



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

**MODELO DE MAXIMIZACIÓN DE LA UTILIDAD ALEATORIA QUE
CONSIDERA EVALUACIÓN SECUENCIAL DE ATRIBUTOS**

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA,
MENCIÓN TRANSPORTE

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL

GABRIEL ANDRÉS NOVA SEPÚLVEDA

PROFESOR GUÍA:

Cristián Angelo Guevara Cue

MIEMBROS DE LA COMISIÓN:

Stephane Hess

Marcela Munizaga Muñoz

Andrés Musalem Said

Este trabajo ha sido parcialmente financiado por:

FONDECYT 1191104

SANTIAGO DE CHILE

2022

MODELO DE MAXIMIZACIÓN DE LA UTILIDAD ALEATORIA QUE CONSIDERA EVALUACIÓN SECUENCIAL DE ATRIBUTOS

Las elecciones de los agentes son de gran interés para diversas áreas científicas cuyos esfuerzos se centran en entender su comportamiento, estimar las valoraciones subjetivas de los atributos, analizar el impacto de políticas o incentivos, entre otros fenómenos. La modelación de elecciones ha estado dominada por los enfoques estáticos debido a su fácil implementación y alta interpretabilidad económica, siendo el modelo de Maximización de la Utilidad Aleatoria (RUM) el más desarrollado. No obstante, el modelo RUM no es tan realista, pues considera que los tomadores de decisión poseen racionalidad perfecta e información completa. A diferencia de los enfoques compensatorios estáticos, el modelo Decision Field Theory (DFT) incluye de manera explícita el proceso de búsqueda de información en anchura, permitiendo modelar que la elección final es afectada por la secuencia de atributos atendidos. Sin embargo, el modelo DFT carece de la interpretabilidad microeconómica del modelo RUM y tiene además algunas limitaciones estadísticas.

Como un primer aporte, esta tesis busca caracterizar el proceso de búsqueda de información que realizan los usuarios previa a la elección a través de datos de procesos y analizar si existe una variación de éste comportamiento influenciado por variables socioeconómicas o por las dimensiones de la tarea de elección. Además, esta tesis avanza en el desarrollo de un modelo RUM que da cuenta de la dinámica cognitiva que permita subsanar restricciones de interpretación, identificación e inferencia de los parámetros del DFT.

En una primera parte, se diseñaron y aplicaron tres encuestas de preferencias declaradas pivotadas con respecto a los viajes de punta mañana que varían en la cantidad de alternativas y atributos (áreas de interés mostradas: AOI). Estos valores se mostraron como panel informativo y se registraron los clics para evaluar el proceso de búsqueda de información de los encuestados. Los hallazgos permiten establecer tres conclusiones principales. Primero, el patrón de búsqueda de información en anchura predomina independiente de las AOI mostradas. Segundo, se realizan más indagaciones que la cantidad de información mostrada y este valor aumenta de manera decreciente con el incremento de las AOI. Tercero, encontramos que las transiciones más probables durante el proceso de deliberación son las que surgen a partir de búsquedas en anchura. En síntesis, la evidencia encontrada sugiere que existe un dominio de búsquedas en Anchura, por lo que el modelo RUM no sería capaz de describir adecuadamente el proceso de deliberación y que los supuestos del enfoque DFT serían más apropiados para estos fines.

En la segunda parte, se avanza en el desarrollo metodológico del modelo RUM-DFT y se aclaran supuestos considerados en una memoria anterior. Utilizando simulaciones de Monte Carlo, se muestra que este enfoque recupera los parámetros del proceso de deliberación, muestra el comportamiento dinámico de las utilidades y posee un buen rendimiento, llegando a valores de verosimilitud similares al DFT, pero con estimadores que se pueden interpretar microeconómicamente. Aún más, al aplicar el modelo propuesto a una base de datos real, se logra mejores indicadores de ajuste que todos los enfoques convencionales. Estos resultados son prometedores y motivan a seguir profundizando esta línea de investigación.

*A mis padres Nathalie y Gabriel,
a mis abuelos Domingo y Sandra,
a mis hermanos Manuel, Marco y Alex,
y a mi novio Alex.*

Gabriel

Agradecimientos

A Nathalie, Alex, Gabriel, Manuel, Marco por estar siempre conmigo aconsejando y fomentando la educación como pilar de cambio, crecimiento y desarrollo personal. Son pieza fundamental, de escuchar y dar comentarios, que siempre son bienvenidos pues saben que vamos hacia el mismo objetivo.

A Alex Dee, mi novio, por ser el soporte de todo este proceso, contenerme en mis vacilaciones o fluctuaciones de ánimo cuando las cosas no iban bien, por hacerme notar lo valioso de mis avances y evitar el síndrome del impostor, por sobre todo... amarme.

A mis amigos Martin, Jorge, Joaquín, Cristian, Octavio y Francisco por ser mis amigos durante tanto tiempo, ya son familia, por estar siempre presente en las diferentes peripecias.

A mis amigos Matías Boche, Benjamín Ulloa, Diego Fuentealba, Matías contreras, Javiera Ybar por todas esas tardes de juegos de mesa, conversaciones, consejos y risas que nunca faltaron.

Al Profesor Angelo Guevara por el ser el que me motivo continuamente a profundizar en los temas de investigación, en su forma detallada y minuciosa de trabajar que inculcó en mí, en enseñarme las bases de mi especialidad y ser tenazmente el propio juez de los avances realizados, en ofrecerme trabajar en el proyecto Biomonitor desde el año 2019, por gestionar la pasantía de investigación en el Instituto de Transporte de la Universidad de Leeds, por respaldarme en el congresos, postulación al doctorado y estar totalmente presente en las diferentes etapas de crecimiento académico.

A Stephane Hess por escuchar mis ideas, dar retroalimentaciones, presentarme a otros investigadores, invitarme a sus cursos de formación académica y confiar en mí para seguir trabajando conjuntamente a futuro.

A Thomas O. Hancock, un apasionado del tema, por recibirme en Leeds, por guiarme, darme una infinidad de comentarios e ideas de la investigación realizada en esta tesis. Asimismo, por todos los almuerzos y conversaciones de temas que van más allá de lo académico.

A Smoy Belizaire y a Nicolas Cabello, por ser el personal técnico que permitió reestructurar y montar los instrumentos aplicados en esta tesis.

A Maximiliano Lizana y David Palma, investigadores chilenos residentes en Leeds que me acogieron, me aconsejaron que lugares visitar, como afrontar la pasantía, como prepararme para el congreso y me mostraron aspectos más personales, haciéndolos parte importante de

mi experiencia durante la investigación en Leeds. David, No olvidaré el trekking y lo embarrados que quedamos!!

A todos los que conocí en esta etapa, me dieron algún comentario, idea, apoyo, tales como: Yasna Cornejo, Elena Galindo, María Olga Leiva, Rodrigo González

A la Agencia Nacional de Investigación y Desarrollo, que a través del Fondo Nacional de Desarrollo Científico y Tecnológico (ANID, FONDECYT) 1191104 y de la beca ANID PIA/-BASAL AFB180003, permitieron financiar el desarrollo e implementación de los instrumentos aplicados en esta tesis. Además, financiaron la inscripción y parte de los viáticos del viaje realizado a la International Choice Modelling Conference (ICMC) realizada en Reykjavik, Islandia (Mayo, 2022).

Tabla de Contenido

1. Introducción	1
1.1. Motivación	1
1.2. Objetivo general	3
1.3. Objetivos específicos	3
1.4. Preguntas de investigación	3
1.5. Resumen metodológico	4
1.6. Estructura de la tesis	4
2. Marco teórico y estado del arte	6
2.1. Modelos de elección discreta	6
2.1.1. Modelos probabilísticos de elección discreta	6
2.1.2. Modelos probabilísticos estáticos	7
2.1.2.1. Modelo de maximización de la utilidad aleatoria	8
2.1.2.2. Minimización del Arrepentimiento Aleatorio	10
2.1.3. Modelos probabilísticos dinámicos	11
2.1.3.1. Teoría del campo de decisión	11
2.2. Búsqueda de información en modelos de elección discreta	17
2.2.1. Proceso de toma de decisiones	17
2.2.2. Proceso de búsqueda de información	19
2.2.3. Encuestas de datos de procesos	22
3. Encuesta Click-tracker y Eye-tracker	24
3.1. Click-tracker	24
3.1.1. Diseño	24
3.1.2. Implementación	26
3.1.3. Participantes y procedimiento	26
3.2. Eye-tracker	28
3.2.1. Diseño	28
3.2.2. Implementación	29
4. In Depth, Breadth-first, or Both?	32
4.1. Constructos para el proceso de búsqueda de información	32
4.2. Cantidad de búsqueda de información	35
4.2.1. Fijaciones en atributos	37
4.2.2. Fijaciones en alternativas	38
4.3. Filtración	39
4.4. Patrón de búsqueda de información	40
4.5. Matriz de transición	43

4.6.	Orden de patrón de búsqueda	46
4.7.	Duración	49
5.	Modelo de maximización de la utilidad aleatoria que considera evaluación secuencial de atributos	51
5.1.	Modelo econométrico	51
5.2.	Toma de decisión en cada paso t	51
5.3.	Funciones de utilidad	53
5.3.1.	Valor inclusivo de elegir	54
5.3.2.	Valor inclusivo de seguir con el proceso de búsqueda de información .	55
5.4.	Expresiones de probabilidad	55
5.4.1.	Probabilidad de elegir y seguir observando	55
5.4.2.	Probabilidad de elegir alternativa i	56
5.4.3.	Probabilidad de observar atributo k	56
5.5.	Probabilidades finales	57
5.6.	Probabilidades latentes	57
5.7.	Estimación	57
5.7.1.	Métodos de estimación	58
5.7.2.	Ejemplo	60
5.7.3.	Codificación en R	61
6.	Resultados con Datos Simulados y caso de estudio	63
6.1.	Análisis del modelo con GDP RUM-DFT	63
6.1.1.	Función de utilidad	64
6.1.2.	Factor de memoria	66
6.1.3.	Probabilidad de observar atributos	66
6.1.4.	Análisis de estimación RUM-DFT-SP	67
6.1.5.	Análisis de estimación RUM-DFT-DT	68
6.1.6.	Análisis de estimación RUM-DFT-SC	71
6.2.	Análisis del modelo con GDP RUM	75
6.3.	Análisis del modelo con GDP DFT	77
6.4.	Datos reales: Swiss Metro	78
7.	Conclusiones	81
	Bibliografía	84
	Anexos	88
A.	Focus Group	88
A.1.	Objetivos	88
A.2.	Convocatoria	88
A.3.	Metodología	88
A.4.	Focus Group	89
A.5.	Resultados	90
B.	Estimaciones	92

Índice de Tablas

2.1.	Categorización de las teorías de decisión.	7
3.1.	Dimensiones experimentales de encuestas con seguimiento de clics y tradicional.	25
3.2.	Estadística socioeconómica de los encuestados.	27
4.1.	Cantidad de búsqueda de información en tareas de elección.	36
4.2.	Porcentaje de fijaciones sobre alternativas y diferencias estadísticas.	38
4.3.	Porcentaje de observaciones en que se realizan al menos alguna vez los tipos de búsquedas de información.	40
4.4.	Patrones de búsquedas de información.	42
4.5.	Porcentaje de transiciones según el patrón de búsqueda.	43
4.6.	Duración media de las fijaciones en cada tarea de elección	50
5.1.	Matrices para la estimación del modelo.	62
6.1.	Rangos utilizados en Monte Carlo para experimento simulado.	63
6.2.	Valores de parámetros para generar los datos simulados	64
6.3.	Promedio de las estimaciones del modelo RUM-DFT con secuencia de atributos observados.	67
6.4.	Resultado de la estimación del modelo RUM-DFT con el tiempo de deliberación conocido.	69
6.5.	Resultados de estimación de modelo DFT escalado que incluye el tiempo de deliberación agregado.	71
6.6.	RUM-DFT-SC con factores de escala para diferentes PI.	72
6.7.	RUM-DFT-SC con α fijo y conocido	73
6.8.	Estimación RUM-DFT-SC considerando diferentes T_{max}	74
6.9.	Estimación de modelos en datos de encuestas tradicionales.	74
6.10.	Resultados de modelos en GDP RUM.	76
6.11.	Estimación de modelos aplicados a datos simulados a partir del enfoque DFT.	77
6.12.	Estimaciones de modelos aplicados a datos reales de SwissMetro.	79
6.13.	Estimación de Logit Mixto con datos de SwissMetro	80
A.1.	Participantes Focus Group	92
B.1.	Resultados del modelo RUM-DFT-SP en iteraciones.	92
B.2.	Resultados del modelo RUM-DFT-DT en iteraciones.	93
B.3.	Estimación de modelos DFT con parámetros de peso y escala aplicados a datos simulados a partir del enfoque RUM-DFT.	93
B.4.	Puntos iniciales para estimación con factores de escala.	94

Índice de Ilustraciones

2.1.	Hancock et al., (2021). Detención del proceso de deliberación al alcanzar el umbral interno o externo.	13
	18figure.caption.13	
	20figure.caption.14	
2.4.	Proceso de elección basado en RUM (A), RRM (B) y DFT (C)	21
3.1.	A) Preguntas socioeconómicas. B) Preguntas de preferencias reveladas: Movilidad. C) Preguntas declaradas: Panel informativo con seguimiento de clics	27
3.2.	Riesgo de distorsión de Métodos de Rastreo de Procesos.	28
3.3.	Caption	31
4.1.	Búsqueda en profundidad (azul), anchura (rojo), diagonales adyacentes (verdes) y diagonales no adyacentes (gris).	34
4.2.	Matriz de transición de encuesta con 3 alternativas y 6 atributos	34
4.3.	Boxplot cantidad de búsqueda de información normalizada por AOI.	36
4.4.	Fijaciones sobre atributos en CT23 (a), CT26 (b) y CT36 (c).	37
4.5.	Fijaciones sobre alternativas en encuestas CT23 (a), CT26 (b) y CT36 (c). Donde A, B y C corresponde a las alternativas mostradas de izquierda a derecha en las encuestas.	38
4.6.	Porcentaje de áreas de interés no fijadas	39
4.7.	Porcentaje de atributos no fijados	39
4.8.	Patrones de búsqueda de información en CT23.	41
4.9.	Patrones de búsqueda de información en CT26.	41
4.10.	Patrones de búsqueda de información en CT36.	42
4.11.	Matriz de transición de encuesta CT23. Profundidad (azul), Anchura (rojo), Diag. adyacentes (gris) y Diag. no adyacentes (verde).	44
4.12.	Matriz de transición de encuesta CT26. Profundidad (azul), Anchura (rojo), Diag. adyacentes (gris) y Diag. no adyacentes (verde).	45
4.13.	Matriz de transición de encuesta CT36. Profundidad (azul), Anchura (rojo), Diag. adyacentes (gris) y Diag. no adyacentes (verde).	45
4.14.	Orden de patrones de búsqueda de información en CT23.	46
4.15.	Orden de patrones de búsqueda de información en CT26.	47
4.16.	Orden de patrones de búsqueda de información en CT36.	48
4.17.	Duración promedio de las búsquedas en encuesta CT23.	49
4.18.	Duración promedio de las búsquedas en encuesta CT26.	49
4.19.	Duración promedio de las búsquedas en encuesta CT36.	50
5.1.	Toma de decisión durante el proceso de deliberación	52
5.2.	Toma de decisión incluyendo proceso de búsqueda de información	54
5.3.	\tilde{h}^{T_n} : Secuencia de atención sobre los atributos hasta T_n	59
5.4.	$H^{\tilde{T}}$ Secuencias posibles de atención sobre los atributos hasta \tilde{T}	59

5.5.	H Secuencias posibles de atención sobre los atributos	60
6.1.	Dinámica de utilidades con 4 alternativas y 2 atributos.	65
6.2.	Dinámica de utilidades con 4 alternativas y 3 atributos.	65
6.3.	Tiempo de generación y estimación de modelo RUM-DFT con secuencia de atributos atendidos.Promedio de las observaciones en la línea roja	68
6.4.	Tiempo de generación y estimación de modelo RUM-DFT con tiempo de deliberación. Promedio de las observaciones en la línea roja	70
A.1.	Participantes Focus Group	88

Capítulo 1

Introducción

1.1. Motivación

Tomar una decisión se define como el proceso de deliberación mediante el cual los individuos eligen entre diferentes alternativas para resolver algún problema cotidiano. En el área de la psicología, se describe a través de una serie de etapas cognitivas que debe realizar el Tomador de decisión antes de poder realizar dicha elección. Primero, debe darse cuenta de la carencia o necesidad de algo. Segundo, buscar información a través de sus experiencias previas (información interna) o adquirir y procesar el valor de atributos (Información externa). Y, finalmente, elegir una alternativa basada en sus preferencias y en la valoración de atributos con alguna regla de decisión (Engel et al., 1968).

Diversas áreas como la economía, marketing, economía de la salud y transporte poseen un gran interés en comprender el proceso de elección, ya que pueden, por ejemplo, estudiar y predecir las elecciones que los agentes realizan en diferentes situaciones de elección, estimar valoraciones subjetivas de bienes o características que no están presentes actualmente en el mercado, analizar el impacto de aplicar una política o incentivos en el comportamiento deseado, entre otras.

De manera general, se utilizan métodos estadísticos y económicos para estimar los parámetros que intervienen en el comportamiento de elección. Así, durante varias décadas, se han elaborado y fomentado el uso de modelos de elección discreta para explicar y predecir cómo los individuos realizan dichas elecciones. Busemeyer y Townsend (1993), plantean una clasificación de los modelos de elección discreta en estáticos y dinámicos.

Por un lado, los modelos estáticos son aquellos en que las probabilidades de elección son independientes del proceso cognitivo y se destacan por su gran poder explicativo, siendo el enfoque de Maximización de Utilidad Aleatoria el más destacado (RUM en adelante) (McFadden, 1976). En esta teoría, el investigador supone que los tomadores de decisión son agentes racionales, que poseen información completa y escogen una alternativa luego de realizar un proceso de búsqueda de información en profundidad de forma implícita. Es decir, los individuos conceptualizan e integran todos los atributos de una alternativa a la vez para construir la utilidad de esta. Dependiendo de los supuestos sobre la distribución de los errores de la utilidad aleatoria, se desprenden diferentes especificaciones, entre las cuales se encuentran el modelo Probit, Logit multinomial (MNL), Logit anidado (NL) y Logit mixto

(ML), en que las utilidades, por lo general se ven como se muestra en la ecuación (1.1).

$$U_i = V_i + \varepsilon_i = \sum_{k=1}^K \beta_k x_{ki} + \varepsilon_i \quad (1.1)$$

En ella se observa, que para la alternativa i dentro del conjunto de elección (\mathbb{C}), la utilidad aleatoria de la alternativa i (U_i) está compuesta por la suma de dos elementos. Primero, una parte sistemática (V_i), que corresponde a la suma de los atributos que definen la situación de elección (X), ponderados por sus respectivas valoraciones (β). Y, en segundo lugar, por un término aleatorio (ε_i) que representa todo aquello que el investigador no puede capturar a través de la componente sistemática.

Por otra parte, los modelos dinámicos consideran que las preferencias cambian durante la situación de elección debido al proceso cognitivo. Este enfoque ha sido representado por la teoría del campo de decisión (DFT). El modelo DFT fue propuesto inicialmente por Busemeyer (1985), mejorado en Busemeyer y Townsend (1993) como un modelo dinámico, cuyas últimas contribuciones corresponden a Hancock et al., (2018). En este último, se considera que el proceso cognitivo es de carácter iterativo de búsqueda de información en anchura, es decir, los individuos se enfocan y evalúan un atributo en específico a la vez, para actualizar iterativamente las preferencias de las alternativas hasta realizar su elección. La tarea de mirar un atributo y actualizar las preferencias se realiza hasta que el tomador de decisión alcanza su límite interno (preferencia) o externo (tiempo), instante en el cual, elige aquella alternativa que presente el mayor valor de preferencia.

Hasta este punto aún hay una disyuntiva que no se ha podido cerrar y corresponde a la manera en cómo se incluye el subproceso de búsqueda de información en los modelos de elección discreta estáticos o dinámicos. Esto es, si se considera la carga cognitiva de los encuestados o no. Por un lado, a pesar de que los modelos compensatorios estáticos son bastante prometedores, son muy generales y poco realistas, ya que no consideran el proceso de deliberación y asumen un proceso de búsqueda de información en profundidad. Sin embargo, en la realidad se ha evidenciado un comportamiento en anchura en situaciones de elección arriesgada a través de seguimiento ocular [Noguchi y Stewart (2014); Stewart et al., (2016); Stewart et al., (2016); Sui et al., (2020)]. Y, por otro lado, en estudios recientes muestran que las estimaciones del modelo DFT se ajustan satisfactoriamente a los datos e incluso mejor que los modelos estáticos convencionales [Qin et al., (2013); Hancock et al., (2018)]. No obstante, el modelo DFT presenta limitaciones, tales como, basarse en implementaciones matriciales ad-hoc del modelo, carecer de un marco teórico estadístico robusto y de un enfoque que sea compatible con el principio de maximización de la utilidad aleatoria.

Estas limitaciones motivan la necesidad de verificar el tipo de evaluación secuencial de atributos que realizan los usuarios de transporte público, con el fin de argumentar que siguen un proceso de búsqueda de información en anchura adoptado en el enfoque DFT. Esos esfuerzos van en la línea de plantear un modelo RUM que dé cuenta de esa dinámica cognitiva que permita subsanar restricciones de identificación e inferencia de los parámetros del modelo DFT. Así mismo, se busca explorar y analizar si el proceso de búsqueda de información, como la adquisición y procesamiento se ven influenciados por la cantidad de alternativas y atributos presentes en las situaciones de elección.

1.2. Objetivo general

El objetivo fundamental de la tesis es desarrollar y aplicar una metodología para recolectar evidencia de comportamiento de evaluación secuencial de atributos, del tipo Decision Field Theory (DFT), en elecciones de transporte público y desarrollar un modelo de maximización de utilidad aleatoria (RUM) que dé cuenta de esta dinámica. Este nuevo enfoque de modelación deberá combinar de manera práctica las herramientas económicas y estadísticas del enfoque RUM, con la capacidad de replicar el realismo del proceso cognitivo del enfoque DFT.

1.3. Objetivos específicos

1. Confeccionar y aplicar encuesta de preferencias declaradas (Click-tracker) que muestre los atributos como en un tablero de visualización de información, con el fin de capturar datos de procesos (secuencia de los atributos clicados por los tomadores de decisión y tiempo dedicado a cada tarea).
2. Analizar los datos de procesos con el fin de identificar el tipo de búsqueda de información que realizan los usuarios de transporte, cuando son sometidos a encuestas de preferencias declaradas que varían en la cantidad de atributos y alternativas mostradas.
3. Diseñar y aplicar experimento Eye-Tracker de seguimiento ocular on-line a través de cámara web, para identificar el tipo de búsqueda de información que los usuarios de transporte realizan.
4. Realizar un análisis crítico y evaluación del estado del arte de los modelos propuestos en la literatura que incorporan el enfoque DFT. Formular un modelo RUM-DFT que esté basado en maximización de la utilidad y dé cuenta de la evolución de utilidad de los individuos, siguiendo el comportamiento descrito en los modelos DFT.
5. Evaluar indicadores de desempeño dentro y fuera de la muestra del modelo RUM-DFT propuesto, respecto de modelos convencionales, utilizando los datos recolectados de Click-Tracker, Eye-Tracker y de encuestas realizadas en investigaciones externas.

1.4. Preguntas de investigación

El presente trabajo pretende dar luces a las siguientes preguntas de investigación:

¿Qué tipo de búsqueda de información, ya sea en anchura, profundidad u otro, realizan los usuarios al elegir rutas de transporte público?

¿El proceso búsqueda de información se agudiza con el aumento de atributos y alternativas cuando los usuarios de transporte público responden encuestas de preferencias declaradas?

¿Es posible formular un modelo de RUM con un enfoque DFT que capture el proceso de generación de datos de elección de ruta de transporte público y que tenga un mejor desempeño que los modelos MNL, ML y DFT, utilizando diferentes bases de datos?

1.5. Resumen metodológico

Para cumplir con el objetivo general, se desarrolla una metodología que permita evidenciar y analizar el comportamiento de la evaluación secuencial que realizan los usuarios de transporte público en encuestas de preferencias declaradas. Además, a partir de las respuestas, se logra estimar y analizar la validez del modelo RUM-DFT formulado. La metodología utilizada consta de 5 fases que son descritas a continuación.

1. Fase de investigación: Se revisa las últimas investigaciones del estado del arte de los modelos Decision Field Theory y Maximización de la Utilidad Aleatoria para formular modelo conjunto. Asimismo, se estudia bibliografía relacionada a la construcción de encuestas de preferencias declaradas que varían en el número de alternativas y atributos con seguimiento de clicks, para poder evidenciar cuáles son las principales ventajas y limitaciones para su aplicación.
2. Fase de diseño: Se formula el modelo de maximización de utilidad aleatoria que considera evaluación secuencial de atributos (RUM-DFT). Luego, se estudia la validez y el comportamiento del modelo propuesto, generando una simulación de Monte Carlo para ello. Por otro lado, se construye una encuesta denominada Click-tracker (CT) que consta de una parte de preferencias reveladas y otra de preferencias declaradas. En la primera sección, se recopila información sociodemográfica y las características típicas de viaje en transporte público en punta mañana. La información de movilidad se utilizó para construir 8 preguntas hipotéticas de preferencias declaradas pivotadas con seguimiento de los atributos clicados.
3. Fase de implementación: Se aplica Click-tracker a usuarios del transporte público, captados en diferentes paradas o estaciones concurridas de la red de transporte público de la ciudad de Santiago de Chile. A cada encuestado, se le presenta de forma aleatoria una de las 4 posibles situaciones de elección que varían según la cantidad de alternativas y atributos.
4. Fase de análisis: Se realiza un diagnóstico del modelo propuesto a través de un Monte Carlo, en la cual se observa el comportamiento de éste y la validez de los supuestos realizados. Por otro lado, se crean y se analizan los datos con seguimiento de clicks con el fin realizar un análisis estadístico del proceso de deliberación para las distintas encuestas. En particular, se estudia la cantidad de búsqueda de información, los patrones de búsqueda de información, la importancia relativa de los atributos y la duración de los clics realizado por los encuestados.
5. Fase de validación: Se realiza una comparación del modelo propuesto con los utilizados convencionalmente, usando diferentes indicadores de bondad de ajustes dentro y fuera de muestra, utilizando la base de datos obtenida, y también bases de datos reales.

1.6. Estructura de la tesis

Se expone a continuación un resumen de la estructura del presente trabajo, con el fin de facilitar la comprensión del lector:

Capítulo 2: Marco teórico. Se expone una revisión bibliográfica relacionada los modelos de elección discreta asociada al modelo de maximización de la utilidad aleatoria y decision field theory, junto con las herramientas estadísticas que servirán para el análisis.

Capítulo 3: Búsqueda de información en modelos de elección discreta. Se define la toma de decisiones, el proceso de búsqueda de información y los constructos que permiten analizar el proceso de deliberación.

Capítulo 4: Diseño de la encuesta Click-Tracker. Se detalla la metodología que se siguió para construir e implementar la encuesta de preferencias declaradas pivoteada con seguimiento de clics.

Capítulo 5: Modelación y Evaluación. Se realiza un diagnóstico del modelo a través de un Monte Carlo, se detallan los resultados de la muestra obtenida y se estiman diferentes especificaciones del modelo propuesto para comprobar si se obtienen mejores indicadores de bondad de ajustes que otros modelos convencionales de la literatura.

Capítulo 6: Conclusiones. Se muestran las principales conclusiones del trabajo, respondiendo las preguntas de investigación y verificando el cumplimiento de los objetivos planteados. Además, se mencionan las posibles implicancias para la creación de políticas públicas y las limitaciones y extensiones del trabajo.

Capítulo 2

Marco teórico y estado del arte

2.1. Modelos de elección discreta

En este capítulo, se detalla el marco teórico en el que se basan los modelos de elección discreta y se muestran los supuestos adoptados en las formulaciones más utilizadas. La finalidad consiste en establecer un marco teórico adecuado para la formulación de un modelo de maximización de utilidad aleatoria (RUM) que incorpore el proceso de búsqueda de información de manera explícita en la formulación, con la dinámica del proceso cognitivo y los grandes supuestos que están detrás del modelo de Decision Field Theory (DFT).

2.1.1. Modelos probabilísticos de elección discreta

Los modelos de elección discreta han sido propuestos, utilizados y fomentados ampliamente en la literatura desde hace varias décadas atrás. Estos corresponden a un enfoque matemático que permite realizar estimaciones y predicciones de los comportamientos que realizan los agentes económicos en diferentes áreas tales como la economía, salud, marketing, transporte, entre otras.

Las diferentes especificaciones existentes se engloban dentro de la teoría económica clásica del consumidor, en la cual, el individuo se enfrenta a una situación de elección y debe escoger una alternativa tras una comparación de los atributos que la definen, siguiendo alguna regla de decisión que haya considerado. Los supuestos que se adoptan generalmente son:

- Los agentes económicos, tales como personas, empresas, familia, etc. son los tomadores de decisión y se definen a través de un vector de características socioeconómicas (S_n).
- Existe un conjunto de alternativas disponibles para cada agente que definen la situación de elección (J_n).
- Cada una de las alternativas se caracteriza por un vector de atributos (K_j).
- Los agentes pueden elegir solo una alternativa.
- La elección es tomada siguiendo alguna de las reglas de decisión. Los criterios que se destacan son Maximización de la Utilidad, Dominancia, Satisfacción, Lexicográficas, entre otras (Ben-akiva y Ierman, 1985). Se considerará el criterio de Maximización de la Utilidad dado el objetivo de esta tesis.

La revisión literaria llevada a cabo permite identificar que existe y se mantiene actualmente una discusión acerca del procesos de la toma de decisión. Esto se relaciona con los supuestos adoptados en la estructura, forma funcional y etapas del proceso. En este capítulo se muestran a grandes rasgos los modelos compensatorios convencionales más utilizados y nuevos enfoques provenientes de la psicología matemática.

Busemeyer y Townsend (1993) realizan una clasificación de los modelos de elección categorizándolos en determinísticos o probabilísticos y si las utilidades o preferencias se construyen de manera dinámica o estática. Los modelos determinísticos indican que, bajo situaciones de elección que tengan las mismas características, se obtiene la misma elección por parte de los agentes económicos. Sin embargo, bajo observaciones empíricas se mostró que este comportamiento no ocurría en la mayoría de los casos y que los supuestos adoptados eran inconsistentes. En cambio, los modelos probabilísticos consideran que el comportamiento individual tiene un grado de aleatoriedad, es decir, existe una probabilidad asociada a la elección de una alternativa y que es imposible de modelar de forma completamente precisa.

En relación con la segunda categorización, los modelos estáticos son aquellos en que las probabilidades de elección son independientes del proceso cognitivo y que no varían durante el tiempo de deliberación. El tiempo de deliberación corresponde al tiempo que considera el individuo desde que adquiere la información sobre los atributos hasta que realiza la elección. Por otro lado, en los modelos dinámicos las probabilidades no son constantes durante el tiempo de deliberación, ya que se incluyen parámetros asociados a la memoria, orden de la adquisición, similitud de alternativas, carga cognitiva, entre otros.

En la tabla 2.1 se muestran los modelos probabilísticos que se detallan en esta sección. Esto con el fin de sentar la bases para construir un modelo de maximización de utilidad aleatoria que incorpore el proceso de búsqueda de información relacionada al valor de los atributos realizada por los encuestados.

Tabla 2.1: Categorización de las teorías de decisión.

Categoría	Estática	Dinámica
Determinístico	Utilidad Esperada	Dinámica de Acción
Probabilístico	Maximización de la Utilidad Aleatoria Minimización de Arrepentimiento Aleatorio	Teoría de Campo de Decisión

2.1.2. Modelos probabilísticos estáticos

Los modelos probabilísticos estocásticos son un enfoque de modelación de elección discreta que considera la existencia de probabilidades de elección (definidas según alguna regla de decisión). Sin embargo, no incorpora la influencia del proceso de deliberación, es decir, las probabilidades son constantes desde que comienza la situación de elección hasta que se elige la alternativa definitivamente (Busemeyer y Townsend, 1993).

Para el cálculo de las probabilidades de elección, a estos modelos típicamente se les debe entregar como valores de entrada todos los atributos que definen la situación de elección, la alternativa elegida y características socioeconómicas del tomador de decisión, si el investigador lo considera. Además, se asume que el proceso de búsqueda de información ocurre de

manera implícita e instantáneamente previa a la elección considerando todos los atributos de las alternativas. Esto último es una limitante de estos modelos, ya que se ha evidenciado que los tomadores de decisiones no atienden todos los atributos o filtran la información para tomar su decisión. Por lo cual, el cálculo de las probabilidades de elección de las alternativas no es del todo correcto (Scarpa et al., 2010).

2.1.2.1. Modelo de maximización de la utilidad aleatoria

McFadden (1976) comentó críticas sobre la racionalidad de los tomadores de elecciones en la maximización de la utilidad determinística y avanzó en la modelación incorporando cierta aleatoriedad. En este nuevo enfoque, el investigador supone que los tomadores de decisión son agentes racionales, poseen información completa de la situación de elección y escogen una alternativa siguiendo el criterio de maximización de utilidad. Sin embargo, no es capaz de capturar toda la información necesaria para modelar perfectamente el comportamiento de elección que realizan.

De manera general, se define que el tomador de decisión n elige la alternativa i con la mayor utilidad aleatoria (U_{in}) dentro del conjunto de elección (C_n). La utilidad U_{in} está compuesta por una utilidad sistemática representado por V_{in} y una parte aleatoria capturada por ε_{in} . Además, si se considera linealidad en los parámetros en la utilidad sistemática, la utilidad queda como se muestra en la ecuación (2.1).

$$U_i = V_i + \varepsilon_i = \sum_{k=1}^K \beta_k x_{ki} + \varepsilon_i \quad (2.1)$$

En la cual, x_{kin} representa el valor del atributo k de la alternativa i con parámetro β_k , que determina la influencia sobre la utilidad. Por otro lado, la parte aleatoria (ε_{in}) captura el conocimiento imperfecto del investigador o la heterogeneidad no observada. A partir de lo anterior, se puede expresar la probabilidad de elegir la alternativa i como la probabilidad de que la utilidad aleatoria de la alternativa i sea mayor o igual que el resto, tal como se muestra a continuación:

$$P(i|C_n) = P(U_{in} \geq U_{jn} \quad \forall j \in C_n) \quad (2.2)$$

$$P(i|C_n) = P(\varepsilon_{jn} - \varepsilon_{in} \geq V_{in} - V_{jn} \quad \forall j \in C_n) \quad (2.3)$$

$$P(i|C_n) = F_{\varepsilon_{jn}-\varepsilon_{in}, \dots, \varepsilon_{Jn}-\varepsilon_{in}}(V_{jn} - V_{in}, \dots, V_{Jn} - V_{in}) \quad (2.4)$$

Donde F corresponde a la función de distribución acumulada (FDA) multivariada de $\varepsilon_i - \varepsilon_j \forall j$. Que es equivalente a una función de distribución de dimensión $J-1$. Dependiendo del supuesto que se haga sobre el vector de los ε_{in} , se tendrán diferentes modelos.

A continuación, se detallan algunos de los modelos convencionales más utilizados:

1. Probit: El primer supuesto que se puede adoptar es que los errores ε_{in} distribuyan de manera Normal Multivariada ($\varepsilon_{in} \sim MVN(0, \Sigma)$) como tantos fenómenos naturales.

Así, la probabilidad de elección de la alternativa i es:

$$P_n(i|C_n) = \int_{-\infty}^{V_{1n}-V_{2n}} \int_{-\infty}^{V_{1n}-V_{3n}} \cdots \int_{-\infty}^{V_{1n}-V_{Jn}} n(q; 0, \Sigma) dq \quad (2.5)$$

Donde $n(q; 0, \Sigma)$ denota la densidad multivariada normal con media cero y matriz var-cov Σ . Entre las ventajas de este modelo, se destaca las siguientes: permite modelar patrones de sustitución flexibles, se puede extender a coeficientes aleatorios normales tales como heterogeneidad aleatoria y se puede extender a datos de panel con correlación serial. Las desventajas de este modelo radican en que es muy complejo ya que es una integral de $J-1$ dimensiones y no es una expresión matemática cerrada fácil de calcular.

2. Logit multinomial (MNL): Este modelo se genera al adoptar que los errores ε_{in} son independientes e idénticamente distribuidos Valor Extremo Tipo I ($\varepsilon_{jn} \sim i.i.d. \text{ EVI}(\eta, \mu)$). Así, la probabilidad de elección de la alternativa i es:

$$P_n(i|C_n) = \frac{e^{\mu V_{in}}}{\sum_j e^{\mu V_{jn}}} \quad (2.6)$$

En comparación al modelo anterior, esta es una expresión cerrada para la probabilidad de elección, es fácil de estimar y como los errores son *i.i.d.*, la matriz de varianza-covarianza no sufre de heterocedasticidad ni autocorrelación. Sin embargo, este modelo es muy sencillo y produce resultados no razonables cuando se tienen alternativas no independientes entre sí o existe correlación de errores no observados entre ellas.

3. Logit Anidado: En ciertas elecciones hay patrones de sustitución más fuertes entre algunas alternativas y ocurre cuando existe correlación entre atributos no observados de esas alternativas. Por lo cual, en este modelo no se cumple la propiedad de Independencia Irrelevantes entre Alternativas (*IIA*) y la estructura de correlación se modela en nidos. Así, la probabilidad de elegir la alternativa i dentro del nido m (N_m) se expresa como:

$$\mathbb{P}(i) = \mathbb{P}_{N_m} \cdot \mathbb{P}_{i|N_m} = \left(\frac{e^{\mu_m I_m}}{\sum_l e^{\mu_l I_l}} \right) \cdot \left(\frac{e^{\frac{V_i}{\mu_m}}}{\sum_{j \in N_m} e^{\frac{V_j}{\mu_m}}} \right) \quad (2.7)$$

$$\text{con } I_m = \ln \left(\sum_{j \in S_m} e^{\frac{V_j}{\mu_m}} \right) \quad (2.8)$$

Donde \mathbb{P}_{N_m} denota la probabilidad de que se elija una alternativa dentro del nido m (N_m). $\mathbb{P}_{i|N_m}$ corresponde a la probabilidad de que se elija la alternativa i condicional a que se elige una alternativa del nido N_m . I_m corresponde al valor esperado de elegir una alternativa en el nido m que se propaga hacia la raíz del árbol.

La ventaja de estos modelos radica en que son fáciles de implementar, se han fomentado bastante debido a que poseen una base microeconómica sólida y algunos tienen formulaciones matemáticamente cerradas. Lo anterior, permite calcular, por ejemplo, valoraciones subjetivas de los atributos, estimar el impacto en escenarios futuros, analizar planes y políticas, entre otros. Sin embargo, a pesar de ser bastante prometedores, estos modelos consideran que

los agentes adquieren y procesan la información de manera instantánea, tienen la capacidad de recordar perfectamente los valores de los atributos y que las preferencias no varían a través del tiempo debido al proceso cognitivo. Más aún, se considera un **proceso de búsqueda de información en profundidad** implícito en la modelación. Lo anterior se debe a que el cálculo de las probabilidades de elección, el investigador asume que el tomador de decisión conceptualiza todos los atributos a la vez de la misma alternativa de manera previa a la elección.

2.1.2.2. Minimización del Arrepentimiento Aleatorio

El modelo de minimización del arrepentimiento aleatorio (RRM) se basa en que los agentes, al momento de elegir, se anticipan y minimizan las emociones negativas asociada a cada alternativa (C. G. Chorus et al., 2008).

Según Chorus (2010), el arrepentimiento sistemático de cada alternativa (RR_i) se obtiene como la suma de los arrepentimientos binarios ($RR_{i \leftrightarrow j}^k$) asociados a todas las comparaciones bilaterales entre alternativas bajo el mismo atributo, tal como se muestra en la ecuación (2.9).

$$RR_i = \sum_{i \neq j} \sum_{k=1 \dots K} RR_{i \leftrightarrow j}^k \quad (2.9)$$

Donde $RR_{i \leftrightarrow j}^k$ hace referencia al arrepentimiento de elegir la alternativa i en vez de j con respecto al atributo k . A su vez, define que los niveles de arrepentimiento son no negativos. En caso de que la alternativa i sea mejor que la alternativa j en el atributo k , $RR_{i \leftrightarrow j}^k$ tendrá un valor igual a cero. En caso contrario, será igual a la diferencia del arrepentimiento bajo el atributo k ponderada por el coeficiente β_k , tal como se muestra a continuación:

$$RR_{i \leftrightarrow j}^k = \max \{0 + \nu_{0k}, \beta_k \cdot (x_{jk} - x_{ik}) + \nu_{xk}\} \quad (2.10)$$

Se incorporan dos errores (ν_{0k}, ν_{xk}) con distribución de valor extremo tipo I para representar la heterogeneidad no observada en las percepciones de los atributos. Para el cálculo de las probabilidades de elección, se utiliza el resultado de que la integral de los arrepentimientos sobre $f(\nu_{0k}, \nu_{xk})$ resulta en la formulación logsum para el valor esperado del máximo (M. E. Ben-Akiva y Lerman, 1985), tal como se muestra a continuación:

$$\int_{\nu} RR_{i \leftrightarrow j}^k \cdot f(\nu) d\nu = \ln \left(1 + e^{\beta_k (x_{jk} - x_{ik})} \right) \Rightarrow RR_{i \leftrightarrow j}^k = \ln \left(1 + e^{\beta_k (x_{jk} - x_{ik})} \right) \quad (2.11)$$

Finalmente, el arrepentimiento sistemático puede reescribirse usando la formulación anterior, y dado que el arrepentimiento aleatorio es matemáticamente equivalente a la maximización del negativo de este, las probabilidades de elección se pueden derivar siguiendo la formulación Logit Multinomial. Por lo tanto, la probabilidad de elección de la alternativa i es igual a:

$$\mathbb{P}_i = \frac{e^{-\sum_{i \neq j} \sum_k RR_{i \leftrightarrow j}^k}}{\sum_J e^{-\sum_{j \neq l} \sum_k RR_{j \leftrightarrow l}^k}} \quad (2.12)$$

En Chorus (2010) y Chorus et al., (2014) se realizan comparaciones teóricas y prácticas entre el modelo RUM y el modelo RRM, mostrando que este último tiene mejores ajustes en ciertas situaciones de elección. Las ventajas que se pueden destacar son que se reconoce que las elecciones pueden ser no totalmente compensatorias; los agentes pueden posponer su elección

para buscar más información cuando tienen conocimiento limitado; y, además, permite explicar el compromise effect que no es posible capturarlo a través de modelos compensatorios (C. Chorus y Bierlaire, 2013).

Por último, cabe destacar que el modelo RRM incorpora de manera implícita e instantánea en la modelación el **proceso de búsqueda de información en anchura** y asume que hay información completa. Esto se debe a que los tomadores de decisiones realizan comparaciones bilaterales de alternativas en cada paso del proceso de deliberación considerando un atributo, con el fin de calcular el arrepentimiento (C. Chorus, 2012).

2.1.3. Modelos probabilísticos dinámicos

Los modelos probabilísticos dinámicos son un enfoque de modelación discreta con probabilidades de elección definidas a partir de una regla de decisión, pero que incorpora de manera explícita el proceso de deliberación que afecta la elección final. A saber, las probabilidades varían producto de que hay una constante adquisición y procesamiento de información (atributos) que se incorpora para actualizar el valor de las preferencias o utilidades, previa a la elección.

En Stewart et al., (2016) se encuentra que el tiempo de deliberación está relacionado con las elecciones de las alternativas, ya que dan cuenta de que aumenta el tiempo cuando hay alternativas más similares entre sí. Estos resultados son concordantes con hallazgos encontrados previamente en Mosteller y Nogee, (1951); Jamieson y Petrusic (1977). Petrusic y Jamieson (1978) muestran que existe una relación entre las probabilidades de elección y el tiempo de decisión que les permite concluir que el tiempo de decisión puede ser una forma eficaz de estimar la fuerza de la preferencia. Busemeyer y Townsend (1993) comentan que los tomadores de decisión frecuentemente limitan su tiempo de deliberación y este hecho podría argumentar que existan decisiones irracionales que son capturadas erróneamente por modelos convencionales. Además, hay varios trabajos que muestran empíricamente que los tomadores de decisión revisitan más de una vez los atributos para tomar su decisión (Jhonson et al., (2008); Stewart et al., (2016)). Sin embargo, existe una filtración de atributos, centrando la atención a ciertos valores que pueden ser más complejos de conceptualizar o que intervienen en mayor medida en la función de utilidad o preferencia (Jacoby (1975) y Payne (1976))

Todos estos antecedentes motivaron la necesidad de construir un marco teórico que incluya parámetros del proceso de deliberación y que se modele explícitamente, con el fin de dar cuenta de la dinámica que existe en la toma de elecciones. A continuación, se expone el modelo Decision Field Theory proveniente de la psicología matemática que permite subsanar esta brecha.

2.1.3.1. Teoría del campo de decisión

El modelo Decision Field Theory (en adelante DFT), o Teoría de Campo de Decisión, es un enfoque dinámico que considera que las preferencias varían durante la situación de elección. Este fue diseñado inicialmente como un modelo cognitivo para capturar el proceso de deliberación en la toma de elecciones (Busemeyer y Townsend (1992), Busemeyer y Townsend (1993)). Luego, DFT se extendió a un modelo estocástico-dinámico que permitía incluir múltiples atributos (Diederich, 1997) y también se generalizó a la toma de decisiones de múltiples alternativas (Roe et al., 2001), llamándose Teoría del Campo de Decisiones de

Múltiples Alternativas (MDFT).

Las últimas contribuciones son de Hancock et al., (Hancock et al., 2018) quienes mejoran los mecanismos que soportan el modelo DFT para hacerlo más competitivo con los de elección tradicionales. Estos avances permiten incorporar heterogeneidad entre y dentro de los tomadores de decisiones. Luego, en Hancock et al., (2021), se incluyen parámetros de escala en el mecanismo básico del modelo DFT, con el fin de evitar conceptualizar valores a priori de los parámetros que afectan la estimación e identificación del modelo. Finalmente, en Hancock et al., (2022-WP) se extiende el modelo escalado para incluir datos de procesos de seguimiento ocular, para capturar los pesos de atención de los atributos con mayor realismo durante el proceso de deliberación.

De manera general, este modelo asume que el proceso cognitivo es de carácter iterativo de **búsqueda de información en anchura**, es decir, los individuos se enfocan y evalúan un atributo en específico a la vez, para actualizar iterativamente las preferencias de las alternativas hasta realizar su elección. El supuesto de que los individuos busquen atributos en atributos es concordante con los resultados empíricos obtenidos de los análisis de datos de procesos (Noguchi et al., (2014); Sui et al., (2020)). Esto se debe a que los encuestados realizan comparaciones de alternativas bajo el mismo atributo con mayor frecuencia que otros patrones de búsqueda de información, tales como Profundidad, Diagonales Adyacentes y Diagonales no adyacentes (Payne, 1976). En el capítulo 4, se muestran argumentos a favor de que los usuarios de transporte público realizan predominantemente búsquedas en anchura, pero no de manera total, evidenciando que los supuestos adoptados en el modelo DFT son adecuados y concordantes para ser incluidos el proceso de deliberación en la toma de elecciones.

La tarea de mirar un atributo y actualizar las preferencias puede terminar debido a dos razones. Primero, el proceso se itera hasta que el tomador de decisión alcanza su límite interno (preferencia) asociado a que la alternativa elegida es lo suficientemente buena para el (Satisficing Behaviour, Simon (1957)). En segundo lugar, el investigador puede imponer un tiempo limitante externo (Maximising Behaviour, Schwartz et al., (2002)), instante en el cual, el individuo elige aquella alternativa que presente el mayor valor de preferencia. Este proceso se evidencia en la figura 2.1, ya que el tomador de decisiones elige alternativas diferentes si se impone un tiempo máximo (por ejemplo $t = 4$) o si alcanza su umbral interno (línea horizontal en $t = 10$).

Este modelo poco convencional, generalmente ha sido utilizado para estudiar los efectos de similitud, atracción y compromiso (Roe et al., 2001) y para investigar que tan bien puede explicar estos efectos en contextos de elección en comparación a otros modelos. Si bien existen enfoques compensatorios para realizar este análisis, por ejemplo, Guevara y Fukushi (2016) que utilizan un modelo Nested Logit para estudiar el efecto de similitud, el modelo DFT se destaca por ser dinámico y permite analizar decisiones arriesgadas o elecciones afectadas por la presión del tiempo (Busemeyer y Townsend, 1993). Por último, se ha mostrado que el modelo DFT tiene mejores indicadores de ajustes que los modelos RUM en datos de preferencias declaradas (Hancock et al., 2018), como también, en datos de preferencias reveladas de transporte (Hancock et al., 2021).

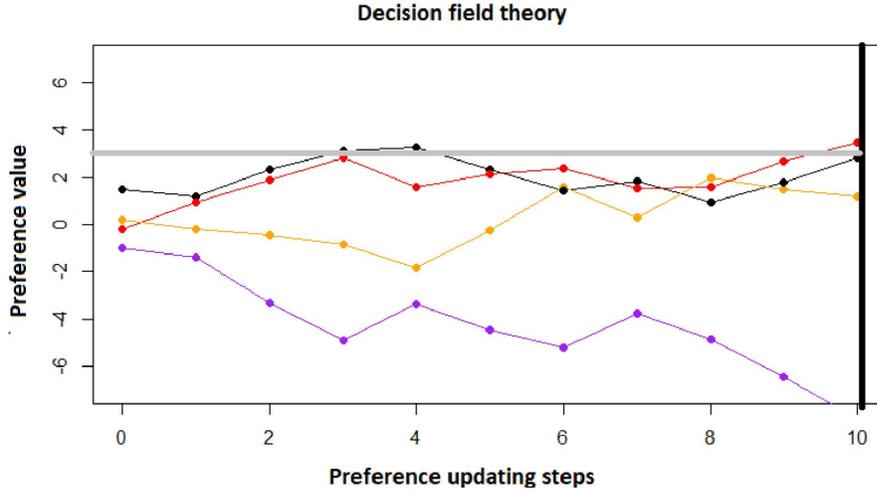


Figura 2.1: Hancock et al., (2021). Detención del proceso de deliberación al alcanzar el umbral interno o externo.

Mecanismos básicos del DFT

Las últimas mejoras metodológicas de los mecanismos del modelo DFT fueron propuestas por Hancock et al., (2018). A continuación, se detalla con el fin de explicar su operación y dar luces de sus limitaciones, lo que motiva el planteamiento de un modelo con base en la Maximización de la Utilidad Aleatoria. Se utiliza la notación de esos autores y se seguirá su desarrollo expositivo.

La idea principal del modelo se sustenta en que las preferencias de las alternativas se actualizan durante el proceso de deliberación. En cada paso del proceso de, previa a la elección, los individuos adquieren y conceptualizan el valor de un solo atributo para actualizar las preferencias de todas las alternativas disponibles, las veces que estimen conveniente (Busemeyer y Townsend, 1993). Por lo cual, en cada paso t , los valores actuales de preferencias se obtienen a partir del paso anterior multiplicada por una matriz de retroalimentación más un vector de valencia. De manera general, se tiene que:

$$P_t = S \cdot P_{t-1} + V_t \quad (2.13)$$

En la cual, P_t y P_{t-1} son vectores que tienen los valores de preferencias de cada alternativa en el paso t y $t - 1$ del proceso de deliberación. P_0 corresponde al vector de preferencias iniciales o preconcebidas de las alternativas asociadas a las experiencias previas de los tomadores de decisión. S es la matriz de retroalimentación relacionada al proceso de búsqueda de información, que es fundamental para el desarrollo del modelo y se define como se muestra en la ecuación (2.14). V_t corresponde al vector de valencia aleatorio que contiene el valor de preferencia de las alternativas al observar cierto atributo en el paso t y se define en la ecuación (2.15).

$$S = I - \phi_2 e^{-\phi_1 D^2} \quad (2.14)$$

La matriz de retroalimentación esta compuesta por el parámetro de sensibilidad (ϕ_1), el parámetro de memoria (ϕ_2) y una medida de distancia entre los atributos a través de las alternativas (D^2). El parámetro de sensibilidad captura el efecto de similitud, es decir, afecta

a las alternativas que compiten entre sí (Roe et al., 2001). El parámetro de memoria da a conocer qué tanta información pueden recordar los agentes durante el proceso de búsqueda. Este valor afecta directamente los valores de la diagonal de la matriz de retroalimentación, mostrando que valores positivos ($S_{i,i} > 1$) indican que la memoria crece y valores negativos ($S_{i,i} < 1$) que decae durante el tiempo de deliberación. Se ha demostrado que los individuos tienen diferentes memorias y capacidad para procesar y almacenar la información adquirida (Jacoby (1975); Payne (1976)). Además, en análisis de datos de procesos anteriores y el evidenciado en este trabajo (Capítulo 4) muestran que los agentes revisitan los valores de los atributos. Esto asociado a una pérdida de información que puede ser capturada por este parámetro. La matriz de distancia se puede definir de varias maneras, por ejemplo, Roe et al., (2001) mencionan que debería usarse distancias psicológicas, pero en la aplicación calcularon distancias dando cuenta de la posición relativa que tienen las alternativas en el espacio de la evaluación de atributos múltiples. Otro ejemplo es de Qin et al., (2013), quienes utilizan la distancia euclidiana en el mismo espacio de evaluación.

$$V_t = C \cdot M \cdot W_t + \varepsilon_t \quad (2.15)$$

Por otro lado, el vector de valencia aleatoria esta compuesto por una matriz de contraste (C), utilizada para comparar las alternativas entre sí y se define como $C_{i,i} = 1$ y $C_{i,j} = -1/(n-1)$ con n la cantidad de alternativas. M corresponde a la matriz con los atributos. W_t es un vector que indica el atributo que está siendo atendido en el paso t por el tomador de decisión, es decir, $W_t = [0, \dots, 1_k, \dots, 0]$ si el tomador de decisión está observando el atributo K^{th} en el paso t . Por lo tanto, el modelo DFT típicamente estima los pesos de atención w_k , que corresponden a la probabilidad de que el atributo x_k esta siendo atendido en un paso dado ($\sum_k W_k = 1$). Finalmente, ε_t es el vector de errores, los cuales distribuyen usualmente $\varepsilon \sim N(0, 1)$. En el modelo DFT base, dado que se debe estimar los pesos de atención y estas son probabilidades no negativas, el investigador debe conocer a priori el efecto de los atributos e introducirlos de manera positiva en el cálculo de las preferencias. Esto conlleva problemas de identificación y un arte en la definición de los valores iniciales en la estimación. En el siguiente apartado se comentará el modelo DFT con parámetros de escala y la inclusión de datos de procesos.

Previo al cálculo de las probabilidades, es necesario determinar el valor esperado y covarianza de las preferencias en el tiempo. Al expandir la ecuación (2.13), resulta en:

$$P_t = \sum_{k=0}^{t-1} S^k \cdot V_{t-k} + S^t \cdot P_0 \quad (2.16)$$

Dado que los vectores de peso w_j y W_t son procesos estocásticos estacionarios, entonces V_t se considera un proceso estacionario con media $E[V_t]$ y una matriz de covarianza dada por $Cov[V_t]$, tal como se muestran en las ecuaciones (2.17) y (2.18), respectivamente.

$$E[V_t] = \mu = C \cdot M \cdot w_m \quad \text{con } w_m = [w_1, w_2, \dots, w_n] \quad (2.17)$$

$$Cov[V_t] = \Phi = C \cdot M \cdot \Psi \cdot M' \cdot C' + s \quad \text{con } \Psi = Cov[W_t] \quad \text{y } s = Cov[\varepsilon_t] \quad (2.18)$$

A partir de los últimos desarrollos de Hancock et al., (2018), el valor esperado y la covarianza de P_t se pueden calcular para un tiempo específico del proceso de deliberación y no hasta el

infinito como era usual. Las expresiones finales se muestran en la ecuación (2.19) y (2.20), respectivamente.

$$E[P_t] = \xi_t = (I - S)^{-1}(I - S^t) \cdot C \cdot M \cdot w_m + S^t \cdot P_0 \quad (2.19)$$

$$Cov[P_t] = \Omega_t = (I - z)^{-1}(I - z^t)\bar{\Phi} \quad (2.20)$$

Con w_m vector de pesos de los atributos y Z una transformación de S tal que $\overline{S\Phi S'} = Z\bar{\Phi}$.

Cálculo de probabilidades

Tal como demuestran Roe et al., (2001), al conocer el valor esperado y la covarianza de los valores de preferencias en el tiempo t $\langle \xi_t, \Omega_t \rangle$, se puede calcular la probabilidad de elegir alternativas. Según la teoría, se elige la alternativa A dentro del conjunto de consideración $\mathbb{C} = \{A, B, C\}$ si tiene un valor de preferencia mayor que el resto de las alternativas en el tiempo t . Por lo tanto, la probabilidad se puede expresar como:

$$\mathbb{P}[P_t(A) > P_t(B) \cap P_t(A) > P_t(C)] = \int_{X>0} \frac{1}{2\pi |\Lambda|^{0.5}} e^{-\frac{1}{2}(X-\Gamma)'\Lambda^{-1}(X-\Gamma)} dX \quad (2.21)$$

Con $X = [P_t(A) - P_t(B), P_t(A) - P_t(C)]'$, $\Gamma = L\xi_t$, $\Lambda = L\Omega_t L'$ y $L = \begin{bmatrix} 1 & -1 & 0 \\ 1 & 0 & -1 \end{bmatrix}$.

DFT Escalado

En Hancock et al., (2021) se mejora el mecanismo básico del vector de valencia (V_t), con el fin de subsanar limitaciones asociadas a la identificación y escala de los valores de los atributos. En esta especificación, se incluye un vector de coeficientes de escala específicos de atributos β que multiplican la matriz de atributos (M), dando como resultado la siguiente función para el vector de valencia aleatoria en el paso t :

$$V_t = C \cdot \beta \cdot M \cdot W_t + \varepsilon_t \quad (2.22)$$

Junto a ello, se multiplican los atributos por sus coeficientes de escala antes de calcular las distancias entre alternativas en la matriz de retroalimentación (D), por lo cual, la distancia entre las alternativas i y j es:

$$D_{n,i,j}^2 = \sum_{k=1}^K [\beta_k (x_{n,i,k} - x_{n,k,k})]^2 \quad (2.23)$$

La adición de parámetros de escalas conllevan a tres principales beneficios, comentado por los autores. Primero, ya no se genera un impacto en la estimación al variar la unidad de los parámetros. En segundo lugar, los atributos se ajustan según su importancia relativa antes de ingresar a la matriz de retroalimentación. Esto permite calcular distancias psicológicas simplemente tomando la distancia euclidiana. Finalmente, ya no es necesario realizar suposiciones a priori sobre si un atributo tiene un impacto positivo o negativo en la probabilidad de elección, ya que los parámetros de escalas permiten la libertad de capturar el signo en la estimación. Aún más, permite que en un modelo DFT con coeficiente aleatorio tenga parámetros con diferentes signos entre individuos. Por último, no es clara la ganancia de ajuste cuando

se fija la matriz de retroalimentación y se incluyen estos parámetros de escala (Hancock et al., 2021).

DFT Escalado con datos de procesos

En Hancock et al., (2022-WP) se incorpora datos fisiológicos en el modelo DFT obtenidos a partir de una encuesta de elección de alojamiento y un experimento de conducción simulado de aceptación de brechas. Específicamente, se prueba la inclusión de parámetros asociados a datos de seguimiento ocular, tales como la cantidad de fijaciones y el tiempo de la mirada sobre los atributos en los pesos de atención (w_k) y en los parámetros de escalas (β_k) tal como se muestra en la ecuación (2.24) y (2.25), respectivamente.

$$w_k = w_k + \alpha_{\#fijaciones} \cdot x_{\#fijaciones} + \alpha_{duración} \cdot x_{duración} \quad (2.24)$$

$$\bar{\beta}_k = \beta_k + \alpha_{\#fijaciones} \cdot x_{\#fijaciones} + \alpha_{duración} \cdot x_{duración} \quad (2.25)$$

Los resultados muestran que al datos de seguimiento ocular, estos pueden relacionarse con los parámetros del proceso de deliberación del modelo DFT, logrando más mejoras sustanciales en el ajuste que otros modelos econométricos como el modelo MNL.

Ventajas

Existen diversas ventajas que se pueden asociar al modelo Decision Field Theory y se detallan a continuación:

1. Es un modelo dinámico estocástico que incorpora explícitamente el proceso de deliberación que realizan los tomadores de decisión a través de parámetros tales como sensibilidad (ϕ_1), memoria (ϕ_2), pesos de atención (w_m) y la matriz de distancias psicológicas (D).
2. El modelo asume que el proceso de búsqueda de información es totalmente en anchura al igual que el modelo RRM, es decir, los tomadores de decisiones realizan comparaciones de alternativas bajo un mismo atributo en cada paso del proceso de deliberación. Este supuesto se ha evidenciado a través de seguimiento ocular cuando los individuos eligen entre 2 alternativas en elecciones arriesgadas (Noguchi y Stewart (2014)). En el capítulo 4 de este trabajo, se muestran resultados de que este comportamiento predomina cada vez más cuando se aumenta la cantidad de atributos y alternativas mostrados en encuestas de preferencias declaradas.
3. Bajos ciertos contextos, el DFT se ajusta y predice mejor que los modelos convencionales de la teoría de elección discreta tales como RUM y RRM (Hancock et al., (2018); Hancock et al., (2021)).
4. En Qin et al., (2013), se analizan las elecciones de Park and Ride utilizando el modelo DFT y se calibra utilizando datos reales. Los resultados evidencian que es capaz de dar cuenta del proceso de deliberación complejo y de los factores que intervienen, tales como preferencias iniciales el tiempo y umbral de deliberación para la elección de modo.

Desventajas

Las limitaciones y problemas del modelo Decision Field Theory que se destacan a continuación, se han encontrado en publicaciones tales como Hancock et al., (2018); Hancock et al., (2021) y son relevantes para este trabajo.

1. El costo computacional es excesivamente alto y demora hasta 318 veces más en ejecutarse que un modelo Logit Multinomial. La implementación no es fácil ya que para las probabilidades se deben calcular las matrices que intervienen en el proceso y luego calcular la integral correspondiente. Sin embargo, el modelo se encuentra implementado en el paquete Apollo de R (Hess y Palma, 2019) que facilita que otros investigadores comiencen a utilizar más este enfoque en sus datos recolectados.
2. El modelo DFT está sustentado desde la psicología matemática y las relaciones de las variables se representan matricialmente. Por lo cual, solo es posible establecer interpretaciones de los parámetros desde el punto de vista del proceso de deliberación, es decir, se puede hablar de: los pesos de atención de los atributos, memoria, sensibilidad, entre otros. Sin embargo, no es posible realizar comentarios microeconómicos de los parámetros de manera tradicional. Esto imposibilita el cálculo de valores subjetivos y la aplicación de este modelo para planificación y políticas públicas.
3. Los valores iniciales de los parámetros no son claros para el proceso de estimación. Por ejemplo, para realizar la estimación de un modelo DFT con 4 alternativas y 2 atributos, se deben fijar 8 valores iniciales de los parámetros de manera adecuada para que se pueda completar el proceso con éxito, es decir, que la optimización no se quede atascada en un óptimo local y pueda entregar los valores de los errores estándar.

Esto se evidenció durante el trabajo de esta tesis, ya que al intentar estimar el modelo DFT usando el software Apollo, se obtenían diferentes valores al variar los puntos iniciales. Este problema no era particular del modelo DFT base, también ocurrió al estimar el modelo DFT escalado y el DFT escalado con datos de procesos. Por lo cual, se gastó bastante tiempo y se iteró varias veces (Ensayo-Error) para poder encontrar resultados finales con estos modelos.

2.2. Búsqueda de información en modelos de elección discreta

En este capítulo se dará a conocer el marco teórico del proceso de búsqueda de información, que corresponde a las etapas de adquisición y procesamiento de los atributos para llevar a cabo la elección. Se comenzará definiendo las fases que intervienen en el proceso de deliberación. Luego, se detallarán los diferentes patrones de búsqueda de información que pueden ocurrir y cuáles de estos han sido adoptados por los modelos de elección discreta. Finalmente, se precisarán los constructos, tales como la cantidad y la duración de la búsqueda de información, matriz de transiciones, paso medio, entre otros, con el fin de que realizar el análisis estadístico y presentar resultados asociados al proceso búsqueda de información que realizan los usuarios de transporte público.

2.2.1. Proceso de toma de decisiones

En las primeras investigaciones del comportamiento del consumidor no se tenía noción del proceso de deliberación que realizaban los agentes. Bajo la teoría económica clásica del consumidor, el proceso se describía vagamente como una comparación de alternativas, que se definen a partir de las valoraciones subjetivas que tienen los individuos sobre los atributos, siguiendo alguna regla de decisión.

En cambio, el área de la psicología ya había sentado una base más sólida de los subprocesos que intervienen previa a la elección de una alternativa. Por ejemplo, Engel et al., (1968) menciona que los individuos pasan por ciertas etapas antes de tomar su elección. Primero, los tomadores de decisión deben darse cuenta de que poseen una carencia o problemática relacionada a una elección. Segundo, deben buscar información a través de sus experiencias previas o adquirir nueva información que posee un costo de procesamiento. Finalmente, con la información recopilada deben realizar una evaluación de las alternativas con alguna regla de decisión y posterior elección.

Estas definiciones de la psicología al ser más exhaustivas se comenzaron a incorporar en la teoría del comportamiento de elección y se trataron de adoptar algunos supuestos en la modelación. Por ejemplo, McFadden (1999) define la toma de decisiones como un proceso cognitivo, que permite llegar desde las percepciones y creencias que tiene el individuo sobre la información disponible (que están influenciados por actitudes y preferencias) hasta la toma de una elección. Ben-Akiva et al., (2012) avanza un poco más en esta línea, al desarrollar un marco general de modelos de elección que incluye una representación del proceso y el contexto de la toma de decisiones. En particular, describe el comportamiento de elección del consumidor como un flujo de toma de decisiones que consta de varios pasos, lo que se puede apreciar en la figura 2.2 (Adaptación de McFadden (1999)).

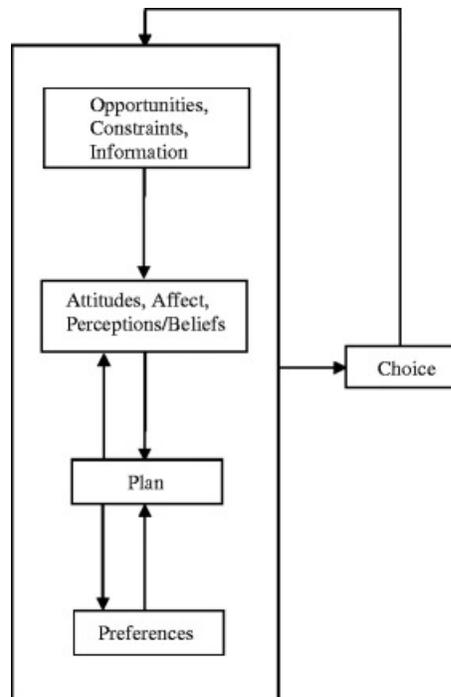


Figura 2.2: The process of decision making. Ben-akiva et al., (2012)

En esta representación se hacen definiciones que están ligadas a lo planteado previamente por Engel et al., (1968) y se pueden observar subprocesos que por lo generalmente pasa cualquier tomador de decisión:

1. Reconocimiento del problema: El tomador de decisión se percata de las oportunidades y limitaciones que posee en relación con la situación de elección.

2. Búsqueda de información: Son todas las indagaciones o tareas cognitivas que realiza el tomador de decisiones para conceptualizar el valor de las preferencias o utilidades de las alternativas disponibles. Se pueden categorizar en dos áreas:
 - a) Búsqueda interna: Corresponde al proceso de recordar creencias, juicios, experiencias o ideas preconcebidas de las alternativas desde la memoria.
 - b) Búsqueda externa: Conciernen a la adquisición y el procesamiento de información de fuente externa sobre el valor de los atributos de las alternativas.
3. Evaluación de alternativas: El tomador de decisión actualiza sus preferencias preconcebidas con la nueva información procesada y define un criterio o estrategia para la elección.
4. Elección: Se evalúan las alternativas y se realiza la elección siguiendo el criterio fijado en el paso anterior.
5. Retroalimentación: Se genera un aprendizaje de la situación de elección con el fin de actualizar percepciones y criterio de decisión.

A pesar de que los modelos de elección discreta han incorporado de manera general las etapas que intervienen en el proceso de deliberación, no se han enfocado en un subproceso que es vital en la toma de decisiones. Este corresponde a cómo los individuos adquieren la información externa y cómo la procesan para tomar su decisión. A continuación, se profundiza en este subproceso para comprender cómo se puede analizar e incorporar de manera general en la modelación de elección discreta.

2.2.2. Proceso de búsqueda de información

El proceso de búsqueda de información se define como las etapas a través de las cuales, un individuo realiza tareas cognitivas, tales como indagar en su memoria, adquirir nueva información y procesar los datos para llevar a cabo su elección (Payne et al., (1992), Riedl et al., (2008)). En la figura 2.3, Xie (2019) presenta las etapas que están involucradas en el proceso de búsqueda de información que podrían incorporarse en modelos de elección discreta.

Por un lado, se encuentra la búsqueda interna que se relaciona con la recuperación de información almacenada por los individuos. Se han realizado bastantes estudios para tratar de comprender este proceso, pero aún no está clara la manera de cómo incorporar de manera aplicada los hallazgos de la memoria de las personas en modelos de elección. Para efectos de esta tesis, se realizarán supuestos adecuados para las experiencias previas de los usuarios y sus búsquedas internas.

Por otra parte se encuentra la búsqueda externa, la cual corresponde a la etapa de adquisición y procesamiento de la nueva información que los individuos obtienen de fuentes externas (Holland y Kleinmuntz, 1994). Según, Schulte-Mecklenbeck et al., (2017) este subproceso está definido por las fijaciones pre-decisivas que tiene el tomador de decisión sobre los atributos durante el tiempo de deliberación. A partir de las transiciones entre estas atenciones, se puede construir los patrones de búsqueda de información que realizan los sujetos previa a la elección. Los esfuerzos de esta tesis estarán puestos en comprender, analizar e incorporar el proceso de búsquedas externa, ya que el comportamiento que siguen los usuarios se puede

capturar a través de datos de procesos de una manera no tan complicada como las búsquedas internas.

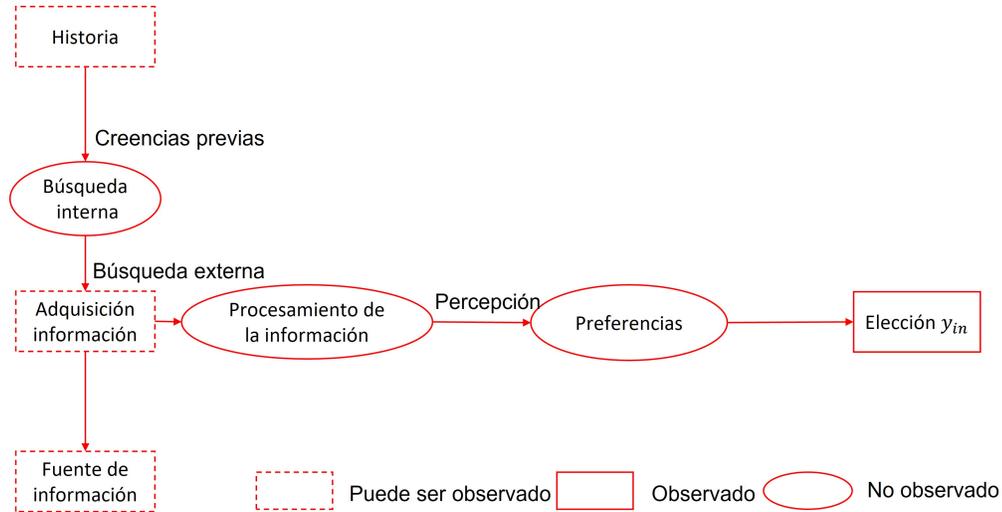


Figura 2.3: El proceso de búsqueda de información. Xie (2019)

A continuación, se detallan cuatro diferentes patrones de búsqueda de información que pueden realizar las personas para adquirir y procesar la información asociada a los atributos de las alternativas disponibles. Estas definiciones son similares a las descritas por Bettam y Jacoby (1976); Payne (1976); Johnson et al.(2008); Noguchi y Stewart (2014); Jiang et al.(2016) y dependen de las transiciones de los atributos observados o atendidos consecutivamente por los tomadores de decisión.

1. **Búsqueda de Información en Profundidad** ocurre cuando el individuo conceptualiza todos los atributos de una alternativa antes de realizar comparaciones con el resto de las alternativas. Por lo tanto, es esperable que la atención fluctúe bajo distintos atributos, pero dentro de la misma alternativa. Los modelos de Maximización de la Utilidad Aleatoria incluyen este patrón de manera implícita en el cálculo de las probabilidades de elección, ya que se asume que los individuos construyen las utilidades de las alternativas considerando el valor de todos los atributos disponibles previo a elección. En la siguiente ecuación se muestra en rojo la forma de cómo se incorpora este patrón en la modelación.

$$U_{in} = \beta_0 + \beta_1 \cdot X_{in1} + \dots + \beta_k \cdot X_{ink} + \varepsilon_{in}$$

2. **Búsqueda de Información en Anchura** ocurre cuando el individuo se enfoca en un solo atributo en particular y actualiza el valor de todas las alternativas disponibles simultáneamente para su evaluación. Por lo tanto, es esperable que la atención se concentre más en un mismo atributo y que las transiciones se den con mayor frecuencia entre las alternativas. Este patrón ha sido incorporado en diferentes modelos de elección discreta. Por un lado, el modelo RRM lo incluye de manera implícita en la modelación, pues las probabilidades de elección dependen del arrepentimiento que se calcula a través de las comparaciones bilaterales de atributos. Por otro lado, el modelo DFT incluye este patrón de manera explícita, pues la actualización de las preferencias preconcebidas

durante el proceso de deliberación se realiza con respecto a un atributo a la vez. En las siguientes dos ecuaciones se muestra en rojo la forma de cómo se incorpora este patrón en la modelación.

$$RRM : RR_{i \leftrightarrow j}^k = \ln \left(1 + e^{\beta_k (x_{jk} - x_{ik})} \right)$$

$$DFT : P_t = S \cdot P_{t-1} + C \cdot M \cdot W_t + \varepsilon_t$$

Cabe destacar que, este comportamiento se ha evidenciado y se ha respaldado a partir de los hallazgos encontradas por Noguchi y Stewart (2014), los cuales indican que las comparaciones de un par de alternativas bajo la misma dimensión de atributo se dan con mayor frecuencia. Es por lo que los modelos psicológicos de elección debiesen modelarse de tal manera.

- Búsqueda de Información poco comunes** se da cuando la atención es más errática de lo normal. Por un lado, se encuentran las búsquedas diagonales adyacentes que capturan las transiciones que se dan hacia atributos y alternativas contiguos. En cambio, las transiciones diagonales no adyacentes se dan cuando la atención transita entre atributos y alternativas no contiguos que implican un mayor gasto cognitivo.

En la figura 2.4 se muestra los patrones de búsqueda de información adoptados en los diferentes modelos de elección discreta (Adaptación de Chorus 2012). Las flechas sólidas representan las conceptualizaciones, las flechas discontinuas representan el proceso de búsqueda de información y comparaciones de alternativas.

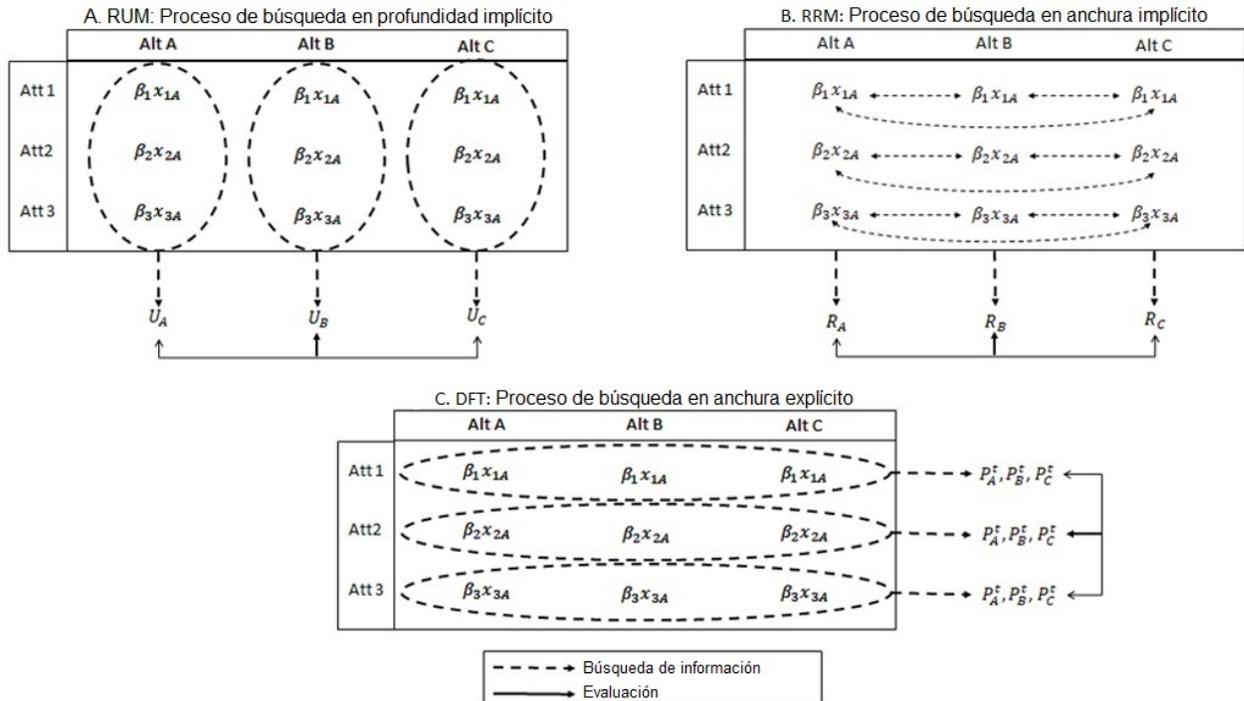


Figura 2.4: Proceso de elección basado en RUM (A), RRM (B) y DFT (C)

2.2.3. Encuestas de datos de procesos

Un método común para validar las teorías ha sido diseñar materiales experimentales que permitan probar las distintas predicciones hechas por cada teoría dentro del mismo espacio de decisión. Tradicionalmente, se han utilizado las encuestas de preferencias reveladas (RP) y declaradas (SP) para capturar los datos necesarios para estimar los modelos de elección discreta y probar las hipótesis planteadas.

Por un lado, las encuestas de preferencias reveladas recopilan información del comportamiento realizado por cada persona. Una base de datos con las compras de las personas o un cronograma de viajes que realizó alguien, son ejemplos de preferencias reveladas. Si bien estos instrumentos tienen el beneficio de entregar información real de las acciones de las personas, son muy costoso de aplicar, las variables pueden ser difícil de medir, pueden tener poca varianza y no se puede incluir alternativas hipotéticas o que no están presente actualmente en el mercado.

En contraste, en las encuestas de preferencias declaradas se obtiene información de las elecciones de los encuestados en situaciones hipotéticas. Típicamente, a los tomadores de decisión se les entrega una batería de preguntas, las cuales muestran la información relevante para la toma de decisiones en un formato de matriz de atributos por alternativas llamado paneles informativos (Payne (1976), Shi et al., (2013)). En cada pregunta, las columnas se pueden etiquetar haciendo mención a las alternativas y las filas a los atributos. Su uso se argumenta ya que la aplicación del instrumento es menos costosa, permite el estudio de alternativas experimentales o inexistentes, se conoce la situación de elección de los encuestados y es más eficiente que las encuestas RP. Sin embargo, se ha mostrado evidencia que en algunas situaciones no se refleja adecuadamente el comportamiento real de las personas debido al sesgo hipotético. Por lo cual, la situación hipotética, el conjunto de elección, las alternativas, atributos, sus niveles y sus rangos son dimensiones del diseño experimental que deben ser cuidadosamente especificado por el investigador (Meyerhof et al., 2015).

El desarrollo de estos 2 tipo de encuestas ha sido fructífero para conocer las elecciones de los individuos, estimar modelos y poder calcular las valoraciones que intervienen en el proceso de elección. Sin embargo, no han podido mostrar el proceso cognitivo que está involucrado en la toma de decisiones. Como resultado, los investigadores comenzaron a enfocarse en métodos de rastreo de procesos destinados a evidenciar las etapas cognitivas subyacentes involucradas (para una revisión reciente, ver Schulte-Mecklenbeck et al., (2017)).

En los primeros experimentos, se registraba de manera manual los atributos que consideraba el encuestado para la toma de decisiones. Por ejemplo, Payne (1976) construye una situación de elección de departamento como **paneles informativos (IB)**. En estos, los valores de los atributos de las alternativas no están disponibles y el tomador de decisión debe acceder a la información indicando que **área de interés (AOI)** quiere conocer (representa el atributo k-ésimo de la alternativa j). Esta metodología se implementó con el fin de mostrar evidencia de que los tomadores de decisiones emplean diferentes procesos heurísticos para reducir la cantidad de información necesaria para tomar una elección. Siguiendo la misma línea, Bettman et al., (1977) registran manualmente las búsquedas de información realizadas por los encuestados enfrentados a una situación de compra presentada como un panel informativo.

En la misma época, se comienza a implementar el seguimiento ocular para capturar datos de procesos. Usando equipos adecuados, se puede almacenar de manera pasiva métricas de la mirada, tales como fijaciones, ubicación, duración, movimientos sacádicos, entre otros (ver Glaholt y Reingold (2011) para una revisión detallada). Russo y Rosen (1975), registran las fijaciones de la mirada una situación de elección de vehículos usados con un equipo con sensor fotoeléctrico y almacenan la información en una computadora. Dado los excesivos grados de libertad para analizar la captación de la información, lo costoso que siguen siendo estos equipos y la imposibilidad de tener a varios encuestados a la vez, los esfuerzos se comenzaron a centrar en el análisis de movimiento del mouse.

Jhonson et al., (1989) construye la herramienta online MouseLab que permite configurar diferentes situaciones de elección como paneles informativos, con el fin de capturar los movimientos del mouse que realizan los tomadores de decisiones para acceder a los atributos ocultos previo a la elección. Sin embargo, esta metodología ha sido criticada por aumentar el grado de distorsión ya que los tomadores de decisión deben superar una barrera artificial para acceder la información (Schulte-Mecklenbeck , (2017)).

Actualmente, las líneas de investigación se centran en desarrollar, implementar y mejorar instrumentos que capturen datos de procesos de manera online, junto a la reducción de los costos involucrados. Ejemplo de estos son Yang y Krajbich (2021) que realizan seguimiento ocular usando la cámara de los encuestados. En este trabajo se centrará en implementar y aplicar encuestas que capturen datos de procesos seguimiento de clics y ocular de manera online.

Capítulo 3

Encuesta Click-tracker y Eye-tracker

En esta sección se detalla la metodología seguida para el diseño e implementación de los instrumentos que permiten recolectar evidencia del proceso de búsqueda de información que realizan los usuarios de transporte público.

3.1. Click-tracker

En primer lugar, se construyen tres encuestas con seguimiento de clics que varían en la cantidad de alternativas y atributos mostrados como áreas de interés (AOI) siguiendo un formato de panel informativo. Estos instrumentos permiten recolectar datos del proceso de búsqueda de información de tareas de elección con diferentes tamaños experimentales. El análisis estadístico utilizando constructos cognitivos permitirá verificar que las tareas más complejas requieren un mayor esfuerzo cognitivo para tomar esas decisiones. Además, se confecciona una encuesta mostrada como un formato tradicional para comparar el comportamiento de elección.

Una vez definidas las encuestas, se implementan en una página web y se evalúan al aplicarlas en un focus group para comprobar que se obtiene la secuencia de atributos clicados, el tiempo de cada clic y las elecciones de cada pregunta. Así mismo, se reciben comentarios y retroalimentaciones para mejorar el instrumento.

3.1.1. Diseño

El diseño de los cuatro instrumentos aplicados en esta tesis consta de una parte de preferencias reveladas y otra de preferencias declaradas. La primera sección de los instrumentos, se recopila información sociodemográfica relevante del tomador de decisión y características típicas del viaje al trabajo en transporte público en punta mañana. En la segunda sección, se construyen 8 preguntas hipotéticas de preferencias declaradas pivotadas utilizando el valor de los atributos de movilidad obtenidos previamente de cada encuestado.

La diferencia radica en que tres de ellas, las preguntas son mostradas como paneles informativos y se realiza un seguimiento de los clics (CT) para acceder a la información en la sección de preferencias declaradas. Esta metodología permite abordar las inquietudes de la investigación ya que, a través del seguimiento de los clics, se puede evaluar todos los procesos de búsqueda intermedios que operan sobre la información disponible para llegar a una

decisión final (Bröder et al., (2013); Glöckner et al., (2011)). Además, se sigue el enfoque de Diseño de Diseños propuesto por Hensher (2004), pues es utilizado por una serie de estudios con el fin de analizar el comportamiento de las elecciones cuando se varían las dimensiones del diseño experimental, y a su vez, esto permite verificar si varía el proceso de búsqueda de información en las encuestas con seguimiento de clics.

Por lo cual, a cada uno de los participantes se le muestra una de las cuatro posibles situaciones de elección que varían según la cantidad de alternativas o atributos disponibles y si se muestra la información de manera tradicional o como panel informativo. La tabla 3.1 muestra los 4 tipos de situaciones de elección que se construyen en este estudio, indicando el formato de visualización y si recopila la secuencia de clics, la cantidad de alternativas disponibles, los atributos que la definen y las áreas de interés presentadas.

Tabla 3.1: Dimensiones experimentales de encuestas con seguimiento de clics y tradicional.

Encuesta	Tipo	Formato	Alternativas	Atributos	AOI
CT23	CT	IB	2	3	6
CT26	CT	IB	2	6	12
CT36	CT	IB	3	6	18
PD26	T	M	2	6	12

CT: Click-Tracker. T: Tradicional. IB: Panel Informativo. M: Matriz de atributos.

El formato de panel informativo es implementado en las primeras 3 encuestas, en la cual, el valor de los atributos no están disponibles y el tomador de decisión para acceder a la información relevante debe realizar pulsaciones sobre las AOI (sección 2.2.3). Cabe destacar que bajo este formato no se conoce realmente el proceso de deliberación, pero si proxys bastante válidos que permiten construir la secuencia de evaluación de atributos de manera adecuada (Just y Carpenter, 1980). La cuarta encuesta de preferencias declarada se diseña de manera tradicional con el fin de analizar si el tipo de formato afecta o induce cierto comportamiento de elección.

La consideración de las dimensiones experimentales de las encuestas CT23, CT26 y CT36 no es aleatoria, pues se aumenta de manera constante la cantidad de información disponible a la que pueden acceder a los encuestados (AOI). Esta configuración permite analizar el comportamiento de búsqueda de información cuando varía la cantidad de alternativa y atributos, con el fin de discernir si existe un impacto en el proceso.

Los factores de los perfiles de cada una de las preguntas hipotéticas, que permiten pivotar los valores atributos obtenidos en la sección de preferencias reveladas, se obtienen a partir de un diseño experimental D-efficient utilizando el software Ngene (Ngene, 2018). Para este proceso, se consideró un modelo MNL con parámetros de los atributos obtenidos a partir de estudios previos para la ciudad de Santiago, Chile. Dado que se plantea una encuesta pivoteada, se realizó un Monte Carlo que permitió verificar que se recuperaban los parámetros al estimar un modelo MNL utilizando características simuladas de movilidad de 100 individuos y posterior aplicación de la encuesta con los factores pivotantes. Este proceso fue iterativo, en la que se variaban los parámetros MNL necesarios en Ngene y se actualizaba el diseño en la simulación

con el fin de encontrar el diseño óptimo. Luego, la encuesta piloto se aplicó a un focus group, se plantearon preguntas relacionada a los atributos considerados, si estos permitían modelar correctamente la elección de ruta de transporte público, que tan intrusivo es el formato de panel informativo con seguimiento de clics. Todas estas respuestas se consideraron para lograr un diseño adecuado, para no llegar a resultados pocos concluyentes o gastar esfuerzos y recursos innecesarios, con el fin de corregir los instrumentos previa a la aplicación definitiva.

3.1.2. Implementación

Las cuatro encuestas se implementaron en un domino web (<http://www.clicktracker.cl>) y la base de datos se almacena en MySQL. Estrictamente, la base de datos recopila, en cada una de las preguntas respondidas por los encuestados, la siguiente información:

1. El tipo de encuesta, pudiendo ser CT23, CT26, CT36, SP26.
2. Las respuestas relacionadas a características socioeconómicas: edad, género, nivel educacional, situación laboral, Tipo de tarifa, cantidad de días que utiliza el transporte público, ingreso y la cantidad de personas con las que cohabitan.
3. Los Valores de los atributos que definen el viaje típico en punta mañana: tiempo de caminata, tiempo de espera, tiempo de viaje, costo, número de transbordos y disponibilidad de asiento que usualmente experimenta en el viaje.
4. La secuencia de atributos clicados más la alternativa elegida ($\mathbb{S}_{\text{AOI}_n^q}(t)$) junto a la duración de cada clics ($\mathbb{S}_{\text{T}_n^q}(t)$), como se muestra a continuación:

$$\mathbb{S}_{\text{AOI}_n^q}(t) = \{A_1, A_7, A_{12}, A_2, A_5, \dots, A_1, C\} \quad (3.1)$$

$$\mathbb{S}_{\text{T}_n^q}(t) = \{d_1, d_2, d_3, d_4, d_5, \dots, d_{DT}\} \quad (3.2)$$

A partir de la secuencia de atributos, se define las fijaciones que corresponde a las AOI clicadas por el encuestado en cada paso del proceso de deliberación, tal como se muestra en la ecuación (3.3).

$$f_{nt}^{jk} = \begin{cases} 1 & \mathbb{S}_{\text{AOI}_n^q}(t) == \text{AOI}_{jk} \\ 0 & \sim \end{cases} \quad (3.3)$$

En la cual, vale 1 si el atributo k de la alternativa j esta siendo atendido en el paso t del proceso de deliberación por el tomador de decisión n en la tarea de elección q .

La figura 3.1.A muestra la sección de preguntas socioeconómicas, la figura 3.1.B las preguntas de movilidad (preferencias reveladas) y la figura 3.1.C muestra un ejemplo de una tarea de elección que contiene 3 alternativas y 6 atributos en un formato de panel informativo con seguimiento de clics (preferencias declaradas).

3.1.3. Participantes y procedimiento

Se aplicaron los 3 tipos de encuestas click-tracker (CT23, CT26, CT36) y una encuesta tradicional (SP26) en septiembre 2021, obteniendo una muestra de 350 encuestados, de los cuales solo 332 individuos contestaron de manera adecuada. Los usuarios de transporte públicos se captaron de manera aleatoria en diferentes locaciones concurridas de la ciudad de Santiago, tales como paraderos de buses o estaciones de metros, indicándoles que al responder

Figura 3.1: A) Preguntas socioeconómicas. B) Preguntas de preferencias reveladas: Movilidad. C) Preguntas declaradas: Panel informativo con seguimiento de clics

la encuesta estarían participando por una Gifcard de \$25.

Una vez terminada la etapa en terreno, se procesa la información, eliminando las observaciones que tenían algún error o anomalía en las respuestas. Fue necesario realizar este paso ya que los encuestados pudieron haber respondido de manera aleatoria solo por participar del incentivo mencionado anteriormente o haber ingresado erróneamente los valores en la etapa de preguntas de preferencias reveladas.

Tabla 3.2: Estadística socioeconómica de los encuestados.

Encuesta	N	Edad	Masculino	Tarifa completa	Ocupación
CT23	91	27	48 %	60 %	45 % - 48 % - 7 %
CT26	81	27	46 %	56 %	41 % - 49 % - 10 %
CT36	79	23	51 %	30 %	18 % - 76 % - 6 %
PD26	75	44	43 %	59 %	

Trabajador - Estudiante - Otro.

Finalmente, La asignación de la muestra resultó en una asignación bastante equilibrada, teniendo 91 respuestas para CT23; 81 para CT26; 79 para CT36 y 75 para PD26. La edad media de los participantes fue de 26,56 años con ($D.E. = 10,04$). El 181 del total de la muestra eran estudiantes y el 163 eran hombres. Las características socioeconómicas no difirieron significativamente en las 4 encuestas en cuanto a edad ($F = 0,89, p = 0,45$) o género ($\chi^2 = 1,13, p = 0,77$) y o sistema de pago ($\chi^2 = 1,13, p = 0,77$). La Tabla 3.2 muestra las

estadísticas descriptivas de las cuatro encuestas experimentales.

3.2. Eye-tracker

En segundo lugar, se detalla el diseño e implementación de una encuesta en que la información relevante se muestra de manera tradicional, pero se registra la mirada de manera pasiva con la cámara web de los encuestados. La figura 3.2, obtenida de Schulte-Mecklenbeck et al., (2017), muestra que este instrumento reduce el riesgo de distorsión y se espera que tenga resultados más concluyentes que los obtenidos con los instrumentos anteriores. Esto se debe a que se reduce el efecto de demanda (no es necesario hacer clics sobre las AOI) y el efecto reactivo (no se distorsionan las heurísticas, ya que la información es mostrada en su totalidad como matriz de atributos).

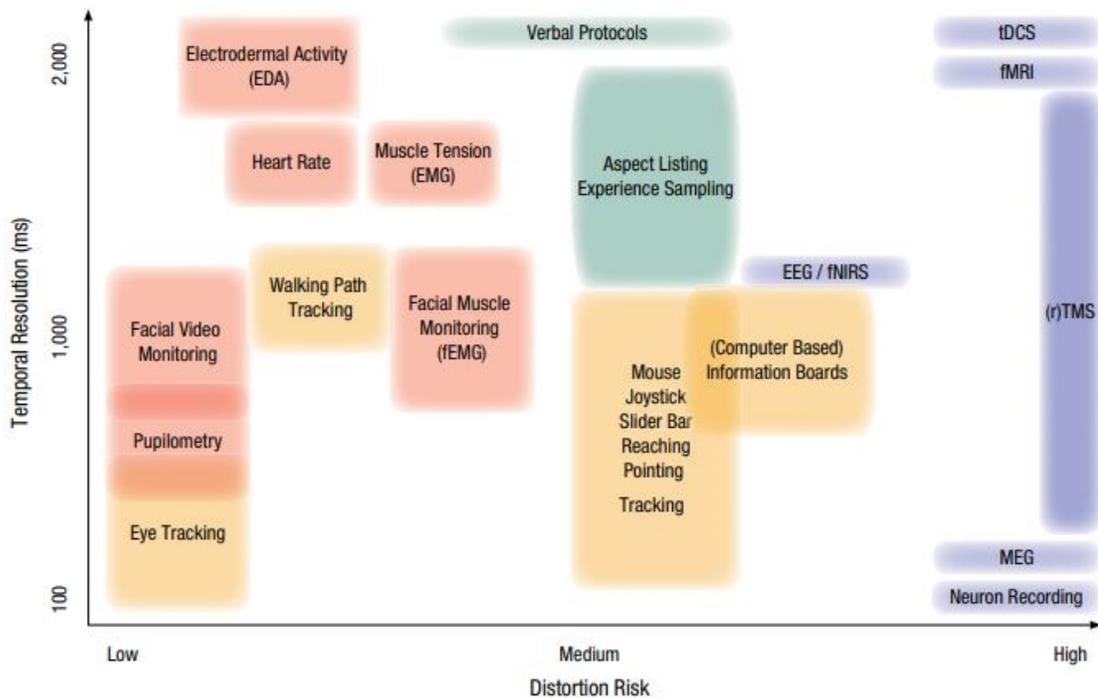


Figura 3.2: Riesgo de distorsión de Métodos de Rastreo de Procesos.

3.2.1. Diseño

Este instrumento replica la estructura general de las encuestas Click-tracker presentadas en la sección anterior. En la primera parte, se recopila información sociodemográfica y características típicas del viaje de transporte público en punta mañana del tomador de decisión. En la segunda sección, se presentan las 8 preguntas hipotéticas de preferencias declaradas pivoteadas utilizando el valor de los atributos de movilidad obtenidos previamente de cada encuestado. Los factores se obtienen de manera similar a lo descrito en la subsección 3.1.1.

A diferencia con los instrumentos anteriores, esta encuesta se monta utilizando la biblioteca WebGazer (Papoutsaki et al., 2018) de jsPsych (De Leeuw, 2015), lo que permite utilizar la cámara web de los encuestados para capturar la secuencia de los atributos atendidos previa

a la elección. Esto quiere decir que se registran las fijaciones de la mirada sobre las áreas de interés mostradas en cada tarea de elección. Sin embargo, en Yang et al., (2021) comentan que es razonable utilizar 4 a 6 AOI para reducir los errores de las fijaciones. (Ver más detalles en la implementación).

Dado lo anterior, se considera dos alternativas con dos atributos: Tiempo y costo de viaje. La información relevante para la toma de elección es mostrada completamente de manera tradicional, es decir, como una matriz que contiene etiquetada las alternativas en las columnas y los atributos en las filas. Por lo cual, en este instrumento se elimina la barrera para acceder a los valores de los atributos y se puede tener registro completo de la atención con una mayor frecuencia que en los instrumentos Click-tracker.

3.2.2. Implementación

A continuación, se detallan solo las librerías y códigos que permiten rastrear la mirada utilizando la cámara web de los encuestados, ya que el resto de la secciones de la encuesta no varían con respecto a los instrumentos anteriores.

1. Se utiliza el software WebGazer, que fue implementado por Papoutsaki et al., (2016) como una herramienta de JavaScript y se desarrolló para monitorear los movimientos oculares mientras los encuestados navegan por internet. Luego, Yang et al., (2021) integran ésta a una herramientas de psicología de código abierto llamada jsPsych.
2. jsPsych es un marco de JavaScript que permite crear experimentos de comportamiento ejecutables en navegadores web (De Leeuw, 2015). Los experimentos se construyen a partir de comandos que están implementados en esta herramienta y son mostrado como una cadena de ejecutables. Además, permite la integración de otras bibliotecas que estén basadas en el mismo lenguaje de programación.
3. Por lo tanto, cargamos, adaptamos e incorporamos el complemento WebGazer (jsPsych) en la sección de preguntas de preferencias declaradas en nuestro código base. Esto permite establecer niveles deseados de calibración y validación de la mirada previa a las tareas de elección. De manera general, las funciones y línea de tiempo de ejecutables que se incorporan al experimento Eye-tracker son:

Código 3.1: Inicialización, calibración, inicialización e implementación de WebGazer en Eye-Tracker.

```
1 // Permission to use the camera. Face preview.
2 var init_camera = {
3   type: 'webgazer-init-camera',
4   button_text: 'Continuar'
5 }
6 // Calibration text before the experiment
7 var calibration_instructions_1 = {
8   type: 'html-button-response',
9   choices: ['Click to begin'],
10  post_trial_gap: 1000
11 }
12 var calibration = {
```

```

13   type: 'webgazer-calibrate',
14   calibration_points: [[50,50], [20,20], [20,80], [80,20], [80,80]],
15   repetitions_per_point: 1,
16   randomize_calibration_order: true,
17 }
18
19 function eyeExperiment(text_list, experiment_index){
20   return {
21     type: 'webgazer-survey',
22     // Center of AOI
23     validation_points: [[25,30], [70,30], [25,75], [70,75]],
24     validation_point_coordinates: 'percent',
25     rectangle_width: 630, // default = 500 pixels
26     rectangle_height: 270, // default = 200 pixels
27
28     time_to_saccade: 0,
29     text_list: text_list,
30     keyboard_choices: ['ArrowLeft', 'ArrowRight'],
31     experiment_index: experiment_index,
32     show_validation_data: true,
33     show_predictions: true,
34     show_points: true,
35   }
36 }
37 // Updates the mobility value with the corresponding pivoting factor
38 function loadDataEyeInterview(buttons) {
39   buttons.forEach(button => {
40     if (eyeInterviews[0].interview == "eye-tracker-22") {
41       button.value = interview22(button.row, button.value)
42     }
43   })
44 }
45 // Multiply the pivot factor with time and impute the travel cost.
46 function interview22(row, value){
47   switch (row) {
48     case 1:
49       return Math.round((TIME) * value);
50     case 2:
51       return value; //COST
52   }
53 }
54
55 // Executable line
56 var timeline_experiments = [init_camera, calibration_instructions_1, calibration];
57
58 //Function that allows to start the executable timeline after the SP questions (
59   ↪ mobility) .
60 function startExperiment(){
61   document.querySelector(".container").style.display = "none";
62   movilidad = loadDataMovilidad(); // Load RP data (mobility)
63   generateExperiments(timeline_experiments); // add Eye-Tracking to the timeline

```

```

64 ////////////////////////////////////////////////// JsPsych Experiment Initialization //////////////////////////////////////
65 jsPsych.init({
66   timeline: timeline_experiments, // experimentos reales
67   display_element: 'jpsych-div',
68   extensions: [{type: 'webgazer'}],
69   on_finish: function() {
70     document.querySelector(".container").style.display = "block";
71     experimentData = jsPsych.data.get().filter({trial_type: 'webgazer-survey'}).
    ↪ values(); // to send it to the server
72   }
73 })
74 }

```

Finalmente, este instrumento es montado en el mismo dominio web (<http://www.clicktracker.cl>) y base de datos MySQL que los instrumentos anteriores. Cabe destacar que se almacenan las características socioeconómicas, los valores de movilidad, la secuencia de fijaciones de la mirada (atributos atendidos) y la duración de estas.

La figura 3.3 muestra la situación de elección con la implementación de WebGazer, que permite rastrear de manera pasiva la mirada de los encuestados.

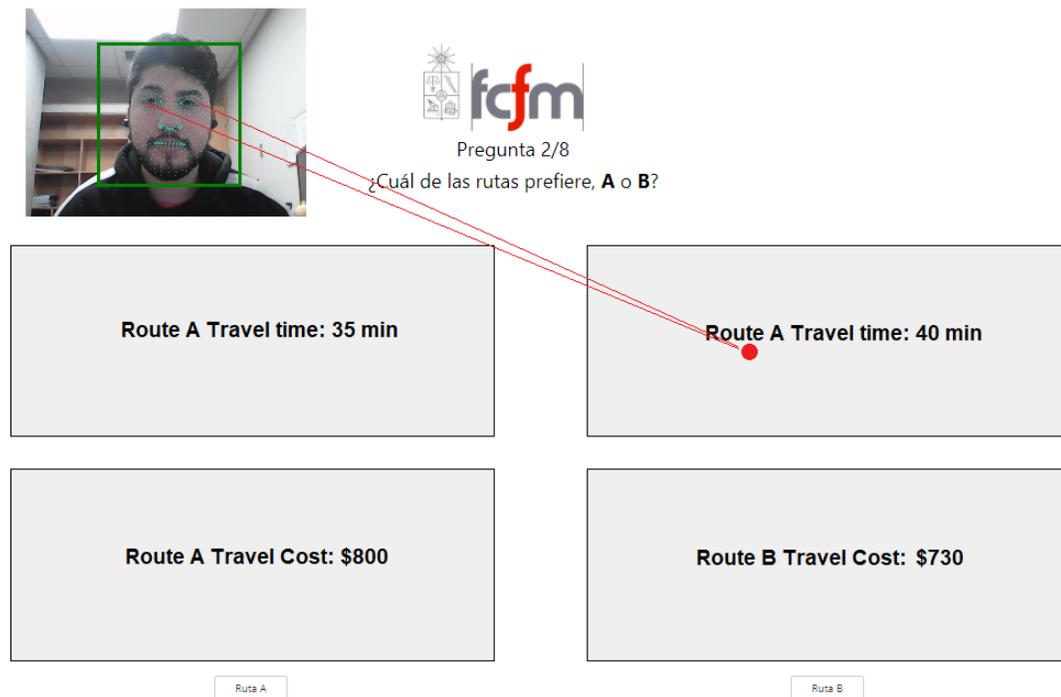


Figura 3.3: Caption

A continuación, se detallan los constructos considerados, permitieron analizar el proceso de búsqueda de información y evaluación secuencial de atributos en la elección de ruta a través del seguimiento de clics.

Capítulo 4

In Depth, Breadth-first, or Both?

En el presente capítulo se detallan los constructos considerados que permiten caracterizar el proceso de búsqueda de información que realizan los usuarios de transporte público. A continuación, se detallan los principales hallazgos encontrados a partir del cálculo y análisis de esos indicadores aplicados sobre el seguimiento de clics recolectados en esta tesis. Estos resultados pueden dar luces sobre el proceso de búsqueda de información, con el fin de incluir adecuadamente la deliberación en el modelamiento a través de parámetros psicológicos.

4.1. Constructos para el proceso de búsqueda de información

A partir de los datos de procesos, se pueden elaborar constructos que han sido ampliamente estudiados en la literatura sobre psicología y cognición. Estos serán utilizados en esta tesis, con el fin de caracterizar el proceso de búsqueda de información que realizan los usuarios de transporte público. A continuación, se definen los constructos considerados, como se obtienen numéricamente, instrumento de rastreo (seguimiento manual, ocular o mouse) y referencia a otros trabajos que lo han utilizados.

1. Cantidad de búsqueda de información (AIS): Indica la cantidad de fijaciones que se realizan sobre un área de interés durante todo el proceso de deliberación, tal como se muestra en la ecuación (4.1).

$$AIS_n = \sum_t \sum_k \sum_j f_{nt}^{jk} \quad (4.1)$$

Donde f_{nt}^{jk} representa la fijación o atención sobre el atributo k de la alternativa j realizado por el tomador de decisión n en el paso de deliberación t (definido en 3.3) y AIS_n se define como la suma de todas las fijaciones durante todo el proceso de deliberación para ese encuestado.

Este indicador se ha utilizado en la psicología y otras áreas que buscan entender la toma de decisiones. Por ejemplo, Payne et al., (1976) contabiliza manualmente las AOI que observaban los encuestados, para concluir que estos se limitan a la información cuando se enfrentan a problemas de elección más complejos. Otro caso es el presentado en Jhonson et al., (2008) en el cual se usa la cantidad de clics sobre las AOI para analizar si las hipótesis adoptadas en la Heurística de Prioridad permiten modelar las estrategias

en decisiones arriesgadas. Otro ejemplo reciente es de Meißner et al., (2020), quienes cuentan la cantidad de fijaciones oculares con el fin de analizar la adaptabilidad de los tomadores de elección cuando se enfrentan a tareas de elección con diferentes cargas cognitivas.

Este constructo se puede variar para analizar cuáles son los atributos y alternativas que más atención reciben de los encuestados durante el proceso de deliberación, tal como se muestra en la ecuaciones (4.2) y (4.3), respectivamente.

$$\text{Atención sobre los atributos} \quad FAtt_{nk} = \sum_t \sum_j f_{nt}^{jk} \quad (4.2)$$

$$\text{Atención sobre las alternativas} \quad FAlt_{nj} = \sum_t \sum_k f_{nt}^{jk} \quad (4.3)$$

2. Filtración: Corresponde a las áreas de interés que no es considerada durante el proceso de deliberación previa a la elección final. En este trabajo, se calcula como el porcentaje de áreas de interés que tienen fijaciones igual a cero siguiendo la definición de Meißner et al., (2020).
3. Patrón de búsqueda de información (ISP): Este constructo indica cómo los encuestados van adquiriendo y procesando la información durante el proceso de deliberación. Los patrones se pueden determinar a partir de las transiciones entre dos fijaciones o atenciones de AOI consecutivas que va observando el encuestado, tal como se muestra la ecuación (4.4).

$$ISP_n^{tipo} = \sum_t \sum_k \sum_j f_{nt}^{jk} \cdot I_{nt}^{tipo} \quad (4.4)$$

Donde I_{nt}^{tipo} indica el tipo de patrón de búsqueda de información realizado por el tomador de decisión n en cada paso t. La figura 4.1 es un ejemplo de una pregunta hipotética CT36 y muestra las transiciones que se pueden realizar desde la AOI_1 al resto de las AOI . A partir de estas transiciones, se definen los patrones de búsquedas en anchura (si fija AOIs consecutivas bajo el mismo atributo), en profundidad (si fija AOIs que sean de la misma alternativa), diagonales (si fija AOIs consecutivas que no son de la misma alternativa o mismo atributo).

Este constructo ha sido utilizado de manera similar por Bettam y Jacoby (1976), quienes indican que hay diferencias individuales en el almacenamiento de la memoria para el procesamiento de la información cuando se analizan los patrones de búsqueda de información. En Noguchi et al., (2014) mediante el seguimiento ocular identifican que los individuos realizan en mayor frecuencia búsquedas bajo la misma dimensión de atributos (búsqueda en anchura) cuando realizan comparaciones entre dos alternativas. En Stewart et al., (2016) se identifica patrones comunes y poco comunes, al analizar las transiciones de la mirada en tareas de elección con dominancia y coordinación asimétrica.

4. Matriz de transición: Este constructo se define a partir de las frecuencias relativas de las transiciones entre dos fijaciones consecutivas sobre las AOI, con el fin de mostrar la fijación más probable que se dará en el siguiente paso, tal como se muestra en la ecuación (4.5).

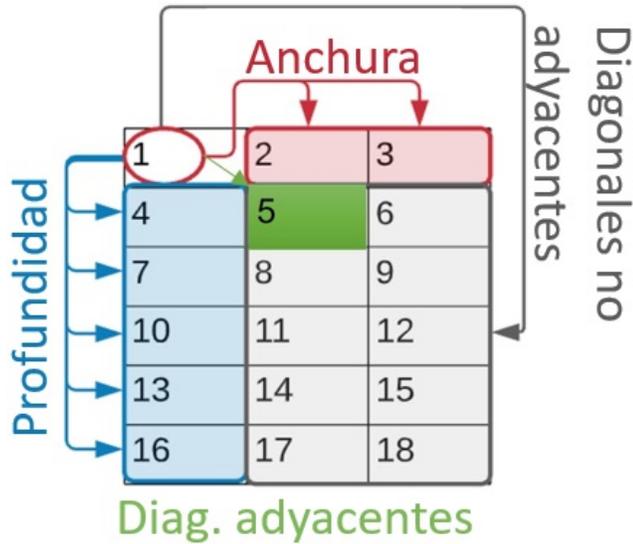


Figura 4.1: Búsqueda en profundidad (azul), anchura (rojo), diagonales adyacentes (verdes) y diagonales no adyacentes (gris).

$$Tr_{xy} = \frac{1}{\sum_n AIS_n} \cdot \sum_n \sum_t \sum_k \sum_j f_{nt}^{jk} \cdot I_{nt}^{x \rightarrow y} \quad (4.5)$$

Donde $I_{nt}^{x \rightarrow y}$ indica el tipo de transición realizado por el encuestado n en el tiempo de deliberación t . Las transiciones posibles dependen de la cantidad de áreas de interés mostradas de cada instrumento (cantidad de alternativas y atributos). En la figura 4.2 se presenta un ejemplo de la matriz de transiciones de la encuesta CT36, en la cual, la primera columna muestra la atención sobre los atributos en el paso t y el resto de las columnas exhiben los atributos observados en el paso $t+1$. Cada una de las celdas (x, y) de la matriz Tr_{xy} , representa la frecuencia relativa de las transiciones entre ese par de atributos.

		Attribute observed in step t+1																	
		Alternative A						Alternative B						Alternative C					
Attribute observed in step t		WKT	WT	TT	C	T	SA	WKT	WT	TT	C	T	SA	WKT	WT	TT	C	T	SA
Alternative A	WKT Walking Time	$x \dots \dots \dots Tr_{xy} \dots \dots \dots y$																	
	WT Waiting Time																		
	TT Travel Time																		
	C Cost																		
	T Transfer																		
	SA Seat Availability																		
Alternative B	WKT Walking Time	$x \dots \dots \dots Tr_{xy} \dots \dots \dots y$																	
	WT Waiting Time																		
	TT Travel Time																		
	C Cost																		
	T Transfer																		
	SA Seat Availability																		
Alternative C	WKT Walking Time	$x \dots \dots \dots Tr_{xy} \dots \dots \dots y$																	
	WT Waiting Time																		
	TT Travel Time																		
	C Cost																		
	T Transfer																		
	SA Seat Availability																		

Figura 4.2: Matriz de transición de encuesta con 3 alternativas y 6 atributos

Bault et al., (2016) utiliza este constructo para comparar los patrones de búsqueda de información que se dan en los periodos de lectura y decisión en loterías probabilísticas. De manera similar, Jhonson et al., (2008); Stweart et al., (2016) y Stewart et al., (2016) utilizan la matriz de transiciones para mostrar los patrones que realizan los encuestados en diferentes tareas de elección.

5. Duración: Se define como el tiempo promedio dedicado a cada fijación realizada durante el proceso de deliberación como se muestra en la ecuación (4.6).

$$\bar{D}_n^q = \frac{1}{\sum_n AIS_n^q} \sum_t D_{nt}^q \quad (4.6)$$

Donde D_{nt}^q representa el tiempo que permanece visible el área de interés fijada en el paso de deliberación t por el tomador de decisión n en la tarea de elección q . El promedio de las duraciones en cada tarea para cada individuo corresponde a \bar{D}_n^q .

Cabe destacar que las duraciones de las fijaciones proporcionan una valiosa información sobre los procesos cognitivos subyacentes (Horstmann et al., 2009). Además, esta métrica se ha usado principalmente en datos de procesos de seguimiento ocular, para evidenciar cómo la duración de las fijaciones varía dependiendo de la complejidad de las actividades de lectura (Rayner et al., 2012). Otra aplicación, con MouseLab se obtienen los tiempos de cada fijación, con el fin de obtener conclusiones sobre las hipótesis de la Heurística de Prioridad (Johnson et al., 2008).

6. Orden de patrones (PO): Este constructo se define como el patrón de búsqueda de información que predomina en cada paso del proceso de deliberación. Esta medida se obtiene a partir de las frecuencias de los patrones a lo largo del tiempo de deliberación de todos los participantes.

4.2. Cantidad de búsqueda de información

Las búsquedas de información que realizaron los encuestados previa a la elección se calcularon siguiendo el constructo definido en la ecuación (4.1) y se resume en la tabla 4.1. En esta se muestra el promedio y desviación estándar de la cantidad de búsqueda de información, total y normalizada por las áreas de interés en cada una de las encuestas (CT23, CT26, CT36).

De manera general, en promedio se realizaron más búsquedas de información que la cantidad total de áreas de interés mostradas en cada instrumento, dando cuenta que los usuarios de transporte público no capturan el valor de los atributos en una primera instancia y necesitan reconceptualizar esos valores para incluirlos en sus utilidades o preferencias. Además, se puede observar que este constructo crece de manera significativa al aumentar la cantidad de atributos o alternativas. Por otro lado, Al considerar la AIS normalizada por las AOI en las diferentes encuestas y realizar un test de medias, se puede destacar que se genera una mayor aumento en la cantidad de búsquedas cuando se añaden atributos ($t = 6, 36$) en comparación a cuando se aumentan las alternativas ($t = 2, 71$). Por lo cual, la cantidad de búsqueda de información aumenta a tasas decrecientes con las AOI mostradas en las encuestas, pero en mayor medida cuando se añaden atributos.

Tabla 4.1: Cantidad de búsqueda de información en tareas de elección.

Encuesta	AOI	AIS	AIS/AOI
CT36	18	19,5 (11,8)	1,1 (0,7)
CT26	12	14,6 (10,1)	1,2 (0,8)
CT23	6	9,2 (5,4)	1,6 (0,9)
CT	-	14,4 (10,2)	1,3 (0,8)

La figura 4.3 muestra un boxplot con las fijaciones realizadas por los encuestados durante el proceso de deliberación en las diferentes tareas de elección, normalizadas por la cantidad de AOI correspondiente. Este gráfico refuerza el hallazgo anterior, ya que se puede apreciar que los intervalos de confianza son distintos entre sí. Es más, se muestra que se busca menos información por AOI cuando aumenta la carga cognitiva. También, la mayor diferencia se encuentra entre las encuestas CT23-CT26 que entre las encuestas CT26-CT36, dando cuenta que se intensifica la cantidad de búsquedas en un mayor grado con el aumento de atributos.

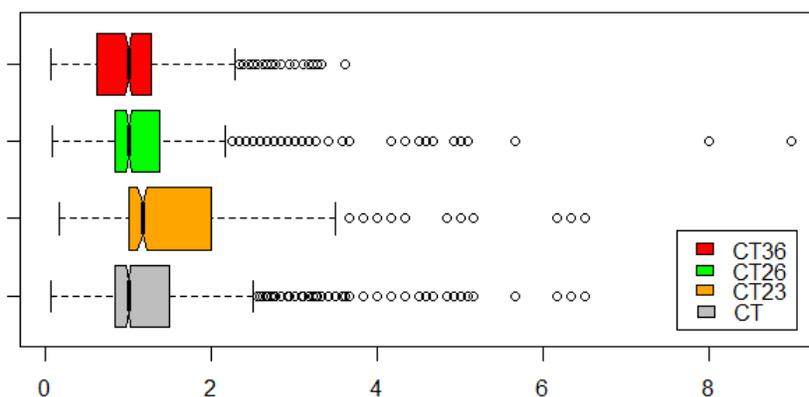


Figura 4.3: Boxplot cantidad de búsqueda de información normalizada por AOI.

Al realizar un análisis por características socioeconómicas, se destaca que sistemáticamente los usuarios de transporte público de género masculino realizan más búsquedas de información que el resto de la población en todas las encuestas ($p\text{-value} < 0,001$ en todos los casos). Por otro lado, al analizar según la tarifa pagada, los encuestados que poseen descuento realizan más búsquedas de información significativamente que los usuarios que pagan una tarifa completa en las encuestas CT23 y CT36 ($p\text{-value} < 0.001$ en ambos casos).

Estos hallazgos están en la misma línea que los encontrados por Kawak et al., (2015). Al igual que esos autores, se encuentra que el número de búsquedas realizadas aumenta a medida que avanza el experimento y este incremento fue mucho más pronunciado para los adultos. En particular para este trabajo, son los adultos quienes pagan una tarifa completa. Esto demuestra que los encuestados con tarifa reducida (Estudiantes/jóvenes) realizan un procesamiento de información más completo e intenso previo a la toma de elección.

Sin embargo, este constructo da a conocer solo la cantidad búsquedas y no sobre las áreas de interés más atendidas por los encuestados (atributos y alternativas). En las siguiente

subsecciones mostramos este análisis para identificar si es necesario incluir diferentes pesos de atención sobre los atributos.

4.2.1. Fijaciones en atributos

Las atenciones sobre los atributos se pueden observar en las figuras 4.4.a, 4.4.b y 4.4.c. Estos boxplot muestran los porcentajes de las fijaciones sobre los atributos presentados en las encuestas CT23, CT26 y CT36, calculados a partir de la ecuación 4.2. De manera general, se puede observar que el porcentaje promedio de atención sobre los atributos decae de manera en que fueron mostrados (de arriba hacia abajo en la encuestas), salvo por el tiempo de viaje en las encuestas CT26 y CT36.

Estos hallazgos son concordantes a los mostrados por Venkatraman et al., (2014) quienes muestran heterogeneidad en patrones de búsqueda de información al utilizar seguimiento ocular. Una de sus conclusiones hace mención a que se realizan más transiciones entre alternativas consistente con el orden de lectura (de izquierda a derecha). Sin embargo, en relación con la componente vertical, se está parcialmente de acuerdo, pues en este trabajo solo se encuentra una componente de lectura naturales a este tipo de problemas (de arriba a abajo) y no de naturaleza de la visualización o inspección general (de abajo hacia arriba) de manera significativa.

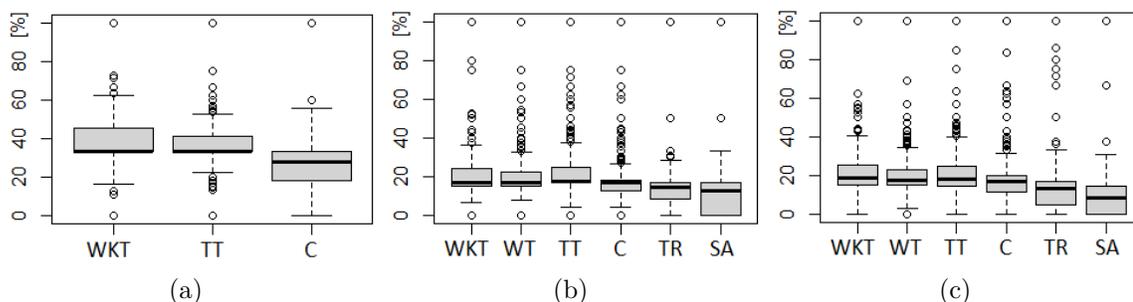


Figura 4.4: Fijaciones sobre atributos en CT23 (a), CT26 (b) y CT36 (c).

WKT: Tiempo de caminata, WT: Tiempo de espera, TT: Tiempo de viaje, C: Tarifa, TR: Transbordos, SA: Disponibilidad de asiento.

Por otro lado, en estudios anteriores, se ha evidenciado que los usuarios se enfocan más en el costo de las alternativas y esto no ocurre de manera general en estas encuestas. Existen dos razones principales para argumentar este comportamiento. Primero, los tomadores de decisión pueden percibir de manera clara y precisa la tarifa al ser un valor monetario, por lo cual no necesitan revisitar este atributo en mayor medida para recordarlos e incluirlo en sus preferencias. En segundo lugar, las pocas atenciones se pueden deber a que las tarifas en el transporte público de Santiago no varían en gran medida, son valores fijos para la mayoría de los viajes en punta mañana y lo usuarios tienen una idea clara de estos valores. Esta idea fue mencionada durante la discusión realizada en el Focus Group (Anexo A).

4.2.2. Fijaciones en alternativas

Por otra parte, las fijaciones hacia las alternativas se pueden observar en las figuras 4.5.a, 4.5.b y 4.5.c. Estas muestran los boxplot con los porcentajes de las atenciones sobre las alternativas en cada una de las encuestas CT23, CT26 y CT36, obtenidos siguiendo la ecuación 4.2.

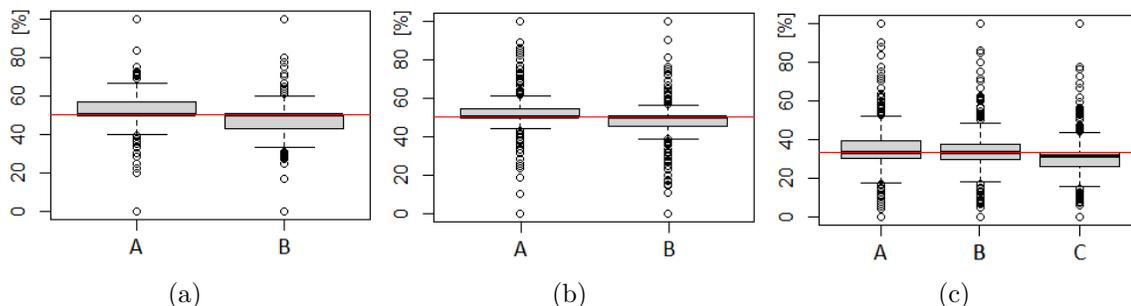


Figura 4.5: Fijaciones sobre alternativas en encuestas CT23 (a), CT26 (b) y CT36 (c). Donde A, B y C corresponde a las alternativas mostradas de izquierda a derecha en las encuestas.

De manera general, se puede mencionar que las alternativas ubicadas a la izquierda tienen más atención que las mostradas en el centro y a la derecha en las tareas de elección. En particular, en las encuestas CT23 y CT26, se puede observar que las alternativas de la izquierda (Ruta A) tienen un porcentaje de atención más alto que las ubicadas a la derecha (Ruta B) con medias significativamente distintas, tal como muestra la tabla 4.2. En cambio, al añadir una tercera alternativa (Ruta C) en la encuesta CT36, esta tiene menor atención que las alternativas A y B, que no presentan diferencias entre ellas.

Tabla 4.2: Porcentaje de fijaciones sobre alternativas y diferencias estadísticas.

Encuesta	Atención en A	Atención en B	Atención en C	Δ_{AB}	Δ_{BC}
CT36	35,2 %	33,8 %	31,0 %	1,90	3,76
CT26	52,3 %	47,7 %	-	7,89	-
CT23	52,9 %	47,1 %	-	15,8	-

Para cerrar el análisis de este constructo, se puede comentar que estos resultados son concordantes a los encontrados por Meißner et al., (2020), quienes concluyen que las dimensiones de la situación del elección afectan el proceso de búsqueda de información. Los hallazgos muestran que aumentar la cantidad de atributos y alternativas conlleva un aumento de búsqueda de información e inducen cierta filtración de atributos. La novedad de esta tesis radica en que se replican estos resultados en la elección de ruta de transporte público y se evidencia un mayor impacto en el proceso de deliberación al añadir atributos sobre la cantidad de alternativas.

4.3. Filtración

La figura 4.6 muestra el porcentaje de áreas de interés que no fueron fijadas durante el proceso de deliberación en cada una de las encuestas presentadas. En esta imagen se observa, de manera general, que aumentar la cantidad de alternativas o atributos conlleva un aumento significativo de la información filtrada. Esto ya se había podido evidenciar con los boxplot 4.4 y 4.5, en los cuales muestran observaciones que no fijaron en ningún momento ciertos atributos o alternativas. Asimismo, se puede muestra que el porcentaje de áreas de interés no atendidas aumenta a medida que el tomador de decisión avanza en las tareas de elección. Es más, al observar.

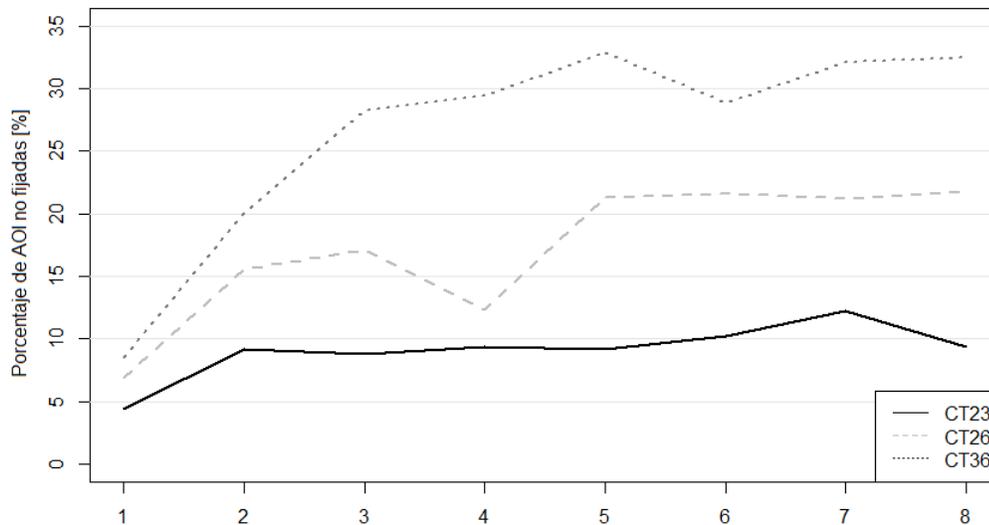


Figura 4.6: Porcentaje de áreas de interés no fijadas

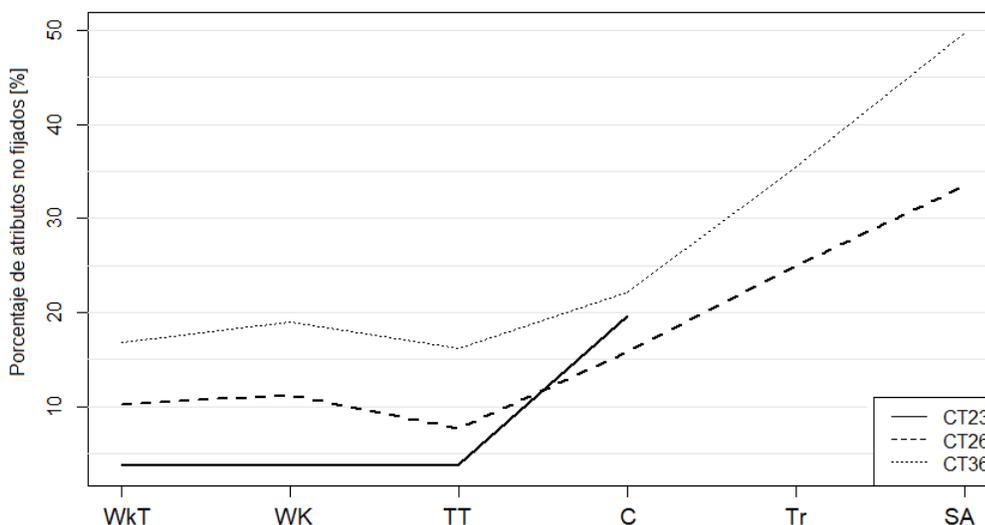


Figura 4.7: Porcentaje de atributos no fijados

Como último comentario, de la figura 4.4, se puede evidenciar que hay porcentajes de fijaciones nulos sobre algunos atributos. Estos valores muestran que los encuestados durante todo el

proceso de deliberación no consideraron esa información o no atendieron esos atributos para tomar su elección. En otras palabras, en un modelo que considera todos los atributos para la construcción de las utilidades o preferencias, se tendría errores en el cálculo de probabilidades de elección, pues no se estaría capturando el proceso de generación de datos verdadero y la estimación de los parámetros poblacionales no sería adecuada.

4.4. Patrón de búsqueda de información

Para comenzar, se puede calcular la cantidad de encuestados que realizan al menos alguna vez cada uno de los patrones de búsqueda de información previa a la elección, con el fin de mostrar que existe heterogeneidad en el proceso de deliberación. Por ejemplo, en la fila Breadth-First de la tabla 4.3, se muestra que este patrón es realizado por la mayoría de los encuestados y existe un predominio en todas las encuestas. Además, se puede observar que hay un aumento de este tipo búsquedas cuando se añaden más atributos, pero un decrecimiento con el aumento de alternativas. Este comportamiento se repite de manera similar con búsquedas diagonales adyacentes en las diferentes encuestas.

En relación con el resto de los patrones, el comportamiento no es claro, ya que en la encuesta CT26, se intensifican las búsquedas en profundidad y disminuyen las adyacentes no diagonales. Esta conducta puede deberse a que en este panel informativo se muestra las áreas de interés en un formato horizontal más rectangular que el resto de las encuestas. Resultado similar de Meißner et al., (2020), quienes muestran que una encuesta con 3 alternativas disminuye las búsquedas en profundidad, favoreciendo otros patrones, cuando se compara con una con dos alternativas (siendo ambas encuestas con 6 atributos).

Tabla 4.3: Porcentaje de observaciones en que se realizan al menos alguna vez los tipos de búsquedas de información.

ISP	CT23	CT26	CT36
Profundidad	62 %	88 %	71 %
Anchura	87 %	95 %	92 %
Diag. adyacentes	80 %	88 %	40 %
Diag. no adyacentes	29 %	27 %	76 %
N	632	648	728

Los boxplots de las figuras 4.8, 4.9 y 4.10 muestran el porcentaje de patrones de búsquedas de información realizados por los encuestados, previa a la elección (valores obtenidos a partir del constructo mostrado en 4.4).

En relación con la encuesta CT23 (figura 4.8), el patrón de búsqueda en anchura tiene la mayor proporción de ocurrencias durante el proceso de deliberación con media de $m = 46,6\%$ y que supera significativamente al $m = 26,0\%$ de las búsquedas en profundidad ($p\text{-value} < 0,001$). Este último es significativamente mayor que las búsquedas diagonales adyacentes con $m = 23,1\%$ ($p\text{-value} = 0.0169$) y no adyacentes con $m = 4,2\%$ ($p\text{-value} < 0.001$).

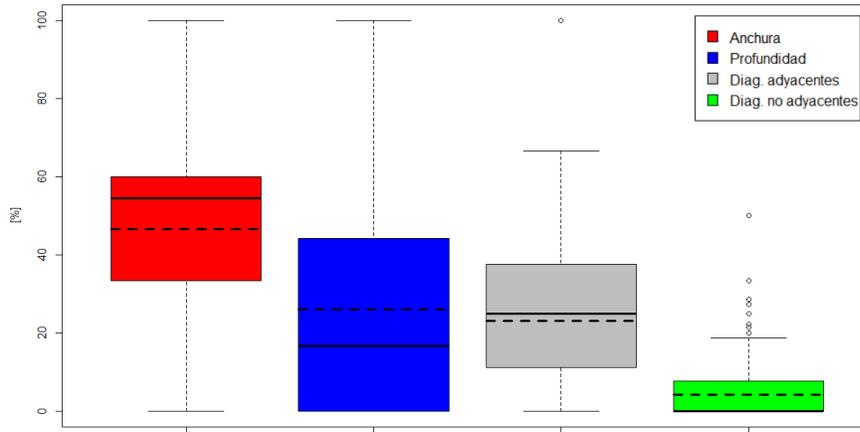


Figura 4.8: Patrones de búsqueda de información en CT23.

Al aumentar la cantidad de atributos, en la encuesta CT26 (figura 4.9), se genera un incremento significativo en la proporción de ocurrencia de patrones de búsquedas en anchura en comparación con la encuesta CT23 (p-value= 0.0017). Además, en este instrumento, hay un aumento considerable de patrones diagonales adyacentes en comparación con las búsquedas en profundidad (p-value< 0.001), evidenciando que al haber más AOI mostradas verticalmente, los encuestados tenderían a seguir un comportamiento de lectura en español.

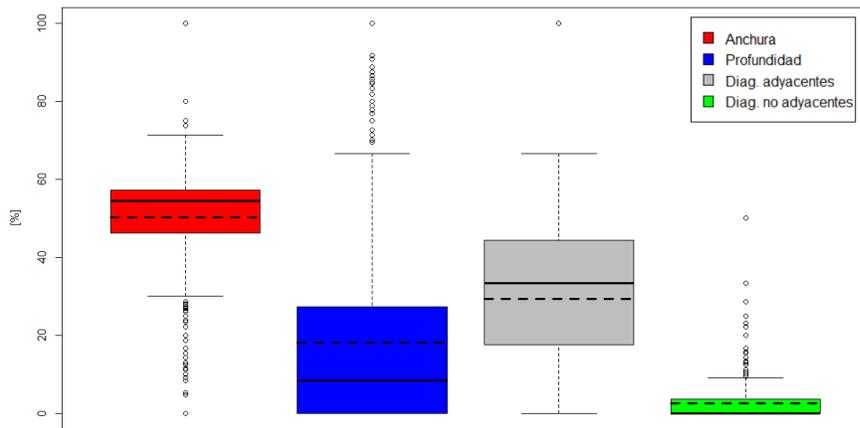


Figura 4.9: Patrones de búsqueda de información en CT26.

En la encuesta con la mayor carga cognitiva (CT36 - figura 4.10), al aumentar la cantidad de alternativas, se vuelve a generar un aumento significativo de la proporción de búsquedas de información en anchura (p-value= 0.005) en comparación con el instrumento anterior. Así mismo, se puede observar que los patrones en profundidad alcanzan al rededor de un 25,5 % de las ocurrencias y luego le siguen las búsquedas diagonales no adyacentes con media $m = 13,1 \%$. A partir de estos resultados, se puede desprender que, al presentar una mayor cantidad de alternativas, los participantes experimentan un mayor gasto cognitivo de seguir un orden de lectura en español. Es por ello que dejan de realizar transiciones diagonales adyacentes o no adyacentes y aumentan los patrones en profundidad. Por lo cual, en situaciones cotidianas de elección definidas por varios atributos y alternativas, el proceso de búsqueda de información está dominado por patrones en anchura seguidos por patrones en profundidad.

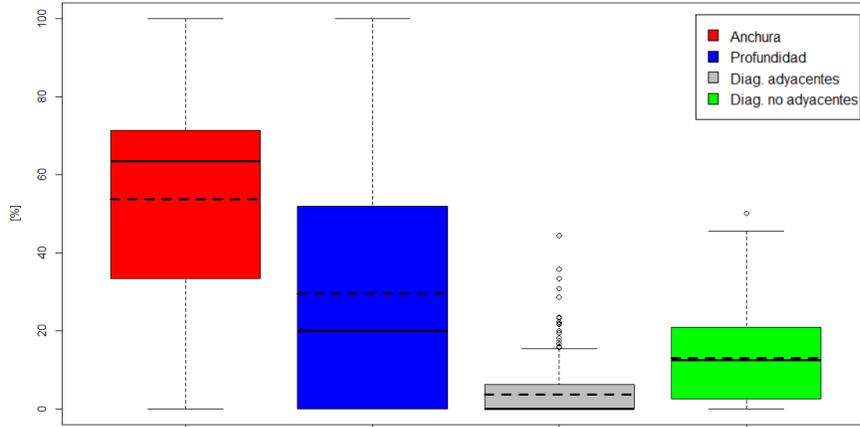


Figura 4.10: Patrones de búsqueda de información en CT36.

De manera general, más de un 45 % de las búsquedas durante el proceso de deliberación fueron realizadas siguiendo un patrón en anchura en cualquiera de los instrumentos aplicados. Es más, se puede notar que este comportamiento se intensifica independientemente de las áreas de interés mostradas. Estos resultados presentan por primera vez, que el proceso de búsqueda de información de elección de ruta está fuertemente construido como una secuencia de transiciones sobre atributos de la misma dimensión. Luego, le siguen patrones de búsquedas en profundidad y diagonales adyacentes que dependen de la cantidad de atributos y alternativas mostrados. Por lo cual, deben realizarse más experimentos para desentrañar si existe una relación sistemática de las proporciones de estos tipos de búsqueda.

La tabla 4.4 muestra los valores medios de las proporciones de los patrones de búsqueda de información en las encuestas, la desviación estándar y cantidad de observaciones. Cabe destacar que, todos los test de medias relacionados a las búsquedas en anchura son significativamente diferentes cuando se aumenta la cantidad de AOI presentadas. Y además, Estos test son significativos cuando se comparan las medias con los patrones que le secundan en ocurrencias en todas las encuestas.

Tabla 4.4: Patrones de búsquedas de información.

ISP_n^{type}	CT23	CT26	CT36
Profundidad	26 % (28 %)	18 % (24 %)	30 % (30 %)
Anchura	47 % (24 %)	50 % (18 %)	54 % (27 %)
Diag. adyacentes	23 % (16 %)	29 % (16 %)	4 % (6 %)
Diag. no adyacentes	4 % (8 %)	3 % (5 %)	13 % (1 %)
N	728	648	632

Estos hallazgos empíricos son concordantes con los comentarios de Kwak et al., (2015), que hacen mención a que los patrones de búsqueda de información son complejos y mixtos. En el presente trabajo, se avanza en presentar situaciones de elección con múltiples atributos y alternativas, que permiten sustentar la idea anterior. Además, estos resultados contradicen

las conclusiones de Su et al., (2013), quienes comentan que los tomadores de decisión construyen sus utilidades únicamente como ponderaciones y suma sin algún proceso heurístico más complejo. Por ejemplo, el uso selectivo de la información sobre las alternativas y comparaciones simples.

4.5. Matriz de transición

Las matrices de transición muestran las frecuencias relativas entre fijaciones consecutivas. Estos resultados se resumen en las figuras 4.11, 4.12 y 4.13, las cuales revelan las probabilidades de que los encuestados atiendan una área de interés en particular en el paso t condicional a una AOI anterior. A partir de las figuras, se pueden obtener dos hallazgos importantes. Primero, es posible conocer los patrones de búsqueda de información agregados que predominan entre los participantes para llegar a tomar su decisión final. Y en segundo lugar, se puede conocer empíricamente la probabilidad de observar un atributo en el paso siguiente dentro del proceso de búsqueda de información. Esto permite, incluir la manera en que se adquiere la información evidenciada y sus pesos de atención en el modelo a proponer que incorpora la evaluación secuencial de atributos. Por lo cual, esta modelación permite integrar, por vez primera, adecuadamente el proceso de actualización de las utilidades o preferencias para la posterior comparación de alternativas y elección.

De manera general, cuando hay pocas AOI, los participantes realizan una mayor cantidad de transiciones posibles entre áreas de interés (sin agregar según el tipo de patrón de búsqueda). Se evidencia también, que al aumentar la carga cognitiva mostrada, los encuestados favorecen ciertas transiciones y heurísticas. Independiente de lo anterior, como se evidencia en la tabla 4.5 la búsqueda de información en anchura predomina sobre el resto de los patrones posibles. En esta se muestra los valores agregados de las transiciones según el tipo de patrón de búsqueda de información en cada encuesta ($\sum Tr_{xy}$). Por otro lado, el segundo patrón que interviene en el proceso depende de la cantidad de atributos y alternativas mostradas, pudiendo ser en profundidad para paneles con más atributos que alternativas y diagonales en con más alternativas que atributos. Estos resultados son concordantes con los comentados en la sección 4.4.

Tabla 4.5: Porcentaje de transiciones según el patrón de búsqueda.

$\sum Tr_{xy}$	Proceso de Búsqueda de Información			
Encuesta	Profundidad	Anchura	Diag. adyacentes	Diag. no adyacentes
CT23	29,5 %	44,5 %	21,4 %	4,6 %
CT26	20,6 %	48,2 %	28,5 %	2,7 %
CT36	31,5 %	50,5 %	4,3 %	13,7 %

Las transiciones agregadas realizadas por los tomadores de decisión en las diferentes encuestas son concordantes a los encontrados por Stewart et al (2015). En ese trabajo se evidencia que las transiciones comunes (en esta investigación anchura y profundidad) constituyen alrededor de un 75 % de las transiciones totales. Además, comentan que estas transiciones están asociadas a comparaciones útiles para los encuestados. Estos evalúan los atributos para obtener un valor esperado de las ganancias en un juego del Dilema del Prisionero. A juicio de

los hallazgos encontrados en la presente investigación, se puede asociar que los tomadores de decisión realizan estas búsquedas y comparaciones para conceptualizar el valor esperado de las utilidades o preferencias.

De manera detallada, en la matriz de transiciones de la encuesta CT23 (figura 4.11), se observa que los mayores porcentajes de transición desde la alternativa A son del tipo en Anchura y desde la alternativa B no hay predominio claro de búsquedas diagonales adyacentes o en profundidad. Esto podría sugerir que los encuestados observan los valores de los atributos de izquierda a derecha y en algunos casos saltan a la siguiente línea de manera diagonal o en profundidad.

			Attribute observed in step t+1						
			Alt. A			Alt. B			
Attribute observed in step t			WT	TT	C	WT	TT	C	
Alt. A	WT	Waiting Time	0	6	1	13	1	0	21%
	TT	Travel Time	3	0	4	1	12	1	20%
	C	Cost	1	1	0	2	0	8	13%
Alt. B	WT	Waiting Time	4	9	0	0	5	0	19%
	TT	Travel Time	2	3	6	2	0	4	18%
	C	Cost	2	1	3	1	1	0	9%

Figura 4.11: Matriz de transición de encuesta CT23. Profundidad (azul), Anchura (rojo), Diag. adyacentes (gris) y Diag. no adyacentes (verde).

Al aumentar la cantidad de atributos, en la matriz de transición CT26 (figura 4.12), se puede observar que la mayoría de las celdas tienen un valor nulo o cercano a cero. Esto muestra que, al aumentar la carga cognitiva, los encuestados prefieren ciertas heurísticas de búsqueda de información. En este caso particular, vemos que se mantiene el predominio de los patrones en anchura y hay una intensificación de las búsquedas diagonales adyacentes, pero una disminución de las búsquedas en profundidad y diagonales no adyacentes. Esto evidencia que, al mostrar una mayor cantidad de AOI verticales (asociadas a los atributos) que AOI horizontales (asociadas a las alternativas), favorece que los tomadores de decisión sigan un comportamiento de lectura.

Por último, en la matriz de transición de la encuesta CT36 (figura 4.13), se puede apreciar que desde las alternativas A y B predominan las búsquedas en Anchura, mostrando una mayor tendencia de transiciones horizontales hacia la derecha. Luego, le siguen búsquedas en profundidad. En este instrumento en particular, se encontraron que los movimientos diagonales tienden a ser nulos, lo que sugiere que el aumento de AOI o un formato de panel informativo que tenga similar cantidad de atributos y alternativas, induce a patrones comunes. Por otro lado, desde la alternativa C no se encuentra un predominio de ningún patrón, pero solo se encuentran transiciones del tipo en profundidad, anchura y diagonales no adyacentes de manera menor.

Estos hallazgos son concordantes a los expuestos en Bault et al., (2016). En esa investigación se muestra que las transiciones no son independientes y que los patrones de las miradas son consistentes. Esto se debe a que hallaron muchas transiciones entre las ganancias o entre las probabilidades de ganancias a través de las alternativas (Anchura), y luego, miradas entre

Attribute observed in step t		Attribute observed in step t+1												
		Alternative A						Alternative B						
		WKT	WT	TT	C	T	SA	WKT	WT	TT	C	T	SA	
Alternative A	WKT Walking Time	0	2	0	0	0	0	8	0	0	0	0	0	11%
	WT Waiting Time	1	0	2	0	0	0	0	7	0	0	0	0	11%
	TT Travel Time	0	1	0	1	0	0	0	0	8	0	0	0	11%
	C Cost	0	0	0	0	1	0	0	0	0	6	0	0	8%
	T Transfer	0	0	0	0	0	1	0	0	0	0	5	0	7%
	SA Seat Availability	0	0	0	0	0	0	0	0	0	0	0	4	5%
Alternative B	WKT Walking Time	2	6	0	0	0	0	0	2	0	0	0	0	10%
	WT Waiting Time	1	2	5	0	0	0	1	0	1	0	0	0	10%
	TT Travel Time	0	0	3	4	0	0	0	1	0	1	0	0	10%
	C Cost	0	0	1	1	4	0	0	0	0	0	1	0	8%
	T Transfer	0	0	0	0	1	4	0	0	0	0	0	1	6%
	SA Seat Availability	0	0	0	0	0	1	0	0	0	0	0	0	2%

Figura 4.12: Matriz de transición de encuesta CT26. Profundidad (azul), Anchura (rojo), Diag. adyacentes (gris) y Diag. no adyacentes (verde).

Attribute observed in step t		Attribute observed in step t+1																		
		Alternative A						Alternative B						Alternative C						
		WKT	WT	TT	C	T	SA	WKT	WT	TT	C	T	SA	WKT	WT	TT		C	T	SA
Alternative A	WKT Walking Time	0	2	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	0	7%
	WT Waiting Time	1	0	2	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	7%
	TT Travel Time	0	1	0	2	0	0	0	0	4	0	0	0	0	0	1	0	0	0	7%
	C Cost	0	0	0	0	1	0	0	0	0	3	0	0	0	0	0	1	0	0	6%
	T Transfer	0	0	0	0	0	1	0	0	0	0	2	0	0	0	0	0	0	0	5%
	SA Seat Availability	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	3%
Alternative B	WKT Walking Time	1	0	0	0	0	0	0	2	0	0	0	0	4	0	0	0	0	0	7%
	WT Waiting Time	0	1	0	0	0	0	1	0	2	0	0	0	0	3	0	0	0	0	7%
	TT Travel Time	0	0	1	0	0	0	0	1	0	1	0	0	0	0	3	0	0	0	7%
	C Cost	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	3	0	0	6%
	T Transfer	0	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	2	0	5%
	SA Seat Availability	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	3%
Alternative C	WKT Walking Time	1	2	0	0	0	0	1	0	0	0	0	0	0	2	0	0	0	0	7%
	WT Waiting Time	0	1	2	0	0	0	0	1	0	0	0	0	1	0	2	0	0	0	6%
	TT Travel Time	0	0	1	2	0	0	0	0	1	0	0	0	0	1	0	1	0	0	6%
	C Cost	0	0	0	1	2	0	0	0	0	1	0	0	0	0	0	0	1	0	5%
	T Transfer	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	4%
	SA Seat Availability	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2%

Figura 4.13: Matriz de transición de encuesta CT36. Profundidad (azul), Anchura (rojo), Diag. adyacentes (gris) y Diag. no adyacentes (verde).

la ganancia y su probabilidad asociada (Profundidad). En segundo lugar, los participantes exploraron preferentemente de izquierda a derecha similar a lo encontrado en estas encuestas. Además, va en línea y refuerza lo encontrado en Noguchi et al 2014, quienes argumentan que en cada una de las comparaciones de pares de alternativas se dan bajo una sola dimensión de atributo. a la luz de los resultados, es posible concluir que: Los modelos de elección psicológicos deben incluir un proceso de búsqueda de información en anchura, con cierto grado de libertad que permita captar otros patrones secundarios, tales como en profundidad o diagonales utilizados en menor medida por los tomadores de decisión.

4.6. Orden de patrón de búsqueda

En las figuras 4.11, 4.12 y 4.13 se grafican las curvas que representan las veces en que los encuestados realizaron los diferentes patrones de búsquedas de información en cada paso del proceso de deliberación. Estos valores se obtuvieron utilizando las fijaciones realizadas por los encuestados y luego se agregaron en su totalidad. A partir del análisis de estas curvas se puede desprender el orden en que se realizan estos tipos de búsquedas.

Primeramente, a partir de la encuesta CT23 (figura 4.11), se puede observar que hay una mayor cantidad de encuestados que realizan preferentemente búsquedas en anchura en una primera instancia y se mantiene durante la mayoría del tiempo de deliberación (hasta $t=13$ hay 83,5% de encuestados que ya decidieron por una alternativa). Luego, hasta $t=4$ le siguen las búsquedas diagonales adyacentes, y en el resto del tiempo (hasta $t=13$) transiciones en profundidad. Con respecto a los patrones no adyacentes, son menores y estos corresponden al valor mínimo en el 92% del tiempo de deliberación con respecto a las otras transiciones.

Cabe señalar que se realizan más comparaciones en profundidad a medida que se avanza a lo largo del tiempo de deliberación, esto se evidencia por dos razones. Primero, la pendiente de la curva es menor que la tasa de decaimiento de las transiciones en Anchura. Y en segundo lugar, la cantidad de búsquedas en profundidad son mayores que el resto de patrones desde el primer tercio del proceso en adelante.

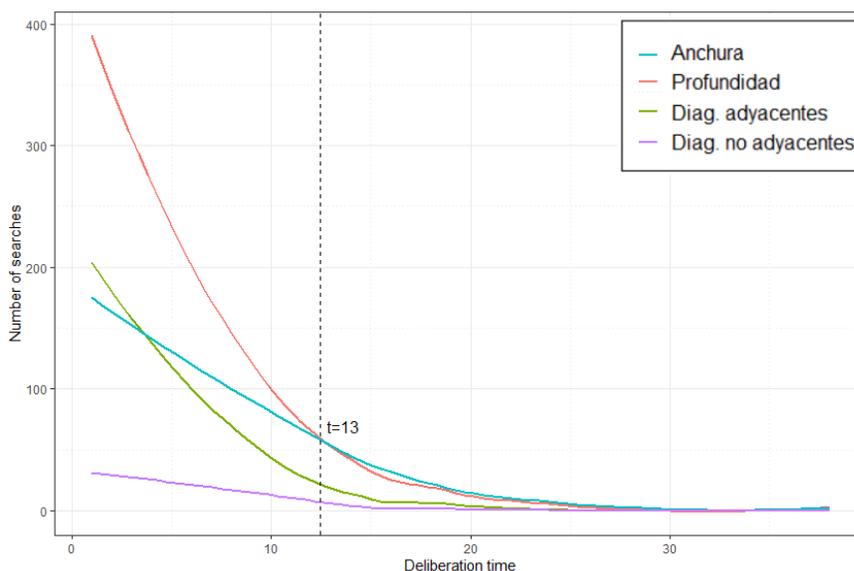


Figura 4.14: Orden de patrones de búsqueda de información en CT23.

Por otro lado, en la encuesta CT26, se mantiene el claro predominio de ocurrencias de búsquedas en anchura que son realizadas en una primera etapa del tiempo de deliberación (hasta $t=31$ hay 95,1% de encuestados que ya decidieron). Sin embargo, ahora le siguen las transiciones diagonales adyacentes conforme a lo expresado en la matriz de transiciones correspondiente. Por último, las comparaciones no adyacentes corresponden al 88,8% de las veces a los valores mínimos de ocurrencia en todo el proceso. Se destaca, al igual que en el caso anterior, a medida que se avanza en el tiempo se generan más búsquedas en profundidad con respecto al resto

de los patrones y se tiene un punto de inflexión luego del primer tercio de proceso deliberativo.

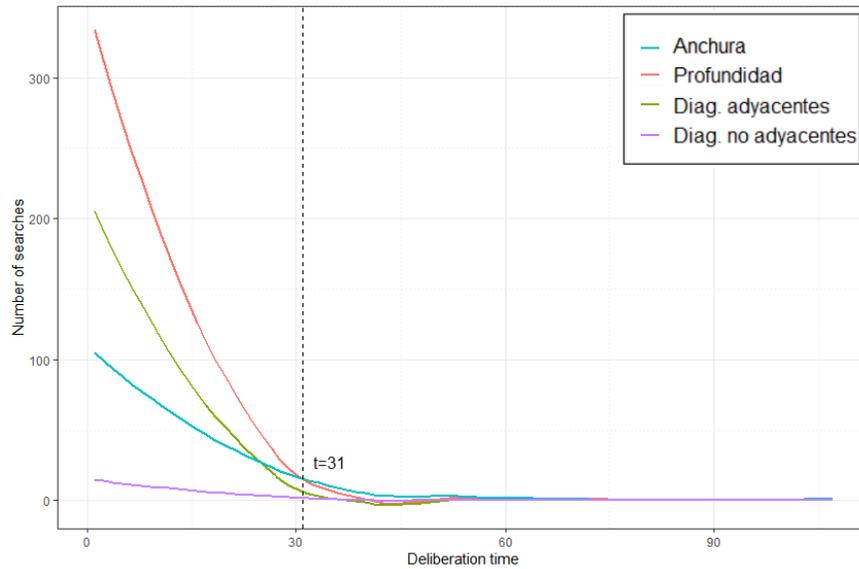


Figura 4.15: Orden de patrones de búsqueda de información en CT26.

Por último y al igual que en el resto de las encuestas, cuando se aumenta la cantidad de alternativas, se mantiene la gran cantidad de ocurrencias de búsquedas en anchura en comparación con el resto de patrones y estas son realizadas en la primera etapa del proceso de deliberación (hasta $t=34$ hay 87,9% de encuestados que ya eligieron). Luego, le siguen los patrones en profundidad y estos dominan en las búsquedas más tardías del proceso de deliberación, al igual que en todos los casos anteriores (la curva presenta una menor pendiente y existe un punto de inflexión cercano al 50% del proceso). En cuanto a las búsquedas adyacentes no diagonales, estas se incrementan significativamente y capturan los números de las transiciones adyacentes, pues representan los saltos que se realizan en un orden de lectura lexicográfico. Independiente de lo anterior, en ningún caso superan la cantidad de anchura y profundidad.

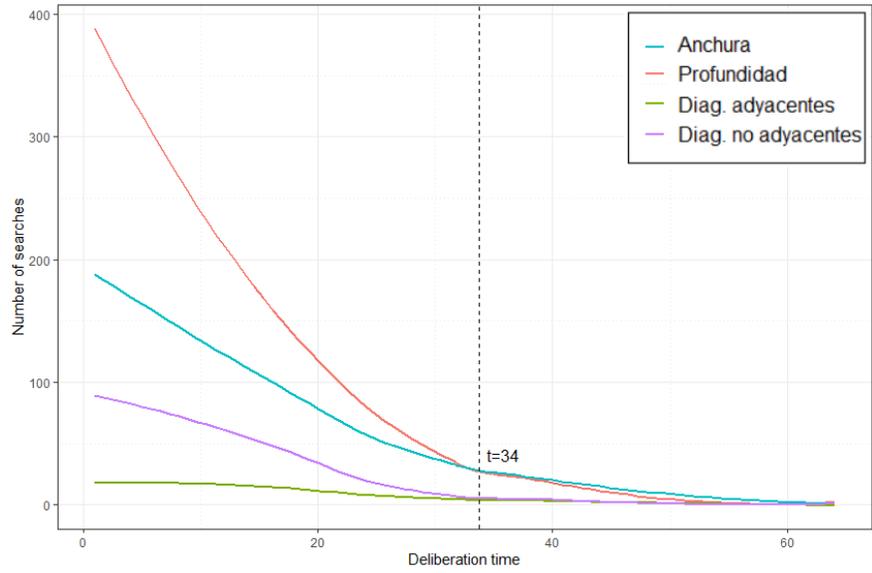


Figura 4.16: Orden de patrones de búsqueda de información en CT36.

4.7. Duración

Los boxplots en las figuras 4.17, 4.18 y 4.19 muestran el tiempo promedio de las búsqueda de información de cada una de las 8 tareas de elección de las encuestas CT23, CT26 y CT36, respectivamente. Además, se destaca en rojo el promedio de estos valores y son mostrados en la tabla 4.6. Estos valores se obtienen como la cantidad de tiempo que permanecen visibles las áreas de interés clicadas, siguiendo la formulación mostrada en la ecuación 4.6.

A partir de estos valores, se puede observar que existe una constante reducción del promedio de las duraciones de los clics mientras los encuestados avanzan en la encuesta. Esto sugiere dos posible razones. Por un lado, los encuestados adquieren cierto aprendizaje para utilizar el instrumento y cliclean más rápido. O, por otro lado, los participantes comienzan a memorizar la ubicación de las áreas de interés relevante para tomar su elección y realizan ciertas heurísticas de búsqueda de información adquiridas durante el transcurso de las tareas de respondidas anteriormente.

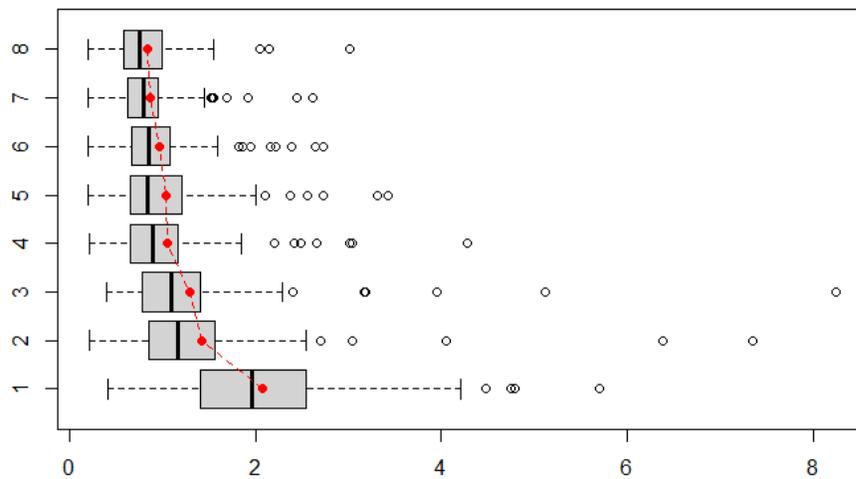


Figura 4.17: Duración promedio de las búsquedas en encuesta CT23.

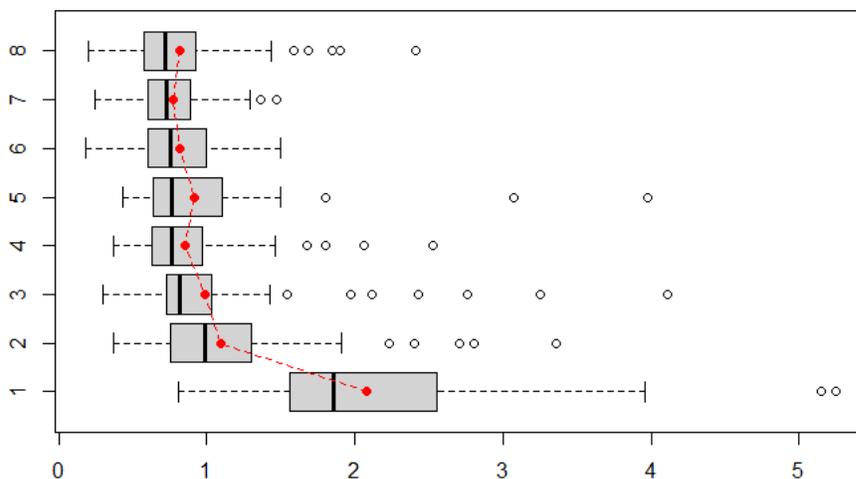


Figura 4.18: Duración promedio de las búsquedas en encuesta CT26.

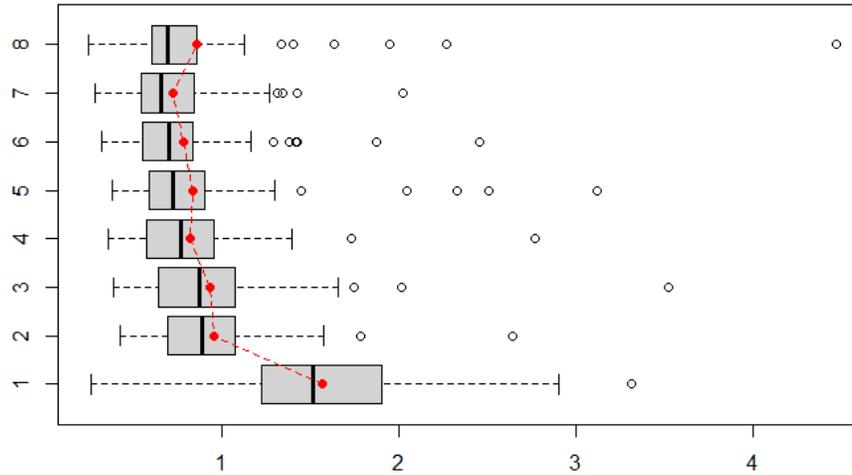


Figura 4.19: Duración promedio de las búsquedas en encuesta CT36.

Asimismo, se examinan cómo las duraciones de las fijaciones varían a lo largo de las tareas de elección. Se estiman parámetros lineales que indican cuanto varía la duración de las adquisiciones y búsquedas de la información con respecto al tiempo de deliberación, mostrando que decaen de manera significativa a una razón de $\beta_{CT23} = -57,2$ [ms] (p-value= $< 0,001$), $\beta_{CT26} = -22,5$ [ms] (p-value= $< 0,001$) y $\beta_{CT36} = -15,8$ [ms] (p-value= $< 0,001$) (Para un mayor detalle, ver figuras con ajuste lineal de las duraciones en Anexo ??).

Tabla 4.6: Duración media de las fijaciones en cada tarea de elección

Tarea de elección	CT23	CT26	CT36
Q1	2,081	2,080	1,565
Q2	1,422	1,097	0,950
Q3	1,298	0,986	0,929
Q4	1,054	0,850	0,816
Q5	1,043	0,919	0,831
Q6	0,963	0,817	0,780
Q7	0,864	0,773	0,722
Q8	0,836	0,815	0,855

Por lo cual, la duración no es constante durante el proceso de deliberación y es contradictorio a los resultados mostrados por Stewart et al., (2015). Esto se debe a que los experimentos realizados en este trabajo son más complejos y tal como se ha evidenciado a partir de los diferentes constructos, intervienen diferentes patrones de búsqueda de información mostrando una inestabilidad en el procesamiento de la información. Lo que implica diferencias en la duración de la adquisición y procesamiento de la información (Rayner, Pollatsek, Ashby y Clifton, 2012). Sin embargo, las duraciones breves y con variabilidad a lo largo de la deliberación son más consistentes a procesos automáticos como modelos acumuladores (Glöckner et al., 2012).

Capítulo 5

Modelo de maximización de la utilidad aleatoria que considera evaluación secuencial de atributos

5.1. Modelo econométrico

La gran diferencia entre el modelo DFT con el propuesto en esta tesis, radica en que este enfoque presenta un marco teórico estadístico robusto que es compatible con el principio de maximización de la utilidad aleatoria (RUM) e incorpora la mayoría de los supuestos del modelo proveniente de la psicología matemática. El modelo RUM-DFT al considerar una evaluación secuencial de atributos, se asume que existe una **utilidad subyacente que varía** durante lo largo del tiempo a medida que se observan y evalúan los atributos, pudiendo ser revisitados más de una vez y consecutivamente al igual que en el modelo DFT. Por lo tanto, el número de pasos es ilimitado.

Cabe destacar que se asume y se incorpora de manera explícita en la modelación el proceso de búsqueda de información en anchura que realizan los usuarios, es decir, actualizan las utilidades considerando un atributo a la vez, de la misma forma que en el modelo DFT. Sin embargo, la comparación definitiva de las alternativas solo se realiza cuando se detiene el proceso de búsqueda de información. Se ha evidenciado que este comportamiento ocurre en la práctica, en elecciones riesgosas y cortoplacistas, mediante el seguimiento ocular en diferentes investigaciones ya comentadas en la sección anterior.

La tarea de mirar un atributo y actualizar la utilidad se realiza hasta que el usuario alcanza su límite interno (preferencia) o uno externo (tiempo), instante en el cual, elige aquella alternativa que le presente el mayor valor de preferencia. Además, se incorpora una **tolerancia**, que permite representar la existencia de un costo cognitivo cuando se sigue con el proceso de búsqueda de información, volviéndose cada vez más restrictivo con el aumento de del tiempo de deliberación.

5.2. Toma de decisión en cada paso t

¿Cómo los individuos realizan la evaluación secuencial de los atributos? En una situación de elección, los individuos deben elegir alguna alternativa j , definida cada una de ellas por

K atributos, dentro del conjunto de consideración (C). Se define U_{jn}^t como la utilidad de la alternativa j del individuo n $\in N$ en cada paso $t \in T$ y U_{jn}^0 como la utilidad preconcebida de cada alternativa. Luego, el individuo en cada paso t debe escoger si elegir alguna alternativa con la información actual $e(t)$ o si desea realizar nueva búsqueda de información para actualizar las utilidades $s(t)$ (ver árbol de decisión en figura 5.1). Si decide por la opción de elegir con las utilidades presentes, se termina el proceso de actualización de las utilidades subyacentes y se escoge aquella que le reporte la mayor utilidad $[i|e(t)]$. En cambio, si decide seguir con el proceso de búsqueda de información, el individuo debe determinar qué atributo observar en el paso t+1 para actualizar las utilidades futuras en t+1 $[k(t+1)|s(t)]$. El proceso iterativo de búsqueda de información se puede detener por dos motivos principales. El primero puede deberse a una limitante externa que obliga a la persona elegir alguna alternativa en un tiempo máximo. En cambio, el segundo motivo corresponde a que el individuo alcanza su límite interno de preferencia. Esto se modela a través de una tolerancia interna que permite captura la diferencia entre el valor esperado de elegir alguna de las alternativas en el paso t y el valor esperado de seguir observar un atributo en el paso t+1.

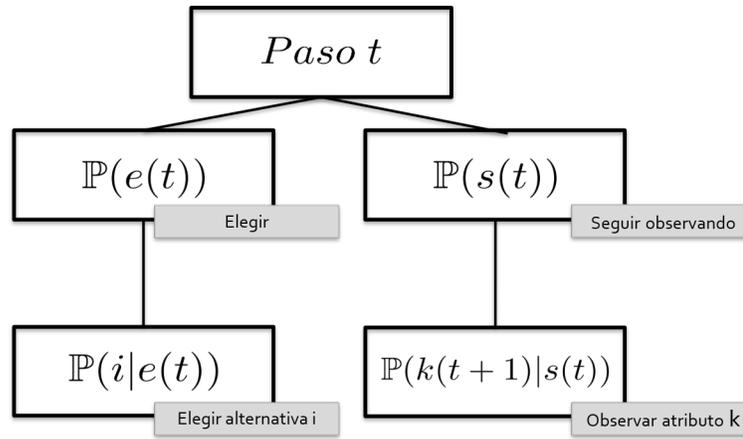


Figura 5.1: Toma de decisión durante el proceso de deliberación

Dado que no se tiene una única secuencia de atributos que podrían observar los individuos $k(1), \dots, k(T)$, se define el conjunto H^t como todos las secuencias de evaluaciones posibles que puede realizar el individuo hasta el paso de deliberación t. Esto quiere decir que en este conjunto, se tienen todas las combinaciones de los K atributos observados hasta t. Del mismo modo, se define un camino cualquiera l hasta t como $h_l^t \in H^t$, siendo l un número de 1 hasta L combinaciones existentes hasta el instante t ($L = \sum_{\tau}^T |J|^\tau$, con $|J|$ el total de alternativas). Por lo tanto, la probabilidad de elegir una alternativa i dado que se decidió elegir y la probabilidad de observar un atributo k en el paso t dado que se escogió seguir observando (búsqueda de información) se pueden representar a través de las ecuaciones (1) y (2), respectivamente.

$$P(i|h_l^t) = P(i|e(t)) \cdot P(e(t)|h_l^t) \quad (5.1)$$

$$P(k(t)|h_l^{t-1}) = P(k(t)|s(t)) \cdot P(s(t)|h_l^{t-1}) \quad (5.2)$$

A continuación, se muestra el desarrollo para obtener estas probabilidades incorporando utilidades que varían durante el proceso de manera dinámica dependiendo del atributo considerado en el paso t.

5.3. Funciones de utilidad

La forma funcional de las utilidades en el modelo RUM-DFT deben considerarse de tal manera que permitan mostrar la evolución de las preferencias de los individuos dado el proceso de búsqueda de información. Por lo cual, el objetivo es plantear una función lo bastante similar a las empleadas en los modelos de RUM para una fácil identificación e inferencia de parámetros, junto a una tratable interpretación y estimación de las valoraciones subjetivas.

Por un lado, debe representar explícitamente el aspecto dinámico, el cual depende del atributo $k(t)$ observado en el paso t y de la utilidad sistemática del instante anterior V_{jn}^{t-1} , tal como se muestra en la ecuación (5.3).

$$U_{jn}^t = \alpha \cdot V_{jn}^{t-1} + (1 - \alpha) \cdot \beta_{k(t)} \cdot X_{jnk(t)} + \varepsilon_{jnt} \quad (5.3)$$

En la cual, α es peso temporal del pasado, $\beta_{k(t)}$ es el parámetro del atributo $k(t)$, $X_{nik(t)}$ corresponde al valor del atributo k de la alternativa i para el individuo n observado en el paso t , y $\varepsilon_{nik(t)}$ es el error que distribuye valor extremo con μ_e . Es necesario destacar que la utilidad aleatoria U_{jn}^t se descompone en dos partes. Primero, la utilidad sistemática V_{jn}^{t-1} , que no tiene variabilidad estocástica pero que depende de los atributos observados y de la valoración que les dan los individuos a estos en cada paso t . La segunda parte corresponde al error ε_{jnt} , que entrega la aleatoriedad a las utilidades y se incorpora solo cuando el individuo decide elegir. En esta tesis, se asume que los errores son EVI.

Esta utilidad sigue una estructura similar a las cadenas de Markov, en la cual la utilidad aleatoria anterior V_{jn}^{t-1} afecta a la utilidad presente. Además, se sigue esta lógica pues se ha considerado en otras modelaciones, tales como en Xie et al., (2019) y Chorus et al., (2013). En este último, asume que la utilidad de adquirir una estimación de algún atributo para una de las alternativas es igual a la utilidad anticipada de elegir entre las alternativas conocidas después de recibir la estimación.

La forma funcional de la utilidad aleatoria en el paso t incorpora la parte aleatoria solo cuando el individuo decide elegir alguna alternativa con la información que posee hasta ese momento. Esto corresponde a una simplificación del proceso real que pasan los tomadores de decisión, ya que no se están incluyendo los errores en cada paso t que le permiten construir su secuencia de atributos atendidos. Una línea de investigación a futuro puede estar centrada en cómo incorporar sistemáticamente el error en cada paso, que muestre la correlación existente y que se pueda estimar de manera adecuada, con el fin de generar la dinámica a partir de las utilidades aleatorias y no sistemáticas únicamente, tal como se muestra en la ecuación 5.4. Al expandir esta última, se puede observar en la ecuación 5.5 la relación de los errores a través del tiempo de deliberación, tal que la correlación es distinta de cero.

$$U_{jn}^t = \alpha U_{jn}^{t-1} + (1 - \alpha) \beta_{k(t)} X_{jnk(t)} + \varepsilon_{jnk(t)} \quad (5.4)$$

$$U_{jn}^t = \alpha^t \cdot V_{jn}^0 + \sum_{l=1}^t \alpha^{t-l-1} (1 - \alpha) \beta_{k(l)} X_{k(l)} + \sum_{l=1}^t \alpha^{t-l-1} \varepsilon_{jnk(l)} \quad (5.5)$$

$$\text{corr}(\varepsilon_{jnk(t-1)}, \varepsilon_{jnk(t)}) \neq 0 \quad (5.6)$$

Por otro lado, dado que se ha asumido que en cada paso el individuo debe decidir si elegir o no, este realiza implícitamente una comparación entre el valor esperado de las utilidades presentes con respecto al valor esperado de las utilidades futuras, que podría obtener si decide seguir con la búsqueda de información. Este subproceso relacionado con la tolerancia modela la detención del proceso de búsqueda de información en el modelo.

La figura 5.2 muestra que el usuario en cada paso tiene dos nodos principales, uno que representa el tiempo presente con las utilidades actuales y otro que muestra el tiempo futuro en caso de que decida seguir observando atributos. Con respecto a la rama izquierda árbol de decisión, la utilidad presente se modela siguiendo el enfoque de maximización de utilidad aleatoria considerando las utilidades subyacentes en el paso t . En cambio, en la parte futura, la utilidad de seguir observando debe representar el comportamiento de búsqueda de información en anchura. Debido a este supuesto es que se generan dos subprocesos, primero se debe analizar la utilidad que podría proporcionar el atributo k -ésimo para todas las alternativas si se observas en en $t+1$, y luego, decidir cuál valor esperado de todos estos genera el mayor impacto en el cambio de la utilidades presentes.

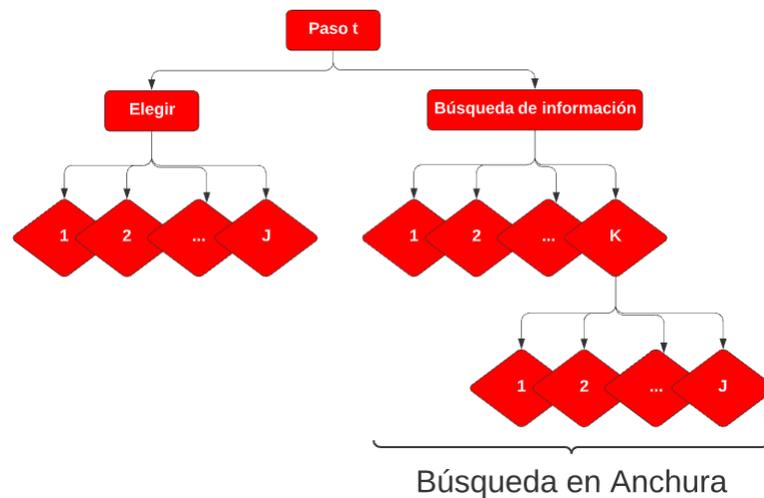


Figura 5.2: Toma de decisión incluyendo proceso de búsqueda de información

Es por lo anterior, que es necesario definir las utilidades que intervienen en el proceso siguiendo la estructura mencionado anteriormente.

5.3.1. Valor inclusivo de elegir

El usuario al momento de elegir en cierto paso t , conceptualiza la utilidad presente (U_e^t) como el valor esperado de las utilidades presentes de cada alternativa en el paso t (U_j^t), similar a la expresión de Nested Logit (M. E. Ben-Akiva y Lerman, 1985). Entonces, se define la utilidad presente en cierto paso t , como:

$$U_e^t = V_e^t + \varepsilon_e^t \quad \Rightarrow \quad V_e^t = E[\max U_j^t \quad \forall j \in C] \quad (5.7)$$

5.3.2. Valor inclusivo de seguir con el proceso de búsqueda de información

Por otro lado, el usuario debe escoger que atributo desea observar en $t+1$ si decide seguir con el proceso de búsqueda de información en anchura. Dado lo anterior, la utilidad futura de seguir buscando (U_s^t) corresponde al valor esperado de las utilidades preconcebidas de observar el atributo k en $t+1$ (U_{sk}^{t+1}), al igual que con la utilidad presente, es decir:

$$U_s^t = V_s^t + \varepsilon_s^t \quad \Rightarrow \quad V_s^t = E[\max U_{sk}^{t+1} \quad \forall k \in K] \quad (5.8)$$

Asimismo, U_{sk}^t depende del valor esperado de las utilidades que podría entregar el atributo k para todas las alternativas si se decide observar en $t+1$, U_{skj}^{t+1} , las cuales se calculan asumiendo que el individuo elige en el paso siguiente $e(t+1)$, es decir:

$$U_{sk}^t = V_{sk}^t + \varepsilon_{sk}^t \quad \Rightarrow \quad V_{sk}^t = E[\max U_{skj}^{t+1} \quad \forall j \in J] \quad (5.9)$$

Finalmente, la utilidad preconcebida de observar el atributo k de cierta alternativa si se decide observar en $t+1$ (U_{kj}^{t+1}) se modela siguiendo el enfoque presentado en la ecuación (5.3), es decir:

$$U_{kj}^{t+1} = V_{kj}^{t+1} + \varepsilon_{kj}^t \quad \Rightarrow \quad V_{kj}^{t+1} = \alpha V_j^t + (1 - \alpha)\beta_{k(t+1)} \cdot X_{k(t+1)} + \varepsilon_{kj} \quad (5.10)$$

Cabe destacar que esta forma de modelar la utilidad futura (U_s^t) incorpora el comportamiento de búsqueda en anchura pues, primero el individuo se enfoca en los valores del atributo k -ésimo para todas las alternativas, y luego, repite este subproceso para todos los atributos. La utilidad futura se podría construir de manera similar para representar búsqueda de información en profundidad o una combinación de ambas.

5.4. Expresiones de probabilidad

Teniendo definido el proceso de elección que se intenta modelar, la toma de decisiones en cada paso y las utilidades subyacentes, se puede realizar la deducción de las expresiones de probabilidad de modelo.

5.4.1. Probabilidad de elegir y seguir observando

Para modelar estas probabilidades se debe tener en consideración que el individuo en el paso t , está decidiendo entre elegir o seguir con la búsqueda de información. Además, estas probabilidades dependen si la diferencia entre la utilidad presente y futura son mayor o no que el umbral interno del individuo (δ^t).

Para efectos de esta tesis, se incorpora la tolerancia como el umbral de que la persona elija alguna alternativa si en el paso siguiente, al observar un atributo, no existe un cambio sustancial en su utilidad subyacente. Además, en esta dinámica se asume que los individuos se vuelven más intolerantes a medida que pasa el tiempo, por lo que requieren cambios esperados más grandes para que decidan seguir buscando información. De lo anterior, se modela la tolerancia como $\delta^t = \delta \cdot t^2$, representando la dinamicidad más sencilla posible.

Dicho lo anterior, la probabilidad de elegir queda como:

$$P(s(t)) = P(|U_e^t - U_s^t| > \delta^t) = P(|V_e^t + \varepsilon_e^t - V_s^t - \varepsilon_s^t| \leq \delta^t) \quad (5.11)$$

Incorporando las ecuaciones (5.7), (5.8), (5.9) y (5.10), la ecuación 5.11 queda como:

$$P(e(t)) = P(|\max\{U_j^t \forall j\} + \varepsilon_e^t - \max\{\max\{U_{skj} \forall j\} \forall k\} - \varepsilon_s^t| \leq \delta^t) \quad (5.12)$$

$$P(e(t)) = P(|LS_e^t + \varepsilon_e^t - LS_s^t - \varepsilon_s^t| \leq \delta^t) \quad (5.13)$$

Ahora, asumiendo que la diferencia de los errores de las utilidades presente, futura, es decir, de las utilidades actuales y de las utilidades preconcebidas de observar los atributos son i.i.d valor extremo con factor de escala correspondientes a su nido, se tienen las siguientes ecuaciones:

$$V_e^t = E[\max U_j^t \quad \forall j \in C] = \frac{1}{\mu_e} \ln \left(\sum_j^J e^{\mu_e \cdot V_j^t} \right) = LS_e^t \quad (5.14)$$

$$V_s^t = E[\max U_{sk}^{t+1} \quad \forall k \in K] = \frac{1}{\mu_e} \ln \left(\sum_k^K e^{\mu_e \cdot V_{sk}^t} \right) = LS_s^t \quad (5.15)$$

$$V_{sk}^t = E[\max U_{skj}^t \quad \forall j \in J] = \frac{1}{\mu_s} \ln \left(\sum_j^J e^{\mu_s \cdot V_{skj}^t} \right) = LS_{sk}^t \quad (5.16)$$

Aplicando las ecuaciones (5.14),(5.16) y (5.15) a la ecuacion(5.13), se tiene que la probabilidad de elegir es:

$$P(e(t)) = \left(\frac{e^{V_s^t + \delta^t}}{e^{V_e^t} + e^{V_s^t + \delta^t}} + \frac{e^{V_e^t + \delta^t}}{e^{V_s^t} + e^{V_e^t + \delta^t}} \right) \quad (5.17)$$

De manera análoga, la probabilidad de seguir observando es:

$$P(s(t)) = \left(\frac{e^{V_e^{t-1}}}{e^{V_e^{t-1}} + e^{V_s^{t-1} + \delta^t}} + \frac{e^{V_s^{t-1}}}{e^{V_s^{t-1}} + e^{V_e^{t-1} + \delta^t}} \right) \quad (5.18)$$

5.4.2. Probabilidad de elegir alternativa i

La probabilidad de elegir una alternativa dado que el individuo decidio elegir, es similar a la del modelo Logit pues se tiene que la distriubución de los errores es EVI.

$$P(i|e(t)) = \frac{e^{V_i^t}}{\sum_j e^{V_j^t}} \quad (5.19)$$

5.4.3. Probabilidad de observar atributo k

La probabilidad de elegir observar un atributo k dado que el individuo decidió seguir con el proceso de búsqueda de información, se construye siguiendo un modelo Logit que considera como utilidad el valor esperado del cambio sobre todas las utilidades si se observa ese atributo

en el paso siguiente. Esto va en línea con el supuesto de que las personas realizan búsqueda de información en anchura. Por lo cual, la expresión queda como:

$$P(k|s(t)) = \frac{e^{\phi_k^{t+1}}}{\sum_k e^{\phi_k^{t+1}}}, \quad \phi_k^{t+1} = E[\max_j U_{skj}^{t+1}] \quad (5.20)$$

Al asumir que los errores son EVI, entonces ϕ_k^{t+1} corresponde a:

$$\phi_k^{t+1} = \frac{1}{\mu} \ln \left(\sum_j e^{\mu \cdot V_{skj}^{t+1}} \right) = LS_{sk}^{t+1} \quad (5.21)$$

5.5. Probabilidades finales

Finalmente, se pueden desarrollar las expresiones de probabilidad de elegir y seguir con el proceso de búsqueda de información de las ecuaciones (5.1) y (5.2), respectivamente:

$$P(i|h_i^t) = \frac{e^{V_i^t}}{\sum_j e^{V_j^t}} \cdot \left(\frac{e^{LS_s^t + \delta^t}}{e^{LS_e^t} + e^{LS_s^t + \delta^t}} + \frac{e^{LS_e^t + \delta^t}}{e^{LS_s^t} + e^{LS_e^t + \delta^t}} \right) \quad (5.22)$$

$$P(k(t)|h_i^{t-1}) = \frac{e^{\phi_k^{t+1}}}{\sum_{k'} e^{\phi_{k'}^{t+1}}} \cdot \left(\frac{e^{LS_e^{t-1}}}{e^{LS_e^{t-1}} + e^{LS_s^{t-1} + \delta^t}} + \frac{e^{LS_s^{t-1}}}{e^{LS_s^{t-1}} + e^{LS_e^{t-1} + \delta^t}} \right) \quad (5.23)$$

5.6. Probabilidades latentes

Las expresiones (5.22) y (5.23) muestran las probabilidades de elegir y observar el atributo k de un camino particular h_i^t dentro de los que pudo haber realizado el individuo. Por lo cual, se debe generalizar estas probabilidades para todo el conjunto de caminos posibles de búsqueda de información H^t que considera todas las combinaciones posibles, pues a priori no se tiene la información de lo observado en pasos intermedios.

Dado lo anterior y consideran el teorema de Bayes, la probabilidad de elegir una alternativa i se puede construir como la probabilidad de elegir i dado un camino particular multiplicado por la probabilidad de elegir ese camino de búsqueda de información en particular:

$$P(i) = \sum_{h_i^t}^{H^t} P(i|h_i^t) \cdot P(h_i^t) \quad (5.24)$$

5.7. Estimación

Para el proceso de estimación del modelo, se deben encontrar los β que maximizan la probabilidad de las elecciones observadas. Al tener $P(i)$ y definiendo la elección y_{ni} hecha por el individuo n de la alternativa i como:

$$y_{ni} = \begin{cases} 1 & \text{si el individuo } n \text{ elige } i \\ 0 & \text{si no} \end{cases}$$

Se puede formular la verosimilitud L^* tal como se muestra a continuación:

$$L^* = \prod_n^N \prod_j^J P(j)^{y_{nj}} \quad (5.25)$$

Finalmente, al aplicar logaritmo natural a la expresión (21), se obtiene la log-verosimilitud L :

$$L = \sum_n^N \sum_j^J y_{nj} \cdot \ln(P(j)) \quad (5.26)$$

5.7.1. Métodos de estimación

En esta tesis se realizó un análisis de tres especificaciones para la estimación del modelo RUM-DFT dependiendo del tipo de información que se posea sobre la situación de elección de los individuos. Cabe señalar que dada la evidencia recolectada a partir de la encuesta Click-Tracker, tales como la elección, la secuencia de atributos observados y la cantidad de pasos que tomó el individuo para tomar su decisión, se pueden estimar las especificaciones 1, 2 y 3 con observaciones reales. Los datos que se podrá obtener del instrumento Eye-tracker permitirán lo mismo.

RUM-DFT-SP

Estimación con información del proceso de búsqueda de información: Para desarrollar este tipo de estimación, es necesario tener información sobre los atributos observados en cada paso t de la evaluación secuencial considerados por los individuos en la situación de elección. Esta base de datos se puede obtener a partir de tecnologías, tales como seguimiento de los atributos clicados en un computador conocido como mouse-tracker, seguimiento de los atributos seleccionados en dispositivos móviles táctiles o seguimiento ocular al responder encuestas de elección.

Para efectos de esta tesis, se puede construir el proceso de evaluación secuencial de los atributos o el camino de búsqueda de información, tal como muestra la figura 5.3 y con esto, se puede obtener la probabilidad de elegir la alternativa mostrada en la ecuación (5.27).

$$P(i|\tilde{h}_l^{T_n}) = \frac{e^{V_i^{T_n}}}{\sum_j e^{V_j^{T_n}}} \cdot \left(\frac{e^{LS_s^{T_n} + \delta t}}{e^{LS_e^{T_n}} + e^{LS_s^{T_n} + \delta T_n}} + \frac{e^{LS_e^{T_n} + \delta t}}{e^{LS_s^{T_n}} + e^{LS_e^{T_n} + \delta T_n}} \right) \quad (5.27)$$

Donde $\tilde{h}_l^{T_n}$ corresponde al camino realizado por el individuo n hasta su tiempo final T_n . Por lo tanto, solo es necesario calcular una probabilidad de elección por individuo que considera esa secuencia de búsqueda de información en particular.

Al tener la información de los caminos de búsqueda de información de todos los individuos, la log-verosimilitud es:

$$L = \sum_n^N \sum_j^J y_{nj} \cdot \ln \left(\frac{e^{V_j^{T_n}}}{\sum_i e^{V_i^{T_n}}} \cdot \left[\frac{e^{LS_s^{T_n} + \delta t}}{e^{LS_e^{T_n}} + e^{LS_s^{T_n} + \delta T_n}} + \frac{e^{LS_e^{T_n} + \delta t}}{e^{LS_s^{T_n}} + e^{LS_e^{T_n} + \delta T_n}} \right] \right) \quad (5.28)$$

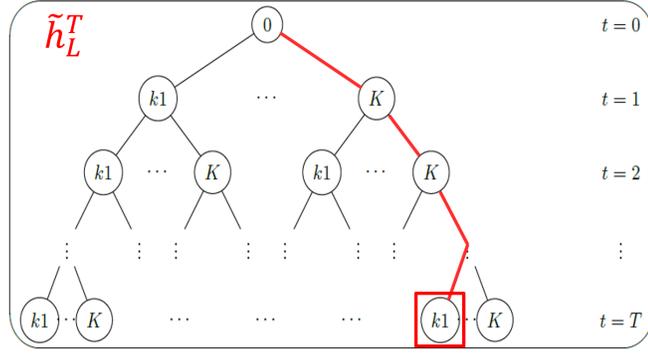


Figura 5.3: \tilde{h}^{T_n} : Secuencia de atención sobre los atributos hasta T_n

RUM-DFT-DT

Estimación con el tiempo del proceso de búsqueda de información: Para desarrollar este tipo de estimación, es necesario tener información sobre el tiempo o la cantidad de pasos que realizan los individuos en el proceso de elección. Esto se puede obtener de manera pasiva en encuestas tradicionales y no se necesita un instrumento construido especialmente como panel informativo para lograr ese objetivo. Por ejemplo, en el software Qualtrics, se puede capturar el tiempo de cada tarea de elección y se puede utilizar como proxies válidos sobre los procesos cognitivos (Horstmann, Ahlgrimm y Glockner, 2009).

Por lo cual, considerando el tiempo de deliberación conocido, tal como muestra la figura 5.5, se puede calcular la probabilidad de elegir la alternativa mostrada en la ecuación (5.29) considerando todas las secuencias de atención posibles hasta el paso \tilde{T} .

$$P(i) = \sum_{h_i^T \in H^{\tilde{T}}} P(i|h_i^T)P(h_i^{\tilde{T}}) \quad (5.29)$$

Donde $P(i|h_i^T)$ corresponde a la probabilidad de elegir la alternativa i condicional a seguir la secuencia de evaluación h_i^T que se muestra en la ecuación (5.27). $P(h_i^{\tilde{T}})$ corresponde a la probabilidad de que el tomador de decisión haya realizado la secuencia h_i^T hasta su tiempo final \tilde{T} . Por lo tanto, no es necesario calcular probabilidades latentes que considera todos los caminos posible de búsqueda de información.

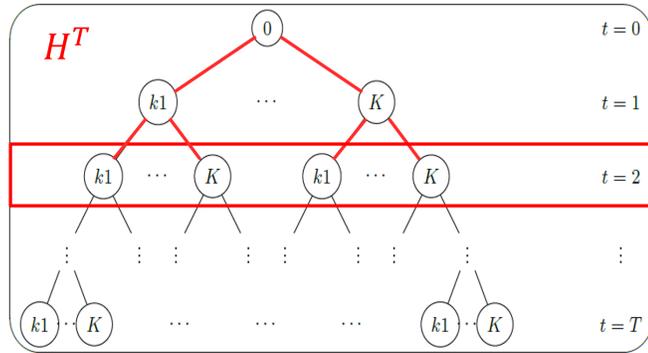


Figura 5.4: $H^{\tilde{T}}$ Secuencias posibles de atención sobre los atributos hasta \tilde{T}

RUM-DFT-SC

Estimación tradicional sin información del proceso de búsqueda de información:

Tradicionalmente, las bases de datos de elecciones discretas solo contienen información socioeconómica de los individuos, los atributos mostrados y las elecciones realizadas por éstos. Dado que no se tiene información del proceso de deliberación, se debe considerar todas las secuencias del proceso de búsqueda de información posibles de la atención sobre los atributos. Por lo cual, las probabilidades de elección se obtienen al calcular la ecuación (5.30) considerando todos los posibles caminos y fijando un tiempo máximo de deliberación, tal como se muestra en la ecuación 5.30. Este último número se debe determinar previamente al proceso de estimación por el investigador. Cabe destacar que un valor más cercano al real mejora la verosimilitud del modelo sacrificando tiempo computacional, pues se generan K^2 caminos posibles al aumentar en un paso el tiempo de deliberación.

$$P(i) = \sum_{h_i^t}^{H^t} P(i|h_i^t) \cdot P(h_i^t) \quad (5.30)$$

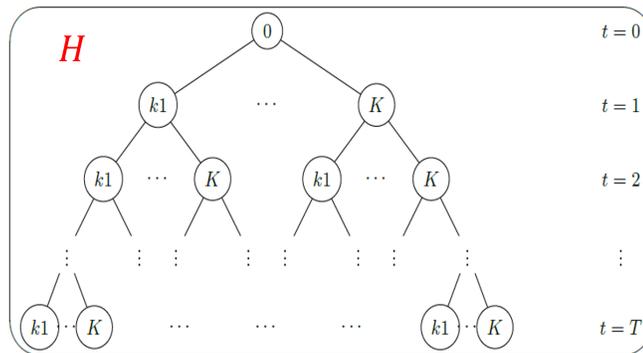


Figura 5.5: H Secuencias posibles de atención sobre los atributos

5.7.2. Ejemplo

En esta sección se realiza un ejemplo teórico para aplicar la teoría a una situación de elección que puede ocurrir en la vida real. Sea el caso de que Marco quiere viajar en transporte público desde su hogar al trabajo en horario punta y desea comenzar su viaje. Esta persona tiene 3 alternativas de rutas que puede seguir a su destino (A, B y C), pero típicamente utiliza la ruta C, ya que él sabe que ha sido una opción más rápida en otras ocasiones. Sin embargo, está dispuesto a analizar las otras alternativas de viaje. Los atributos disponibles que tiene para observar son la tarifa, el tiempo de viaje y cantidad de transbordos.

Toda la información para realizar su elección la tiene disponible al mismo tiempo y se asume que realiza una evaluación secuencial de atributos a través de búsquedas de información en anchura. Por lo cual, de manera general, el individuo inicia su proceso con los valores preconcebidos de las alternativas, fija la atención sobre un atributo, y luego, actualiza las utilidades, este proceso lo realiza iterativamente hasta que alcanza su límite interno de preferencia, que lo lleva a elegir una alternativa.

Considerando que se pudo capturar la secuencia de atributos atendidos y la elección a través

de alguna metodología de seguimiento de procesos. En particular, los atributos atendidos fueron el tiempo de viaje (Tv) de cada alternativa, luego, se fijó en la cantidad de transbordos (Tr), y finalmente, observó la tarifa (C) decidiendo por la alternativa B. Así, el camino realizado por Marco es $h_{Marco}^3 = (Tv, Tr, C)$ y la probabilidad de elegir la ruta B dado a que haya seguido ese camino de evaluación secuencial de atributos, se calcula como:

$$P(Tv, Tr, C, B) = P(B|Tv, Tr, C) \cdot P(Tv|s(1)) \cdot P(Tr|Tv, S(2)) \cdot P(C|Tv, Tr, S(3))$$

Con las probabilidades de observar los atributos dado que se decidió seguir observando en cada paso:

$$\begin{aligned} P(Tv|S(1)) &= \frac{e^{V_{Tv}^1}}{e^{V_{Tv}^1} + e^{V_{Tr}^1} + e^{V_C^1}} \cdot P(S(1)) \\ P(Tr|Tv, S(2)) &= \frac{e^{V_{Tr}^2}}{e^{V_{Tv}^2} + e^{V_{Tr}^2} + e^{V_C^2}} \cdot P(S(2)|Tv) \\ P(C|Tv, Tr, S(3)) &= \frac{e^{V_C^3}}{e^{V_{Tv}^3} + e^{V_{Tr}^3} + e^{V_C^3}} \cdot P(S(3)|Tv, Tr) \end{aligned}$$

Luego, la probabilidad de elegir la ruta B corresponde a:

$$P(B|h_{Marco}^3) = \left(\frac{e^{V_B^{h_{Marco}^3}}}{e^{V_A^{h_{Marco}^3}} + e^{V_B^{h_{Marco}^3}} + e^{V_C^{h_{Marco}^3}}} \right) \cdot \left(\frac{e^{LS_s^3 + \delta^3}}{e^{LS_e^3} + e^{LS_s^3 + \delta^3}} + \frac{e^{LS_e^3 + \delta^3}}{e^{LS_s^3} + e^{LS_e^3 + \delta^3}} \right)$$

5.7.3. Codificación en R

Se utilizó el lenguaje de programación R, y el software RStudio, con el fin de codificar, simular y estimar las diferentes especificaciones modelo planteado en esta tesis. Por otro lado, se utiliza el paquete gratuito Apollo (Hess y Palma, 2019) basado en R para estimar los modelos convencionales para realizar comparaciones estadísticas con el enfoque propuesto. Dada la implantación fragmentada de Apollo en funciones internas permite estimar los modelo RUM, RRM DFT-B y codificar las últimas especificaciones del modelo DFT: DFT-Scaled y DFT-Scaled-DT.

A continuación, se describe de forma general la codificación para la simulación y estimación del proceso de generación de datos siguiendo el enfoque RUM con evaluación secuencial de atributos. Cabe destacar que se utiliza el código base de Negrete (2019) y se aplican las correcciones mencionadas en esta tesis.

En primer lugar, se simulan los diferentes atributos que definen la situación de elección de ruta para cada uno de los individuos considerando valores de Transporte Público para la ciudad de Santiago, Chile. Luego, se dan valores a los parámetros asociados al proceso de deliberación (factor de memoria, tolerancia y escala de los nidos de las utilidades presentes y futuras) para simular el proceso de generación de datos. A partir de estos valores, se obtiene la secuencia de atributos observados (h_n^{Tn}) y la alternativa elegida para cada tomador de decisión n en cada tarea de elección q (J_n^q). En segundo lugar, para estimar el modelo y

analizar si se recuperan los parámetros, se debe calcular la función de verosimilitud. Para lograr esto, dependiendo de la especificación del modelo propuesto, se necesita calcular las probabilidades de todos los caminos (estimación tradicional), las probabilidades de los caminos hasta el tiempo T_n (estimación con tiempo de deliberación) o secuencia de atributos atendidos (estimación con proceso de búsqueda de información).

Para el caso extremo, en el cual no se tiene datos del proceso de deliberación, el investigador debe definir un tiempo máximo (T_{max}) para obtener todos los caminos posibles. En esta tesis, se utilizan valores de $T_{max} \in [6, 10]$, ya que valores superiores generan una gran cantidad de caminos posibles inclusive con una cantidad baja de atributos. Con este valor, se puede conocer el valor de las utilidades para cada una de las alternativas en cada paso del proceso de deliberación, y a su vez, las probabilidades de los caminos que podrían seguir los tomadores de decisión.

Por lo cual, al fijar el valor de T_{max} , se puede conocer el tamaño de las matrices que intervienen en el proceso para el cálculo de la verosimilitud indicadas en la tabla 5.1.

Tabla 5.1: Matrices para la estimación del modelo.

Descripción matriz	Notación	Cantidad	Dimensión
Utilidad de alternativa	V_{ni}^t	J	$N \times H$
Utilidad futura anticipada de atributo k	V_{sk}^t	K	$N \times H$
Valor inclusivo de seguir buscando	V_{futura}^t	1	$N \times H$
Valor inclusivo de elegir	$V_{presente}^t$	1	$N \times H$
Probabilidad de seguir observando	$\mathbb{P}(s(t) h_i^t)$	1	$N \times H$
Probabilidad de elegir	$\mathbb{P}(e(t) h_i^t)$	1	$N \times H$
Probabilidad de elegir alternativa	$\mathbb{P}(i h_i^t)$	I	$N \times H$
Probabilidad de observar atributo	$\mathbb{P}(k(t) h_i^t)$	K	$N \times H$
Probabilidad de cada camino	$\mathbb{P}(h_i^t)$	1	$N \times H$

Capítulo 6

Resultados con Datos Simulados y caso de estudio

En este capítulo, se detallan los resultados de la simulación del proceso de generación de datos siguiendo el enfoque propuesto y la estimación del modelo para verificar si se recuperan los parámetros correctamente. Se muestra el comportamiento de la utilidad, el valor de los parámetros de elección y del proceso de deliberación. Así mismo, se comentan falencias o limitaciones que quedan propuesta como futuras líneas de investigación. Además, se repite el análisis estadístico para comparar el ajuste del modelo cuando el proceso de generación de datos es de maximización de la utilidad aleatoria y Decisión Field Theory.

6.1. Análisis del modelo con GDP RUM-DFT

A continuación, se muestra la simulación Monte Carlo con elecciones ficticias siguiendo el enfoque RUM-DFT. En cada una de estas, se estiman las tres especificaciones del modelo propuesto para analizar el ajuste y realizar comparaciones con otros modelos convencionales. Los datos simulados se obtienen a partir de una elección de ruta de transporte público con $N= 4000$ tomadores de elección, que pueden acceder y conocer toda la información mostrada, en una tarea de elección definida por 4 alternativas disponibles (Bus, Auto, Tren y Bicicleta) y 2 atributos (tiempo de viaje y costo de viaje).

Tabla 6.1: Rangos utilizados en Monte Carlo para experimento simulado.

Alternativa	Tiempo de viaje [minutos]	Costo de viaje [CLP]
Bus	3 -22	\$230 o \$700
Auto	2 - 25	\$0 - \$1800
Tren	4 - 15	\$230 o \$800
Bicicleta	10 - 20	\$0 - \$100

En la tabla 6.1 se muestra los rangos utilizados en la generación de las variables en el experimento Monte Carlo. Para el tiempo de viaje de cada una de las alternativas se generan a partir de una distribución uniforme con diferentes rangos acordes a la ciudad de Santiago.

Este procedimiento se repite para el costo de viaje en alternativas de transporte privado, pero para el bus y tren se definen en dos niveles posible. Esto se debe a que en la ciudad de estudio las tarifas en el transporte público están fijadas y estandarizadas según el horario independiente del trayecto (caso más simple que no involucra trasbordos). Por otro lado, en la tabla 6.2 se encuentran los valores de los parámetros utilizados para generar las elecciones siguiendo cada modelo. Además, los coeficientes que definen el proceso de deliberación a la elección se identifican en rojo.

Tabla 6.2: Valores de parámetros para generar los datos simulados

Parámetros (Símbolo)		RUM-DFT	RUM	DFT
Tiempo de viaje	β_t	-2,000	-2,000	0,000
Costo de viaje	β_c	-0,500	-0,500	-0,738
ASC/Utilidad preconcebida Bus	U_A^0	-0,500	-0,500	-2,889
ASC/Utilidad preconcebida Auto	U_B^0	-0,500	-0,500	-4,473
ASC/Utilidad preconcebida Tren	U_C^0	0,000	0,000	0,000
ASC/Utilidad preconcebida Bicicleta	U_D^0	-1,000	-1,000	0,627
Factor de memoria	α	0,600	-	-
Tolerancia	δ	0,100	-	-
Escala de raíz	μ	0,100	-	-
Escala de utilidades presentes	μ_e	0,100	-	-
Escala de utilidades futuras	μ_f	0,100	-	-
Sensibilidad	ϕ_1	-	-	7,786
Memoria	ϕ_2	-	-	0,024
Error	σ_ϵ	-	-	9,283
Pasos de actualización de preferencias	τ	-	-	3,025

6.1.1. Función de utilidad

Tal como se comentó en la sección 5.3, las utilidades de este modelo son dinámicas y varían a lo largo del proceso de deliberación dependiendo del atributo que el tomador de decisión este atendiendo en cada paso, al igual que el modelo DFT.

En la figura 6.1 se muestra la evolución de las utilidades para un tomador de decisión en la situación de elección definida previamente. En esta imagen se puede observar que las utilidades inician con los valores preconcebidos definidos y evolucionan dependiendo de las búsquedas de información realizada por este encuestado en particular. En este caso, su secuencia de atributos atendidos es $h^8 = \{\text{Costo, Tiempo de viaje, Costo, Costo, Tiempo de viaje, Costo, Costo}\}$. Luego, en el paso $t = 8$, el individuo previsualiza que las utilidades futuras no variarían suficientemente que las utilidades presentes (menos que la tolerancia δ), lo que lleva a decidir elegir el Auto, pues posee la mayor utilidad que el resto de las alternativas en ese paso de deliberación.

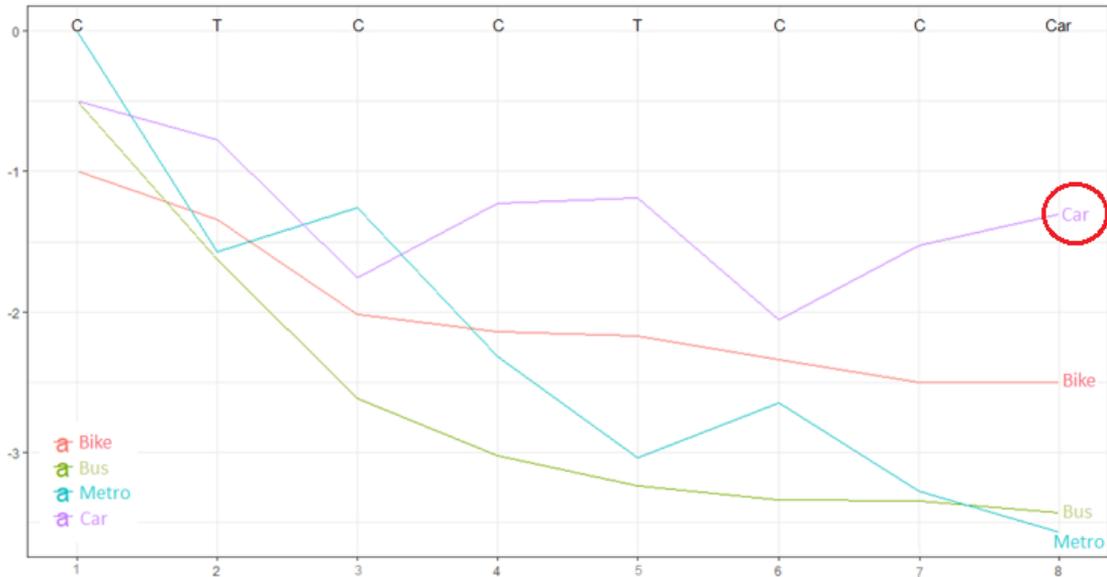


Figura 6.1: Dinámica de utilidades con 4 alternativas y 2 atributos.

De manera análoga, en la figura 6.2 se muestra la evolución de las utilidades para un tomador de decisión en una situación de elección definida por 4 alternativas y 3 atributos. En esta imagen se puede observar que al incluir el tiempo de espera afecta la percepción de las alternativas y realiza otro proceso de búsquedas de información realizada por el encuestado. Es este caso en particular, el individuo atiende los siguientes atributos $h^{10} = \{\text{Costo, Costo, Costo, Costo, Tiempo de espera, Tiempo de espera, Costo, Tiempo de viaje, Tiempo de viaje, Costo}\}$. Luego, en el paso $t = 11$, el individuo decide elegir la bicicleta, pues las utilidades futuras no variarán lo suficiente y esta alternativa posee la mayor utilidad que el resto.

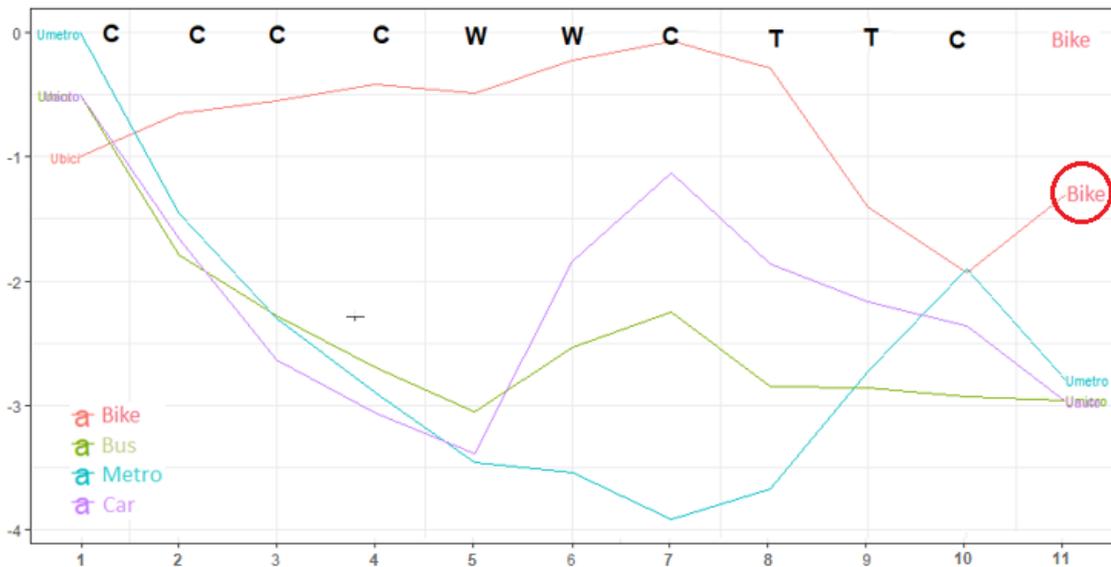


Figura 6.2: Dinámica de utilidades con 4 alternativas y 3 atributos.

Estos gráficos, muestran que el modelo cumple con la dinámica esperada. Se visualiza que los tomadores de decisión re-visitan los atributos, las utilidades varían dependiendo del atributo

atendido y al aumentar la complejidad de la situación de elección, aumenta la cantidad de búsquedas de información realizadas.

6.1.2. Factor de memoria

Dado que se modela la dinámica de las utilidades como un proceso de Markov, en que la información del paso anterior se incluye en la utilidad presente a través α , esto provoca que la función de verosimilitud sea no convexa. En la ecuación (6.1) se muestra la segunda derivada de la utilidad sistemática con respecto a α , evidenciando la dependencia con este parámetro y a los coeficientes (β_k) de los atributos atendidos durante el proceso de deliberación.

$$\frac{\partial^2 V_{ni}^t}{\partial \alpha^2} = \alpha^{t-2} t(t-1) V_{ni}^0 + \sum_{l=1}^t \alpha^{t-2} (t-1) (\alpha t - 1) \beta_{k(l)} X_{nik(l)} \quad (6.1)$$

Por lo cual, se debe tener un especial cuidado en el proceso de estimación para que los optimizadores utilizados alcancen el óptimo global y no se queden atascado en locales. Este problema puede desaparecer estimando un modelo con valores de α conocidos previamente y testear cuál de estos se acercan más al valor verdadero. Por otro lado, para estimar el parámetro adecuadamente y alcanzar el óptimo global, se pueden utilizar heurísticas de optimización más complejas, como por ejemplo el paquete de R llamado Deoptim (Ardia et al., 2011).

6.1.3. Probabilidad de observar atributos

La formulación mostrada en la ecuación (5.20) mejora lo propuesto en la tesis de Negrete (2019), ya que esta supera las falencias de no incorporar la real importancia que los usuarios le dan a los atributos ni la jerarquía en que son observados por ellos. La probabilidad de Negrete era dependiente fuertemente de los efecto de los atributos, positivo o negativo, sobre el valor esperado de las utilidades futuras. Esto se evidencia, ya que un atributo que influye negativamente en la utilidad tiene una menor probabilidad de ser atendido que uno con efecto positivo independiente de sus magnitudes.

Ahora, se considera el valor absoluto del cambio esperado de las utilidades futuras si se observa el atributo k en todas las alternativas. Al probar esta formulación en datos simulados en las secciones 6.1.4, 6.1.5 y 6.1.6, se obtiene un mejor ajuste que otros modelos convencionales y se puede dar interpretabilidad económica a los peso de atención de los atributos. En cambio, en las secciones en las cuales el proceso de generación es distinto al propuesto, se decide varía esta formulación, ya que el modelo tiene un peor ajuste al incluir en esta probabilidad un valor absoluto, dificultando la estimación adecuada de los parámetros. Por lo cual, la forma funcional de atender el siguiente atributo se modela como un modelo logit de constantes, tal como se muestra en la ecuación (6.2). Esta especificación más básica de la probabilidad de atender un atributo permite recuperar los buenos indicadores de ajuste e inclusive cuando se compara con el modelo DFT.

$$P(k|s(t)) = \frac{e^{ASC_k}}{\sum_{k'} e^{ASC_{k'}}}, \quad \text{con } ASC_{\bar{k}} = 0 \quad (6.2)$$

6.1.4. Análisis de estimación RUM-DFT-SP

Para analizar la aplicación de la especificación RUM-DFT-SP del modelo propuesto, se utilizan los datos maximización de la utilidad aleatoria con evaluación secuencial de atributos simulados, en que se conoce la secuencia de atributos atendidos por cada uno de los tomadores de decisión.

Al tener el registro de los atributos atendidos, no se necesitan calcular las probabilidades de decidir elegir o seguir con el proceso de búsqueda de información en cada paso t . Por lo cual, algunos de los parámetros que definen el proceso de deliberación, tales como la tolerancia (δ) y escalas de los nidos de la raíz, presente y futuros (μ , μ_e y μ_f) no son estimados.

La tabla 6.3 muestra el promedio de la estimación de 20 simulaciones, con el fin de verificar si se recuperan los parámetros y notar qué tanto cambian estos resultados si en cada iteración se varían los atributos simulados. A partir de los test estadísticos mostrados en la última columna, se tiene que en la mayoría de los casos, los parámetros se encuentran próximo al valor real. El parámetro α es aquel que se estima de manera más eficiente, ya que tiene la menor desviación estándar y permite representa la memoria del proceso de deliberación significativamente.

Tabla 6.3: Promedio de las estimaciones del modelo RUM-DFT con secuencia de atributos observados.

20 Iteraciones	RUM-DFT-SP			
Parámetros	Valor	Estimador	D.E	$t(\beta)$
β_c	-0,5	-0,492	0,020	0,888
β_{tt}	-2,0	-1,986	0,128	0,771
U_A^0	-0,5	-0,486	0,271	0,655
U_B^0	-0,5	-0,512	0,316	0,757
U_C^0	0,0	fixed	fixed	fixed
U_D^0	-1,0	-1,031	0,318	1,237
α	0,6	0,598	0,056	0,757
LL	-4046,047			
$\bar{\rho}^2$	0,269			
AIC	8102,1			
BIC	8134,6			

Las estimaciones desagregadas se encuentran en la tabla B.1 del Anexo. A partir de los resultados, se puede observar que en más del 95 % de las veces se obtienen parámetros estadísticamente significativos. En más, en todos los casos, los β_t , β_c y α son estadísticamente significativos. En algunos casos, las utilidades preconcebidas o constantes específicas del modelo son poca significativas. Por lo cual, se puede aplicar el modelo RUM-DFT-SP a datos procesos independiente de los atributos generados que definen la situación de elección de ruta en cada iteración. Cabe destacar que este enfoque permite incorporar de manera explícita en la modelación los atributos atendidos en cada paso del proceso de deliberación. Es más, este entregará estimaciones de los coeficientes de los atributos más del proceso de deliberación de

manera correcta en magnitud, con signo esperados e importancia relativa, permitiendo representar adecuadamente el proceso de búsqueda de información de los tomadores de decisión.

La figura 6.3 corresponde a un boxplot que muestra el tiempo de generación de datos siguiendo este enfoque y estimación de las 20 simulaciones. Este tiempo excede a valores cuando se estima modelos convencionales, tales como MNL y MMNL, pero en ningún caso se excede al tiempo de ejecución del modelo DFT aplicado a esta misma base de datos. Además, este costo computacional se justifica, pues permite estimar el modelo que incluye los parámetros del proceso de deliberación.

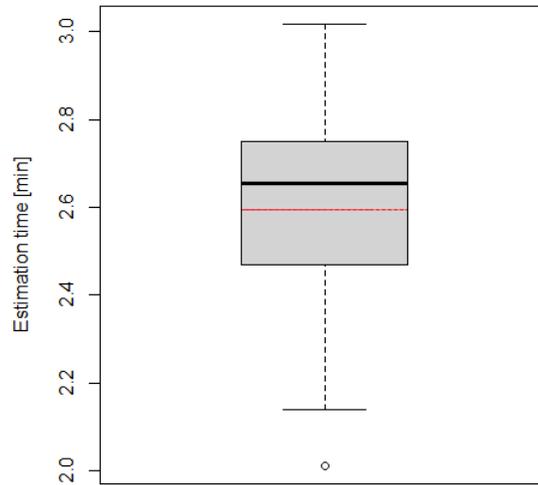


Figura 6.3: Tiempo de generación y estimación de modelo RUM-DFT con secuencia de atributos atendidos. Promedio de las observaciones en la línea roja

Para concluir este análisis, el modelo propuesto identifica de manera significativa los signos y magnitud de los parámetros que intervienen en la utilidad de las alternativas. Además, por primera vez, este enfoque entrega una noción económica a los parámetros que permiten modelar el proceso de deliberación, teniendo un valor potencial con respecto al modelo Decisión Field Theory. Es más, en este modelo se puede incorporar de manera completa la secuencia de datos fisiológicos capturados en una tarea de elección y no de manera agregada como en el modelo DFT-Scaled-DT con datos de procesos.

6.1.5. Análisis de estimación RUM-DFT-DT

La segunda aplicación por analizar corresponde a la especificación RUM-DFT-DT que incluye únicamente el tiempo de deliberación de los encuestados. Por lo cual, la base de datos necesaria para la estimación de este enfoque requiere los atributos de la situación de elección, la alternativa elegida y el registro de la cantidad de etapas, tiempo, clics, fijaciones, o entre otras variables que puedan representar de manera aproximada el tiempo de deliberación y no la secuencia completa de atributos atendidos. A partir de esos valores se puede identificar el tiempo máximo en la base de datos para el cálculo de las probabilidades de elección. Para los datos simulados, el tiempo de deliberación promedio fue de 5,3 fijaciones con un $T_{max}=10$ fijaciones.

En este análisis solo se utiliza una simulación, ya que el tiempo de estimación es alto y se desea comparar el modelo propuesto con el DFT-Scaled-DT en sus dos versiones (estimar parámetros de pesos de atención o de escala). Es razonable comparar estos enfoques a este nivel, ya que ambos utilizan la cantidad total de fijaciones para representar el tiempo de deliberación de manera agregada.

En la tabla 6.4 se muestra los resultados de la estimación del modelo RUM-DFT-DT. Cabe destacar que al igual que la especificación anterior, no es viable estimar los parámetros del proceso de deliberación, pero si se puede conocer el factor de memoria. En base a los resultados, los parámetros estimados tienen el signo y valor esperado. Es más, estos valores están en una proximidad al valor verdadero con el que fueron generados, siendo el factor de memoria (α) y el coeficiente asociado al tiempo de viaje (β_t) los más eficientes.

Tabla 6.4: Resultado de la estimación del modelo RUM-DFT con el tiempo de deliberación conocido.

1 Iteración	RUM-DFT-SP			
Parámetros	Valor	Estimador	S.E	$t(\beta)$
β_c	-0,5	-0,510	0,053	0,188
β_t	-2,0	-2,046	0,226	0,204
U_A^0	-0,5	-0,772	0,287	0,948
U_B^0	-0,5	-0,211	0,308	0,938
U_C^0	0,0	fixed	fixed	fixed
U_D^0	-1,0	-1,258	0,309	0,834
α	0,6	0,670	0,050	1,400
LL	-4153,369			
$\bar{\rho}^2$	0,250			
AIC	8318,7			
BIC	8356,5			

Al comprar estos resultados con respecto al modelo RUM-DFT-SC, que posee la secuencia real que siguieron los tomadores de elección, esta especificación tiene una peor verosimilitud. Esto se debe a que se está estimando una mayor cantidad de probabilidades de elección, condicional a los caminos posibles dependiente del tiempo de deliberación máximo encontrado en la base de datos simulados. Por lo cual, este tipo de modelo siempre tenderá mayor o igual verosimilitud que el enfoque que incorpora la secuencia de atributos atendidos.

En relación con el tiempo de generación y estimación de este enfoque, la figura 6.4 muestra un boxplot con el tiempo de ejecución de 10 simulaciones, en las que se varía las variables generadas. Se puede observar que el tiempo de computación es alto, inclusive mayor que el DFT (Hancock et al., 2018), y se debe a que se están incluyendo todas las posibles secuencias de atributos atendidos hasta el tiempo máximo de deliberación encontrado entre todas las observaciones. Estos valores pueden ser mejorados al incorporar el tiempo de elección para cada observación de manera particular, lo que permitiría reducir la cantidad de cálculos necesarios y mejorar la verosimilitud como efecto colateral. Se sigue justificando el costo computacional sobre el resto de los modelos convencionales, ya que se estiman parámetros del proceso de

deliberación con significado económico.

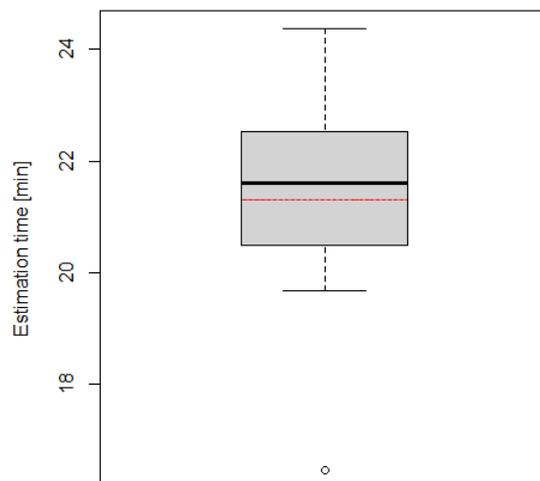


Figura 6.4: Tiempo de generación y estimación de modelo RUM-DFT con tiempo de deliberación. Promedio de las observaciones en la línea roja

Por otro lado, en la tabla 6.5 se muestra la estimación de dos especificaciones del modelo Decision Field Theory que incluye parámetros de escala y la cantidad agregada de las fijaciones sobre los atributos (DFT-scaled-DT), utilizando la base de datos simuladas. Por un lado, el DFT-scaled-DT1 estima los parámetros de pesos de atención en lugar de los de escala, con el fin de dar cuenta de la importancia relativa de los dos atributos que intervienen en la situación de elección. Por el contrario, el DFT-scaled-DT2 estima sólo el parámetro de escala correspondiente fijando los pesos de atención en 1.

Bajo estos enfoques no se puede comentar excesivamente sobre las estimaciones de los parámetros de escala o pesos de atención que afectan las preferencias o a las probabilidades de elección, puesto que estos valores no tienen un sentido microeconómico y no son iguales a al proceso de generación de datos. Sin embargo, se puede apreciar que el peso de atención del costo tiene un mayor impacto negativo que el tiempo de viaje sobre las preferencias.

De la misma manera, en ambas estimaciones, se puede observar que el parámetro de sensibilidad y memoria son no significativos. Por un lado, el primer factor es razonable que no sea capturado totalmente por el DFT-scaled, debido a que en la generación de datos no se simulaban alternativas similares entre sí o correlacionadas. Y, en segundo lugar, es indudable que el parámetro asociado a la memoria sea no significativo, pues no se conoce exactamente la secuencia de atributos atendidos en este enfoque. Por lo cual, el modelo DFT-scaled con los coeficientes del proceso de deliberación iguales a cero estadísticamente, inducen a que la matriz de retroalimentación sea igual a la Identidad, no permita mostrar la competencia de alternativas en similitud, ni el efecto del decaimiento de la memoria y nula representatividad adecuadamente el proceso de deliberación.

Además, se puede observar un leve mejor ajuste del primer modelo sobre aquel que estima la escala. Este resultado es similar al encontrado en Hancock et al., (2022) y contrario al mostrado en Hancock et al. (2021), que descubrieron que los modelos DFT con parámetros

Tabla 6.5: Resultados de estimación de modelo DFT escalado que incluye el tiempo de deliberación agregado.

1 Iteración	DFT-Scaled-DT1			DFT-Scaled-DT2		
Parámetros	Estimador	D.E.	$t(0)$	Estimador	D.E.	$t(0)$
γ_c	-1,069	0,108	-9,927	0,000	fixed	fixed
γ_t	0,000	fixed	fixed	0,000	fixed	fixed
β_c	1,000	fixed	fixed	0,411	0,147	2,796
β_t	1,000	fixed	fixed	1,000	fixed	fixed
P_A^0	1,429	0,823	1,737	0,930	0,542	1,717
P_B^0	0,000	fixed	fixed	0,000	fixed	fixed
P_C^0	2,337	1,021	2,288	1,418	0,785	1,807
P_D^0	-1,514	0,912	-1,660	-0,885	0,850	-1,041
ϕ_1	0,781	1,087	0,719	0,105	0,159	0,662
ϕ_2	-0,016	0,043	-0,364	-0,106	0,235	-0,450
σ_ε	6,311	1,262	5,000	4,560	1,591	2,867
τ	1,875	0,462	4,063	0,876	1,403	0,625
α_f	0,418	0,041	10,088	0,496	0,150	3,314
LL	-4205,220			-4206,560		
$\bar{\rho}^2$	0,240			0,240		
AIC	8428,440			8431,120		
BIC	8485,086			8487,766		

de escala estimados superaban sistemáticamente a los modelos DFT con pesos de atención estimados. En este caso particular, no hay una ganancia significativa de verosimilitud. Por lo cual, es preferible considerar el modelo DFT-Scaled-DT2 ya que se evitan los problemas mencionados en la sección 2.1.3.1.

Para cerrar este análisis, se puede mencionar que los indicadores de bondad de ajuste de ambos modelos DFT-scaled tienen un peor rendimiento que el modelo propuesto, al observar el $\bar{\rho}^2$, AIC y BIC. Esto es lógico, debido a que la generación de datos fue siguiendo el enfoque del modelo propuesto. Independiente de lo anterior, el factor de memoria (α) solo es posible recuperarlo significativamente utilizando el modelo RUM-DFT-DT. Así mismo, este es capaz de dar cuenta de la adquisición y procesamiento de la información buscada previa a la elección de manera razonable, no puramente a partir de los pesos de atención (γ_k) y del vector de error aleatorio (σ_ε) en el modelo DFT-scaled-DT2. La superioridad tanto en bondad de ajuste y especificación microeconómica del proceso de deliberación son buenos indicios y deben ser probados en una base de datos real para ser resultados concluyentes.

6.1.6. Análisis de estimación RUM-DFT-SC

La tercera aplicación por analizar corresponde a la especificación RUM-DFT-SC que utiliza datos de encuestas tradicionales, es decir, solo considera en la estimación los atributos que definen la situación de elección y la alternativa elegida por cada tomador de decisión. Por

lo cual, el investigador no conoce datos de procesos para acotar la generación de las posibles secuencias de atributos atendidos por los tomadores de decisión.

La especificación del proceso de deliberación incluye tres escalas (μ , μ_s y μ_e), una tolerancia (δ) y un factor de memoria (α). Por lo cual, se debe fijar un factor de escala y estimar los otros dos, induciendo a que el modelo sea no convexo si se considera una estimación simultánea en la obtención de estos valores (M. E. Ben-Akiva y Lerman, 1985). Además, incluir el factor de memoria en la dinámica de la utilidades proporciona no convexidad en la función de verosimilitud, tal como se mencionó en la sección 6.1.2.

Para contrarrestar estas problemáticas y estimar un modelo convexo, se puede codificar una estimación secuencial y fijar previamente el valor del factor de memoria. Dado que el código utilizado no considera lo anterior, se deben probar diferentes puntos iniciales de los parámetros, teniendo conocido y no conocido el valor de α , con el fin de analizar cómo varían los resultados finales de los parámetros.

Primero, en la tabla 6.6 se muestra los resultados de la estimación utilizando diferentes puntos iniciales (Anexo B.4) con el factor de memoria ($\alpha = 0,6$) y tiempo de deliberación máximo ($T_{max} = 10$) conocidos. A partir de estos resultados, se puede comentar que los coeficientes estimados para el costo y el tiempo de viaje se acercan a los valores reales con el que fueron simulados, excepto para PP4. Por otro lado, los parámetros de las preferencias iniciales preconcebidas varían dependiendo de los puntos iniciales considerados. Es más, al estimar el modelo con dos factores de escala, se genera un mayor ruido e impacto en las utilidades preconcebidas inicialmente. Por lo cual, para reducir complejidad en la estimación, se decide considerar $\mu = \mu_e = \mu_s$ en las próximas estimaciones con puntos iniciales PP1.

Tabla 6.6: RUM-DFT-SC con factores de escala para diferentes PI.

$T_{max} = 10$ $\alpha = 0.6$	Puntos iniciales								
	Valor	PP1	PP1 SE	PP2	PP2 SE	PP3	PP3 SE	PP4	PP4 SE
β_c	-0,5	-0,466	0,016	-0,451	0,048	-0,455	0,048	-9,351	0,63
β_t	-2,0	-1,916	0,072	-1,855	0,209	-1,868	0,208	-9,998	2,363
U_A^0	-0,5	-3,899	3,755	-1,22	1,727	-2,176	2,942	-2,813	3,742
U_B^0	-0,5	1,016	2,027	0,191	0,65	0,591	1,385	2,425	3,895
U_D^0	-1,0	-7,744	7,241	-2,154	2,817	-4,27	5,817	-8,928	3,54
δ	0,1	0,035	0,05	0,022	0,064	0,027	0,195	0,929	-
μ	1	-	-	0,826	2,985	0,273	2,08	4,164	2,518
μ_e	1	-	-	1,093	0,169	1,048	0,145	0,036	0,002
LL	-4221,340		-4221,693		-4221,417		-4487,49		
Tiempo [min]	35,89		34,42		62,28		26,21		

El problema de recuperar las utilidades iniciales se debe principalmente a la forma funcional de la probabilidad de observar el atributo k-ésimo en el siguiente paso. En esta, se incluye la utilidad futura a través de la multiplicación de la utilidad presente con el factor de memoria, violando la nominalidad de las utilidades. Por lo cual, para que el modelo propuesto capture solo las diferencias de las alternativas y no la ubicación de las constantes específicas iniciales, se pueden proponer dos soluciones. Primero, traer a valor presente las utilidades futuras multiplicándolas por α^{-1} . En segundo lugar, se puede considerar otra especificación para la

probabilidad de observar el atributo en el paso siguiente.

Para el modelo propuesto, no se considera la primera solución, ya que no es clara aún la interpretación de las utilidades finales y como varían en proceso de deliberación. En cambio, se considera reducir la formulación de la probabilidad de observar el atributo k-ésimo solo como un modelo logit simple de constantes. Esta formulación será probada en el caso real de SwissMetro en la siguiente sección.

En segundo lugar, para tratar la no convexidad, se probará la estimación del modelo con diferentes valores fijos y conocidos del factor de memoria, con el fin de analizar que tanto varían estos resultados. Además, se considera los puntos iniciales PP1 y un tiempo de deliberación máximo de 10 pasos.

La tabla 6.7 muestra los coeficientes estimados e indicadores de ajuste cuando se varia α entre 0,1 y 0,9. A partir de estas estimaciones, se puede observar que en la mayoría de los casos se obtienen valores subjetivos del tiempo de viaje cercanos al valor real con el que fueron simulados los datos. De estas estimaciones, cuando se considera $\alpha = \{0,1; 0,9\}$, el modelo propuesto entrega valores más distantes que los reales. Por otro lado, se puede decir que para un rango de valores del factor de memoria cercano al real se logra buenos indicadores de ajuste. Es más, cuando se considera un $\alpha = 0,6$ se obtiene la menor log-verosimilitud, mostrando que el modelo se ajusta correctamente en ese valor. Por lo cual, se puede estimar y recuperar los parámetros relevantes que intervienen en la situación de elección fijando la memoria, con el fin de reducir la complejidad de la estimación.

Tabla 6.7: RUM-DFT-SC con α fijo y conocido

$T_{max} = 10$ PP1	Factor de memoria										
	Valor	$\alpha = 0,1$	$SE_{0,1}$	$\alpha = 0,5$	$SE_{0,5}$	$\alpha = 0,6$	$SE_{0,6}$	$\alpha = 0,7$	$SE_{0,7}$	$\alpha = 0,9$	$SE_{0,9}$
β_c	-0,5	-0,475	0,016	-0,467	0,014	-0,466	0,016	-0,479	0,026	-0,637	0,022
β_t	-2,0	-1,871	0,069	-1,914	0,065	-1,916	0,072	-1,982	0,11	-2,671	0,095
U_A^0	-0,5	-7,344	4,415	-10,859	13,126	-3,899	3,755	-1,393	1,05	-0,313	0,139
U_B^0	-0,5	3,899	3,812	2,13	3,863	1,016	2,027	0,369	0,766	0,168	0,164
U_D^0	-1,0	-25,455	9,827	-25,509	28,598	-7,744	7,241	-2,21	1,538	-0,298	0,173
δ	0,1	1,664	0,658	0,034	0,041	0,035	0,05	0,047	0,063	0,001	0,013
LL		-4242,203		-4221,851		-4221,340		-4221,360		-4229,222	
Tiempo [min]		30,79		55,43		35,89		18,73		11,39	

En tercer lugar, el tiempo máximo de deliberación es otra dimensión que se debe fijar necesariamente previa a la estimación. Para analizar qué tanto varían estos resultados y cuánto afectan en la log-verosimilitud, se estimó el modelo propuesto con diferentes tiempos máximos de deliberación ($T_{max} = \{6, 7, 8, 9, 10\}$) a partir de las mismas elecciones simuladas, con puntos iniciales PP1 y un factor de memoria fijo igual a 0,6.

La tabla 6.8 muestra la estimación del modelo en los diferentes casos de estudio. De estas estimaciones, se puede apreciar que la log-verosimilitud no varían en gran medida al imponer un tiempo de elección menor que el encontrado en la base de datos simulados ($\bar{T}_{max} = 5,3$ pasos). Con respecto a los coeficientes del costo y tiempo de viaje estimados, estos se encuentran cercanos al valor verdadero con los que fueron simulados. Se reitera la problemática con las utilidades preconcebidas, de las cuales no se pueden recuperar estos parámetros, teniendo

signo o magnitudes distintas a los valores generados. Por último, el gran impacto de variar el T_{max} se nota en el costo computacional de las estimaciones, ya que se aumenta excesivamente las dimensiones de las matrices que contienen la diferentes posibles secuencias hasta el ese tiempo.

Tabla 6.8: Estimación RUM-DFT-SC considerando diferentes T_{max}

$\alpha = 0,6$		Tiempo máximo de deliberación									
PP1	Valor	$T_{max} = 6$	SE_6	$T_{max} = 7$	SE_7	$T_{max} = 8$	SE_8	$T_{max} = 9$	SE_9	$T_{max} = 10$	SE_{10}
β_c	-0,5	-0,494	0,026	-0,482	0,024	-0,476	0,022	-0,472	0,021	-0,466	0,016
β_t	-2,0	-2,035	0,109	-1,985	0,104	-1,959	0,097	-1,941	0,092	-1,916	0,072
U_A^0	-0,5	-7,344	0,589	-1,358	0,977	-1,779	1,481	-2,34	2,318	-3,899	3,755
U_B^0	-0,5	0,355	0,598	0,458	0,829	0,444	0,976	0,452	1,141	1,016	2,027
U_D^0	-1,0	-1,622	0,811	-2,354	1,437	-3,223	2,449	-4,18	3,89	-7,744	7,241
δ	0,1	0,165	0,233	0,116	0,166	0,093	0,128	0,074	0,105	0,035	0,05
LL		-4222,414		-4222,052		-4221,788		-4221,583		-4221,34	
Tiempo [min]		1,6		3,89		5,3		7,3		35,9	

Finalmente, se realiza una comparación estadística de la estimación de los datos simulados considerando una base de datos tradicional bajo diferentes modelos, tales como RUM-DFT, DFT y MNL. Esto tiene el objetivo de verificar que el modelo propuesto que incluye el proceso de deliberación y la secuencia de evaluación de atributos, logra una mejora sustancial en el ajuste dentro de la modelación discreta de elecciones.

Tabla 6.9: Estimación de modelos en datos de encuestas tradicionales.

Parámetros (* $p < 0,05$)	RUM-DFT-SC $T_{max} = 8$ pasos	DFT-scaled-1	DFT-scaled-2	MNL
γ_c	-	-	1,000	-
γ_t	-	-	0,838*	-
β_c	-0,476*	0,000	-	-0,295*
β_t	-1,959*	0,844*	-	-0,732*
U_A^0/P_A^0	-1,779	-0,746	-0,469	0,000
U_B^0/P_B^0	0,444	-2,904	-0,596	-0,132*
U_D^0/P_D^0	-3,223	-1,283	0,000	-0,047
δ	0,093	-	-	-
ϕ_1	-	2,557	25,545*	-
ϕ_2	-	-0,016	-0,114*	-
σ_ε	-	7,887*	6,881*	-
τ	-	2,969*	2,780*	-
LL	-4221,788	-4386,42	-4385,14	-4379,93
N°	6	8	8	5
$\bar{\rho}^2$	0,238	0,208	0,209	0,210
AIC	8455,58	8788,84	8786,27	8769,87
BIC	8493,34	8839,2	8836,62	8801,34
Tiempo [min]	5,3	4,2	3,51	0,2

En la tabla 6.9 se muestra la estimación de los modelos RUM-DFT-SC, DFT-scaled-1, DFT-scaled-2 y MNL, la log-verosimilitud, la cantidad de parámetros, indicadores de bondad de ajuste y el tiempo computacional gastado. Dentro de estos resultados, se observa que el modelo propuesto presenta la mejor log-verosimilitud y menores valores en los criterios de información AIC - BIC que el resto de los enfoques. Con respecto a los parámetros del costo y tiempo de viaje (pesos de atención en DFT), estos son significativamente distintos de cero en todos los modelos. Sin embargo, solo el modelo RUM-DFT-SC entrega valores cercanos, en magnitud y signo, a los verdaderos.

Por otro lado, en la mayoría de los casos no se logra estimar correctamente las constantes específicas o utilidades preconcebidas de las alternativas. La única que es estadísticamente distinta a cero, no se encuentran en una vecindad al valor verdadero. Falta y se deja propuesto probar el modelo propuesto con la mejora metodológica mencionada en la sección anterior, con el fin de evidenciar que si se puede recuperar las utilidades iniciales.

Para dar un cierre al análisis a este nivel, el único modelo que recupera los coeficientes del tiempo y costo adecuadamente es el propuesto. Además, este entrega valores adecuados de los parámetros que definen el proceso de deliberación y búsqueda de información previa a la elección. Por último, el tiempo de estimación no difiere bastante que del resto, logrando que el modelo RUM-DFT-SC sea competitivo tanto en estimación e interpretación con base de datos tradicionales simuladas, siguiendo este proceso de generación de datos.

6.2. Análisis del modelo con GDP RUM

En esta subsección, se dan indicios sobre el ajuste del modelo RUM-DFT y recuperación de los parámetros cuando se estima en elecciones ficticias de ruta de transporte público generadas a partir del supuesto que los individuos maximizan su utilidad aleatoria. Para un análisis más adecuado, las utilidades simuladas se obtienen considerando los mismos valores de los atributos de las situaciones anteriores, pero variando solo la regla de decisión.

Para la estimación del modelo propuesto se consideró que las escalas de los nidos de las utilidades presente y futuras eran iguales entre sí, que el tiempo máximo de deliberación fue de 10 pasos y puntos iniciales PP1. Luego, el proceso se desarrolló en dos etapas. En primer lugar, se utilizó el optimizador global DEoptim para obtener el valor del factor de memoria, con el fin de evitar que el modelo convergiera a un óptimo local. Sin embargo, este paquete no entrega las desviaciones estándar de los estimadores. Por lo cual, se realizó una segunda estimación con el valor del factor de memoria conocido y fijo. Así, en esta segunda fase, se puede eliminar la no convexidad, reducir la complejidad de estimación y encontrar las desviaciones estándar de los estimadores. Por otro lado, se empleó Apollo de Hess y Palma (2019) para obtener los resultados de un modelo Logit Multinomial (RUM) y DFT en el que se estima los pesos de atención (Hancock et al., 2018) en la misma base de datos.

De la tabla 6.10, se puede apreciar que el modelo MNL, que sigue la regla de decisión con que fueron simuladas las elecciones, presenta el mejor ajuste al observar los indicadores de ajuste ($\bar{\rho}^2$, AIC y BIC) y además, recupera significativamente los valores de los parámetros, lo que es esperable. Luego, con un mayor tiempo de estimación, el modelo que le sigue en ajuste corresponde al DFT. Este enfoque entrega solo el peso de atención de tiempo de viaje y el

paso de actualización de las preferencias de manera significativa al 95 %. Cabe destacar que al no tener información de la deliberación de los encuestados, el modelo no puede capturar de manera efectiva los parámetros que definen proceso cognitivo, tal como cometa Hancock et al.(2021).

Tabla 6.10: Resultados de modelos en GDP RUM.

Parámetros (* p<0,05)	RUM-DFT 10 Steps	RUM	DFT
β_c	-1,110	-0,495*	0,000 ³
β_t	-5,345*	1,890*	1,263*
ASC_A	-2,158*	-0,579*	-18,510
ASC_B	-0,461	-0,068	-0,977
ASC_D	1,147*	0,379*	13,690
δ	0,000		
$\beta_{\text{peso tiempo}}$	-2,037*		
α	-0,853 ¹		
ϕ_1			12,221
ϕ_2			-0,002
σ_ε			6,172
τ			4,153*
LL	-3060,886	-3037,350	-3053,110
$\bar{\rho}^2$	0,447	0,451	0,448
AIC	6135,77	6084,69	6122,21
BIC	6179,83	6116,16	6172,57
Tiempo [min]	45,3 ¹ + 15,2 ²	0,1	3,3

¹ Estimación con DEoptim. ²Estimación con OptimParallel fijando α y escalas. ³

³ Peso de atención del costo fijo para la estimación.

Por otro lado, el modelo RUM-DFT-SC propuesto, posee una leve diferencia en los criterios de información y solo de 7 puntos en la log-verosimilitud con respecto al modelo DFT. Sin embargo, posee una mayor cantidad de estimadores que son estadísticamente significativos, tienen signos esperables y permiten representar el proceso de búsqueda de información adecuadamente. Cabe destacar que, surge una interrogante relevante asociada a la compensación entre tener una alta interpretabilidad económica que se puede obtener a partir del modelo RUM-DFT en comparación con la leve ganancia en rendimiento del modelo DFT, cuando se quiere incluir de manera explícita el proceso de deliberación y posterior estimación en los Modelos de Elección Discreta.

Tal como se ha comentado en los casos simulados anteriores, los esfuerzos futuros deben estar centrados en reducir el tiempo de estimación o reducir la complejidad del modelo RUM-DFT cuando no se conoce la secuencia de atributos atendidos o el tiempo de deliberación previa a las elecciones, con el fin de que sea fácil de implementar y que no demore tanto en ejecutarse. Ya que en el resto de los casos el modelo es altamente eficaz en ajuste y no excede tanto en el costo computacional.

6.3. Análisis del modelo con GDP DFT

A continuación, se detallan los resultados de la estimación de los modelos RUM-DFT-SC, RUM y DFT, utilizando elecciones ficticias generadas a partir del supuesto que los encuestados siguen el enfoque Decision Field Theory. Para un análisis más adecuado, las preferencias y elecciones se producen considerando los mismos valores de los atributos de la situación de elección utilizadas en las subsecciones anteriores, pero solo se varía la regla de decisión.

Tabla 6.11: Estimación de modelos aplicados a datos simulados a partir del enfoque DFT.

Parámetros (* p<0,05)	RUM-DFT 10 pasos	RUM	DFT
β_c	-0,072*	-0,272*	-0,718
β_t	0,000	-0,573*	0,000 ¹
ASC_A	-0,286	-0,047	-2,883
ASC_B	-0,906*	-0,082	-4,440
ASC_D	-0,079	0,031	5,259
δ	0,0001		
$\beta_{peso\ time}$	-1,713*		
α	0,670*		
ϕ_1			6,706*
ϕ_2			0,044*
σ_ε			1,017*
τ			3,182*
LL	-4497,16	-4501,61	-4490,65
$\bar{\rho}^2$	0,188	0,187	0,189
AIC	9008,314	9013,220	8997,300
BIC	9052,372	9044,690	9047,652
Tiempo [min]	86,06	0,01	3,2

¹ Peso de atención del tiempo fijado en 0,000 para la estimación.

De la tabla 6.11, se puede observar que el modelo DFT que estima el peso de atención del tiempo (Hancock et al., 2018) tiene el mejor ajuste al observar la log-verosimilitud e indicadores de Criterio de Información Bayesiano y Akaike. El DFT estimado logra recuperar los parámetros del proceso de deliberación con los que fueron generadas las preferencias, pero no así el peso de atención del costo es no significativo. En cambio, el modelo RUM-DFT-SC, tiene una leve diferencia de ajuste con respecto al enfoque anterior. Sin embargo, este es último, es capaz de estimar significativamente distinto de cero el parámetro de peso de atención del tiempo (ϕ_{time}), memoria (α), coeficiente del costo (β_t) y la utilidad inicial del auto (ASC_B).

El modelo RUM, que tiene el peor ajuste, entrega solamente resultados significativos y con valores esperables para los coeficientes del tiempo y costo de viaje. Independiente de lo anterior,

como esta construido este enfoque, no permite realizar deducciones sobre el proceso cognitivo.

Se destaca el hecho de que el modelo propuesto, si tener información del proceso de búsqueda de información, puede estimar los parámetros asociados a la deliberación de los tomadores de elección. La dificultad del modelo RUM-DFT esta en su complejidad de estimación induciendo un alto tiempo computacional, en comparación con el resto de los modelos implementados en Apollo.

6.4. Datos reales: Swiss Metro

Finalmente, en esta sección se realiza una comparación del modelo propuesto con otros enfoques convencionales en una base de datos reales. Los datos utilizados corresponde a una encuesta de preferencias reveladas y declaradas enmarcado en el proyecto de SwissMetro. El objetivo era conectar los principales centros urbanos de Suiza con un sistema de metro-tren moderno, sostenible y ultrarrápido. Como análisis de prefactibilidad, se realizaron encuestas PR/PD detalladas, con el fin de analizar del impacto de la demanda y tiempos de viajes. (Bierlaire et al., 2001).

De manera general, se encuestaron a 1105 personas y a cada uno de ellos se le hicieron preguntas socioeconómicas y se les presentaron nueve situaciones de elección. Cada una de las tareas estaba definida por tres alternativas (Tren, SwissMetro y Auto) y por dos atributos relevantes para la elección (tiempo de viaje y costo). Para este caso, se consideraron solo las respuestas de los agentes que tenían como propósito "Estudio" o "Trabajo" y que tuviesen disponible el automóvil. Luego, de filtrar la base de datos, se logra tener un total de 5607 observaciones.

Para testear el modelo RUM-DFT-SC propuesto, se considera puntos iniciales PI1 con escalas de los nidos iguales entre sí y se se da la libertad para estimar la tolerancia (δ) y el factor de memoria (α), que definen en gran medida el proceso de búsqueda de información. El proceso de estimación fue realizado en dos etapas. En primer lugar, se obtuvo todos los parámetros mediante el optimizador DEoptim, que permite encontrar el óptimo global y no quedar atascado en valores intermedios. Sin embargo, este paquete no entrega la matriz de varianza, imposibilitando el calculo de las desviaciones estándar. Por lo cual, se realiza una segunda estimación, pero considerando que el valor del factor de memoria es conocido y fijo permitiendo reducir la complejidad del proceso y así, obtener las desviaciones estándar para realizar en análisis estadístico correspondiente. Además, se iteró dos veces este procedimiento, estableciendo el tiempo máximo de deliberación en siete y diez pasos, con el fin de analizar el trade-off entre costo computacional, coeficientes estimados y ajuste.

La tabla 6.12 presenta los resultados de estimación del modelo RUM-DFT que no considera información del proceso de búsqueda de información con tiempo de deliberación iguala 7 y 10 pasos, junto a otros enfoques convencionales, tales como RUM, DFT, C RRM, μ RRM, P RRM y RAM. El enfoque RUM corresponde a un logit multinomial. El modelo DFT que se muestra corresponde al que estima los pesos de atención (Hancock et al., 2018). Sin embargo, se fija el valor de memoria en 0, la sensibilidad en 0 y el término error en 1, ya que por lo general estos valores son poco significativos cuando no se tiene información de la deliberación de los encuestados. Por último, el resto de los modelos mostrados fueron estimados en

Tabla 6.12: Estimaciones de modelos aplicados a datos reales de SwissMetro.

Parámetros (* $p < 0,05$)	RUM-DFT 7 pasos	RUM-DFT 10 pasos	RUM	DFT	C RRM ¹	μ RRM ¹	P RRM ¹
β_c	-3,745*	-3,657*	-1,150*	-0,867*	0,010*	0,010*	0,010*
β_t	-4,665*	-4,649*	-1,270*	-1,251*	0,010*	0,010*	0,010*
ASC_{Train}	-0,902*	-0,904*	-1,168	-1,120*			
ASC_{Car}	-0,010	-0,013	-0,250	-0,076*			
δ	0,273*	0,259*					
$\beta_{attendtime}$	0,467*	0,482*					
α	0,959 ²	0,931 ²					
ϕ_1				0,000			
ϕ_2				0,000			
σ_ε				1,000			
τ				0,564*			
LL	-4233,941	-4233,918	-4382,500	-4277,170	-4539,672	-4373,356	-4418,252
\bar{p}^2	0,312	0,312	0,305	0,305	0,263	0,290	0,283
AIC	8479,882	8479,820	8772,712	8564,340	9087,265	8756,452	8844,482
BIC	8519,673	8519,611	8799,626	8597,499	9113,618	8790,094	8870,835
Tiempo [min]	59,7 ² + 8,3 ³	301,9 ² + 3,4 ³	0,03	7,03	-	-	-

¹ Estimaciones de Belgiawan et al. (2017). ²Estimación realizada con DEoptim. ³Estimación realizada con OptimParallel fijando α .

el trabajo realizado por Belgiawan et al., (2017).

A partir de esos resultados, se puede comentar que los modelos que incluyen parámetros que permiten modelar el proceso de deliberación, tanto el modelo RUM-DFT y el enfoque DFT, tienen un mejor rendimiento que el resto, en términos de log-verosimilitud y al observar los criterios de información AIC y BIC. Sin embargo, solo a partir del modelo propuesto se puede realizar interpretación económica de los coeficientes de los atributos, tolerancia, memoria y peso de atención que permiten definir el proceso de búsqueda de información planteado.

En mayor detalle, el modelo RUM-DFT tiene los mejores resultados de ajuste en ambos casos, se obtiene que los coeficientes de los atributos del tiempo y costo de viaje son significativos con signos concordante a lo esperado. Asimismo, se puede observar que el peso de atención del tiempo (ϕ_{time}) introducido en la probabilidad de observar en el paso siguiente, es significativo y tiene un valor positivo. Lo anterior representa que es más probable que los tomadores de decisión observen el atributo relacionado al tiempo que el costo de viaje en su proceso de búsqueda de información, con el fin de actualizar sus utilidades previa a la elección. Además, la tolerancia (δ) estimada es significativa y tiene un valor dentro de los esperado, que junto al factor de memoria (α) obtenido con el optimizador global permiten representar adecuadamente el proceso de deliberación. Finalmente, el tiempo de deliberación máximo considerado en ambos casos no modifican en gran medida los valores de los coeficientes ni de la log-verosimilitud. Sin embargo, difieren en el tiempo de estimación considerablemente para encontrar el valor del factor de memoria, pues se considera K^t secuencias de atributos atendidos extras por cada t para estimar los coeficientes. Por lo cual, la limitante de este modelo es el alto costo computacional que se tiene en su estimación y que depende fuertemente del tiempo máximo de deliberación que se fije previamente.

Con respecto a sus contra partes, se destaca el modelo DFT que logra estimar los pesos de atención (β_t y β_c) y paso de actualización de preferencias (τ) significativamente, pero con un peor ajuste de los datos. Este enfoque es competitivo con respecto al RUM-DFT, ya que el proceso de estimación demora menos tiempo y permite modelar el proceso de deliberación. Sin embargo, aún no esta clara la interpretación de estos valores si se quisiera realizar un análisis económico. Luego, le sigue en ajuste el modelo μ RRM, estos buenos indicadores de ajuste se puede deber a que implícitamente se considera que los tomadores de decisión realizan búsquedas en Anchura y se anticipan a valores para reducir su arrepentimiento. Esto último es similar a la idea de que los individuos, en cada paso, atienden un atributo, comparan alternativas bajo ese atributo y se anteponen al valor futuro. Por último, con respecto al modelo Logit Multinomial, se puede comentar que se obtienen valores esperables y significativos de los betas, pero tiene un peor ajuste que los otros dos modelos previamente discutidos. Además, este enfoque no permite cumplir con los objetivos de esta tesis, ya que no se tienen coeficientes directos que muestren de alguna manera el proceso de búsqueda de información y deliberación de los encuestados.

Tabla 6.13: Estimación de Logit Mixto con datos de SwissMetro

Parámetros (* p<0,05)	MMNL
β_c	-2,28*
β_t	-2,80*
LL	-4211,062
$\bar{\rho}^2$	0,238
AIC	8437,974
BIC	8451,992
Tiempo [min]	1,5

De manera adicional, se estimó un modelo Logit Mixto que permite capturar la heterogeneidad en las elecciones. De la tabla 6.13, se puede observar que este modelo tiene un mejor ajuste que el modelo RUM-DFT y obtiene coeficientes significativos con valores concordantes a los valores de los atributos en la literatura. Esto se debe a que el modelo Logit Mixto asume que los individuos tienen diferentes valoraciones de los atributos entre si, pero que son constantes dentro de sus situaciones de elección (9 en este caso) y es razonable encontrar heterogeneidad inter e intra en datos de panel obtenidos de encuestas de preferencias declaradas. Es por eso que cualquier modelo que logre capturar la heterogeneidad dentro de respuestas repetidas, tendrá un mejor ajuste que los mostrados en la tabla 6.12.

Es posible extender el enfoque propuesto a un modelo RUM-DFT Mixto que permita identificar parámetros individuales y heterogeneidad presente en estas base de datos, pero queda como trabajo futuro su implementación, comprobación y estimación. La ecuación 6.3 muestra la modelación de la verosimilitud extendida condicional a la distribución Ω .

$$L = \int_{\beta} \left[\prod_{n=1}^N \prod_{j=1}^J \left(\sum_{h_i^t} P(i|h_i^t) \cdot P(h_i^t) \right)^{y_{ni}} \cdot f(\beta|\Omega) \right] d\Omega \quad (6.3)$$

Capítulo 7

Conclusiones

En esta tesis se cumple con el objetivo general planteado inicialmente, ya que se diseñaron e implementaron instrumentos que permiten recolectar evidencia del proceso de búsqueda de información. Específicamente, los participantes tuvieron que responder encuestas de preferencias declaradas de elección de ruta de transporte público pivotada a las características de sus viajes en punta mañana. Estas herramientas, además de almacenar información relacionada a las características socioeconómicas, movilidad y elecciones de los tomadores de decisión, permiten capturar con gran certeza las secuencias de áreas de interés atendidas que los motivaron tomar sus decisiones a través de seguimiento de los clics y de la mirada.

Además, se pudo caracterizar el proceso de deliberación que está implícito en las elecciones a partir del análisis de dichas respuestas mediante de constructos psicológicos. Los hallazgos encontrados en esta caracterización son incluidos como mejoras metodológicas en el desarrollo del modelo de Maximización de la Utilidad Aleatoria que Incorpora el Proceso de Búsqueda de Información. Se generaron elecciones simuladas utilizando este enfoque propuesto, se estimaron diferentes especificaciones del modelo dependiendo de la información disponible sobre el proceso de deliberación y, finalmente se comprobó su validez en datos reales de SwissMetro.

A continuación se revisará el cumplimiento de los objetivos específicos de esta tesis. En primer lugar, se definieron constructos psicológicos para desentrañar los procesos de búsqueda de información que realizaron los encuestados de manera previa a sus elecciones. Dentro de los análisis realizados en esta sección, se destacan los siguientes cinco hallazgos:

- Lo primero a destacar es que los usuarios de transporte público realizan en su gran mayoría búsqueda de información en Anchura y que el tipo de patrón secundario depende del número de alternativas y atributos (AOI) mostrados en la situación de elección. Por un lado, a medida que aumentan las AOI, las personas buscan con más frecuencia información siguiendo un comportamiento en Anchura. Por otro lado, se encontró que, en general, realizan búsquedas en Anchura en una primera etapa del proceso de deliberación y luego en Profundidad en las últimas búsquedas para validar la alternativa elegida.
- A continuación, se encontró que los usuarios realizan más búsquedas de información que la cantidad de áreas de interés mostradas en cada uno de los instrumentos. Es más, la cantidad de fijaciones aumenta a tasas decrecientes mientras más AOI se presentan y este constructo se incrementa en mayor medida cuando se añaden más atributos que alternativas. Además, se pudo evidenciar que los usuarios masculinos y con tarifa reba-

jada tienen un proceso de deliberación más complejo, pues realizan más fijaciones que el resto de la población.

- Luego, se logró mostrar que la información filtrada aumenta a medida que los encuestados avanzan en las preguntas hipotéticas, independiente de la cantidad de alternativas y atributos. Asimismo, se pudo constatar que hay atributos que nunca son atendidos durante el proceso de deliberación. Por lo cual, los modelos compensatorios actuales están estimado de manera imperfecta, pues estos consideran que los agentes tienen un conocimiento completo de la información.
- Posteriormente, al realizar un análisis de las matrices de transiciones agregadas, se encontró que los participantes realizan una mayor cantidad de transiciones de las posibles cuando hay pocas áreas de interés, y a medida que se aumentan estas, prefieren aplicar ciertas estrategias para tomar una decisión. Además, se observó que la transición más probable corresponde a una búsqueda de información en Anchura en todos los experimentos y este comportamiento se agudiza con la complejidad de los instrumentos.
- Finalmente, la duración decrece sistemáticamente cuando los encuestados avanzan a través de las tareas de elección. Esto evidencia que adquieren un aprendizaje relacionado al instrumento o la ubicación de las áreas de interés relevantes para su decisión. Asimismo, se encuentra que el tiempo de las fijaciones disminuye a lo largo del proceso de deliberación mostrando que el procesamiento de la información cambia.

Si bien algunos de estos resultados se habían presentado previamente en la literatura sobre psicología y cognición, es primera vez que se muestra un análisis detallado de estos constructos aplicados a una situación de elección de ruta de transporte público. De manera general, los hallazgos permiten concluir que los patrones de búsqueda son parte de un proceso de deliberación heurístico, heterogéneo, complejo y mixto, que dependen de las dimensiones de las tareas de la elección y de las características de los encuestados. Sin embargo, existe un predominio de búsquedas en anchura, es decir, la evaluación de la información se realiza a través de comparaciones de alternativas bajo un atributo en particular. Por lo cual, se pueden extender las conclusiones de Noguchi et al., (2014), Venkatraman et al., (2014), Kawak et al., (2015) y Meißner et al., (2020) a situaciones complejas de elección de ruta de transporte público, en la cual intervienen múltiples atributos y alternativas. Queda como propuesto realizar este análisis utilizando el Eye-tracker implementado, con el fin de verificar que estos resultados son independiente del instrumento utilizado.

En segundo lugar, se incorporaron los hallazgos de la sección experimental como supuestos teóricos del modelo RUM-DFT. Además, se realizaron mejoras metodológicas relacionadas a la dinámica de las utilidades y a la probabilidad de atender un atributo en el siguiente paso, consideradas en la etapa cognitiva. Se probó la validez del modelo RUM-DFT mediante un Monte Carlo en 5 casos de estudios simulados. En los tres primeros, se generaron datos siguiendo el enfoque propuesto (RUM-DFT) y se estimó el modelo considerando diferentes niveles de datos del proceso de deliberación. Estos corresponden a: cuando se conoce la secuencia de atributos atendidos, cuando solo se conoce el tiempo máximo de deliberación y cuando no se tiene ninguna información del proceso de deliberación. En los últimos dos Monte Carlo, se simulaban las elecciones siguiendo un proceso de generación de datos de Maximización de Utilidad Aleatoria y Decisión Field Theory, respectivamente. En todos los casos, se

hicieron comparaciones adecuadas con otros modelos convencionales, tales como RUM y DFT.

Los resultados del modelo RUM-DFT son altamente prometedores para el primer caso, ya que esta especificación permite recuperar los parámetros y supera exitosamente a los modelos convencionales al comparar los criterios de información. Esto se debe principalmente a que en este enfoque se evita la integración en el espacio de todas las secuencias de atributos posibles lo que aumenta considerablemente su dimensión en cada paso extra (K^t). Por lo cual, el uso de los instrumentos construidos en esta tesis son funcionales para capturar la secuencia específica de los encuestados y así probar el nuevo modelo.

Con respecto al segundo y tercer caso, el modelo entrega parámetros de los atributos en una vecindad a los valores verdaderos, pero con mayor dificultad lo hace con respecto a las utilidades preconcebidas inicialmente. Específicamente para el caso sin información del proceso de deliberación, se logró reducir la complejidad y tiempos de estimación al igualar los factores de escala de los nidos de utilidades presentes - futuras y al fijar previamente el valor de memoria. Además, se comprobó que se recupera los buenos indicadores de bondad de ajuste y log-verosimilitud para valores de memoria cercanos al real.

Por otro lado, en el cuarto y quinto caso, el modelo RUM-DFT tiene indicadores de ajuste comparables con los enfoques que fueron generados las elecciones (RUM y DFT, respectivamente). Es más, la diferencia es leve que motiva cuestionarse el trade-off entre interpretabilidad económica de los parámetros del proceso de deliberación de este modelo con respecto a los coeficientes del DFT y del modelo básico MNL. Sin embargo, no es claro como podría colapsar este enfoque en los otros dos. Por lo cual, queda como trabajo propuesto simplificar o mejorar este modelo, con el fin de entender qué valores de los parámetros nos llevan a un enfoque RUM o DFT.

En cuarto lugar, se estimó el modelo RUM-DFT utilizando la base de datos SwissMetro y se compararon signos, magnitud y significancia de los parámetros, indicadores de bondad ajuste y tiempo de estimación con los enfoques MNL, DFT, C RRM, μ RRM, P RRM y MMNL. De manera general, los modelos que incorporan los supuestos sustentados en esta tesis en alguna medida, tales como que el proceso de búsqueda es en anchura, los encuestados atienden más de una vez los atributos y se centran en ciertos atributos, filtrando la información, obtienen los mejores indicadores de ajuste. Es más, la especificación del modelo RUM-DFT que no incluye información del proceso de deliberación, es capaz de estimar significativamente los coeficientes de los atributos, tolerancia y memoria con valores razonables, superando exitosamente al enfoque DFT y MNL.

Finalmente, se hicieron comentarios asociados a dos mejoras como trabajo futuro. Primero, buscar reducir el espacio factible de secuencias de atributos que pueden atender los usuarios, con el fin de reducir el tiempo computacional. Una propuesta es seguir el enfoque de Guevara et al., (2017), quienes muestran que se pueden recuperar los estimadores a través de la estimación máxima verosímil simulada con muestreo aleatorio (MSLRs). Así, en el proceso de estimación solo se considerarían subconjuntos aleatorios de secuencias de atención de atributos. En segundo lugar, extender el enfoque propuesto a un modelo RUM-DFT Mixto que permita la variación de gusto, logrando, al igual que el Logit Mixto en comparación con el Logit, ganar unidades de ajuste debido a que se está tratando la heterogeneidad.

Bibliografía

- Bault, N., Wydoodt, P., y Coricelli, G. (2016). Different attentional patterns for regret and disappointment: An eye-tracking study. *Journal of Behavioral Decision Making*, 29(2-3), 194–205.
- Belgiawan, P. F., Schmid, B., Dubernet, I., y Axhausen, K. W. (2017). Comparison between rum, rrm variants, and ram: Swiss sp and rp data sets. En *17th swiss transport research conference (strc 2017)*.
- Ben-Akiva, M., de Palma, A., McFadden, D., Abou-Zeid, M., Chiappori, P.-A., de Lapparent, M., . . . others (2012). Process and context in choice models. *Marketing Letters*, 23(2), 439–456.
- Ben-Akiva, M. E., y Lerman, S. R. (1985). *Discrete choice analysis: theory and application to travel demand* (Vol. 9). MIT press.
- Bettman, J. R., y Jacoby, J. (1976). Patterns of processing in consumer information acquisition. *ACR North American Advances*.
- Bierlaire, M., Axhausen, K., y Abay, G. (2001). The acceptance of modal innovation: The case of swissmetro. En *Swiss transport research conference*.
- Bröder, A., Glöckner, A., Betsch, T., Link, D., y Ettlín, F. (2013). Do people learn option or strategy routines in multi-attribute decisions? the answer depends on subtle factors. *Acta psychologica*, 143(2), 200–209.
- Busemeyer, J. R. (1985). Decision making under uncertainty: a comparison of simple scalability, fixed-sample, and sequential-sampling models. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 11(3), 538.
- Busemeyer, J. R., y Townsend, J. T. (1992). Fundamental derivations from decision field theory. *Mathematical Social Sciences*, 23(3), 255–282.
- Busemeyer, J. R., y Townsend, J. T. (1993). Decision field theory: a dynamic-cognitive approach to decision making in an uncertain environment. *Psychological review*, 100(3), 432.
- Chorus, C. (2012). Random regret minimization: an overview of model properties and empirical evidence. *Transport reviews*, 32(1), 75–92.
- Chorus, C., y Bierlaire, M. (2013). An empirical comparison of travel choice models that capture preferences for compromise alternatives. *Transportation*, 40(3), 549–562.
- Chorus, C., van Cranenburgh, S., y Dekker, T. (2014). Random regret minimization for consumer choice modeling: Assessment of empirical evidence. *Journal of Business Research*, 67(11), 2428–2436.

- Chorus, C. G. (2010). A new model of random regret minimization. *European Journal of Transport and Infrastructure Research*, 10(2).
- Chorus, C. G., Arentze, T. A., y Timmermans, H. J. (2008). A random regret-minimization model of travel choice. *Transportation Research Part B: Methodological*, 42(1), 1–18.
- De Leeuw, J. R. (2015). jspsych: A javascript library for creating behavioral experiments in a web browser. *Behavior research methods*, 47(1), 1–12.
- Diederich, A. (1997). Dynamic stochastic models for decision making under time constraints. *Journal of Mathematical Psychology*, 41(3), 260–274.
- Engel, J. F., Kollat, D. T., y Blackwell, R. D. (1968). Consumer behavior. new york: Holt, rinehart^ winston. *One of the earliest presentations of a cognitive model of consumer choice*.
- Glaholt, M. G., y Reingold, E. M. (2011). Eye movement monitoring as a process tracing methodology in decision making research. *Journal of Neuroscience, Psychology, and Economics*, 4(2), 125.
- Glöckner, A., y Herbold, A.-K. (2011). An eye-tracking study on information processing in risky decisions: Evidence for compensatory strategies based on automatic processes. *Journal of Behavioral Decision Making*, 24(1), 71–98.
- Guevara, C. A., y Fukushi, M. (2016). Modeling the decoy effect with context-rum models: Diagrammatic analysis and empirical evidence from route choice sp and mode choice rp case studies. *Transportation Research Part B: Methodological*, 93, 318–337.
- Guevara, C. A., Tang, Y., y Gao, S. (2017). The initial condition problem with complete history dependency in learning models for travel choices. *Transportation research procedia*, 23, 758–771.
- Hancock, T. O., Hess, S., y Choudhury, C. F. (2018). Decision field theory: Improvements to current methodology and comparisons with standard choice modelling techniques. *Transportation Research Part B: Methodological*, 107, 18–40.
- Hancock, T. O., Hess, S., Marley, A. A., y Choudhury, C. F. (2021). An accumulation of preference: two alternative dynamic models for understanding transport choices. *Transportation Research Part B: Methodological*, 149, 250–282.
- Hensher, D. A. (2004). Identifying the influence of stated choice design dimensionality on willingness to pay for travel time savings. *Journal of Transport Economics and Policy (JTEP)*, 38(3), 425–446.
- Hess, S., y Palma, D. (2019). Apollo: A flexible, powerful and customisable freeware package for choice model estimation and application. *Journal of choice modelling*, 32, 100170.
- Horstmann, N., Ahlgrimm, A., y Glöckner, A. (2009). How distinct are intuition and deliberation? an eye-tracking analysis of instruction-induced decision modes. *An Eye-Tracking Analysis of Instruction-Induced Decision Modes (April 1, 2009)*. MPI Collective Goods Preprint(2009/10).
- Hulland, J. S., y Kleinmuntz, D. N. (1994). Factors influencing the use of internal summary evaluations versus external information in choice. *Journal of Behavioral Decision Making*, 7(2), 79–102.
- Jacoby, J. (1975). Perspectives on a consumer information processing research program.

Communication Research, 2(3), 203–215.

- Jacoby, J., Szybillo, G. J., y Busato-Schach, J. (1977). Information acquisition behavior in brand choice situations. *Journal of Consumer research*, 3(4), 209–216.
- Jamieson, D. G., y Petrusic, W. M. (1977). Preference and the time to choose. *Organizational Behavior and Human Performance*, 19(1), 56–67.
- Jiang, T., Potters, J., y Funaki, Y. (2016). Eye-tracking social preferences. *Journal of Behavioral Decision Making*, 29(2-3), 157–168.
- Johnson, E. J., Payne, J. W., Bettman, J. R., y Schkade, D. A. (1989). *Monitoring information processing and decisions: The mouselab system* (Inf. Téc.). DUKE UNIV DURHAM NC CENTER FOR DECISION STUDIES.
- Johnson, E. J., Schulte-Mecklenbeck, M., y Willemsen, M. C. (2008). Process models deserve process data: Comment on brandstätter, gigerenzer, and hertwig (2006).
- Just, M. A., y Carpenter, P. A. (1980). A theory of reading: from eye fixations to comprehension. *Psychological review*, 87(4), 329.
- Kwak, Y., Payne, J. W., Cohen, A. L., y Huettel, S. A. (2015). The rational adolescent: Strategic information processing during decision making revealed by eye tracking. *Cognitive development*, 36, 20–30.
- McFadden, D. (1976). The revealed preferences of a government bureaucracy: Empirical evidence. *The Bell Journal of Economics*, 55–72.
- McFadden, D., Machina, M. J., y Baron, J. (1999). Rationality for economists? En *Elicitation of preferences* (pp. 73–110). Springer.
- Meißner, M., Oppewal, H., y Huber, J. (2020). Surprising adaptivity to set size changes in multi-attribute repeated choice tasks. *Journal of Business Research*, 111, 163–175.
- Mosteller, F., y Noguee, P. (1951). An experimental measurement of utility. *Journal of Political Economy*, 59(5), 371–404.
- Ngene, C. (2018). 1.2 user manual & reference guide. *ChoiceMetrics Pty Ltd.: Sydney, Australia*.
- Noguchi, T., y Stewart, N. (2014). In the attraction, compromise, and similarity effects, alternatives are repeatedly compared in pairs on single dimensions. *Cognition*, 132(1), 44–56.
- Papoutsaki, A., Gokaslan, A., Tompkin, J., He, Y., y Huang, J. (2018). The eye of the typer: a benchmark and analysis of gaze behavior during typing. En *Proceedings of the 2018 acm symposium on eye tracking research & applications* (p. 16).
- Papoutsaki, A., Sangkloy, P., Laskey, J., Daskalova, N., Huang, J., y Hays, J. (2016). Webgazer: Scalable webcam eye tracking using user interactions. En *Proceedings of the 25th international joint conference on artificial intelligence (ijcai)* (pp. 3839–3845).
- Payne, J. W. (1976). Task complexity and contingent processing in decision making: An information search and protocol analysis. *Organizational behavior and human performance*, 16(2), 366–387.
- Payne, J. W., Bettman, J. R., y Johnson, E. J. (1992). Behavioral decision research: A constructive processing perspective. *Annual review of psychology*, 43(1), 87–131.

- Petrusic, W. M., y Jamieson, D. G. (1978). Relation between probability of preferential choice and time to choose changes with practice. *Journal of Experimental Psychology: Human Perception and Performance*, 4(3), 471.
- Qin, H., Guan, H., y Wu, Y.-J. (2013). Analysis of park-and-ride decision behavior based on decision field theory. *Transportation research part F: traffic psychology and behaviour*, 18, 199–212.
- Rayner, K., Pollatsek, A., Ashby, J., y Clifton Jr, C. (2012). *Psychology of reading*. Psychology Press.
- Riedl, R., Brandstätter, E., y Roithmayr, F. (2008). Identifying decision strategies: A process- and outcome-based classification method. *Behavior research methods*, 40(3), 795–807.
- Roe, R. M., Busemeyer, J. R., y Townsend, J. T. (2001). Multialternative decision field theory: A dynamic connectionist model of decision making. *Psychological review*, 108(2), 370.
- Russo, J. E., y Rosen, L. D. (1975). An eye fixation analysis of multialternative choice. *Memory & Cognition*, 3(3), 267–276.
- Scarpa, R., Thiene, M., y Hensher, D. A. (2010). Monitoring choice task attribute attendance in nonmarket valuation of multiple park management services: does it matter? *Land economics*, 86(4), 817–839.
- Schulte-Mecklenbeck, M., Johnson, J. G., Böckenholt, U., Goldstein, D. G., Russo, J. E., Sullivan, N. J., y Willemsen, M. C. (2017). Process-tracing methods in decision making: On growing up in the 70s. *Current Directions in Psychological Science*, 26(5), 442–450.
- Schwartz, B., Ward, A., Monterosso, J., Lyubomirsky, S., White, K., y Lehman, D. R. (2002). Maximizing versus satisficing: happiness is a matter of choice. *Journal of personality and social psychology*, 83(5), 1178.
- Shi, S. W., Wedel, M., y Pieters, F. (2013). Information acquisition during online decision making: A model-based exploration using eye-tracking data. *Management Science*, 59(5), 1009–1026.
- Simon, H. A. (1957). Models of man; social and rational.
- Stewart, N., Gächter, S., Noguchi, T., y Mullett, T. L. (2016). Eye movements in strategic choice. *Journal of behavioral decision making*, 29(2-3), 137–156.
- Stewart, N., Hermens, F., y Matthews, W. J. (2016). Eye movements in risky choice. *Journal of Behavioral Decision Making*, 29(2-3), 116–136.
- Sui, X.-Y., Liu, H.-Z., y Rao, L.-L. (2020). The timing of gaze-contingent decision prompts influences risky choice. *Cognition*, 195, 104077.
- Venkatraman, V., Payne, J. W., y Huettel, S. A. (2014). An overall probability of winning heuristic for complex risky decisions: Choice and eye fixation evidence. *Organizational Behavior and Human Decision Processes*, 125(2), 73–87.
- Xie, Y., y cols. (2019). *Choice modeling with observed and unobserved information search* (Tesis Doctoral no publicada). Massachusetts Institute of Technology.
- Yang, X., y Krajbich, I. (2021). Webcam-based online eye-tracking for behavioral research. *Judgment and Decision Making*, 16(6), 1486.

Anexos

Anexo A. Focus Group

A.1. Objetivos

El trabajo realizado busca cumplir con los siguientes objetivos:

1. Recopilar, analizar, incorporar y aplicar comentarios críticos de aplicación piloto “Clik-Tracker”, con el fin de capturar de manera adecuada la secuencia de atributos atendidos por los encuestados.
2. Explicar, formular y argumentar que procesos cognitivos y búsqueda de información, realizan los usuarios al momento de elegir alguna ruta de transporte público.

A.2. Convocatoria

Para esta actividad se contó con una cantidad de 8 personas, ya que con grupos más grandes puede ser difícil generar un debate entre los participantes, imposibilitando una conversación constructiva entre el investigador y los convocados. El grupo de estudio preliminar a convocar son estudiantes de la Universidad de Chile de diferentes carreras universitarias.

A.3. Metodología

Para poder conseguir los objetivos anteriormente planteados, se aplicaron métodos de investigación cualitativa: focus group y técnicas proyectivas. Inicialmente, el investigador fue quien dio paso a la comunicación realizando preguntas abiertas, luego guió y permitió que los participantes avanzarán a nuevos temas asociados a los objetivos.

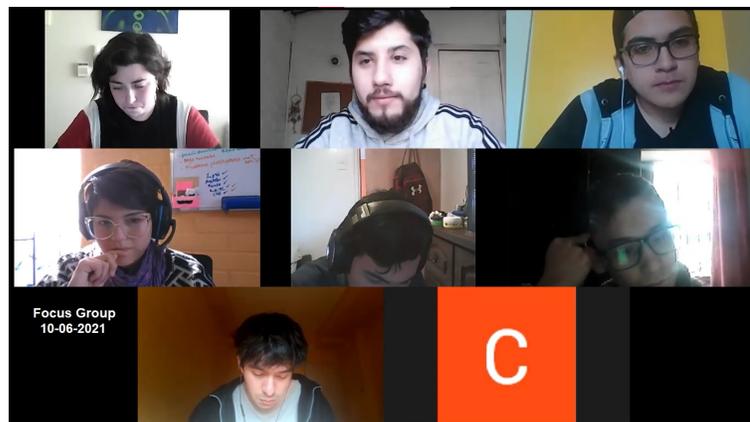


Figura A.1: Participantes Focus Group

El Focus group fue realizado a través de una reunión online el día 10 de agosto 2021 entre las 14:30 - 16:00 horas, tal como se muestra en la figura A.1. La duración del focus group no se extendió más allá de 90 minutos, esto aseguró mantener el enfoque del grupo.

¿Qué preguntas debieron realizarse en esa reunión? Se preparó una Guía de discusión para facilitar la comunicación entre los participantes, que se muestra a continuación.

A.4. Focus Group

Primera etapa: Introducción

- Se agradece a los participantes la asistencia y participación del evento, se presenta el investigador y da la palabra para que el resto se presente también. “Este evento corresponde a un focus group, lo que básicamente significa que vamos a tener una conversación y discusión de temas relevantes asociado a la aplicación y evaluación de una encuesta denominada Klik-Tracker, junto a vivencias cotidianas que ustedes realizan al momento de realizar una elección de ruta de transporte público. Dada la temática, quiero que se sientan libre de hablar sobre lo que quieran. No es necesario tener respuestas inmediatas a mis preguntas o alguna idea en su cabeza para comenzar, es posible que no haya pensado mucho en esto antes, espero intervenir y ayudarlos para darle dinamismo a la conversación. Voy a grabar la discusión para tener un registro, se realizará un análisis detallado de lo conversado y escribiré un registro de lo más destacable de la discusión; nadie será identificado por su nombre en la grabación”.
- Se les solicita a los participantes entregar información personal: Nombre, Edad, Genero, Carrera universitaria, si poseen TNE (tarjeta con descuento) y la cantidad de días que utilizan el transporte público a la semana.
- Se les da a los participantes una breve introducción sobre la aplicación Click-Tracker, link o código QR para que pueda utilizar esta misma.

Segunda etapa: Preguntas asociadas a Click-Tracker

Se agradece a los participantes las respuestas entregadas y se les menciona que daremos paso a la conversación abierta para evaluar la App Klik-Tracker apoyados visualmente con un PowerPoint.

Se realizan preguntas abiertas para fomentar la comunicación relacionadas a:

- Preguntas socioeconómicas: ¿Qué opinión tiene de esta parte de la encuesta? ¿Qué se buscaba preguntar en esta parte de la encuesta? ¿Alguna de estas preguntas es difícil de responder? ¿Cuál?
- Preguntas de preferencias reveladas: ¿Qué opinión tiene de esta parte de la encuesta? ¿Qué se buscaba preguntar en esta parte de la encuesta? ¿Lo que se preguntó describe bien su viaje habitual? ¿Falta añadir algo? ¿Faltó añadir algún atributo?
- Preguntas de preferencias reveladas: ¿Qué opinión tiene de esta parte de la encuesta? ¿Qué se buscaba preguntar en esta parte de la encuesta? ¿Qué tan complejo le parece la forma de seleccionar los botones (áreas de interés) para observar los atributos de las

alternativas? ¿Cambiaría algo de lo mostrado? ¿Cómo la modificaría?

Para elegir cada ruta de transporte público en cada experimento, usted diría que:

1. Revisó exhaustivamente los atributos y alternativas hasta quedar completamente convencido de su alternativa preferida
 2. Revisó parcialmente los atributos y alternativas hasta que, pasado un tiempo “razonable”, eligió la alternativa que le parecía mejor en ese instante
- Fin de la sección: ¿Tiene algún comentario general adicional sobre el funcionamiento de la encuesta?

Tercera etapa: Preguntas asociadas a comportamiento de búsqueda de información

Se agradece a los participantes las respuestas entregadas y se les menciona que daremos paso a la conversación abierta para describir los procesos cognitivos que realizan al momento de realizar una elección de ruta de transporte público.

Se realizan preguntas abiertas para fomentar la comunicación relacionadas a:

- Toma de decisión: ¿Cómo describiría la manera en que toma la decisión de elegir ruta de transporte público? ¿Qué tanto se parecía el experimento a la forma en que usted elige alternativas de viaje cotidianamente?
- Búsqueda de información: ¿Usted diría que su comportamiento es más similar a anchura, profundidad, u otro? Se explica patrones con imágenes.
- Atributos considerados para la elección: ¿Qué características o atributos consideran al elegir algún modo de transporte público? ¿Qué atributos considera más importantes y menos importantes?
- Tolerancia de búsqueda de información: ¿Es agotador pensar en elegir la mejor alternativa? ¿Hasta que punto siguen eligiendo?

Cuarta etapa: Cierre de actividad

Se agradece a los participantes por las respuestas entregadas en todo el evento y se les menciona la importancia de haber participado.

Se menciona la forma de pago por su colaboración en el focus group.

A.5. Resultados

La tabla A.1 muestra los participantes que asistieron al Focus Group online. Además, sus respuestas se agruparon en comentarios positivos y negativos que se pueden ver a continuación:

Comentarios positivos

Se generan comentarios, tales como:

- “Me dí cuenta que no miré toda la información disponible, fue un factor importante apretar click y acordarse lo que había visto anteriormente. Esto me permitió ser consciente de que el tiempo de espera es más importante para mi. No mire algunos valores, pues me importaban otros”.
- “Al comienzo no sabía el propósito de hacer clics sobre los atributos. Luego, me permitió filtrar aquellos que me eran más importante. Por ejemplo, el tiempo de caminata es super importante para mi por el tema de la seguridad”.
- “La metodología permite dar cuenta en los encuestados la inquietud de como vamos eligiendo la información. Dado que no me molesta el transbordo, me centré en otros valores.”

Relacionado al comportamiento de elección:

- “Al comienzo, comparaba las alternativas mirando todos los atributos como en profundidad, pero con el tiempo cuando me acostumbre, solo me enfocaba en ciertos atributos.”
- “Los costos mostrados no me generan una problemática para elegir, ya que la diferencia nominal entre las alternativas es menor que los otros atributos. No fue un problema pensar en pagar adulto ya que me ha pasado y al menos tengo que pagar \$ 700.”
- “Las primeras preguntas me costó y me demoré hartó en elegir, luego me tomé menos tiempo. Puede haber sido que me acostumbre al método o las últimas alternativas fueron más fácil de elegir.”
- “Quizás es agotador ver todos los atributos, ya que son tres alternativas, uno en general solo compara dos alternativas en metro y bus.”

Comentarios a mejorar

- En la pregunta relacionada al nivel educacional, las categorías no queda totalmente representadas.
- Mejorar contexto de situación de elección, con el fin de expresar: “Considere los atributos que generalmente experimenta en su viaje en punta mañana”.
- No todos los participantes están dispuestos a declarar el ingreso familiar. Se genera una mayor voluntad cuando se recuerda que es parte de una tesis de investigación sin fines de lucro.
- No todos los participantes muestran un agrado en el hacer clics para obtener la información de los atributos. Uno menciona dejar la información visible durante un tiempo, que le permita memorizar los valores (Esta visión de la metodología no permite responder las preguntas de investigación).
- Mejorar descripción de los atributos considerados en la situación de elección, justificar y centrar valores mostrados.

Tabla A.1: Participantes Focus Group

Participante	Edad	Estudios	O/D	Modo	Días de uso
P1	23	Ingeniería Civil	Maipú - FCFM	TP - Bicicleta	5
P2	25	Teoría del Arte	Moneda - FA	Solo Bus	6
P3	23	Contador Auditor	San Bernardo - FEN	Colectivo-Bus-Tren-Metro	5
P4	20	Geografía	Peñaflor - FAU	Bus interurbano - Metro - Bus	5
P5	21	Ingeniería Civil	Puente Alto - FCFM	Bus - Metro - Caminata	6
P6	19	Agronomía	Cerro Navia - FCA	Bus - Metro - Bicicleta	4
P7	20	Periodismo	Providencia - FCI	Bus Interurbano - Bus	5

Anexo B. Estimaciones

La tabla B.1 muestra cada uno de los resultados de la generación y estimación del modelo RUM-DFT-SP. Se puede observar que más del 95 % de los parámetros se recuperan correctamente, en signo y magnitud.

Tabla B.1: Resultados del modelo RUM-DFT-SP en iteraciones.

Parámetros (* $p < 0,05$)	β_t	β_c	ASC_{Bike}	ASC_{Bus}	ASC_{Car}	α
Real value	-2,000	-0,500	-1,000	-0,500	-0,500	0,600
1	-1,935*	-0,487*	-1,621*	-0,887*	-0,859*	0,574*
2	-2,000*	-0,499*	-0,77*	-0,058*	-0,029*	0,592*
3	-2,158*	-0,522*	-0,593*	0,119	-0,18*	0,618*
4	-2,166*	-0,475*	-1,268*	-1,254	-0,501*	0,561*
5	-1,872*	-0,488*	-1,158*	-0,443*	-0,607*	0,579*
6	-1,901*	-0,471*	-1,252*	-0,363*	-0,738*	0,549*
7	-2,009*	-0,502*	-1,238*	-0,576*	-0,467*	0,591*
8	-2,044*	-0,466*	0,700'	-0,330'	-0,306*	0,599*
9	-2,089*	-0,516*	-0,810'	-0,286*	-0,611*	0,626*
10	-1,901*	-0,472*	-1,000'	-0,803*	-0,429*	0,603*
11	-1,900'	-0,478*	-1,198*	-0,958*	-0,431*	0,588*
12	-2,117*	-0,528*	-0,866*	-0,348*	-0,286*	0,646*
13	-1,955*	-0,491*	-0,614*	-0,204*	-0,425*	0,605*
14	-1,947*	-0,483*	-1,328*	-0,025*	-0,358*	0,569*
15	-2,105*	-0,485*	-0,842*	-0,092*	-0,38*	0,614*
16	-2,045*	-0,522*	-1,137*	-0,991	-0,943*	0,641*
17	-2,076*	-0,504*	-0,756*	-0,203*	-0,708*	0,629*
18	-2,115*	-0,481*	-1,009*	-0,773*	-0,296*	0,609*
19	-1,905*	-0,494*	-0,577*	0,033	-0,293*	0,625*
20	-1,867*	-0,482*	-1,464*	-0,648*	-0,916*	0,576*

* Parámetro estimado significativamente ($|t| < 1,96$).

La tabla B.2 muestra cada uno de los resultados de la generación y estimación del modelo RUM-DFT-DT. Se puede observar que más del 90 % de los parámetros relacionando al tiempo y el costo de viaje se recuperan correctamente, en signo y magnitud.

Tabla B.2: Resultados del modelo RUM-DFT-DT en iteraciones.

Parámetros (* p<0,05)	β_t	β_c	ASC_{Bike}	ASC_{Bus}	ASC_{Car}	α
Real value	-2,000	-0,500	-1,000	-0,500	-0,500	0,600
1	-1,566	-0,392	-1,093*	-0,596*	-0,660*	0,593*
2	-1,798*	-0,445*	-0,301	-0,014	0,113	0,646*
3	-2,211*	-0,542*	-0,591*	0,130	-0,219*	0,613*
4	-2,558*	-0,616*	-2,22*	-1,954	-0,601*	0,526*
5	-1,887*	-0,487*	-0,992*	-0,452*	-0,583*	0,608*
6	-1,887*	-0,477*	-0,658*	-0,248*	-0,483*	0,649*
7	-1,837*	-0,463*	-0,708*	-0,383*	-0,242*	0,669*
8	-2,526*	-0,609*	-1,278*	-0,554*	-0,478*	0,544*
9	-2,366*	-0,586*	-1,245*	-0,399*	-0,722*	0,586*
10	-2,132*	-0,525*	-0,816*	-0,68*	-0,368*	0,653*

* Parámetro estimado significativamente ($|t| < 1.96$).

La tabla B.3 muestra los resultados del modelo DFT estimando parámetros de pesos de atención (scaled-1) o de escala (scaled-2).

Tabla B.3: Estimación de modelos DFT con parámetros de peso y escala aplicados a datos simulados a partir del enfoque RUM-DFT.

1 Iteración	DFT-Scaled-1			DFT-Scaled-2		
Parámetros	Estimador	D.E.	$t(0)$	Estimador	D.E.	$t(0)$
γ_c	-0,656	0,082	-8,024	0,000	fixed	fixed
γ_t	0,000	fixed	fixed	0,000	fixed	fixed
β_c	1,000	fixed	fixed	1,000	fixed	fixed
β_t	1,000	fixed	fixed	1,501	0,178	8,434
P_A^0	-0,957	1,850	-0,518	-0,829	0,779	-1,066
P_B^0	0,000	fixed	fixed	0,000	fixed	fixed
P_C^0	2,203	1,770	1,245	0,534	0,786	0,679
P_D^0	0,223	1,796	0,124	-0,402	0,715	-0,563
ϕ_1	7,652	0,285	26,859	0,153	0,045	3,427
ϕ_2	0,076	0,002	31,503	0,156	0,066	2,340
σ_ϵ	6,342	0,859	7,383	4,394	0,558	7,870
τ	2,412	0,313	7,700	1,688	0,262	6,438
LL	-4372,760			-4366,110		
$\bar{\rho}^2$	0,210			0,211		
AIC	8761,520			8748,220		
BIC	8811,870			8798,570		

La tabla B.4 muestra los puntos iniciales considerados en la estimación del modelo RUM-DFT-SC con factores de escalas.

Tabla B.4: Puntos iniciales para estimación con factores de escala.

Parámetros	Puntos iniciales			
	PI1 ¹	PI2	PI3	PI4
β_c	0.100	0.100	-2,000	0.100
β_t	0.100	0.100	-2,000	0.100
U_A^0	0.100	0.100	-2,000	0.100
U_B^0	0.100	0.100	-2,000	0.100
U_C^0	0.100	0.100	-2,000	0.100
U_D^0	0.100	0.100	-2,000	0.100
α	0.001	0.001	0.001	0.001
μ	-	1	1	0.01
μ_e	-	1	1	0.01

¹ Todos los factores de escala fijados en 1.