige un tipo de regla lexicográfica.

Dein Freund hat Dir die folgende Rangfolge für die Wichtigkeit der Eigenschaften von Hotelangeboten angegeben:

- 1 Weiterempfehlung in Prozent
- 2 Preis
- 3 Nähe zum Stadtzentrum
- 4 Zimmerkategorie
- 5 Meerblick
- 6 Qualität des Essens

Bitte entscheide Dich für ein Angebot, indem Du die zuvor gelernte Entscheidungsregel anwendest.

	Angebot A	Angebot B	Angebot C	Angebot D
Qualität des Essens	schlecht (-)	schlecht (-)	schlecht (-)	mittel (o)
Weiterempfehlung in Prozent	50% (-)	90% (+)	70% (o)	50% (-)
Nähe zum Stadtzentrum	1km (+)	2km (o)	1km (+)	2km (o)
Meerblick	direkter Meerblick (+)	seitlicher Meerblick (o)	kein Meerblick (-)	direkter Meerblick (+)
Preis	699 Euro (+)	699 Euro (+)	899 Euro (-)	899 Euro (-)
Zimmerkategorie	standard (-)	luxuriös (+)	standard (-)	gehoben (o)

Figura 3.1: Diseño de una pregunta donde se exige seguir una estrategia lexicográfica. Se le indica al encuestado el orden de importancia de los atributos.

Cabe mencionar que en todas las preguntas realizadas, las opciones fueron generadas al azar, por lo cual un mismo diseño de alternativas no se enfrentó a más de una persona, ni tampoco en más de una sola pregunta. Los posibles valores que toman cada uno de los atributos se muestran en la Tabla 3.1.

Atributo	Valor 1	Valor 2	Valor 3
Recomendaciones adicionales	50 % (-)	70 % (o)	90 % (+)
Precio	899 €(-)	799 €(o)	699 €(+)
Distancia al centro de la Ciudad	3km (-)	2km (o)	1km (+)
Calidad de la Comida	mala (-)	media (o)	buena (+)
Vista al Mar	Sin vista (-)	Vista lateral (o)	Vista directa (+)
Categoría de la Habitación	Estándar (-)	elevado (o)	lujoso (+)

Tabla 3.1: Posibles valores para cada atributo.

3.1. Captura y Almacenamiento de los Datos

Los participantes realizaron sus elecciones frente a la pantalla de un computador en donde se les mostraron las opciones disponibles. Se utilizaron lentes especiales que capturan los movimientos de sus ojos, siendo éstas las herramientas de eye tracking. Se registraron las fijaciones que los encuestados realizaron por toda la pantalla del computador, en donde se produjo interacciones entre las instrucciones, el nombre de las opciones y atributos, y de los valores mismos. No obstante, para esta investigación solo se consideran las fijaciones que están dentro de la matriz de atributos-opciones.

Además se establecieron algunos criterios para escoger las fijaciones dentro de la matriz atributos-opciones:

- No se consideran todas las fijaciones producidas después de la última fijación en el botón *Siguiente*¹.
- En caso de que no haber fijaciones en el botón *Siguiente*, se eliminaron todas las fijaciones después de que el participante miró por primera vez alguno de los botones para seleccionar las alternativas. Esto se debe a que los encuestados levantaban la vista mientras esperaban que apareciera la siguiente pregunta en la pantalla.

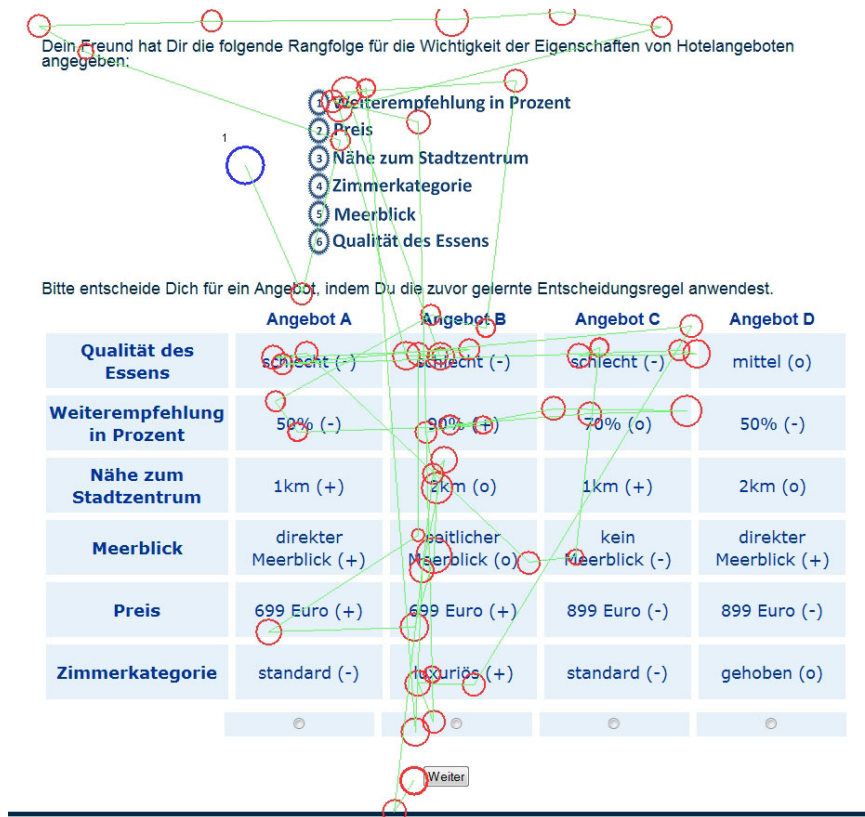


Figura 3.2: Muestra de una serie de fijaciones registrada durante un proceso de respuesta

¹Como el experimento se realizó en alemán, el nombre del botón es *Weiter*, lo que en español significa *Siguiente*

3.2. Estructura y Diseño de Datos

A pesar de las especificaciones anteriores, cabe destacar que el tiempo de duración de una fijación no es relevante para este estudio debido a que se trabajó con las posiciones de la vista dentro de cada uno de los cuadrantes de la matriz atributos-opciones. Estos cuadrantes responden al nombre de *Área de Interés* (AOI - Areas Of Interest). Por lo tanto, las series de fijaciones fueron transformadas a *series de posiciones de la matriz*, para ser trabajadas en este último formato.

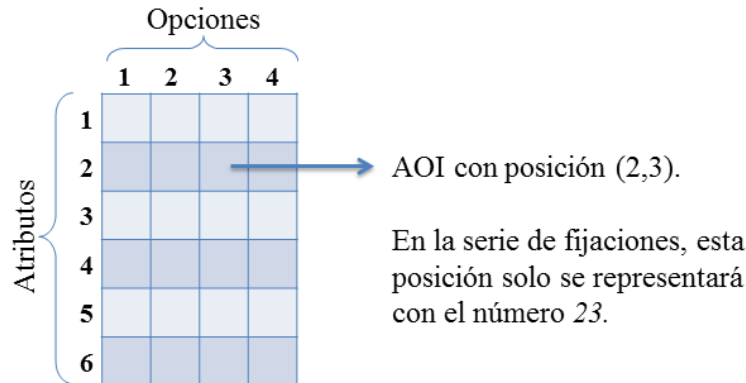


Figura 3.3: Ejemplo de casilla o Área de Interés (AOI) en la posición (2,3), dentro de la matriz atributos-opciones.

La transformación de los datos se realizó mediante un método estándar programado por desarrolladores del Departamento Técnico de la Universidad de Bielefeld en Alemania, y no fue posteriormente ajustado por el investigador a cargo Martin Meißner.

Debido a esta nueva nomenclatura, un efecto interesante que se produce es la secuencia consecutiva de fijaciones que son representadas con la misma AOI. Una de las posibles explicaciones de aquello se atribuye a la complejidad de algunas alternativas por el nombre compuesto que pueden tomar. A modo de ejemplo, suponiendo que un posible valor para un atributo fuese *Habitación Matrimonial*, para que un participante pueda comprender lo que significa debe ser necesario que lea la característica por medio de al menos dos o tres fijaciones (considerando una fijación por palabra).

A razón de casos como este se desprenden otras consideraciones interesantes:

- Los encuestados no tienen la necesidad de leer todas las letras para una palabra.
- A medida que los encuestados vayan respondiendo preguntas, serán capaces de reconocer algunas de las características de los atributos y responder con mayor rapidez. Esto se debe a que existe un período de aprendizaje y reconocimiento de la información.
- Si los ojos se mueven de un punto a otro, es posible que este salto no sea preciso, por lo que existen fijaciones adicionales para dar con la información buscada, la cual puede estar dentro de la misma AOI. Esta *fijación intermedia*, también puede servir de guía para buscar los puntos de información relevante.

Una de las consecuencias de lo anterior, es que para atributos cuyos nombres son más largos,

parecerá que el encuestado lo evaluó más tiempo la AOI. Sin embargo, como se considera el factor *aprendizaje*, efectos de esta índole solo debieran producirse en las preguntas del inicio.

Capítulo 4

Análisis Descriptivo

Los primeros acercamientos a los datos agregados son útiles para desarrollar las intuiciones que más adelante darán paso a las hipótesis centrales de este trabajo de investigación. Como se mencionó anteriormente, en el experimento participaron 60 personas, donde cada una de ellas respondió 12 preguntas lexicográficas y 12 preguntas conjuntivas. Para cada pregunta se almacenó la serie de fijaciones, que más tarde fueron representadas por una serie de AOI (Áreas de Interés). Cada una de estas secuencias, se caracterizan porque varían en el orden y el número total de fijaciones.

A cada una de estas series de fijaciones, se les ha denominado con el nombre de *Caso*, los que corresponden a secuencias únicas por persona y por pregunta. El experimento cuenta con un total de 720 casos distintos por cada una de las reglas en cuestión, por lo tanto se tiene un total de 1440 casos en el experimento completo.

4.1. Fijaciones

Un primer acercamiento a los datos, es analizar la distribución del *número de fijaciones* por caso. Cómo se puede apreciar en el histograma de la Figura 4.1, en su mayoría los casos poseen entre 15 y 25 fijaciones. Existen dos situaciones particulares:

- **Si el encuestado realizó pocas fijaciones** (Entre una o dos fijaciones): Puede interpretarse como falta de interés del participante por responder correctamente las preguntas.
- **Si el encuestado realizó demasiadas fijaciones**: Puede deberse a un *problema de memoria*, llamado de esta manera por la dificultad de recordar un orden de atributos preestablecido, como el que se indica en la regla lexicografica. También, el encuestado puede estar confundido por no comprender correctamente la regla de decisión que debe aplicar.

De la muestra total de casos, tan solo dos de ellos cuentan con el número mínimo de fijaciones registradas (dos fijaciones), y solo un caso tiene tres fijaciones; el resto posee series con número de fijaciones igual o mayor a cuatro, lo cual es considerado suficiente para poder realizar una elección. Es por ello que ninguno de los casos fue eliminado.

Distribución del Número de Fijaciones por Caso




Figura 4.1: Histograma de la distribución del número de fijaciones.

N° de Fijaciones	Valor Estadístico
Media	27,20
Des. Estándar	19,73

Tabla 4.1: Valores de media y desviación estándar para los datos agregados.

Para comprobar que los participantes tienen algún grado de *aprendizaje*, se estudia el número de fijaciones segmentado *por pregunta*, en donde se espera encontrar una disminución en el total de fijaciones a medida que el encuestado avanza respondiendo las preguntas. La hipótesis detrás de esto es la siguiente:

Cuando el consumidor adquiere práctica en el uso de la regla de decisión, podrá encontrar con mayor rapidez la respuesta, lo que se verá reflejado en un número menor fijaciones.

Vale destacar que la disminución en el número de fijaciones también puede deberse al reconocimiento de los atributos por parte de los encuestados. Los resultados de esta distribución pueden verse en la Tabla 4.2. Este análisis está agregado por el tipo de regla. Luego, se concluye que efectivamente se cumple con lo esperado, pues los participantes aprenden y se familiarizan con la regla utilizada.

4.2. Fijaciones y Elecciones

Los siguientes análisis tienen por finalidad entender la *variabilidad* de la secuencia de fijaciones a lo largo del tiempo. Para ello, cada una de las series de fijaciones se divide en dos conjuntos llamados *períodos*; en donde el primer período contiene la mitad de las fijaciones y el segundo período la otra mitad restante. Para los casos donde el número de fijaciones de la serie es impar,

Pregunta	50 %	2,5 %	97,5 %
1	30,0	14,0	98,0
2	27,0	12,5	99,5
3	24,0	10,5	97,0
4	24,5	10,5	85,5
5	24,5	10,0	71,5
6	22,0	10,0	67,5
7	20,0	9,5	93,5
8	22,0	10,0	85,0
9	22,5	9,0	81,0
10	20,0	8,5	69,0
11	21,0	10,0	84,5
12	20,0	8,0	72,0

Tabla 4.2: Número promedio de fijaciones considerando el 2,5 % , 50 % y 97,5 % de los valores de la distribución por pregunta.

el segundo período contiene una fijación más. Vale destacar que esta división no altera el orden secuencial original de las series.

Se asume que la atención es equivalente al número de fijaciones, es decir, aquellas alternativas que posean un mayor número de fijaciones, reciben mayor atención. Basado en este supuesto, se propone un orden de las alternativas, el cual está ordenado según el *porcentaje de fijaciones de cada período*. Los posibles valores asignados por el orden de opciones son:

Valor	Significado de la alternativa
1	Recibe la mayor atención.
2	Recibe la segunda mayor atención.
3	Recibe la tercera mayor atención.
4	Recibe la menor atención.

Tabla 4.3: Significado del valor del orden de opciones.

Con el total de esta información se genera una matriz de transiciones (Figura 4.2), en donde sus posiciones pueden ser interpretados de la siguiente manera:

$$(x, y) = (\text{Ranking en el } 1^\circ \text{ Período}, \text{Ranking en el } 2^\circ \text{ Período})$$

En este caso, la diagonal tienen los valores más altos e incrementan a medida que se avanza en el orden, es decir que es más probable que la alternativa menos mirada en el primer período siga siendo la menos mirada en el segundo, de manera análoga con la alternativa que es la más mirada en el primer período, se espera con mayor probabilidad de que sea también en el segundo período.

Se puede concluir que existe una tendencia de al menos un 32 % de probabilidad de mantener el orden inicial.

		1° Período			
		1	2	3	4
2° Período	1	32%	27%	22%	19%
	2	25%	38%	21%	16%
	3	22%	20%	38%	19%
	4	21%	15%	18%	46%

Figura 4.2: Matriz de Transiciones generada según el orden de las opciones durante el 1° y 2° período.

Hasta este punto no se ha incluido la *elección* de los encuestados. Para introducir las elecciones al método anterior, se plantea un nuevo orden cuyo rango es similar al recién explicado, pero su significado es diferente:

Valor	Significado de la alternativa
1	Recibe la mayor atención y es escogida por el encuestado.
2	Recibe la segunda mayor atención y es escogida por el encuestado.
3	la tercera mayor atención y es escogida por el encuestado.
4	Recibe la menor atención y es escogida por el encuestado.

Tabla 4.4: Significado del valor del orden de opciones.

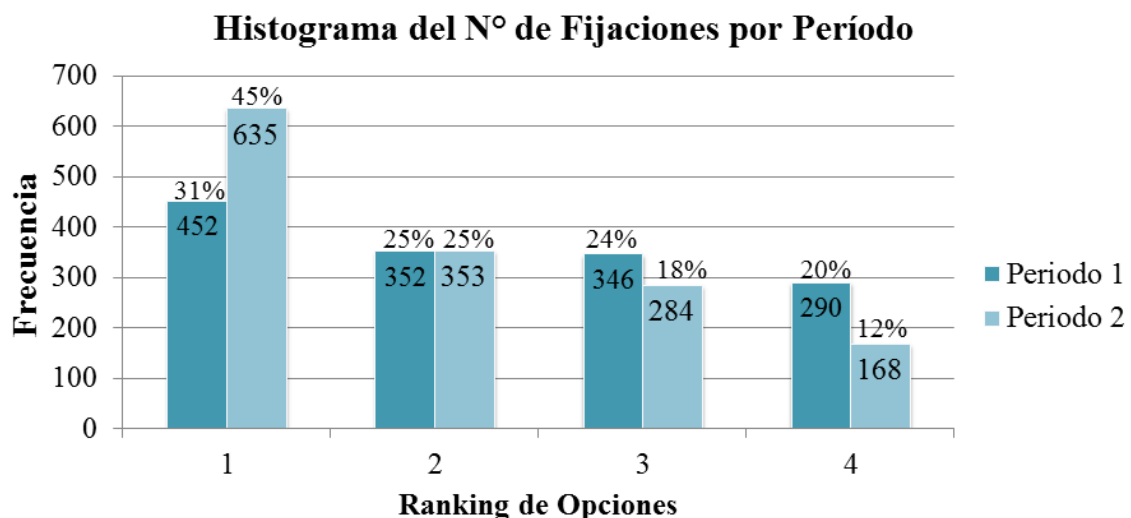


Figura 4.3: Resultados para el orden de fijaciones por período, condicionado a la elección.

El histograma indica el número de casos en donde la alternativa escogida (ya sea la 1, 2, 3 o 4) coincide con la repartición de la atención, segmentado por períodos.

Se muestra la existencia de una fuerte tendencia a escoger la alternativa más vista, sobre todo en el segundo período que parece ser más informativo respecto al primero. Lo anterior implica que a medida que el participante está más próximo a escoger, focaliza su atención (y por ende su mirada) con mayor probabilidad en la alternativa que elegirá.

4.2.1. Dinámica de Fijaciones

El estudio de la atención dinámica ha sido dividido en dos tipos. El primero de ellos hace referencia a los movimientos que se aplican entre opciones (Figura 4.4), y el segundo trabaja con los movimientos entre atributos (Figura 4.5). En una matriz de transición con movimiento entre opciones se puede analizar la probabilidad de estar en una opción i y cambiarse a la opción j . Para una matriz de transición entre atributos el análisis es similar.

		Opciones de Salida			
		1	2	3	4
Opciones de Llegada	1	56%	30%	9%	5%
	2	23%	46%	25%	6%
	3	10%	19%	42%	29%
	4	13%	17%	24%	46%

Figura 4.4: Matriz de Transición entre Opciones

		Atributos de Salida					
		1	2	3	4	5	6
Atributos de Llegada	1	62%	15%	5%	6%	5%	7%
	2	15%	58%	12%	5%	5%	5%
	3	9%	17%	50%	12%	5%	6%
	4	4%	4%	11%	60%	13%	7%
	5	4%	5%	5%	14%	59%	14%
	6	6%	5%	5%	6%	15%	64%

Figura 4.5: Matriz de Transición entre Atributos.

Los valores de la diagonal en ambos casos son considerablemente mayores que el resto, lo que significa (a modo de ejemplo para la matriz de transición de atributos) que si un encuestado está mirando un atributo en particular, con mayor probabilidad se esperaría que continúe mirando dentro del mismo atributo, ya sea en la misma opción o en las otras.

Cuando se está mirando un atributo u opción, la transición más probable es a los atributos u opciones más cercanas, lo que da cuenta de que la serie de fijaciones tiende a seguir un movimiento

continúo sin saltos aleatorios. Este análisis es similar para la matriz de transición entre opciones, en donde los valores de la diagonal también son los más altos. Sin embargo, en este caso la probabilidad de permanecer en la misma opción es muy similar a la de cambiarse a cualquiera de las dos opciones más cercanas.

4.2.2. Fuentes de Variabilidad

Un análisis de las desviaciones estándar considerando el total de *casos*, permite determinar dos conclusiones interesantes:

- Hay mayor variación entre las fijaciones repartidas en las alternativas, que las repartidas entre preguntas.
- Hay una mayor variación entre las fijaciones repartidas en las preguntas, que las repartidas entre personas.

4.3. Análisis y Tipos de Transiciones

Se ha determinado que las transiciones de la vista son un punto clave para entender el comportamiento de los encuestados. Es por ello, que desde ahora en adelante las transiciones toman más relevancia en la investigación. Para seguir con el estudio, se han clasificado las transiciones en tres tipos:

- **Transiciones Horizontales (entre atributos):** Se refieren a los movimientos horizontales de la vista, en donde se comparan los valores de las distintas opciones dentro de un mismo atributo. Esto es independiente del sentido.
- **Transiciones Verticales (entre opciones):** Son movimientos verticales de la vista en donde se adquiere la información para una misma opción. Esto es independiente del sentido.
- **Transiciones Diagonales:** Corresponden a todos los otros movimientos de la vista dentro de la matriz.

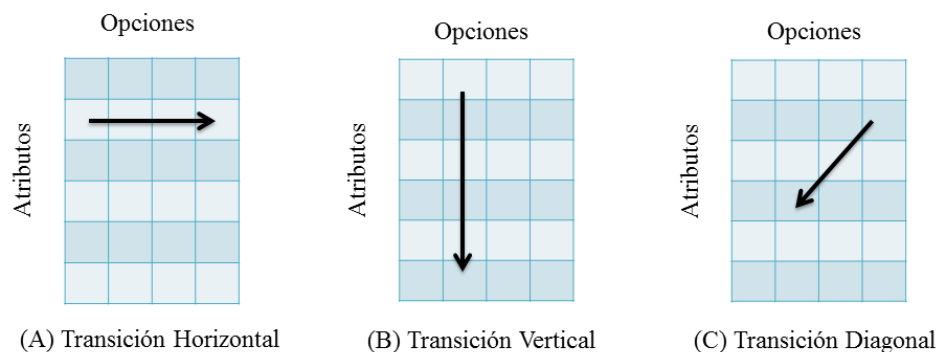


Figura 4.6: Ejemplo de los tipos de transiciones.

Según el tipo de regla (lexicográfica o conjuntiva) se establecen diferentes formas de recorrer una matriz. Sería de esperar que al contabilizar el número de transiciones horizontales y verticales para cada una de las reglas, las cantidades sean significativamente diferentes. Para el siguiente análisis, se propone mirar el comportamiento de los individuos a través de los tipos de transiciones realizadas en cada regla. Para ello, se plantea la siguiente clasificación:

- **Sin Normalizar:** Considera el número de transiciones (horizontales o verticales) de un *caso*.
- **Normalizadas:** Considera el número de transiciones (horizontales o verticales) de un *caso*, dividiendo por el número total de las transiciones de la serie respectiva.

El objetivo es comparar las diferencias poblacionales *reales* (datos sin normalizar) del número de fijaciones, y las diferencias poblacionales *normalizadas* para comprobar que el tipo de transición (vertical u horizontal) es un buen discriminador en algunas de estas dimensiones. Se proponen ocho variables para luego ser sometidas a un test de diferencias de medias.

La nomenclatura de las utilizada para las variables, es la siguiente:

$$\bar{X}_{R,T}^O = \text{Promedio de transiciones del tipo } O \text{ para la regla } R, \text{ para un tipo de datos } T.$$

En donde $O \in \{H, V\}$ representa la orientación de las transiciones, pudiendo ser horizontal o vertical. Por otro lado $R \in \{L, C\}$, representa la regla utilizada, ya sea lexicográfica o conjuntiva. El tipo de datos $T \in \{S, N\}$ corresponde a las transiciones Sin Normalizar o Normalizadas. A continuación, en la Figura 4.7 se muestra un esquema que clarifica la proveniencia de las variables propuestas:

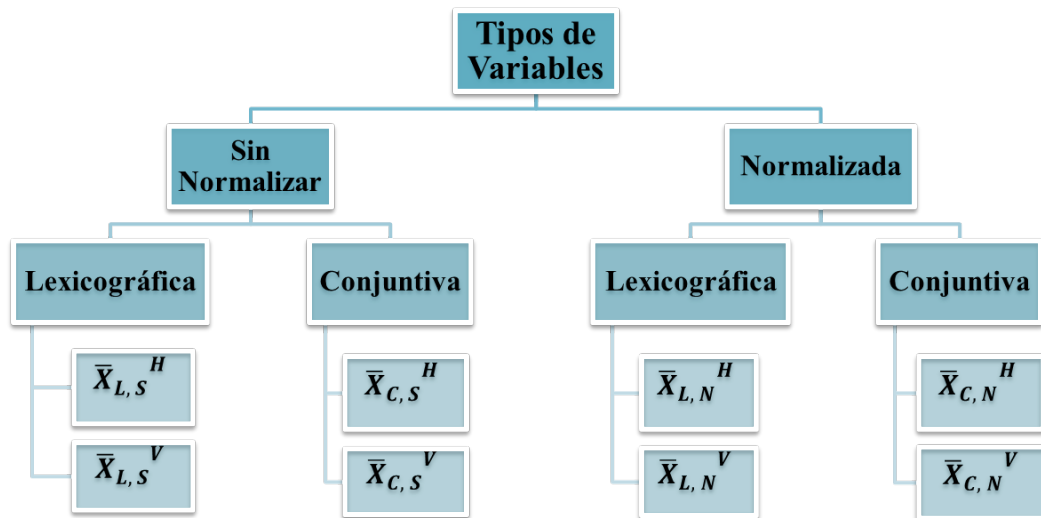


Figura 4.7: Diagramación que resume el origen de las ocho variables propuestas.

La metodología consiste en comparar las medias de las poblaciones entre reglas distintas (lexicográfica y conjuntiva), para un mismo tipo de transición (horizontal o vertical). A modo de ejemplo, y siguiendo la nomenclatura de la Figura 4.7, uno de los test de medias compararán las variables $\bar{X}_{L,N}^H$ y $\bar{X}_{C,N}^H$.

4.4. Resultados de los Tests

4.4.1. Caso 1: Sin Normalizar

En la comparación de las variables horizontales y verticales, los resultados obtenidos siguen la misma tendencia:

El número de transiciones tanto horizontales como verticales, es mayor para una regla lexicográfica que para una regla conjuntiva.

Los resultados arrojados pueden verse en la Tabla 4.5 y la Figura 4.8, mientras que la información numérica de todos estos gráficos se encuentra en la sección de Apéndices E. A pesar de que la desviación estándar para cada grupo es muy grande respecto al valor promedio de cada población, estos valores son muy diferentes entre sí, siendo la del grupo lexicográfico casi el doble que la del grupo conjuntivo. Cabe destacar que las diferencias de los Test de Medias se construyen considerando el número de las fijaciones de la regla lexicográfica menos el número de fijaciones de la regla conjuntiva. Esto es igual para todos los casos.

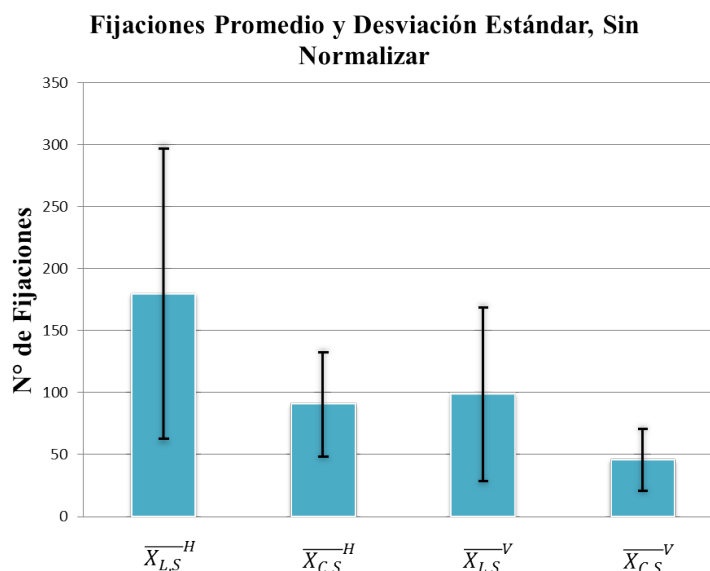


Figura 4.8: Número de Fijaciones y su Desviación Estándar, sin normalizar. La información numérica está en Apéndices E.

Transición	t	dt	Sig. (2-colas)	Media Diff.	Std. Error Diff.	Lower	Upper
Horizontal	19,100	904,307	,000	88,701	4,644	79,586	97,815
Vertical	19,102	904,228	,000	53,220	2,786	47,752	58,688

Tabla 4.5: Resultados Test de Medias, sin Normalizar.

La alta desviación estándar muestra que a pesar de la segmentación establecida, existe una gran heterogeneidad en cada uno de los grupos, esto puede atribuirse a que aún existen otros aspectos importantes del comportamiento visual de los individuos que no han sido capturados por estas variables.

Este análisis no es suficientemente explicativo ya que no permite comparar proporcionalmente entre una regla y otra, lo que induce un nuevo análisis con las variables *normalizadas*, es decir que se dividen las transiciones horizontales y verticales por el total de transiciones de la serie.

4.4.2. Caso 2: Normalizado

Los resultados entregados por el test pueden verse en la Tabla 4.6 y en la Figura 4.9. Al comparar las diferencias de medias entre las variables $\bar{X}_{L,N}^V$ y $\bar{X}_{C,N}^V$ se tiene un valor negativo. Este signo permite concluir lo siguiente:

Proporcionalmente hay más transiciones horizontales y verticales en la regla lexicográfica que en la conjuntiva.

Esta hipótesis podría estar explicada directamente por el diseño de la encuesta, debido a una comparación *injusta*, pues en la regla lexicográfica hay situaciones en las cuales se debe comparar en todos los atributos para dar con la alternativa correcta, situación que no se repite en la regla conjuntiva, donde solo se comparan hasta un máximo de dos atributos. Por lo tanto, es necesario analizar cómo integrar la dificultad de la tarea en el análisis.

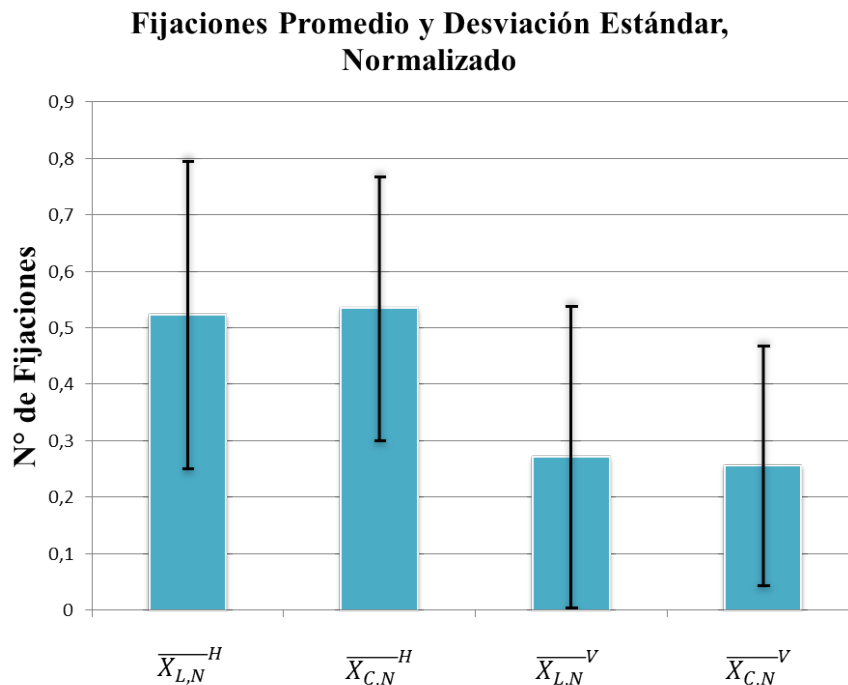


Figura 4.9: Número de Fijaciones y su Desviación Estándar, Normalizado. La información numérica está en Apéndices E.

Transición	t	dt	Sig. (2-colas)	Media Diff.	Std. Error Diff.	Lower	Upper
Horizontal	-9,175	1438	0,000	-0,122	0,013	-0,149	-0,096
Vertical	11,588	1438	0,000	0,147	0,012	0,122	0,172

Tabla 4.6: Resultados Test de Medias, Normalizado.

4.5. Comparación *Equivalente*

Como se mencionó, la comparación anterior no evalúa las reglas en igualdad de condiciones, por lo que se crea otro análisis que sí permita comparar las reglas bajo otra metodología, la que se ha denominado *Comparación Equivalente* puesto que solo se consideran los casos de la regla lexicográfica de menor dificultad, donde se debe mirar dos atributos como máximo para contar con la información necesaria para elegir.

La selección considera solo 240 casos (de un total de 720), lo que representa un tercio de los datos. En esta comparación, el número de casos con los que se trabajó para la regla conjuntiva, fue de 240, los que fueron seleccionados al azar. Los resultados de la comparación equivalente pueden verse en la Tabla 4.7 y en la Figura 4.10.




Figura 4.10: Caso Equivalente: Número de Fijaciones y su Desviación Estándar, sin normalizar. La información numérica está en Apéndices E.

Los resultados de la comparación equivalente son interesantes de analizar, porque ya no siguen la tendencia de los análisis anteriores, puesto que ahora tanto los promedios como las desviaciones estándar son muy similares entre sí. Esto se repite tanto para el caso normalizado como para el sin

Transición	t	dt	Sig. (2-colas)	Media Diff.	Std. Error Diff.	Lower	Upper
Horizontal	-0,229	478	0,819	-0,469	2,056	-4,510	3,571
Vertical	-0,180	478	0,857	-0,336	1,867	-4,005	3,333

Tabla 4.7: Resultados Test de Medias, Equivalente sin Normalizar.

normalizar. Para ambos casos, las diferencias entre un grupo y otro no son significativas, es decir que se produce un efecto interesante cuando se controla porcentualmente y por dificultad, ya que la diferencia entre las medias decrece considerablemente. El resto de los detalles se encuentra en la Tabla 4.8 y la Figura 4.11.

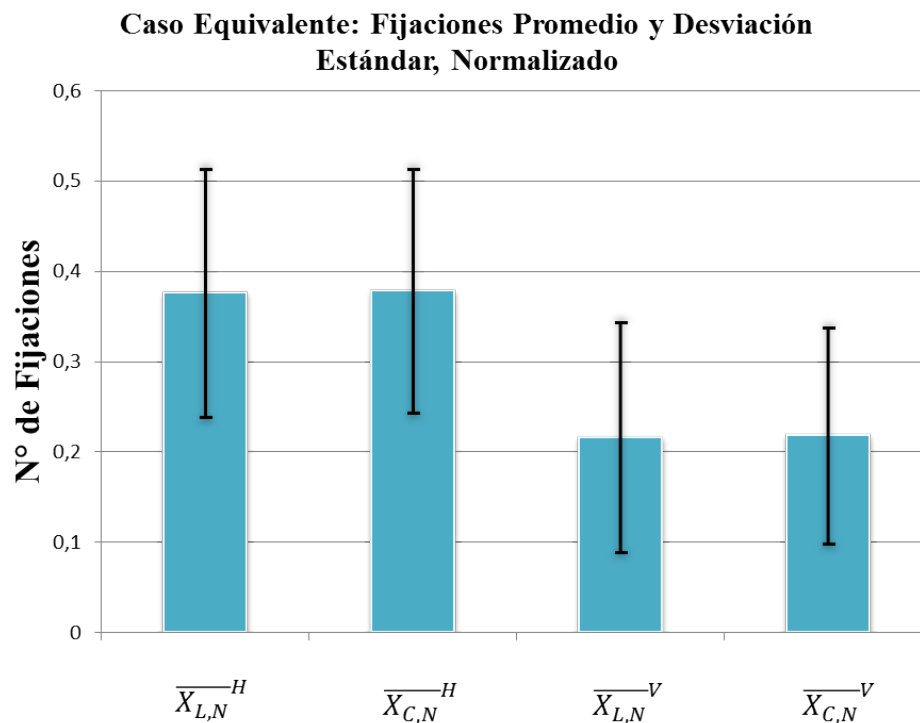


Figura 4.11: Caso Equivalente: Número de Fijaciones y su Desviación Estándar, Normalizado. La información numérica está en Apéndices E.

Transición	t	dt	Sig. (2-colas)	Media Diff.	Std. Error Diff.	Lower	Upper
Horizontal	-0,229	478	0,819	-0,002	0,012	-0,027	0,020
Vertical	-0,180	478	0,857	-0,002	0,011	-0,024	0,020

Tabla 4.8: Resultados Test de Medias, Equivalente Normalizado.

4.6. Conclusiones del Capítulo

Para una serie de fijaciones, el *número de fijaciones* y la secuencia de ellas son un buen indicio de la complejidad de las reglas, pero no son suficientes para poder generalizar este análisis en la predicción o caracterización de una regla. Por su parte, el *número de fijaciones* tiene un valor promedio de 27 fijaciones por tarea, su varianza es demasiado alta (cerca de 20 fijaciones) para ser utilizada como parámetro único.

En cuanto a la *secuencia de las fijaciones*, permite acercarse a la respuesta correcta al considerar las últimas fijaciones de la serie, pero aun así no es suficiente para generalizar. Es por ello que se plantean análisis que permitan caracterizar el comportamiento para las reglas basado en su tipo de transiciones.

Relacionado con la cantidad de fijaciones, se tiene que mientras más atributos se deben mirar para escoger alguna alternativa, más aumenta la dificultad que enfrenta un encuestado en una pregunta ya que tiene que adquirir más información. Esto se puede ver en que el promedio de transiciones para una regla lexicográfica fue siempre mayor que en una conjuntiva (180 y 92 para transiciones horizontales y 99 y 46 para transiciones verticales).

De esta idea se puede desprender que para una tarea más compleja, se esperaría tener un mayor número de fijaciones, y se deduce que la regla lexicográfica tiene un mayor nivel de dificultad versus una conjuntiva, ya que en la primera se puede mirar un máximo de seis atributos, mientras que en la conjuntiva solo dos (recordando que esto último es por construcción del experimento).

Dado que la regla lexicográfica y conjuntiva son muy diferentes entre sí para este experimento, se realiza una *comparación equivalente* en donde la idea es seleccionar solo aquellos casos del experimento lexicográfico en que basta revisar un máximo de dos atributos (para hacerlo equivalente al caso conjuntivo). El supuesto detrás es que a pesar de que el diseño del experimento permite hacer la elección mirando solo dos atributos, la persona encuestada no lo sabe y es de esperar que mire todos los atributos que sean de su interés.

Por último, se debe considerar que puede existir un efecto de *inseguridad*, que incita a las personas a revisar su elección antes de seleccionar definitivamente esta alternativa. Este fenómeno implica hacer un *barrido final* por los atributos de la opción escogida para verificar que es la mejor, lo cual puede influir en el número de transiciones verticales.

Capítulo 5

Análisis Multivariado

Se ha mostrado que la dificultad en la utilización de las reglas de decisión lexicográfica y conjunta es distinta en el experimento, siendo la primera de mayor dificultad. La existencia de este tipo de diferencias, permite orientar este capítulo en búsqueda de nuevos patrones de la serie de fijaciones, a través de la proposición de variables que más tarde puedan ser evaluadas en una regresión del tipo Logit, para luego estudiar su nivel de ajuste y predicción.

5.1. Modelo Logit Binomial

Se utiliza una Regresión Logit Binomial debido a que la variable dependiente es categórica y corresponde al tipo de regla de decisión. Como se ha explicado, solo se está trabajando con dos reglas, por lo que los posibles valores que la variable dependiente puede tomar son:

$$Y_i = \begin{cases} 1 = \text{Si es una regla lexicográfica} \\ 0 = \text{Si es una regla conjunta} \end{cases} \quad (5.1)$$

Si bien los valores que toma la variable dependiente en cada uno de los casos son conocidos en este experimento, la idea detrás es generar variables que permitan discriminar entre una regla y otra, para luego poder contrastar los resultados arrojados con la clasificación real.

5.2. Variables Propuestas

Las variables propuestas tienen por finalidad incluir características exclusivas del diseño del experimento de análisis conjunto, y adicionalmente consideran la información de las fijaciones y transiciones para cada pregunta. Son un total de 13 variables, su diseño y utilidad son descritos a continuación.

5.2.1. Número de fijaciones ($N_{fijaciones}$)

Se calcula como la suma total de fijaciones para cada uno de los casos. Su creación deriva de la dificultad de una regla, puesto que se espera que esta variable tome un valor mayor en una regla más compleja (lexicográfica), que en una de menor dificultad (conjuntiva).

A pesar de que en el análisis de la comparación equivalente en la sección 4.5, se concluyó que las diferencias entre el número de fijaciones de una regla y la otra o eran significativas, no se considerarán debido a que se trabajará con el total de los datos, y por ende con los tres tipos de dificultad.

5.2.2. Primer Atributo más Observado ($AtributoTop^1$)

Para una serie, se reparten las fijaciones según el atributo en el que se hayan realizado. Posteriormente, estos valores son divididos por el total de fijaciones de la serie en cuestión. Así, el atributo que tenga el mayor porcentaje de fijaciones será considerado como $AtributoTop^1$.

La creación de esta variable se sustenta porque las personas miran lo que les interesa, y reparten su atención entre los atributos de manera heterogénea cuando tienen mayor claridad de lo que se está buscando. En este caso, la regla conjuntiva establece dos atributos necesarios, por lo que se esperaría que los encuestados repartieran fuertemente sus fijaciones y por ende su atención, en dos atributos.

Para el caso lexicográfico, se esperaría que esta variable tuviera un menor valor ya que las fijaciones lexicográficas son más dispersas.

5.2.3. Segundo Atributo más Observado ($AtributoTop^2$)

Esta variable es similar a la anterior y su justificación es la misma, pero el valor que entrega es el porcentaje de fijaciones en el segundo atributo más mirado.

5.2.4. Primera Opción más Observada ($OpcionTop^1$)

De manera análoga a las variables $AtributoTop^1$ y $AtributoTop^2$, esta variable considera el porcentaje de fijaciones más alto, pero de las opciones. Agregar esta variable está fundamentado por el comportamiento impuesto por la regla lexicográfica, ya que como se presentó en el Capítulo 4, esta regla tiene un mayor número de transiciones verticales en comparación con su rival.

5.2.5. Segunda Opción más Observada ($OpcionTop^2$)

Esta variable es similar a $OpcionTop^1$, pero considera el segundo porcentaje más alto de las opciones.

5.2.6. Algún Atributo Observado Completamente para la Primera Mitad de la Serie de Fijaciones ($AtributoCompleto^{Inicio}$)

Esta variable es una indicatriz que se define de la siguiente manera:

$$AtributoCompleto^{Inicio} = \begin{cases} 1 = & \text{Si en la Primera mitad de la serie, existe algún atributo} \\ & \text{para el cual se miró en todas las opciones.} \\ 0 = & \text{Si no.} \end{cases} \quad (5.2)$$

La hipótesis subyacente, es que las personas no siguen inmediatamente las instrucciones para responder, pues necesitan hacer una inspección general de la matriz de datos para reconocer la diagramación de la información. Esto generaría fijaciones en desorden al inicio de la serie.

Dicha inspección sería más común para un caso lexicográfico, puesto que las instrucciones de elección son más complejas y exigen mayor memoria (recordar los seis atributos y el orden específico que se les asigna). Por ende, se espera que esta variable tome el valor 1 principalmente en los casos conjuntivos que por sobre los lexicográficos.

Esta interpretación pareciera ser contradictoria a lo esperado por la definición teórica de las reglas, en donde se esperaría que en un caso perfecto la variable siempre tomase el valor 1 para una regla lexicográfica. Aún así, lo propuesto es más coherente con el comportamiento real e incierto de las personas, pues ellas están muy lejos de actuar de manera perfecta.

5.2.7. Algún Atributo Observado Completamente para la Segunda Mitad de la Serie de Fijaciones ($AtributoCompleto^{Fin}$)

Esta variable es análoga a $AtributoCompleto^{Inicio}$ pero considera la segunda mitad de la serie de fijaciones. Se espera que tome el valor 1 con las series conjuntivas, debido a que se deben mirar menos atributos para poder escoger, lo que implica que hay más probabilidades de que el encuestado mire esos atributos más veces. Por otro lado, en la serie lexicográfica se deberían descartar opciones por lo que en la última mitad, se espera contar con un mayor porcentaje de fijaciones en una opción, que en un atributo.

5.2.8. Variables derivadas de la *Serie Ideal*

Lo interesante de las variables que serán descritas, es que mezclan tanto la información del diseño de la encuesta (que es la que actualmente se utiliza para trabajar los resultados del análisis conjunto) con las fijaciones y transiciones capturadas directamente del experimento. Se plantea el concepto de *Serie Ideal*, el cual corresponde al camino perfecto que debería seguir un encuestado sin que se equivoque o desvíe en ningún momento. Además, esta serie considera que el participante procesa la información de cada una de las AOIs sin la necesidad de regresar a revalidar algún dato por falta de memoria. Por lo tanto, se esperaría que este fuera el comportamiento de un computador cuando tuviese que enfrentar un problema de selección de estos tipos.

La serie ideal se calcula para cada uno de los casos, por lo que se aprovecha la información de la misma matriz que se le presentó a cada uno de los encuestados. Esta serie también asume algunas restricciones:

- El recorrido de la serie ideal siempre comienza en la izquierda y se mueve hacia la derecha.
- Se parte en el atributo de la primera opción.
- Después de haber encontrado la alternativa correcta, no se realizan más fijaciones.

Según la definición de la regla conjuntiva es posible establecer dos series ideales que cumplen con las restricciones recién mencionadas. Una de ellas propone un recorrido vertical comparando entre los dos atributos en cuestión. La segunda, establece un movimiento inicial horizontal, similar al de la regla lexicográfica, por lo que analiza todo un atributo completo para posteriormente evaluar solo aquellos que superen los umbrales establecidos. Para el caso de la regla lexicográfica, se considera una sola serie ideal.

Hasta este punto, se tiene que para cada uno de los casos hay dos tipos series: La *Ideal* y la *Real*. Las seis variables que se describirán a continuación, pretenden hacer una comparación de estas series según los tipos de transiciones registradas (horizontal y vertical). Esta *comparación* consiste en calcular el valor absoluto de la diferencia de los porcentajes de fijaciones horizontales y verticales, una serie ideal y una serie real. Es decir:

$$Comparacion^I = \left| \frac{N_{Real}^I}{N_{Real}^{Total}} - \frac{N_{Ideal}^I}{N_{Ideal}^{Total}} \right| \quad (5.3)$$

Donde I representa el tipo de transición, que puede ser *Horizontal* o *Vertical*. De la descripción anterior, se desprenden seis variables que sirven para comparar las transiciones. Estas son:

- **Lexicográfica Horizontal Ideal (Lex^H):** Compara transiciones horizontales entre series de fijaciones lexicográficas ideal y real.
- **Lexicográfica Vertical Ideal (Lex^V):** Compara transiciones verticales entre series de fijaciones lexicográficas ideal y real.
- **Conjuntivo Vertical Horizontal Ideal ($ConjVert^H$):** Compara transiciones horizontales

entre series de fijaciones conjuntivo vertical ideal y real.

- **Conjuntivo Vertical Vertical Ideal** ($ConjVert^V$): Compara transiciones verticales entre series de fijaciones conjuntivo vertical ideal y real.
- **Conjuntivo Horizontal Horizontal Ideal** ($ConjHorz^H$): Compara transiciones horizontales entre series de fijaciones conjuntivo horizontal ideal y real.
- **Conjuntivo Horizontal Vertical Ideal** ($ConjHorz^V$): Compara transiciones verticales entre series de fijaciones conjuntivo horizontal ideal y real.

Los estadísticos descriptivos se muestran en la Tabla 5.1

Estadísticos Descriptivos				
Variables	Min	Max	Media	Desv. Std.
$N_{fijaciones}$	2	164	27,200	19,725
$AtributoTop^1$	0,181	1,000	0,441	0,163
$AtributoTop^2$	0,000	0,500	0,248	0,079
$OpcionTop^1$	0,250	1,000	0,457	0,099
$OpcionTop^2$	0,000	0,500	0,287	0,067
Lex^H	0,000	0,750	0,330	0,126
Lex^V	0,000	0,632	0,229	0,113
$ConjVert^H$	0,000	0,727	0,228	0,147
$ConjVert^V$	0,000	0,563	0,196	0,122
$ConjHorz^H$	0,000	0,750	0,403	0,134
$ConjHorz^V$	0,000	0,632	0,205	0,109
$AtributoCompleto^{Inicio}$	0,000	1,000	0,618	0,485
$AtributoCompleto^{Fin}$	0,000	1,000	0,280	0,449

Tabla 5.1: Estadísticos básicos de las variables propuestas.

5.3. Evaluación de las Variables en el Modelo Logit Binomial

Las variables propuestas se utilizaron como *entrada* en un modelo Logit con la finalidad de evaluar su calidad de predicción. Se define v_i como:

$$v_i = \beta_0 + \beta_1 N_i^{fijaciones} + \beta_2 AtributoTop_i^1 + \beta_3 AtributoTop_i^2 + \beta_4 OpcionTop_i^1 + \beta_5 OpcionTop_i^2 + \beta_6 Lex_i^H + \beta_7 Lex_i^V + \beta_8 ConjVert_i^H + \beta_9 ConjVert_i^V + \beta_{10} ConjHorz_i^H + \beta_{11} ConjHorz_i^V + \beta_{12} AtributoCompleto^{Inicio} + \beta_{13} AtributoCompleto^{Fin}$$

El modelo permite estudiar el ajuste y los errores en los que se incurrió. Para ello se trabaja con las medidas: *Matriz de confusión*, *Accuracy*, *Recall* y *True Negative*. *Accuracy* representa el porcentaje total de éxito en la predicción. *Recall* indica el porcentaje de veces en que se predice

correctamente la regla lexicográfica en este caso será denominado como $True_{Lex}$, y $True Negative$ señala el porcentaje de veces en que se predice correctamente la regla conjuntiva, que será denominado como $True_{Conj}$.

Cada uno de estos ratios se estiman de la siguiente manera:

$$Accuracy = \frac{Lex_{EsLex} + Conj_{EsConj}}{Lex_{EsLex} + Conj_{EsConj} + Lex_{EsConj} + Conj_{EsLex}} \quad (5.4)$$

$$True_{Lex} = \frac{Lex_{EsLex}}{Lex_{EsLex} + Lex_{EsConj}} \quad (5.5)$$

$$True_{Conj} = \frac{Conj_{EsConj}}{Conj_{EsConj} + Conj_{EsLex}} \quad (5.6)$$

En la Figura 5.1 se muestra la matriz de confusión con la que se trabaja, donde Lex_{EsConj} puede interpretarse como *el número de veces que el modelo predijo que un caso correspondía a una regla lexicográfica, dado que realmente era conjuntiva*. De manera análoga se interpretan las otras variaciones (Lex_{EsLex} , $Conj_{EsConj}$ y $Conj_{EsLex}$).

		Valores Predichos	
		Lex	Conj
Valores Reales	Lex	Lex_{EsLex}	$Conj_{EsLex}$
	Conj	Lex_{EsConj}	$Conj_{EsConj}$

Figura 5.1: Matriz de confusión.

El conjunto de datos con los que se trabajó fue dividido en dos subconjuntos: el primero de ellos corresponde al *conjunto de entrenamiento*, el cual está conformado por el 70 % de los casos. El segundo es el conjunto de prueba que abarca el 30 % de los casos restante. Los resultados indican que el 80,44 % de los casos son predichos correctamente, lo cual es un buen indicio de que se está capturando gran parte de la información. Además, este modelo permite identificar con mayor certeza aquellas reglas que son del tipo conjuntiva versus una lexicográfica. El valor de los coeficientes de la regresión puede verse en la Tabla 5.2.

		Valores Predichos	
		Lex	Conj
Valores Reales	Lex	373	74
	Conj	123	437

Figura 5.2: Matriz de confusión para el conjunto de entrenamiento.

Variabes	Coficiente (β)	Desv. Std.
β_0	-3,79	1,14
$N_{fijaciones}$	0,06	0,00
$AtributoTop^1$	-0,74	0,88
$AtributoTop^2$	-4,98	1,19
$OpcionTop^1$	5,79	0,97
$OpcionTop^2$	4,07	1,21
Lex^H	-13,18	1,59
Lex^V	-3,61	2,28
$ConjVert^H$	1,47	0,55
$ConjVert^V$	0,95	0,64
$ConjHorz^H$	11,44	1,76
$ConjHorz^V$	0,86	2,37
$AtributoCompleto^{Inicio}$	0,30	0,16
$AtributoCompleto^{Fin}$	-0,54	0,17

Tabla 5.2: Coeficientes del modelo Logit Binomial.

		Valores Predichos	
		Lex	Conj
Valores Reales	Lex	168	36
	Conj	56	173

Figura 5.3: Matriz de confusi3n para el conjunto de prueba.

Ratio	Muestra 70 %	Muestra 30 %
Accuracy	80,44 %	78,75 %
$True_{Lex}$	75,20 %	75,00 %
$True_{Conj}$	85,52 %	82,78 %

Tabla 5.3: Valores de los ratios para el conjunto de entrenamiento y de prueba.

El conjunto de prueba tiene un ajuste similar al del conjunto de entrenamiento, por lo que se considera un buen indicio del poder discriminante de las variables. Aun as3, no deja de ser interesante evaluar el aporte de las variables a la regresi3n y la correlaci3n que puedan tener entre ellas.

5.4. Selección de Variables y Resultados

Para la selección se realiza un Análisis Factorial para estudiar el aporte de cada variable en la regresión, además se aplica un test de Muestras Independientes para estudiar la hipótesis de si una persona sigue exactamente los movimientos teóricamente establecidos para un tipo de regla, la diferencia entre lo *ideal* y lo *real* deberá tender a cero.

5.4.1. Test de Muestras Independientes

La idea detrás de este análisis surge para comparar el comportamiento de las variables, e inspeccionar si los valores obtenidos concuerdan con lo esperado. La construcción del estadístico utilizado es la siguiente:

$$t = \frac{\bar{X}_{Lex} - \bar{X}_{Conj}}{S_{\bar{X}_{Lex} - \bar{X}_{Conj}}} \quad (5.7)$$

Variable	t	dt	Sig. (2-colas)	Media Diff.	Std. Error Diff.	Lower	Upper
<i>N</i> _{fijaciones}	16,636	652,210	0,000	17,605	1,058	15,527	19,683
<i>AtributoTop</i> ¹	-13,100	1000,221	0,000	-0,124	0,009	-0,143	-0,106
<i>AtributoTop</i> ²	-6,496	880,803	0,000	-0,032	0,004	-0,041	-0,022
<i>OpcionTop</i> ¹	4,815	1002,467	0,000	0,030	0,006	0,018	0,043
<i>OpcionTop</i> ²	3,727	1004,289	0,000	0,015	0,004	0,007	0,024
<i>Lex</i> ^H	4,268	1006,000	0,000	0,034	0,081	0,018	0,050
<i>Lex</i> ^V	1,427	970,865	0,154	0,010	0,007	-0,003	0,024
<i>ConjVert</i> ^H	1,000	971,390	0,318	0,015	0,015	-0,014	0,044
<i>ConjVert</i> ^V	2,116	1002,907	0,035	0,027	0,013	0,001	0,053
<i>ConjHorz</i> ^H	-7,672	987,627	0,000	-0,064	0,008	-0,080	-0,047
<i>ConjHorz</i> ^V	1,510	974,948	0,131	0,010	0,006	-0,003	0,023
<i>Atributo-Completo</i> ^{Inicio}	8,722	1006	0,000	0,256	0,029	0,199	0,314
<i>Atributo-Completo</i> ^{Fin}	-2,810	1006	0,005	-0,079	0,028	-0,135	-0,024

Tabla 5.4: Resultados Test de Diferencias de Medias.

Los resultados del test de diferencia de medias están en la Tabla 5.4. Acá se deduce que solo hay tres variables que no son significativas al 95 % de confianza:

- *ConjHorz*^V: Tiene sentido que sea eliminada, pues en una serie ideal conjuntiva horizontal a lo más se tendrá solo una fijación vertical, lo cual no permite hacer una comparación adecuada y significativa.

- $ConjVert^H$: Similar al caso anterior. Con un máximo de 4 fijaciones horizontales en menos del 30 % de los casos para este experimento (persona-pregunta), no es significativo para predecir.
- Lex^V : Su comportamiento es similar a $ConjHorz^V$, pero a diferencia de la primera hay más transiciones verticales, sin embargo no alcanzan a ser proporcionalmente suficientes como para ser significativas.

Las variables restantes son interesantes de analizar pues son consistentes con lo observado previamente. Las razones se explican a continuación.

- $N_{fijaciones}$: Hay más fijaciones en una regla lexicográfica que en una conjuntiva, es consistente con lo observado.
- $AtributoTop^1$: Era de esperar que el primer atributo más mirado recibiera mayor énfasis en una regla conjuntiva que en una lexicográfica, pues en la primera hay menos atributos necesarios que mirar para decidir. Esto podría implicar que el participante tuviera menos oportunidades de olvidarse de la regla, y por lo tanto se acerque con mayor facilidad a la serie ideal.
- $AtributoTop^2$: Similar al caso de la variable $AtributoTop^1$, por lo que también es útil para identificar una regla conjuntiva.
- $OpcionTop^1$: Por el desarrollo de una regla lexicográfica, se esperaría que una opción fuese recibiendo constantemente más fijaciones que el resto de las opciones que van siendo descartadas. Es consistente con lo anterior y es útil para identificar la regla lexicográfica.
- $OpcionTop^2$: Similar al caso de la variable $OpcionTop^1$. También es útil para identificar una regla lexicográfica.
- Lex^H : Es consistente con lo observado, pues hay más transiciones en una regla lexicográfica que en una conjuntiva.
- $ConjVert^V$: Esta variable indica que a pesar de tratarse de una serie conjuntiva vertical, *se realizan más transiciones verticales en una serie lexicográfica que en una conjuntiva*. Esto puede deberse a que en este experimento la serie ideal conjuntiva tendrá un máximo de cuatro transiciones verticales. A diferencia de una serie lexicográfica, que puede tener un máximo de seis. Por lo tanto, es consistente con el resto de los análisis pero es útil para identificar reglas lexicográficas.
- $ConjHorz^H$: Esta variable es consistente con la regla conjuntiva, lo que implica que las personas son más propensas a seguir una serie conjuntiva horizontal que una vertical.
- $AtributoCompleto^{Inicio}$: Dado que en una regla conjuntiva se puede mirar de dos formas (horizontal y vertical), en caso de ser vertical, la mayoría de las veces no sería necesario mirar un atributo completo para decidir. A diferencia de la regla lexicográfica que solo tiene un camino y *sí* es necesario observar un atributo por completo. Por otro lado, esto también podría cumplirse para una regla conjuntiva horizontal, aunque no necesariamente se da en todos los casos conjuntivos.

- *AtributoCompleto^{Fin}*: Debido a que en una regla conjuntiva la serie de fijaciones es más simple y focalizada, es más probable que en un segundo período de la serie se observe un atributo completo. Además en la regla lexicográfica se debiese aplicar un descarte de alternativas que no permitiría realizar dicha acción.

Considerando solo las *variables significativas*, los resultados obtenidos de correr la regresión Logit Binomial se muestran en la Tabla 5.5 en la columna de nombre *Var Sig.*.

Ratio	Muestra 70 %	Muestra 30 %	Var. Sig.
Accuracy	80,44 %	78,75 %	79,37 %
<i>TrueLex</i>	75,20 %	75,00 %	74,44 %
<i>TrueConj</i>	85,52 %	82,78 %	84,31 %

Tabla 5.5: Ratios para el conjunto de entrenamiento, prueba y variables significativas.

Se puede concluir que el tipo de transición puede ser fundamental para caracterizar una regla. Sin embargo, a pesar de que su poder predictivo sea del 80 % aún queda una brecha amplia que no puede ser explicada por las variables y da cuenta de la existencia de otros aspectos que aún no han sido capturados.

5.4.2. Análisis Factorial

El análisis Factorial se realizó para el total de los casos. La finalidad fue reducir la cantidad de variables trabajadas sin perder demasiada información. Se probó con distintas cantidades de factores hasta concluir que 10 factores eran suficientes ya que explican cerca del 97 % de la varianza.

Esta reducción pudiese parecer conservadora, pero tras un análisis de la matriz de correlación de las variables (Apéndice, Tabla C.2), se puede ver que en la mayoría de las combinaciones las correlaciones son bajas, dando cuenta del poder explicativo de las variables. El porcentaje de la varianza explicada suele ser más bien parejo, donde el valor máximo para una variable tan solo asciende a un 16 % y no establece gran diferencia con el porcentaje mínimo de una variable (cerca de un 8 %).

Los factores obtenidos, fueron ingresados al modelo Logit como variables. Los resultados muestran que el modelo con los factores, logra una predicción del 80 %, lo cual no es una gran diferencia con el ajuste de las variables originales. Por esta razón es que se decide seguir trabajando con las variables antes señaladas en lugar de los factores, puesto que tienen un poder similar de predicción y además, facilitan la interpretación.

Ratio	Muestra 70 %	Muestra 30 %	A. Factorial	Var. Sig.
Accuracy	80,44 %	78,75 %	80,00 %	79,37 %
<i>TrueLex</i>	75,20 %	75,00 %	75,42 %	74,44 %
<i>TrueConj</i>	85,52 %	82,78 %	84,58 %	84,31 %

Tabla 5.6: Resumen de los ratios para el conjunto de entrenamiento, prueba, Análisis Factorial y las variables significativas.

Como se puede observar en la Tabla 5.6, los resultados de las métricas de ajuste del modelo en cada uno de los análisis resultaron ser muy similares. Debido a esto, se optó por considerar solo las variables originales significativas, y no los factores (resultantes del análisis factorial) puesto que las primeras tienen una interpretación bastante más directa en la regresión.

5.5. Análisis de Correlación entre las Reglas y lo Observado

Se puede decir que es importante saber si las personas están mirando los atributos que deben para escoger de manera correcta, pero más interesante aún es saber si lo están haciendo de la forma en que la regla lo establece. Así es como surgen dos hipótesis a comprobar:

- **Hipótesis 1:** Las personas miran las áreas de interés que deben mirar, según la regla establecida.
- **Hipótesis 2:** La repartición de la atención para cada atributo es consistente con lo establecido en el enunciado para cada tipo de regla.

La *Hipótesis 1* surge porque se quiere comprobar que las personas adquieren la información básica necesaria para tomar la decisión correcta (según lo planteado en el experimento). Para comprobarlo, se exige que el total de las fijaciones de una serie ideal estén contenidas en la serie de fijaciones de cada persona, al menos una vez y sin importar la secuencia ni la frecuencia.

En esta comparación se tiene que en el 100 % de los casos de estudio los encuestados miraban al menos una vez todas las áreas de interés necesarias para escoger. Sin embargo, la diferencia del número de fijaciones de una serie ideal con el de una serie real es muy grande, lo que indica que:

En promedio los individuos miran alrededor de tres veces más la cantidad de atributos estrictamente necesarios.

Para probar la *Hipótesis 2*, se compara el orden de los atributos más mirados para cada una de las series, versus el orden real establecido por el diseño de la encuesta. En donde se exige que el orden de los atributos sea lo más parecido posible al establecido por la regla.

En esta comparación de órdenes se utiliza el test de Cohen Kappa, el cual se aplica en cada uno de los casos y solo para la regla lexicográfica, ya que por el diseño del experimento solo se tiene la secuencia de la importancia para todos los atributos en esta regla. Los resultados del test pueden encontrarse en las Tablas D.1 y D.2 del Apéndice D, de ellos se concluye que:

Las personas no necesariamente reparten la atención siguiendo en orden establecido en el enunciado.

Por lo tanto hay un fuerte indicio de que existen otras variables que aún no han sido identificadas que influyen en la repartición de la atención. En el próximo capítulo se verá que lo concluido de la *Hipótesis 2* es consistente con los siguientes análisis donde el porcentaje de fijaciones determina la importancia de los atributos.

5.6. Conclusiones del Capítulo

Una de las formas más comunes de predecir el comportamiento de un consumidor es utilizando un modelo Logit, que reciba como parámetros variables que capturan patrones del comportamiento de los individuos. En esta investigación, las fijaciones son los datos claves para modelar y capturar los patrones que permitan diferenciar entre una regla y otra.

Las variables propuestas surgen a partir de la investigación descriptiva desarrollada en el capítulo anterior, la que da indicios de que los tipos de transiciones pueden ser muy importantes para caracterizar el comportamiento de un individuo. No obstante, la regresión es una herramienta que, si bien logra un ajuste que puede ser considerado interesante, existen otros aspectos que no puede capturar, entre ellos destaca la *heterogeneidad*.

La heterogeneidad en este caso alude a los gustos y preferencias de los individuos, las cuales son muy diversas dependiendo de la ocasión, edad, gusto, género y necesidades, entre otros aspectos. Por lo tanto, para esta investigación la heterogeneidad resulta ser fundamental para comprender de forma más exacta las elecciones de los individuos. Así, surge la idea de indagar en otros modelos que puedan trabajar con la información visual para capturar las preferencias individuales.

Por otro lado, y antes de continuar con la investigación a nivel individual, se determinaron dos hipótesis relevantes que están relacionadas a la forma en que un participante reparte su atención visual. Esto se llevó a cabo a partir de un estudio de los ordenes de atributos de una regla lexicográfica, en donde se concluyó que las personas siempre recogen la información básica necesaria que les permite escoger, sin embargo, la atención visual no sigue el patrón dado en las instrucciones.

Capítulo 6

Heurísticas de Predicción de Órdenes e Información Visual

Una de las conclusiones obtenidas hasta el momento, es que las personas siguen las instrucciones de manera de dar con la alternativa correcta. Sin embargo, la repartición de la atención es variada y depende de otros factores. En este capítulo se pretende indagar en esta última idea, con el objetivo de descubrir las preferencias individuales entre los atributos. Los siguientes pasos de la investigación estarán concentrados en la regla lexicográfica, ya que se trabaja con el orden de preferencias de los atributos.

6.1. Utilidad Lexicográfica

La utilidad lexicográfica, tal como su nombre lo indica, corresponde al beneficio que le genera un conjunto de atributos a un encuestado. Esta función fue propuesta por Kohli y Jedidi (2007), y tiene la particularidad de que cumple con algunas características exclusivas de la regla lexicográfica. La función de utilidad, tiene al siguiente forma:

$$u(x_k) = \frac{x_{r_1}^k}{n_{r_1}} + \frac{x_{r_2}^k}{n_{r_1} n_{r_2}} + \dots + \frac{x_{r_J}^k}{n_{r_1} n_{r_2} \dots n_{r_J}} \quad (6.1)$$

En donde k representa la opción y x_j^k el valor específico que toma el atributo j para la opción k . A estos diferentes valores del x_j^k , para un k y j en particular, se les conoce con el nombre de *niveles*. Los *niveles* se representa como n_j , dependiendo solo del atributo j . También existe un vector $r = (r_1, r_2, \dots, r_J)$, que *representa el orden de los atributos según su importancia estimada*. Donde r_1 , representa el atributo más importante, r_2 el segundo atributo más importante y así sucesivamente.

La función de utilidad lexicográfica tiene la característica de ser ordinal, puesto que solo puede comparar el orden de los valores de utilidad $u(x_k)$, pero la diferencia entre ellos no se puede interpretar. Otra característica fundamental de esta función, es que para aquellos elementos que tienen mayor importancia según el orden establecido por el vector r_j , no existe una combinación del resto

de los atributos (de menor prioridad) en la cual la utilidad generada sea mayor o igual a la que genera un atributo de mayor prioridad. Es por ello que esta función cumple perfectamente con las exigencias de una regla lexicográfica.

6.2. Heurística Greedy

Esta heurística funciona por medio del algoritmo Greedy, el cual busca soluciones que son óptimas localmente, y así encontrar un óptimo global (Chvatal, 1979). Para el caso particular de esta investigación, el algoritmo trabaja con la información de las elecciones de los participantes, en conjunto con la matriz de opciones-atributos.

Un concepto importante que será utilizado más adelante corresponde al de *hit rate*, el cual es un indicador del porcentaje de veces que el valor predicho por un modelo, coincide con el valor real. En este caso, el *hit rate* define el porcentaje de los casos en que las alternativas arrojadas por Greedy coincide con las alternativas reales escogidas por los encuestados.

A continuación se explican los pasos que sigue la Heurística Greedy:

1. Se definen las variables específicas del problema (número de participantes, elecciones, opciones y cantidad de preguntas por participante, entre otras cosas).
2. Para cada persona se calcula el *hit rate* por atributo.
3. Se selecciona el atributo que posee el máximo *hit rate* y se fija como el atributo más importante en el orden de preferencias.
4. Se continúa buscando el siguiente atributo más importante en el resto de los atributos.
5. Se itera el proceso calculando los *hit rate*. Así hasta haber ordenado todos los atributos.

Este tipo de heurística es útil para predecir el orden de importancia de atributos, especialmente para las personas que usan reglas como la lexicográfica.

6.3. Modelo de Fijaciones No Compensatorio

Este modelo está basado en el supuesto de que *las personas observan aquellos atributos que les generan un mayor interés*. Siguiendo la lógica de una regla lexicográfica que exige disponer de un orden de preferencias de los atributos, se plantea dicho orden en base al *porcentaje de fijaciones por atributo* respecto del total de fijaciones realizadas por persona.

Es decir, aquellos atributos que posean más fijaciones, son los que ocuparán los primeros lugares en el orden de importancia. De forma análoga para los atributos que poseen menos fijaciones. Por lo tanto, el orden decreciente de los porcentajes de fijaciones se utiliza como el orden de importancia de los atributos para cada uno de los participantes.

6.4. Comparación de la Heurística Greedy con la Información Visual

Tanto la heurística Greedy como el Modelo de Fijaciones no compensatorio, generan un orden de importancia de los atributo que se comparan para estudiar la predicción de las elecciones. Otros dos ordenes de importancia que serán utilizado más adelante, son:

- **Orden de Instrucción:** Este es el orden que se les da a los participantes en las instrucciones de cada pregunta.
- **Orden Observado:** Asumiendo que la personas utiliza una regla del tipo lexicografica, este corresponde al orden de importancia exacto que usan los participantes, el cual no necesariamente es el mismo que el orden de instrucción y tiene la característica de que su *hit rate* es del 100 %.

6.4.1. Consistencia de los Distintos Órdenes de Importancia de Atributos

Para cada uno de estos órdenes, se estudian las coincidencias entre ellos mismos, en donde se exige que un número de atributos coincida. Específicamente, se analizan los atributos más importantes, luego los dos primeros más importantes, y así sucesivamente hasta dar con el total de atributos.

Las metodologías que participan en este análisis son la Heurística Greedy, orden de instrucción y el orden dado por el Modelo de Fijaciones no compensatorio. Los resultados obtenidos se muestra en la Tabla 6.1, y que también se encuentran gráficamente en la Figura 6.1.

Atributos Considerados (Según importancia)	Instrucción - Greedy	Instrucción - Fijaciones	Greedy - Fijaciones
1°	91,67 %	80,00 %	80,00 %
1° y 2°	65,00 %	50,00 %	38,33 %
1°, 2° y 3°	38,33 %	23,33 %	20,00 %
1°, 2°, 3° y 4°	28,33 %	15,00 %	8,33 %
1°, 2°, 3°, 4° y 5°	20,00 %	10,00 %	5,00 %

Tabla 6.1: Coincidencias por grupo de atributos.

Como es de esperar, se tiene que mientras más exigencia hay en la condición de atributos, menos es el porcentaje de coincidencia. Sin embargo, la disminución es muy acentuada, sobre todo al exigirlo en dos o más atributos, cuyos porcentajes no superan el 38 %.

Otra tendencia importante, indica que la similitud entre el orden generado por Greedy con el de las instrucciones, tiene una mayor coincidencia que el orden de las instrucciones con el de las fijaciones. A su vez, estas comparaciones tienen una mayor similitud que lo predicho por Greedy y la fijaciones.




Figura 6.1: Distribución gráfica de los resultados de la Tabla 6.1.

6.4.2. Comparación por Atributo Independiente

Otro análisis interesante es observar las predicciones de los atributos, pero esta vez de forma independiente, es decir sin considerar las coincidencias en el resto de los atributos. Acá los ordenes que se comparan son los obtenidos de los mismos métodos establecidos en el punto anterior. Los resultados arrojados están en la Tabla 6.2.

r_j	1°	2°	3°	4°	5°	6°
Instrucción - Greedy	91,67 %	65,00 %	40,00 %	40,00 %	41,67 %	50,00 %
Instrucción - Fijaciones	80,00 %	50,00 %	35,00 %	33,33 %	43,33 %	45,00 %
Greedy - Fijaciones	80,00 %	38,00 %	30,00 %	26,67 %	41,67 %	35,00 %

Tabla 6.2: Resultados de la comparación de atributos independientes.

Al analizar los atributos de manera independiente, se tiene que nuevamente el atributo más importante es el que tiene un mayor nivel de coincidencias, seguido por el segundo, tercero y cuarto atributo según su respectiva importancia.

No obstante, un efecto que se produce en los atributos quinto y sexto, es un aumento en las coincidencias, lo que puede estar explicado porque el individuo tiene conocimiento claro de lo que prefiere y de lo que no, por lo que los valores que están en medio son los que causan más ruido en la predicción.

Coincidencias por atributo independiente

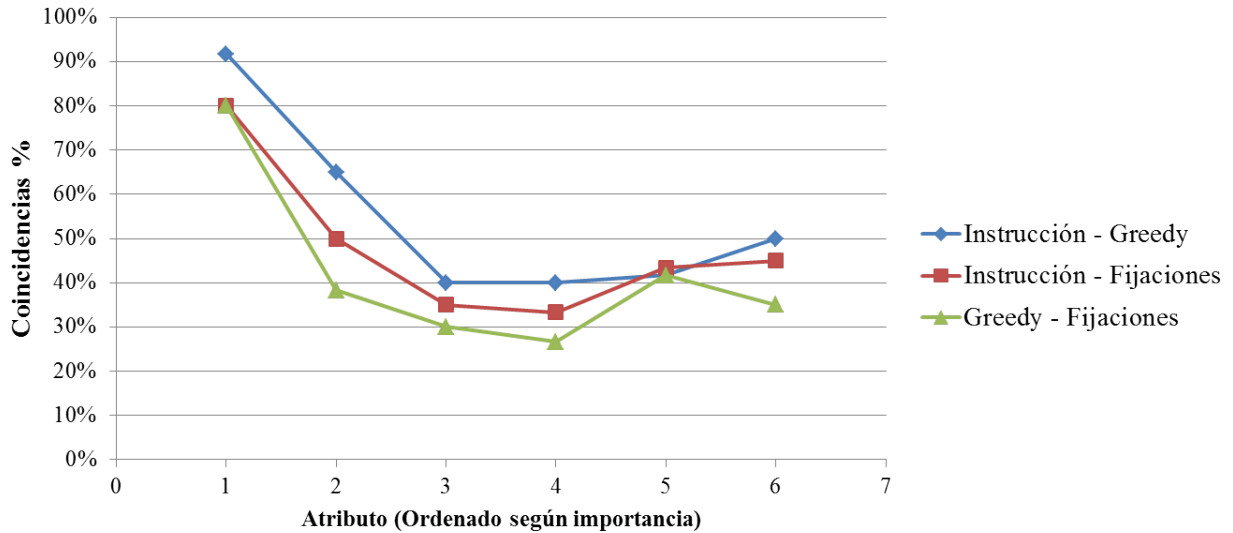


Figura 6.2: Distribución gráfica de los resultados de la Tabla 6.2.

6.4.3. Hit Rate

Hasta este punto, solo se ha analizado los órdenes sin considerar la elección. Lo que se presenta a continuación es un análisis basado en las elecciones hipotéticas que tendría una persona que sigue de manera perfecta la regla lexicográfica, aplicando un orden de preferencias dado. En esta oportunidad son tres órdenes diferentes: El obtenido por Greedy, el del modelo de Fijaciones y el de las instrucciones. Para cada uno, se calculan los *hit rate* bajo dos escenarios distintos:

- Hit Rate 1: La comparación es con las alternativas del orden observado.
- Hit Rate 2: La comparación con las alternativas obtenidas del orden de las instrucciones.

Órdenes	Hit Rate 1	Hit Rate 2
Observado	100,00 %	-
Instrucciones	91,94 %	100,00 %
Greedy	93,47 %	95,83 %
Fijaciones	77,78 %	75,83 %

Tabla 6.3: Resultados de los casos del *hit rate* tipo 1 y tipo 2.

Para la estimación del *hit rate* 1 en el caso del modelo de Fijaciones, se obtiene un valor de 77,78 %, el cual es un buen indicio de la predicción. Sin embargo, los otros dos órdenes obtienen resultados mucho mejores, cuyos valores alcanzan el 91,94 % para las instrucciones y 93,47 % para Greedy. A pesar de esta diferencia, cabe destacar que la estimación de las fijaciones cuenta con dos ventajas importantes:

- La estimación no trabaja con la elección (A diferencia de la heurística Greedy).
- No conoce la regla impuesta (A diferencia del orden de las instrucciones).

Lo anterior permite concluir que bajo un escenario de mayor desconocimiento en donde no se conocen las elecciones o las reglas, las fijaciones podrían ser una herramienta factible para estimar las elecciones.

Otro efecto que se desprende, es que la predicción de Greedy es levemente mayor que el predicho por las instrucciones. Las razones detrás de este efecto aluden al diseño de la heurística, debido a que se construye para en base a la maximización del *hit rate*, incluyendo aquellos casos en los cuales los encuestados se equivocaron. Por lo tanto, los errores de elección de los encuestados perjudican directamente al orden de las instrucciones, y no al establecido por la heurística.

Para el caso de la estimación del *hit rate 2*, se tiene que el valor obtenido por Greedy es mejor aún que en el caso anterior, ascendiendo al 95,83 %, no así para el caso de las fijaciones que disminuyen a un 75,83 %. La variación obtenida de la estimación, leve en ambos casos, puede estar explicada por el manejo de los errores de los encuestados. Por ejemplo en el caso de las fijaciones, si la persona se equivoca y pone mayor atención en la alternativa incorrecta, es más probable que no coincida con la respuesta ideal. Por otro lado, para la estimación de Greedy solo se trabaja con las respuestas obtenidas y crea un orden ideal, así es como logra una mejor estimación.

6.4.4. Hit Rate Según Dificultad

Otra forma de estudiar los resultados, es comparar las alternativas escogidas por cada orden, pero considerando las diferentes dificultades de la regla lexicográfica. Desarrollar este análisis se clasificaron las preguntas en tres tipos: *fácil*, *medio* y *difícil*. Esta clasificación se desprende según la dificultad aplicar una regla lexicográfica. La clasificación es la siguiente:

- **Fácil** (Valor 1): Si es necesario consultar 1 o 2 atributos para decidir.
- **Medio** (Valor 2): Si es necesario consultar 3 o 4 atributos para decidir.
- **Difícil** (Valor 3): Si es necesario consultar 5 o 6 atributos para decidir.

El resumen de los resultados se muestra en las Tablas 6.4 y 6.5. Como se pudo observar, se predice con mayor exactitud en los casos difíciles, seguido por los de dificultad fácil y, finalmente, los medios.

Hit Rate 1			
-	Instrucciones - Observado	Instrucciones - Greedy	Instrucciones - Fijaciones
Fácil	90,83 %	94,17 %	82,92 %
Medio	90,83 %	91,25 %	71,25 %
Difícil	94,17 %	95,00 %	79,17 %

Tabla 6.4: Resumen de resultados para un *hit rate 1*, en los tres niveles de dificultad.

Al referirse a los métodos implementación, se tiene que la heurística Greedy continúa siendo la que tiene un mayor nivel de acierto, tanto con las elecciones reales, como con las derivadas de las instrucciones. Los efectos producidos acá son para ambos tipos de *hit rate* (1 y 2).

Hit Rate 2		
-	Observado - Greedy	Observado - Fijaciones
Fácil	95,83 %	80,42 %
Medio	94,17 %	67,92 %
Difícil	97,50 %	79,17 %

Tabla 6.5: Resumen de resultados para un *hit rate* 2, en los tres niveles de dificultad.

6.4.5. Heurística Greedy sin los Casos de Respuestas Erroneas

Anteriormente se habían considerado todas las elecciones de los participantes. No obstante, la heurística Greedy se equivoca cuando la elección de los encuestados es la incorrecta. Por lo tanto se realiza otro análisis en donde no se consideran aquellos casos con respuestas erróneas. Los resultados son los siguientes:

Hit Rate 1			
-	Instrucciones - Observado	Instrucciones - Greedy	Instrucciones - Fijaciones
Fácil	100,00 %	99,54 %	85,32 %
Medio	100,00 %	97,71 %	72,48 %
Difícil	100,00 %	99,12 %	81,50 %

Tabla 6.6: Resumen de resultados para el *hit rate* sin considerar las respuestas erróneas en los tres niveles de dificultad.

Los resultados arrojados son mejores que los del punto 6.4.4, lo que se interpreta como la disminución del *ruido* que afectan la predicción.

6.5. Conclusiones del Capítulo

En este capítulo, se trabaja con modelos que permitan generar un orden de importancia de los atributos, tal como el utilizado en la regla lexicográfica. Una heurística cumple con lo anterior y trabaja con la información de las elecciones, es la heurística Greedy. Para comparar estos resultados se crea un Modelo de Fijaciones, que también propone órdenes de importancia de atributos. También se cuenta el orden dado por las instrucciones.

Tanto la heurística Greedy como el modelo de las Fijaciones, puede ser comparados desde varios aspectos. La primera comparación considera solo el primer atributo que ambas reglas señalan como el más relevante, respecto al orden dado por las instrucciones. Aquí se tiene que las coincidencias de Greedy alcanzan un 91,67 % en contraste con el modelo de Fijaciones que solo llega al 80 %. Siendo ambos valores muy altos.

Al considerar las elecciones en la comparación de los métodos, se pueden estimar la predicción a través de los *hit rate*. En donde los resultados para la heurística son más ventajosos aún, alcanzado

valores entre un 93,4 % y 95,8 %, mientras que en el modelo de Fijaciones las predicciones están en un rango del 75,8 % y 77,7 %.

Cabe destacar que estos valores para el modelo de Fijaciones, son considerados muy alto y buenos predictores, pues este modelo no recurre a las respuestas de los individuos, mientras que la heurística Greedy si. Esto último podría explicar el hecho de que en algunos casos, Greedy alcance un mejor resultado que el mismo orden de las instrucciones, debido a que los errores en la elección pueden sobre ajustar la heurística.

Para finalizar, al considerar la dificultad en el análisis se tiene que los resultados obtenidos están en un rango similar a los anteriores, pero sucede un efecto en donde las preguntas de mayor dificultad alcanzan una mejor predicción que las de menor dificultad, y a su vez son mejores que las de dificultad media. Este efecto se atribuyen a que las personas saben que aspectos prefieren y cuales no, siendo los aspectos medios los que generan mayor confusión.

Capítulo 7

Aplicación en una Base de Datos Experimental de Cafeteras

Hasta este punto se ha trabajado con reglas de elección del tipo no compensatorias en conjunto con la Heurística Greedy. No obstante, en la realidad los consumidores toman sus decisiones de muchas formas distintas, donde los métodos de elección compensatorios toman mayor relevancia y son interesantes de analizar.

Los resultados expuestos en el capítulo anterior, indican que los niveles de predicción de las técnicas utilizadas son muy altos (del orden del 95 % en algunos casos), razón por la cual no se continúa investigado bajo este contexto, ya que las posibles mejoras pueden no ser significativas. Así, surge la necesidad de evaluar las elecciones de los consumidores en un nuevo escenario en donde no se les impone un tipo de regla de decisión a seguir, sino que deben hacerlo bajo sus propios criterios. El experimento fue realizado por Martin Meißner y se detalla en la sección siguiente:

7.1. Descripción del Experimento

El siguiente experimento consiste en la elección de comprar una máquina cafetera, en donde el encuestado tiene cuatro opciones diferentes: tres productos de cafeteras distintas entre sí, y la posibilidad de *No Comprar*. El diseño utilizado para mostrar los atributos de cada producto es similar al del experimento anterior. La encuesta se realizó a un total de 62 personas, pero sólo 60 de ellas respondieron válidamente, ya que las dos personas restantes escogieron siempre la opción de *No Comprar*. Todos los encuestados son estudiantes universitarios alemanes y cada uno de ellos se enfrentó a 14 preguntas.

Los atributos que debieron considerar son: marca, material, sistema, diseño, precio de una taza, y el precio de la máquina. A su vez, cada uno de estos seis atributos puede tomar diferentes valores dentro de un rango definido. Estos valores se presentan en la Tabla 7.1. Cada una de las alternativas fue creada al azar para cada persona y ocasión de respuesta, excepto la pregunta número 8, que se generó igual para todos los encuestados.

Atributo	Característica 1	Característica 2	Característica 3	Característica 4
Marca	Braun	Krups	Philips	Severin
Material	Stainless Steel	Plastic	Brushed Aluminium	
Sistema	Pad	Capsule		
Diseño	Design A	Design B	Design C	Design D
Precio por Taza	0.12	0.22	0.32	
Precio	99.99	129.99	159.99	189.99

Tabla 7.1: Tabla con los posibles valores para cada atributo.

If you were in the market to buy a new single-cup coffee brewer and these were your only options, which would you choose?

	A	B	C	D
brand	BRÄUN	PHILIPS	SEVERIN	
material	plastic	Brushed aluminium	Stainless steel	
system	pad	capsule	pad	
design	Design A	Design B	Design C	
price of a cup	32Cent	22Cent	12Cent	
price	189.99	129.99	159.99	None: I wouldn't choose any of these.

Figura 7.1: Diseño de un conjunto de opciones para un análisis conjunto basado en opciones, Martin Meißner and Reinhold Decker (2009).

Si bien la captura de las fijaciones es similar a la del experimento anterior, la gran diferencia en este nuevo escenario es que *no se les indica a los encuestados qué tipo de regla seguir, sino que deben escoger libremente siguiendo sus preferencias.*

Además, se decidió trabajar solo con aquellas respuestas en donde los encuestados decidían comprar alguna cafetera ficticia, es decir que se eliminaron aquellos casos en donde se escogió *No*

Comprar, lo cuales representan cerca del 16 % del total de las respuestas. Esta medida se justifica en los requerimientos de los modelos compensatorios y no compensatorios que son descritos y aplicados más adelante. Luego, todos los modelos se trabajan con la misma base de datos que excluye la opción de *No Comprar*.

Los datos también fueron divididos en dos conjuntos: uno con el 70 % de los datos correspondiente al *Conjunto de Entrenamiento*, y otro con el 30 % restante correspondiente al *Conjunto de Prueba*. Los elementos de cada conjunto fueron escogidos de manera aleatoria.

El objetivo de esta medida es poder calibrar los modelos de elección y estimar los parámetros con los datos del conjunto de entrenamiento y luego evaluar la predicción con los datos del conjunto de prueba. En primera instancia se probará con la Heurística Greedy que predice un orden de importancia de atributos tal como el que utiliza la regla lexicográfica.

7.2. Heurística Greedy

Se aplica la Heurística Greedy en el conjunto de entrenamiento para estimar los órdenes de preferencia de cada individuo. Posteriormente, en el conjunto de prueba y entrenamiento se estiman las elecciones de cada participante basadas en los órdenes de preferencia (generado por Greedy en el conjunto de entrenamiento).

De esta manera es posible calcular los *Hit Rate* de la Heurística para cada uno de los conjuntos. Los resultados obtenidos se muestran en la Tabla 7.2.

Hit Rate		
Modelo	Conjunto de Entrenamiento	Conjunto de Prueba
Heurística Greedy	41,51 %	29,45 %

Tabla 7.2: Hit Rate para la Heurística Greedy.

Los resultados indican que la heurística puede presentar un cierto sobreajuste en la estimación, ya que su *hit rate* en el conjunto de entrenamiento es cerca de un 12 % mayor que en el conjunto de prueba.

Por otro lado, la fuerte caída en la calidad de predicción respecto a la predicción del capítulo anterior, es atribuida al diseño de la heurística Greedy ya que asume que las personas escogen bajo una regla de decisión lexicográfica, lo cual no es necesariamente cierto en este experimento. Aun así, estos valores son un buen indicio de la diferencia del ajuste en este nuevo contexto, y lo errado que puede estar un modelo al asumir que la elección es siempre lexicográfica. Por esto que surge la necesidad de indagar en modelos de elección compensatoria.

7.3. Modelo Compensatorio: Mixed Logit

El modelo compensatorio escogido, corresponde a un Mixed Logit debido a su característica de *flexibilidad*, porque puede adaptar sus parámetros a casi cualquier modelo de utilidad y, particularmente, consigue asemejarse a un modelo de decisión lexicográfica.¹

El modelo Mixed Logit se define en base a la probabilidad que se le asigna a cada una de las opciones para ser escogidas. Estas especificaciones del comportamiento individual, permite generar parámetros diferentes para cada individuo, lo que le otorga una ventaja de heterogeneidad de estas estimaciones. Matemáticamente, las probabilidades mencionadas pueden representarse por:

$$P_{ni} = \int L_{ni}(\beta) f(\beta) d\beta$$

Donde $f(\beta)$ es la función de densidad en el parámetro β y $L_{ni}(\beta)$ es la probabilidad Logit evaluada en el parámetro β .

Al despejar el parámetro $L_{ni}(\beta)$ de la ecuación anterior y trabajar de forma discreta, la fórmula resultante es:

$$L_{ni}(\beta) = \frac{e^{V_{ni}(\beta)}}{\sum_{j=1}^J e^{V_{nj}(\beta)}}$$

Donde $V_{ni}(\beta)$ es la utilidad observada. Además, el modelo Mixed Logit considera una mezcla de diferentes funciones evaluadas en los distintos parámetros β , cada uno con su respectiva función de densidad $f(\beta)$. Por lo tanto, si la utilidad es lineal en β se tiene que $V_{ni}(\beta) = \beta' x_{ni}$.

Esta distribución mixta puede ser discretizada cuando los parámetros β toman un conjunto finito de valores distintos. Suponiendo que β puede tomar M posibles valores $\beta_1, \beta_2, \dots, \beta_M$ y con probabilidad s_m se tiene que $\beta = \beta_m$, en este caso se tiene que el modelo Mixed Logit se convierte en un *Modelo de Clase Latente* cuya fórmula de la probabilidad es conocida y se representa como:

$$P_{ni} = \sum_{m=1}^M s_m \left(\frac{e^{\beta'_m x_{ni}}}{\sum_j e^{\beta'_m x_{nj}}} \right)$$

También existe un segundo conjunto de parámetros que describen la función de densidad $f(\beta)$. El parámetro que describe la densidad de β es θ , donde la probabilidad de elección pasa a ser una función de este nuevo parámetro tomando la forma:

$$P_{ni}(\theta) = \int L_{ni}(\beta) f(\beta|\theta) d\beta$$

Bajo este contexto, es interesante estimar el valor de los β para cada uno de los tomadores de decisión y, además, conocer la distribución con el parámetro θ .

¹Para indagar más sobre el Modelo Compensatorio Mixed Logit, se recomienda ver el libro *Discrete choice methods with simulation* de Kenneth Train, publicado por Cambridge University, en el año 2009 (Train, 2009).

7.3.1. Aplicación del Modelo Mixed Logit a los Datos Experimentales

El modelo Mixed Logit se aplicó a la base de datos de entrenamiento para estimar los parámetros, que luego son puestos a prueba en el otro conjunto de datos. Los resultados obtenidos pueden verse en la Tabla 7.3.

Hit Rate		
Modelo	Conjunto de Entrenamiento	Conjunto de Prueba
Mixed Logit	53,88 %	28,17 %
Heurística Greedy	41,51 %	29,45 %

Tabla 7.3: Hit Rate para el modelo Mixed Logit y la Heurística Greedy.

Al analizar los valores del los *Hit Rate*, se tiene que las características de *flexibilidad* y *heterogeneidad* del modelo Mixed Logit permiten que alcance un alto valor de predicción en el conjunto de entrenamiento (cerca del 54 %), sin embargo, la diferencia en la predicción respecto al conjunto de prueba es de aproximadamente un 26 %, lo que señala un posible sobreajuste que impacta negativamente en su poder de predictorio.

7.4. Modelo No Compensatorio: Lexicographic Elimination By Attributes (LBA)

Si bien este modelo también asume que los individuos utilizan una regla lexicográfica para escoger, a diferencia de la heurística Greedy, LBA permite integrar mayor heterogeneidad a nivel de personas y de preguntas. En su implementación considera aspectos importantes: *Incertidumbre en el orden de los atributos* y *utilidad lexicográfica* (esta última está descrita en el punto 6.1).

LBA asume que el orden de los atributos que utiliza una persona es desconocido, lo que permite que ante un mismo escenario dos personas con órdenes de preferencias distintos puedan tomar elecciones diferentes (Tversky, 1972b). Un modelo similar al utilizado en este estudio, fue trabajado por Kohli y Jedidi en el 2007 donde se detalla el modelo LBA en mayor profundidad. A continuación se explican las principales características.

7.4.1. Incertidumbre en el orden de los atributos

Se considera que un producto tiene $J \geq 2$ atributos, para un total de T casos. La *importancia no observada* se define para todo $j = 1, \dots, J$ y $t = 1, \dots, T$, como:

$$w_{jt} = v_j + \varepsilon_{jt} \quad (7.1)$$

Donde ε_{jt} es la componente aleatoria y v_j es la componente sistemática, que representa la importancia que una persona le asigna al atributo j , la que puede estar definida como $v = (v_1, \dots, v_J)$.

Siguiendo con la misma nomenclatura, se define el vector $r = (r_1, \dots, r_J)$ que representa el orden de preferencia atributos del participante ². De esta forma, es que $r_s = j$, cuando j es el s -mo valor más importante. Por lo tanto, es interesante estudiar la relación y el *parentesco* entre el orden estimado por v_j y propio de los participantes r_j . La forma de comparar estos órdenes es por medio de la probabilidad $P(r|v)$, que se obtiene a través de un modelo Logit de Orden, y se representa como:

$$P(r|v) = P(w_{r_1} > \dots > w_{r_J}) = \prod_{s=1}^{J-1} \frac{e^{v_{r_s}}}{e^{v_{r_s}} + \dots + e^{v_{r_J}}} \quad (7.2)$$

Arbitrariamente se impone $v_J = 0$, ya que este modelo se define solo cuando la utilidad del atributo J está ajustada.

7.4.2. Descripción del Modelo Jerárquico Bayesiano

En la estimación del v_j (de la ecuación 7.1) se tiene que los parámetros β_{ij} son variables en la población de acuerdo a una distribución $f(\beta_i|X)$ y el término aleatorio ε_{ij} distribuye valor extremo. La inferencia Bayesiana permite encontrar la probabilidad $P(\beta_j|X)$, que se define como una actualización de las creencias previas respecto al parámetro β_j .

Por otro lado, la Jerarquía en un modelo puede ser útil para brindar información *a priori* de la toma de decisión. Así, al incluir ambos aspectos y trabajarlos como un Modelo Jerárquico Bayesiano, se estiman los parámetros teniendo en consideración que los datos describen el comportamiento individual de los consumidores y agregado de la población. En esta misma línea, la distribución de un parámetro β_{ij} está dada por:

$$\beta_{ij} \sim N(\bar{\beta}_j, V_\beta) \quad (7.3)$$

Al analizar cada uno de los β_j individuales, se tiene la información poblacional o *prior*, β_j y V_β . Además, se estiman los valores para los parámetros poblaciones, también conocidos como *hyper-priors*:

$$\bar{\beta}_{ij} \sim N(\bar{\bar{\beta}}_j, A) \quad (7.4)$$

$$V_\beta \sim IW(\nu, \Psi) \quad (7.5)$$

Finalmente el cálculo de la probabilidad de los parámetros es:

$$p(\{\beta_i\}, \bar{\beta}, V_\beta|X) = \prod_i \left(\prod_t p(v_{ijt}|x_{jt}, \beta_{ij}) \right) p(\beta_i|\bar{\beta}, V_\beta) p(\bar{\beta})(V_\beta) \quad (7.6)$$

Con esta estimación de los parámetros β_j , se utiliza el método numérico de la máxima verosimilitud simulada (SML) para encontrar el valor más certero posible. Otras especificaciones del modelo se encuentran en el Apéndice F.

²Se refiere el mismo r_j mencionado en la sección 6.1

7.4.3. Lexicographic Elimination By Aspects con Fijaciones

El modelo se basa en la aplicación del método Jerárquico Bayesiano (Rossi, Alenby y McCulloch 2005) que estima las reglas lexicográficas de los individuos, para un conjunto de datos con sus respectivas elecciones.

Como se estudió en los capítulos anteriores, las fijaciones dan una muestra del comportamiento previo al proceso de elección. Así, con la intención de complementar los modelos actuales con la información de las fijaciones, ya que solo trabajan con la elección como información, es que se propone la siguiente estimación para el parámetro v_{ij} :

$$v_{ij} = \beta_{ij}^1 Var_{ij}^1 + \beta_{ij}^2 Var_{ij}^2 + \varepsilon_{ij} \quad (7.7)$$

Donde cada una de las variables Var_{ij}^n , se crean a partir de las fijaciones para la persona i en el atributo j .

Variables	
Var_{ij}^1	Corresponde al porcentaje de fijaciones en el atributo j .
Var_{ij}^2	Variable <i>dummy</i> que toma el valor 1 si en la primera mitad de la serie el atributo j se miró en todas las alternativas, 0 si no.

Tabla 7.4: Variables utilizadas en la estimación de v_{ij} en el modelo LBA.

El diseño de estas variables nace de las pruebas anteriores de la sección 5.4.1, en donde se demuestra que la cantidad de fijaciones generadas en un cierto atributo, puede significar el interés que una persona tiene por él, lo cual es exactamente lo que pretende estimar el valor del v_j . La justificación detrás de la segunda variable proviene del punto 5.2.6, en donde se intenta capturar el comportamiento no compensatorio de los individuos.

Los resultados de la aplicación del modelo LBA y su versión modificada que integra las fijaciones, puede verse en la Tabla 7.4. A diferencia de los otros modelos, (Mixed Logit y la Heurística Greedy), los del tipo LBA son más consistentes en sus predicciones entre los conjuntos de entrenamiento y de prueba, puesto que la diferencia entre ellos no supera el 2 %. Si bien, los resultados del conjunto de entrenamiento son los menores, presentan una mayor tasa de predicción al compararlo en el conjunto de prueba.

Cabe destacar también que los resultados entre los modelos LBA y LBA con Fijaciones, son muy similares, siendo los resultados del LBA con Fijaciones levemente mejores que los del LBA (cerca de un 5 % mejores al comparar los resultados en los conjuntos de prueba), por lo que se podría pensar que las fijaciones no son un gran aporte para complementar un modelo que actualmente utiliza las respuestas como información base. Este resultado puede deberse a que la información que entregan las fijaciones es *del mismo tipo* que la que generan las respuestas, por lo que el aporte extra no es significativo.

Hit Rate		
Modelo	Conjunto de Entrenamiento	Conjunto de Prueba
LBA con Fijaciones	30,39 %	33,11 %
LBA	33,60 %	28,14 %
Mixed Logit	53,88 %	28,17 %
Heurística Greedy	41,51 %	29,45 %

Tabla 7.5: Hit Rate para el modelo LBA con fijaciones, LBA tradicional, Mixed Logit y Heurística Greedy.

7.5. Modelo de Fijaciones

Hasta el momento, la información de las fijaciones solo se ha utilizado para complementar un modelo ya existente, y no se ha considerado el valor de predicción que pueden generar por si solas. Bajo este supuesto, se propone dos modelos de elección conformados solo en base a las fijaciones sin considerar la elección de los encuestados, pero sí la matriz de opciones.

Uno de los modelos propuestos es del tipo no compensatorio y está basado en una regla lexicográfica. El otro modelo, es del tipo compensatorio y está basado en un modelo Logit simple. El detalle de cada uno de ellos se describe a continuación.

7.5.1. Modelo de Fijaciones No Compensatorias

El modelo propuesto es el mismo que el descrito en la sección 6.3, en donde se trabaja con el porcentaje de fijaciones respecto del total de las fijaciones de una persona, para obtener la importancia de los atributos.

La estimación de estos órdenes, se calcula en el conjunto de entrenamiento que ha sido utilizado en los modelos anteriores, para luego generar las elecciones tanto en el conjunto de prueba y entrenamiento. Los resultados de los *hit rate* para el modelo de fijaciones No Compensatorias se muestran en la Tabla 7.6.

Hit Rate		
Modelo	Conjunto de Entrenamiento	Conjunto de Prueba
Fijaciones No Compensatorias	27,44 %	33,56 %
LBA con Fijaciones	30,39 %	33,11 %
LBA	33,60 %	28,14 %
Mixed Logit	53,88 %	28,17 %
Heurística Greedy	41,51 %	29,45 %

Tabla 7.6: Hit Rate para el modelo de Fijaciones no Compensatorio, LBA con fijaciones, LBA tradicional, Mixed Logit y Heurística Greedy.

Si bien los resultados obtenidos son los más bajos hasta el momento, con un 27 % para el conjunto de entrenamiento, es interesante observar que para el conjunto de prueba el ajuste resulta ser el más alto, cerca de un 34 %. Este mismo efecto, donde los valores del conjunto de entrenamiento son menores que los del conjunto de prueba, se produce también en el modelo LBA con fijaciones, lo que puede indicar que las fijaciones no permiten sobre-ajustar un modelo, pero sí mejoran su índice de predicción.

7.5.2. Modelo de Fijaciones Compensatorias

El modelo de Fijaciones compensatorias tiene la forma de una regresión lineal, en donde los valores de los parámetros β corresponden al porcentaje de fijaciones. Esta regresión se representa a continuación:

$$U_i^{kd} = \beta_{11}^k X_{11}^{kd} + \dots + \beta_{21}^k X_{21}^{kd} + \dots + \beta_{31}^k X_{31}^{kd} + \dots + \beta_{41}^k X_{41}^{kd} + \dots - \beta_5^k X_5^{kd} - \beta_6^k X_6^{kd} \quad (7.8)$$

Donde U_i^{kd} es la utilidad de la opción d escogida por la persona i en la tarea k . Las variables X_{jn}^{kd} se generan a partir de la información de la matriz de opciones-atributos que se le muestra a cada encuestado. Los valores β_{jn}^k son el porcentaje de fijaciones destinadas en la tarea k , en el atributo j para el nivel n .

A modo de ejemplo, si una persona en su pregunta número 7, en el atributo *Material* le aparece el nivel *Stainless Steel*, se contarán todas las fijaciones que la persona realizó en la casilla donde aparece el nivel *Stainless Steel*. Suponiendo que la persona realiza 14 fijaciones, en la casilla para la opción *Stainless Steel*, de un total de 40 fijaciones en toda la tarea 7, se considerará que el valor del parámetro β será:

$$\beta_{Material,Steel}^{Tarea7} = \frac{(fijaciones\ por\ nivel\ especifico)}{(fijaciones\ totales\ por\ tarea)} = \frac{14}{40} = 0,35$$

Siguiendo con este mismo ejemplo, si la característica *Stainless Steel* aparece solo en la opción 2 y no en las otras opciones, su aporte a la regresión sería el siguiente:

$$U_{persona}^{Tarea7,Opcion2} = \beta_{Material,Steel}^{Tarea7} * (X_{Material,Steel}^{Tarea7,Opcion1} + X_{Material,Steel}^{Tarea7,Opcion2} + X_{Material,Steel}^{Tarea7,Opcion3}) + \dots$$

$$U_{persona}^{Tarea7,Opcion2} = 0,35 * (0 + 1 + 0) + \dots$$

Por esta misma razón, las variables X_{jn}^{kd} son *dummies*, y toman el valor 1 cuando en el atributo j aparece el nivel n para la opción d , y valor 0 en caso contrario. Esto se aplica tan solo para los primeros cuatro atributos, debido a que son variables nominales por lo que no tienen un orden establecido (sucede para la Marca, el Material, el Sistema y el Diseño).

Los atributos 5 y 6, se refieren a los precios de las tazas y de las máquinas, respectivamente. Estas variables son ordinales y el cálculo de sus parámetros β respectivos es similar al anterior, pero con la salvedad de que estos parámetros no consideran las fijaciones desagregadas por nivel, si no que solo por atributo.

Siguiendo con el ejemplo anterior, si esa misma persona en su Tarea 7, realiza 10 fijaciones en total entre las tres opciones para el atributo precio de la máquina, y considerando que alcanzó 40

fijaciones en toda la Tarea 7, el cálculo del parámetro sería el siguiente:

$$\beta_{\text{PrecioMaquina}}^{\text{Tarea7}} = \frac{(\text{fijaciones por atributo})}{(\text{fijaciones totales por tarea})} = \frac{10}{40} = 0,25$$

Sin embargo al trabajar con precios, se utiliza el supuesto: *Mientras mayor es el valor del precio, menos conveniente es el producto para los consumidores y viceversa (menor precio, mayor conveniencia)*. De esta forma las variables tendrán un efecto inverso en la regresión. Este supuesto explica el signo negativo de los parámetros β_5^k y β_6^k (parámetros del precio de la taza y de la máquina respectivamente).

Continuando con el ejemplo anterior, si la misma persona en la opción 2 tiene un precio de 99,99 y en la opción 1 tiene un precio de 159,99, el aporte de cada uno de estos valores a la utilidad calculada sería el siguiente:

$$U_{\text{persona}}^{\text{Tarea7,Opcion1}} = -\beta_{\text{PrecioMaquina}}^{\text{Tarea7}} * X_{\text{PrecioMaquina}}^{\text{Tarea7,Opcion1}} + \dots = -0,25 * 159,9 + \dots$$

$$U_{\text{persona}}^{\text{Tarea7,Opcion2}} = -\beta_{\text{PrecioMaquina}}^{\text{Tarea7}} * X_{\text{PrecioMaquina}}^{\text{Tarea7,Opcion2}} + \dots = -0,25 * 99,9 + \dots$$

De esto último se puede ver que para un mismo β de precio (de las tazas o de las máquinas), siempre disminuirá más la utilidad de la opción que posea el precio más alto.

En cuanto a los valores de los parámetros β , se tiene que son muy similares entre sí, excepto para aquellas variables que representan los precios, en particular para aquella que representa el *Precio de la Máquina* por sobre el *Precio de una Taza*. Por lo tanto, este modelo suele considerar las variables de precios como las más relevantes. Los valores y las distribuciones de los parámetros β , pueden encontrarse en sección de Anexos G.

Este modelo también se aplicó a la misma base de datos de entrenamiento utilizada en los experimentos anteriores, la que solo cuenta con tres posibles opciones de cafetera (recordar que se eliminaron aquellos casos en donde los encuestados decidieron *No Comprar*). Es así como para cada una de las tareas, los participantes tienen tres utilidades distintas correspondientes a cada una de las alternativas.

Estas utilidades se trabajan de manera similar a las de un modelo Logit porque se pretende estimar la probabilidad. Por ejemplo la probabilidad de escoger la opción 1 para la persona i en la tarea k , estaría dada por:

$$P_{i1}^k = \frac{e^{U_i^{k1}}}{e^{U_i^{k1}} + e^{U_i^{k2}} + e^{U_i^{k3}}}$$

Finalmente, la opción que se predice es aquella que obtiene la mayor probabilidad de ser escogida. Los resultados de los *Hit Rate* de este modelo se presentan en la Tabla 7.7.

El modelo compensatorio de fijaciones supera ampliamente a todos los otros modelos estudiados, tanto en el conjunto de entrenamiento como en el de prueba. Las razones de su éxito se atribuyen a diversos motivos, como lo son el diseño de las variables X_{jn}^k , ya que cada una de ellas representa la misma información disponible que tienen los encuestados para decidir. También, los valores de los parámetros son estimados a nivel individual y de sus tarea respectivas, por lo que no se trabaja con la información agregada de toda la población.

Hit Rate		
Modelo	Conjunto de Entrenamiento	Conjunto de Prueba
Fijaciones Compensatorias	61,41 %	67,81 %
Fijaciones No Compensatorias	27,44 %	33,56 %
LBA con Fijaciones	30,39 %	33,11 %
LBA	33,60 %	28,14 %
Mixed Logit	53,88 %	28,17 %
Heurística Greedy	41,51 %	29,45 %

Tabla 7.7: Hit Rate para el modelo de Fijaciones Compensatorio, Fijaciones no Compensatorias, LBA con fijaciones, LBA tradicional, Mixed Logit y Heurística Greedy.

Un modelo compensatorio permite considerar diversos aspectos para tomar una decisión. En este caso no asume que los participantes tienen un comportamiento lexicográfico ni de ningún otro tipo de regla, si no que opera en función del comportamiento registrado en las fijaciones. Aun así la predicción no es 100 % exacta, lo que señala que existen otras variables que influyen en la decisión de los individuos que aún no han sido descubiertas.

Dispersión entre el Modelo de Fijaciones Compensatorio y Mixed Logit

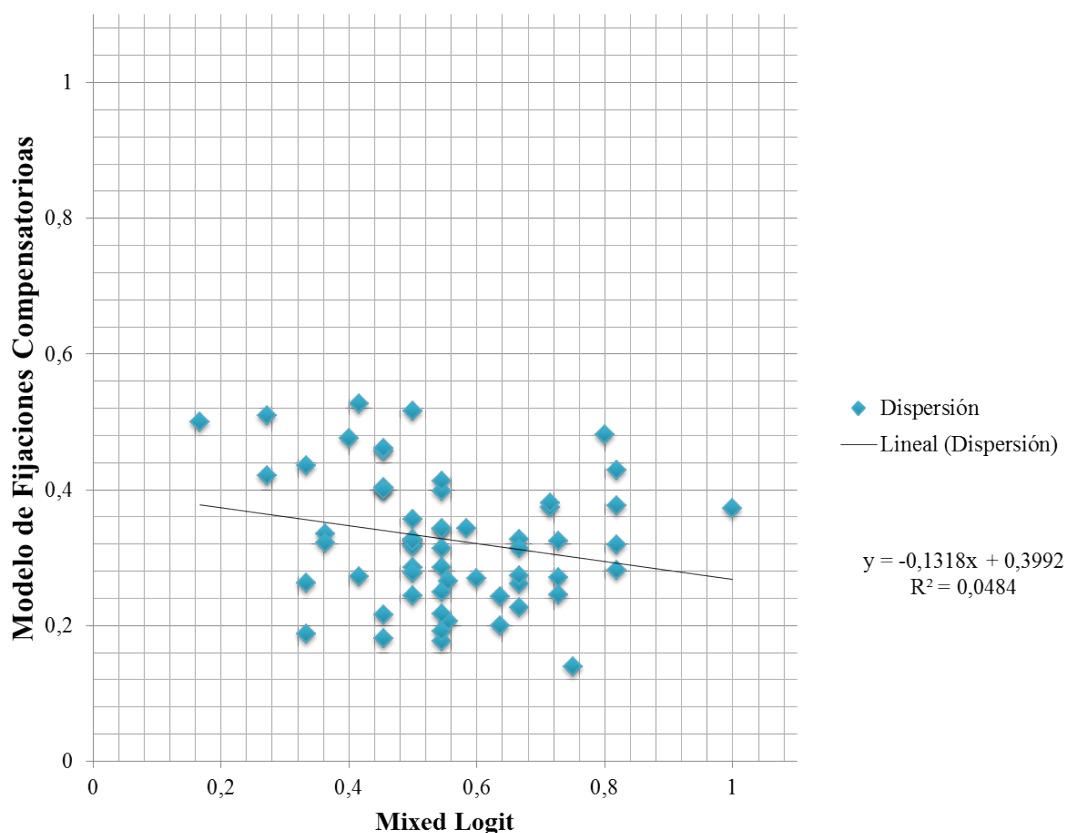


Figura 7.2: Dispersión entre el Modelo de fijaciones compensatorio y el Mixed Logit.

Para hacer una comparación de este modelo de Fijaciones Compensatorio con el Mixed Logit (ya que es el segundo modelo que presenta un alto porcentaje de predicción aunque solo sea en su conjunto de entrenamiento) se analizaron los valores de los *hit rate* a nivel individual para cada uno de los modelos. Es decir, a cada uno de los 60 encuestados se les representó en un plano cartesiano, en donde su coordenada en el eje x representa el valor del *hit rate* que el modelo Mixed Logit y su coordenada en el eje y representa el valor del *hit rate* generado por el modelo de Fijaciones Compensatorio.

En la Figura 7.2, se puede ver la dispersión de los encuestados según los *hit rate* respectivos. La importancia de este análisis es que permite comparar gráficamente las distribuciones de los *hit rate* según los dos tipos de modelos con mejores predicciones. Como se puede observar, el modelo de Fijaciones Compensatorias arroja valores cuyas probabilidades están entre 0,2 y 0,5, mientras que los valores del Mixed Logit están entre 0,2 y 1.

Esta gran varianza en el caso del Mixed Logit, muestra que el modelo puede llegar a alcanzar un ajuste muy alto en su estimación pero que no necesariamente es el adecuado en la predicción. Además, el modelo que fue entrenado con un conjunto cuyos datos fueron seleccionados aleatoriamente, y se dieron casos en donde para una persona solo habían 7 tareas (de un total de 14, puesto que las otras 7 tareas restantes estaban en el conjunto prueba), por lo que era posible esperar que los valores estimados para aquellos casos fueran más propensos a errar. Hay que recordar que esto no debería parecer extraño, ya que como se explicó anteriormente el Mixed Logit opera maximizando el *hit rate* por persona.

En contraste, el modelo de Fijaciones Compensatorias trabaja con un promedio de fijaciones, que no se ve fuertemente afectado en los casos donde se trabaja con al menos 8 tareas por persona. Además, al tratarse de un modelo compensatorio le da mayor flexibilidad para seguir las distintas estrategias por personas. A modo de ejemplo, si a uno de los encuestados solo le interesa tener conocimiento del *Precio de la Máquina* y después del *Material* (como si fuera una regla lexicográfica de solo dos atributos), se esperaría que la gran mayoría de las fijaciones estuviesen repartidas en esos dos atributos, por lo que el modelo compensatorio será fuertemente impactado en estos dos aspectos. Es decir que también cuenta con la ventaja de poder adaptar los pesos de los parámetros β fácilmente.

La regresión lineal de la Figura 7.2, si bien tiene un coeficiente de determinación de 0,04 que señala un mal ajuste de los datos a la regresión, sirve para tener una noción a grandes rasgos del comportamiento de los *hit rate* del modelo de Fijaciones Compensatorias versus el Mixed Logit. Como se puede ver la recta es decreciente, lo que podría interpretarse de la siguiente manera: Mientras más alta es la probabilidad del *hit rate* para un modelo Mixed Logit, menor es la probabilidad para el modelo de Fijaciones Compensatorias.

Esto puede parecer sorprendente para el lector, ya que sería de esperar que ambos modelos pudieran ser consistentes en estos aspectos. Para obtener una explicación de lo anterior, se estudiaron aquellos casos en donde el modelo de Fijaciones Compensatorias cometió más errores en la predicción pero el Mixed Logit acertó. La razón de tomar estos casos, es para probar si ambos modelos pueden ser complementarios, y descubrir en qué casos particulares es preferente usar el modelo Mixed Logit ante el de Fijaciones Compensatorias propuesto.

De las 60 personas que fueron analizadas, en solo 13 de ellas el modelo de Fijaciones Compen-

satorias no logró predecir correctamente al menos la mitad de sus tareas. Por lo que estos casos fueron considerados los de peor predicción. Se llevó a cabo una comparación de los valores de los *hit rate* para cada modelo y los resultados pueden verse en la Figura 7.3.

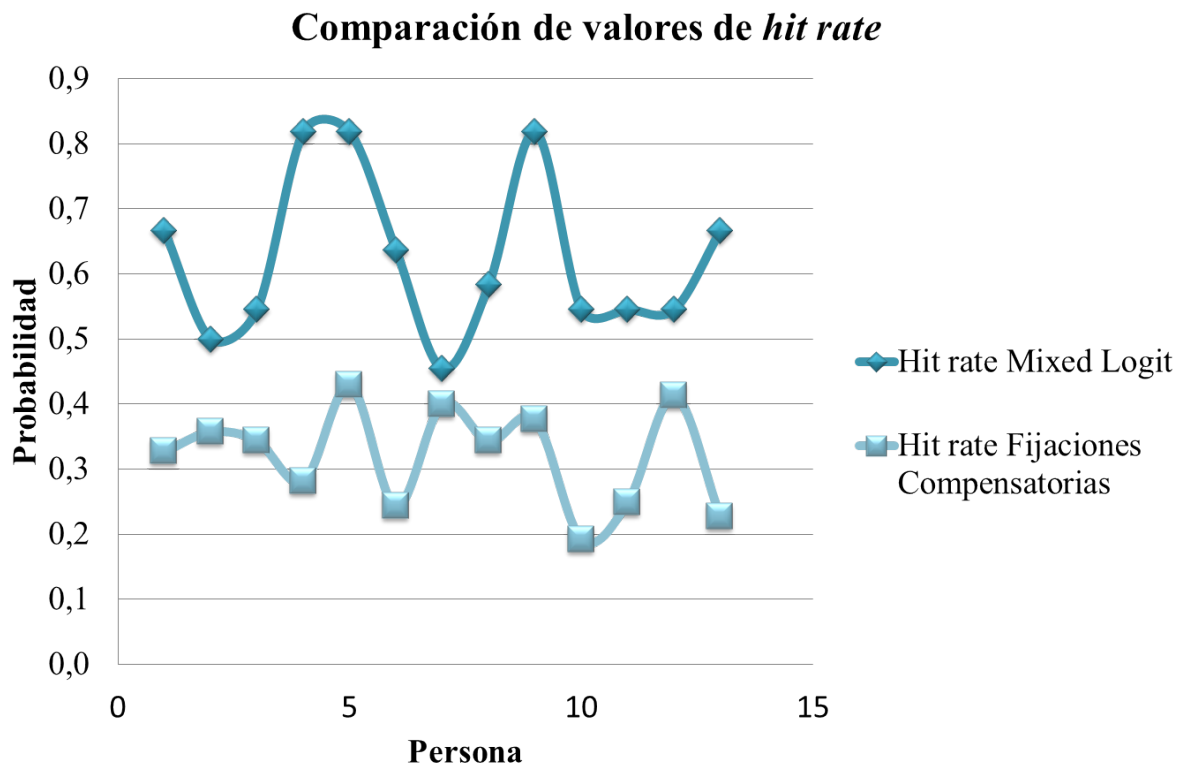


Figura 7.3: Dispersión entre el Modelo de fijaciones compensatorio y el Mixed Logit.

Como se puede apreciar para el caso del modelo de Fijaciones Compensatorias, sus valores de *hit rate* bordean la probabilidad de 0,3, lo que indica que para un caso donde hay tan solo 3 alternativas, sus probabilidades de elección son parejas, por lo que es de esperar que el modelo pueda errar en estos casos. Al observar los *hit rate* del Mixed Logit, suelen ser bastante altos en la mayoría de los casos, con probabilidad oscilante entre 0,4 y 0,9 sin embargo, esto no es un buen indicador ya que la reducción del intervalo no es lo suficientemente significativa para poder deducir algo al respecto (Recordad que el intervalo para un Mixed Logit estaba entre 0,2 y 1). No obstante, se considera que estos casos son uno de los puntos importantes por donde se puede continuar con la investigación.

En conclusión, pareciera ser que el modelo de Fijaciones Compensatorias es mejor que el Mixed Logit ya que además de ser más flexible, no pierde generalidad en la predicción debido a que no se sobre ajusta. Además, se tiene el conocimiento de que para aquellos casos en donde la probabilidad de ser escogido bordea el 0,3, el modelo corre el riesgo de equivocarse, por lo que se muestra otro indicio de un camino interesante para continuar con futuras investigaciones.

7.6. Conclusiones del Capítulo

Contrastar los resultados obtenidos en los experimentos anteriores bajo un nuevo contexto, es de gran utilidad para dar credibilidad y generalidad a la investigación. En esta misma línea, es que se opta por indagar con otro tipo de modelos además de los no compensatorios utilizados al inicio. Además, asumir que los individuos siempre escogen utilizando un tipo de regla lexicográfica, muchas veces puede ser un supuesto erróneo, por lo que contrastar la información con modelos no compensatorios permite evaluar cuándo y cómo los datos de las fijaciones pueden ser más informativos.

De los experimentos realizados, se puede concluir que la información visual es más explicativa cuando se utiliza por si sola, que cuando se utiliza para complementar alguno de los modelos ya existentes que suelen manejar la información de las respuestas. Esta *mezcla* de tipos información puede no entregar conocimientos nuevos.

Finalmente, al comparar los modelos de fijaciones, se tiene que los resultados del modelo compensatorio son sumamente superiores a los del modelo no compensatorio, esto se atribuye a que un modelo no compensatorio puede limitar la información entregada por las fijaciones. En resumen, la información visual puede ser muy informativa, pero depende de la manera en que se trabajen los datos para obtener una mejor predicción.

Capítulo 8

Conclusiones

Las decisiones que toman los consumidores para evaluar productos o servicios, resultan ser interesantes de estudiar porque permiten entender las preferencias de las personas y otros tipos de variables que influyen en la elección. Así es como surge una amplia área de investigación en torno a los procesos de decisión. En esta investigación se trabajó bajo un escenario experimental de Análisis Conjunto, donde además se capturaron los movimientos de la vista y las fijaciones realizadas. De esta manera, se pretende medir el aporte de la información visual en la predicción de estrategias de decisión.

El comportamiento visual de los individuos resultó ser en gran parte consistente con sus elecciones respectivas, debido a que se realizaron más fijaciones en aquellos atributos y opciones que eran relevantes para escoger. Por lo tanto, se concluye que las personas reparten su atención de forma heterogénea concentrando su vista en aquellos atributos que resultan ser de su interés.

Dentro del amplio abanico de las reglas de decisión, esta investigación se focalizó en métodos no compensatorios, trabajando con las estrategias lexicográfica y conjuntiva para caracterizar el comportamiento de estas reglas a través de la información visual. Los diferentes patrones descubiertos, permitieron diferenciar exitosamente estas reglas por medio de modelos de elección y modelos con la información visual (cerca de un 95 % y 80 % respectivamente). Sin embargo, los mejores resultados se logran bajo un contexto experimental ideal, donde la estrategia de decisión es conocida por el investigador.

Las buenas predicciones obtenidas, guían el estudio a un nuevo contexto experimental donde la estrategia de decisión es desconocida. En este caso se plantea integrar la información visual en un modelo de elección lexicográfica. Los resultados de predicción obtenidos son levemente superiores a los del modelo original (cerca de un 3 % mejor), pero aun así ambos modelos rondan el 30 % en la predicción total, lo que indica que asumir que las estrategias de los consumidores son del tipo compensatorias es un supuesto erróneo en gran parte de los casos.

Este hecho, genera la inquietud de probar con otro tipo de estrategias de decisión, es decir, con aquellas que son del tipo compensatorias. Los resultados arrojan valores similares a los obtenidos en los modelos no compensatorios. Sin embargo, es el modelo compensatorio propuesto en base a las fijaciones el que arroja la mejor predicción obtenida durante esta investigación: más del 61 %

de los casos correctamente predichos.

Finalmente se tiene que la información visual de los participantes puede ser muy informativa para predecir, pero los buenos resultados dependen de los modelos que se utilicen para trabajar este tipo de información. Así, su poder informativo no necesariamente será interesante en un modelo no compensatorio, pero sí puede serlo en el área de los modelos compensatorios donde aún queda por investigar.

8.1. Trabajos Futuros

La información visual ha mostrado que puede alcanzar un alto poder predictivo, dependiendo de los modelos de predicción y los supuestos de elección que se apliquen. Gran parte de esta investigación se ha concentrado en los modelos no compensatorios, pero aún queda un área interesante de abordar que son los modelos compensatorios y su complemento con la información visual.

Durante este trabajo, las elecciones relacionadas a la opción de *No Comprar* fueron eliminadas para poder estimar los modelos de elección en su forma original. No obstante, se propone seguir indagando en estos aspectos, es decir, incluir la opción de *No comprar* y estudiar cómo predecirlas, para descubrir cuándo el individuo está dispuesto a comprar y cuándo no, en base a la información que adquiere según lo que se observa.

En la realidad, las personas utilizan reglas compensatorias y no compensatorias dependiendo de la situación en la que deban decidir, es por ello que estudiar las reglas de manera aislada puede ser útil para encontrar los patrones de comportamiento, ya sea visual o no (al utilizar cualquier otro método de rastreo), pero estudiar la interacción entre estos métodos y complementarlos con la información visual pareciera ser un área prometedora, pues guía el estudio desde un caso ideal, a uno cada vez más complejo que represente de forma fidedigna la realidad en las decisiones de los consumidores.

Apéndice A

Otras reglas de decisión

A.1. Additive difference strategy (ADD)

Compara dos opciones a la vez, atributo por atributo. Luego, las diferencias entre los atributos son sumadas para entregar un puntaje de diferencia total a lo largo de todos los atributos para ese par de opciones. El ganador es entonces comparado con la siguiente opción y así sucesivamente. La opción escogida ha ganado todas las comparaciones (Tversky, 1969).

A.1.1. Equal wieghts strategy (EQW)

Escoge la opción con el puntaje de utilidad total más alto, que se define como la suma de la utilidad de todos los atributos de la opción. A diferencia de MAU (ver Número 6 más abajo), EQW simplifica la toma de decisión ignorando los pesos de los atributos (Dawes, 1979; Einshorn & Hogarth, 1975).

A.1.2. Least important heuristic (LIM)

Primero determina el peor valor de cada opción y luego escoge la opción con peor valor menos importante (Jungermann et al., 2005).

A.1.3. Least variance heuristic (LVA)

Escoge la opción con la menor varianza a lo largo de todos los valores de los atributos. LVA hace sentido solo para situaciones de decisión en los cuales no existe una opción dominante (Jungermann et al., 2005).

A.1.4. Multiattribute utility model (MAU)

Escoge la opción con el puntaje de utilidad total ponderado más alto, que se define como la suma ponderada de las utilidades de cada atributo. MAU suele ser visto como una regla normativa (Anderson, 1974; Keeney & Raiffa, 1976; von Winterfeldt & Fischer, 1975).

A.1.5. Majority of confirming dimensions strategy (MCD)

Involucra procesar pares de opciones (como en ADD). Los valores para cada una de las dos opciones son comparadas en cada atributo. La opción con la mayoría de valores de atributos ganadores es seleccionada y luego es comparada con la siguiente opción. El proceso de comparación de a pares termina si todas las opciones han sido evaluadas y la opción ganadora final ha sido identificada (Russo & Doshier, 1983; Wright & Barbour, 1977).

A.1.6. Recognition heuristic (REC)

Escoge la opción con el mejor valor en el atributo name recognition. REC puede ser considerado como un tipo especial de LEX, pues REC elige la opción con el mejor valor en el atributo más importante, a saber, name recognition. Si es que la opción con el mejor valor no es única, REC elige la opción con el mejor valor en el segundo atributo más importante y así sucesivamente (Goldstein & Gigerenzer, 2002).

Apéndice B

Otros Métodos de Rastreo utilizados en el estudio de las reglas de Decisión

A continuación se presentan algunos de estas metodologías:

- **Information display board:** Puede ser el experimento más típico donde la información se muestra a través de letreros; las personas pueden intervenir con los productos y adquieren la información preguntando directamente (Lehmann & Moore, 1980). Requiere de gran esfuerzo para adquirir la información, más de lo que se requiere en eye tracking, por lo que no es una fiel representación de un comportamiento real de elección. Este aumento de esfuerzo incita el uso de otro tipo de estrategias, ya que con information display board puede quedar oculta mucha información (Russo, 1978).
- **Procesos computarizados:** Estos procesos necesitan que la encuesta se lleve a cabo en un computador, puesto que se rastrean las intervenciones que las personas hacen con el ordenador.
 - **Mouselab:** trabaja con una matriz en donde se le muestran claramente las opciones y los atributos al encuestado. Al comienzo del experimento todos los casilleros de la matriz están cerrados, pero para que el participante pueda conocer las características de cada opción, debe posicionar el mouse sobre el casillero que le interesa, y este a su vez le mostrará la información (Riedl, Brandstätter & Roithmayr, 2008). Esta técnica se ha desarrollado y continuamente mejorado (Tabatabai, 1998; Payne, 1993; G.J. Cook & Swain, 1993).
 - **Mouse Trace:** Programa computacional que es la extensión de Mouselab, pero a diferencia del anterior, almacena mucha más información y permite múltiples respuestas y etapas de decisión. También es fácil de usar y funciona registrando todos los movimiento que la persona hace con el mouse, por lo que es más sofisticado en términos de características y almacenamiento de información (Jasper & Shapiro, 2002).
- **Phased narrowing:** Otro tipo de experimento en el que el encuestado puede interactuar personalmente con el encuestador, y consiste en darle a elegir al participante de muchas opciones

de productos una cantidad fija, luego volver a seleccionar menos opciones dentro de las pre-seleccionadas y así sucesivamente. El objetivo es ver como en cada una de las fases varían las decisiones de los sujetos (Jasper & Levin, 2001).

Apéndice C

Resultados del Análisis Factorial

Componente	Valores Propios Iniciales			Valores Propios Extraídos			Valores Propios Rotados		
	Total	% Var.	% Acum.	Total	% Var.	% Acum.	Total	% Var.	% Acum.
1	3,646	28,043	28,043	3,646	28,043	28,043	2,035	15,657	15,657
2	1,825	14,042	42,085	1,825	14,042	42,085	1,715	13,195	28,853
3	1,311	10,084	52,170	1,311	10,084	52,170	1,639	12,606	41,458
4	1,228	9,446	61,616	1,228	9,446	61,616	1,115	8,579	50,037
5	1,109	8,533	70,149	1,109	8,533	70,149	1,083	8,330	58,367
6	1,010	7,770	77,919	1,010	7,770	77,919	1,031	7,930	66,297
7	,974	7,493	85,413	,974	7,493	85,413	1,014	7,801	74,098
8	,573	4,408	89,820	,573	4,408	89,820	1,005	7,732	81,830
9	,500	3,849	93,670	,500	3,849	93,670	,999	7,687	89,517
10	,437	3,360	97,030	,437	3,360	97,030	,077	7,513	97,030
11	,287	2,210	99,240						
12	,060	,450	99,698						
13	,039	,302	100,000						

Tabla C.1: Total de varianza explicada.

-	$N_{\text{fijaciones}}$	$AtributoTop^1$	$AtributoTop^2$	$OpcionTop^1$	$OpcionTop^2$	Lex^H	Lex^V
$AtributoTop^1$	1,000	-,525	-,135	-,030	,097	,074	,237
$AtributoTop^2$	-,525	1,000	-,235	-,097	-,128	-,178	-,412
$OpcionTop^1$	-,135	-,235	1,000	-,102	-,033	-,044	-,106
$OpcionTop^2$,097	-,128	-,033	-,350	1,000	-,051	-,047
Lex^H	,074	-,178	-,044	,256	-,051	1,000	,473
Lex^V	,237	-,412	-,106	,311	-,047	,473	1,000
$ConjVert^H$	-,139	,201	,124	-,125	,025	-,283	-,231
$ConjVert^V$	-,013	,038	,057	-,022	,035	-,119	-,277
$ConjHorz^H$,420	-,591	-,177	,252	,059	,768	,502
$ConjHorz^V$,156	-,358	-,110	,437	-,030	,446	,944
$AtributoCompleto^{Inicio}$,375	-,202	,031	-,095	,040	-,250	-,047
$AtributoCompleto^{Fin}$,226	,112	-,047	-,222	-,132	-,077	-,033

Tabla C.2: Resultados Test de Medias, Equivalente sin Normalizar (Parte 1).

-	<i>ConjVer^H</i>	<i>ConjVert^V</i>	<i>ConjHorz^H</i>	<i>ConjHorz^V</i>	<i>AtributoCompleto^{Inicio}</i>	<i>AtributoCompleto^{Fin}</i>
<i>AtributoTop¹</i>	-,139	-,013	,420	,156	,375	,226
<i>AtributoTop²</i>	,201	,038	-,591	-,358	-,202	,112
<i>OpcionTop¹</i>	,124	,057	-,177	-,110	,031	-,047
<i>OpcionTop²</i>	,025	,035	,059	-,030	,040	-,132
<i>Lex^H</i>	-,283	-,119	,768	,446	-,250	-,077
<i>Lex^V</i>	-,231	-,277	,502	,944	-,047	-,033
<i>ConjVert^H</i>	1,000	,380	-,354	-,217	,030	,043
<i>ConjVert^V</i>	,380	1,000	-,083	-,265	,030	-,029
<i>ConjHorz^H</i>	-,354	-,083	1,000	,457	-,059	-,118
<i>ConjHorz^V</i>	-,217	-,265	,457	1,000	-,074	-,073
<i>AtributoCompleto^{Inicio}</i>	,030	,030	-,059	-,074	1,000	,041
<i>AtributoCompleto^{Fin}</i>	,043	-,029	-,118	-,073	,041	1,000

Tabla C.3: Resultados Test de Medias, Equivalente sin Normalizar (Parte 2).

Apéndice D

Resultados del Test Cohen Kappa

Observed agreement (po)	0,7609
Random agreement (pe)	0,7667
Agreement due to true concordance (po-pe)	-0,0058
Residual not random agreement (1-pe)	0,2333
Cohen's kappa	-0,0248
kappa error	0,0278
kappa C.I. (alpha = 0,1000)	-0,0706 ; 0,0209
Variance	0,0002
z (k/sqrt(var))	-1,6327
p	0,1025
Accept null hypothesis:	Observed agreement is accidental.

Tabla D.1: Resultados del Test Cohen Kappa

La Tabla D.2 muestra los valores de tres métricas calculadas para cada una de las posiciones del ranking. El *Porcentaje*, representa las coincidencias totales de manera porcentual entre el ranking dado en las instrucciones y el establecido por las fijaciones. La *Predicción exacta* es lo mismo que la métrica anterior pero indica el número exacto de casos en donde hay coincidencia por nivel. La *Distancia Eucladiana* como su nombre lo indica es la distancia desde un vector de ranking respecto al otro.

Medidas	1°	2°	3°	4°	5°	6°
Porcentaje (%)	24.5833	14.0278	15.5556	11.5278	17.9167	19.3056
Predicción exacta	177	101	112	83	129	139
Dist. Eucladiana	402.6711	651.9511	572.0069	772.8400	525.1736	475.2400

Tabla D.2: Resumen de las medidas de ajuste para cada una de las posiciones en el ranking.

Apéndice E

Resultados Test de Medias

Regla	N	Promedio	Std. Desviación
$\bar{X}_{L,S}^H$	720	180,361	117,170
$\bar{X}_{C,S}^H$	720	91,659	42,421
$\bar{X}_{L,S}^V$	720	99,220	70,296
$\bar{X}_{C,S}^V$	720	46,000	25,445

Tabla E.1: Resumen de estadísticos básicos, sin Normalizar.

Regla	N	Promedio	Std. Desviación
\bar{X}_L^H	720	0,523	0,272
\bar{X}_C^H	720	0,535	0,234
\bar{X}_L^V	720	0,272	0,267
\bar{X}_C^V	720	0,257	0,212

Tabla E.2: Resumen de estadísticos básicos, Normalizados

Regla	N	Promedio	Std. Desviación
\bar{X}_L^H	240	62,048	22,666
\bar{X}_C^H	240	62,518	22,389
\bar{X}_L^V	240	35,701	20,978
\bar{X}_C^V	240	36,037	19,923

Tabla E.3: Resumen de estadísticos básicos, Equivalente sin Normalizar

Regla	N	Promedio	Std. Desviación
\bar{X}_L^H	240	0,376	0,137
\bar{X}_C^H	240	0,378	0,135
\bar{X}_L^V	240	0,216	0,127
\bar{X}_C^V	240	0,218	0,120

Tabla E.4: Resumen de estadísticos básicos, Equivalente Normalizado

Apéndice F

Fijaciones y Elecciones

Los análisis que se desarrollaron son análogos a los explicados en el Capítulo 4.2 el cual divide un aserie de fijaciones en dos períodos (primera y segunda mitad de la serie), sin embargo la terminología utilizada es levemente diferente:

- **1** : Si el producto que se escoge es el tiene mayor porcentaje de fijaciones.
- **2** : Si el producto que se escoge es el tiene el segundo mayor porcentaje de fijaciones.
- **3** : Si el producto que se escoge es el tiene el menor porcentaje de fijaciones.
- **4** : Si decide no escoger.

Los resultados indican que las personas tienden a escoger los productos que reciben mayor atención, lo que se repite en ambos períodos. Y de manera similar al experimento principal, acá también se cumple que el segundo período parece ser más informativo respecto al producto escogido en relación a las fijaciones trabajadas.

Categoría	Período 1 (%)	Período 2° (%)
1	46	66
2	20	13
3	18	5
4	16	16

Tabla F.1: Tabla de estadísticos capítulo 5.

Este análisis se repitió, pero considerando un total de cuatro períodos. En el primer período se puede ver como los participantes dividen su atención de forma más uniforme entre las alternativas. De manera contraria en el último período se tiene que existe una coincidencia mayor al 60 % de la opción más mirada con la alternativa escogida.

Apéndice G

Valores de los Parámetros β del Modelo de Fijaciones Compensatorio

G.1. Estadísticos para los parámetros β

β	Promedio	Desv. Std.
$\beta_{1,1}$	0,040	0,019
$\beta_{1,2}$	0,040	0,021
$\beta_{1,3}$	0,046	0,017
$\beta_{1,4}$	0,044	0,026
$\beta_{2,1}$	0,058	0,021
$\beta_{2,2}$	0,051	0,016
$\beta_{2,3}$	0,052	0,018
$\beta_{3,1}$	0,094	0,027
$\beta_{3,2}$	0,071	0,021
$\beta_{4,1}$	0,049	0,024
$\beta_{4,2}$	0,051	0,022
$\beta_{4,3}$	0,058	0,020
$\beta_{4,4}$	0,052	0,022
β_5	-0,188	0,037
β_6	-0,215	0,070

Tabla G.1: Tabla de estadísticos para los valores de los parámetros β .

G.2. Hitogramas para los parámetros β




Figura G.1: Histograma que muestra la distribución del parámetro $\beta_{1,1}$.




Figura G.2: Histograma que muestra la distribución del parámetro $\beta_{1,2}$.




Figura G.3: Histograma que muestra la distribución del parámetro $\beta_{1,3}$.




Figura G.4: Histograma que muestra la distribución del parámetro $\beta_{1,4}$.




Figura G.5: Histograma que muestra la distribución del parámetro $\beta_{2,1}$.




Figura G.6: Histograma que muestra la distribución del parámetro $\beta_{2,2}$.




Figura G.7: Histograma que muestra la distribución del parámetro $\beta_{2,3}$.




Figura G.8: Histograma que muestra la distribución del parámetro $\beta_{3,1}$.




Figura G.9: Histograma que muestra la distribución del parámetro $\beta_{3,2}$.




Figura G.10: Histograma que muestra la distribución del parámetro $\beta_{4,1}$.




Figura G.11: Histograma que muestra la distribución del parámetro $\beta_{4,2}$.




Figura G.12: Histograma que muestra la distribución del parámetro $\beta_{4,3}$.




Figura G.13: Histograma que muestra la distribución del parámetro $\beta_{4,4}$.




Figura G.14: Histograma que muestra la distribución del parámetro β_5 .




Figura G.15: Histograma que muestra la distribución del parámetro β_6 .

Bibliografía

- Greg M Allenby, Peter E Rossi, and Robert E McCulloch. Hierarchical bayes models: a practitioners guide. *Available at SSRN*, 655541, 2005.
- Guy Thomas Buswell. How people look at pictures: a study of the psychology and perception in art. 1935.
- Vasek Chvatal. A greedy heuristic for the set-covering problem. *Mathematics of operations research*, 4(3):233–235, 1979.
- Clyde H Coombs. Mathematical models in psychological scaling. *Journal of the American Statistical Association*, 46(256):480–489, 1951.
- Robyn Mason Dawes. Social selection based on multidimensional criteria. *The Journal of Abnormal and Social Psychology*, 68(1):104, 1964.
- Wayne S DeSarbo, Venkatram Ramaswamy, and Steven H Cohen. Market segmentation with choice-based conjoint analysis. *Marketing Letters*, 6(2):137–147, 1995.
- Peter C Fishburn. Exceptional paper-lexicographic orders, utilities and decision rules: A survey. *Management science*, 20(11):1442–1471, 1974.
- James F. Foerster. Mode choice decision process models: A comparison of compensatory and non-compensatory structures. *Transportation Research Part A: General*, 13(1):17 – 28, 1979. ISSN 0191-2607. doi: [http://dx.doi.org/10.1016/0191-2607\(79\)90083-9](http://dx.doi.org/10.1016/0191-2607(79)90083-9). URL <http://www.sciencedirect.com/science/article/pii/0191260779900839>.
- Timothy J Gilbride and Greg M Allenby. A choice model with conjunctive, disjunctive, and compensatory screening rules. *Marketing Science*, 23(3):391–406, 2004.
- Rinus Haaijer and Michel Wedel. Conjoint choice experiments: General characteristics and alternative model specifications. In *Conjoint Measurement*, pages 199–229. Springer, 2007.
- Johanna M Harte and Pieter Koele. Modelling and describing human judgement processes: The multiattribute evaluation case. *Thinking & reasoning*, 7(1):29–49, 2001.
- Robert JK Jacob and Keith S Karn. Eye tracking in human-computer interaction and usability research: Ready to deliver the promises. *Mind*, 2(3):4, 2003.

- J.D. Jasper and Jennifer Shapiro. Mousetrace: A better mousetrap for catching decision processes. *Behavior Research Methods, Instruments, & Computers*, 34(3):364–374, 2002. ISSN 0743-3808. doi: 10.3758/BF03195464. URL <http://dx.doi.org/10.3758/BF03195464>.
- Eric J. Johnson, John W. Payne, James R. Bettman, and David A. Schkade. Monitoring information processing and decisions: The mouselab system. *Unpublished manuscript*, 1989.
- Ioannis Karatzas. and Steven E. Shreve. *Brownian Motion and Stochastic Calculus*. Springer, Berlin, 2nd edition, 2000.
- Gerald L Lohse and Eric J Johnson. A comparison of two process tracing methods for choice tasks. In *System Sciences, 1996., Proceedings of the Twenty-Ninth Hawaii International Conference on*, volume 4, pages 86–97. IEEE, 1996a.
- G.L. Lohse and E.J. Johnson. A comparison of two process tracing methods for choice tasks. In *System Sciences, 1996., Proceedings of the Twenty-Ninth Hawaii International Conference on*, volume 4, pages 86–97 vol.4, Jan 1996b. doi: 10.1109/HICSS.1996.495316.
- Jordan J Louviere and George Woodworth. Design and analysis of simulated consumer choice or allocation experiments: An approach based on aggregate data. *Journal of Marketing Research (JMR)*, 20(4), 1983.
- Keith B Murray. A test of services marketing theory: consumer information acquisition activities. *The Journal of Marketing*, pages 10–25, 1991.
- Rik Pieters and Luk Warlop. Visual attention during brand choice: The impact of time pressure and task motivation. *International Journal of Research in Marketing*, 16(1):1 – 16, 1999. ISSN 0167-8116. doi: [http://dx.doi.org/10.1016/S0167-8116\(98\)00022-6](http://dx.doi.org/10.1016/S0167-8116(98)00022-6). URL <http://www.sciencedirect.com/science/article/pii/S0167811698000226>.
- Philip Protter. *Stochastic Integration and Differential Equations*. Springer, 1990.
- Bob Rehder and Aaron B Hoffman. Thirty-something categorization results explained: selective attention, eyetracking, and models of category learning. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 31(5):811, 2005.
- Daniel Revuz and Marc Yor. *Continuous martingales and Brownian motion*. Number 293 in Grundlehren der mathematischen Wissenschaften. Springer, Berlin [u.a.], 3. ed edition, 1999. ISBN 3540643257. URL http://gso.gbv.de/DB=2.1/CMD?ACT=SRCHA&SRT=YOP&IKT=1016&TRM=ppn+25295551X&sourceid=fbw_bibsonomy.
- Richard Riding and Stephen Rayner. *Cognitive styles and learning strategies: Understanding style differences in learning and behaviour*. D. Fulton Publishers, 1998.
- Renac Riedl, Eduard Brandstatter, and Friedrich Roithmayr. Identifying decision strategies: A process- and outcome-based classification method. *Behavior Research Methods*, 40(3):795–807, 2008a. ISSN 1554-351X. doi: 10.3758/BRM.40.3.795. URL <http://dx.doi.org/10.3758/BRM.40.3.795>.

- René Riedl, Eduard Brandstätter, and Friedrich Roithmayr. Identifying decision strategies: A process-and outcome-based classification method. *Behavior Research Methods*, 40(3):795–807, 2008b.
- Shinsuke Shimojo, Claudiu Simion, Eiko Shimojo, and Christian Scheier. Gaze bias both reflects and influences preference. *Nature neuroscience*, 6(12):1317–1322, 2003.
- Peter Stattgen, Peter Boatwright, and Robert T. Monroe. A satisficing choice model. *Marketing Science*, 31(6):878–899, 2012. doi: 10.1287/mksc.1120.0732. URL <http://pubsonline.informs.org/doi/abs/10.1287/mksc.1120.0732>.
- Kenneth Train. *Discrete choice methods with simulation*. Cambridge university press, 2009.
- Amos Tversky. Choice by elimination. *Journal of mathematical psychology*, 9(4):341–367, 1972a.
- Amos Tversky. Elimination by aspects: A theory of choice. *Psychological review*, 79(4):281, 1972b.
- Michel Wedel and Rik Pieters. Eye fixations on advertisements and memory for brands: A model and findings. *Marketing science*, 19(4):297–312, 2000.
- Michel Wedel and Rik Pieters. *Eye tracking for visual marketing*. Now Publishers Inc, 2008.
- Robert B Zajonc. Attitudinal effects of mere exposure. *Journal of personality and social psychology*, 9(2p2):1, 1968.