



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

MEDICIÓN DE RESPUESTAS A NOTIFICACIONES EN  
SMARTPHONES SEGÚN CARGA COGNITIVA Y PERFIL DE ADICIÓN  
DEL USUARIO

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL  
INDUSTRIAL

IGNACIO ANDRÉS MENARES JIMÉNEZ

PROFESOR GUÍA:  
ÁNGEL JIMÉNEZ-MOLINA

MIEMBROS DE LA COMISIÓN:  
GONZALO HUERTA-CANEPA  
IGNACIO CALISTO LEIVA

Este trabajo ha sido financiado por el proyecto Fondecyt 11130252.

SANTIAGO DE CHILE

2017

# Resumen Ejecutivo

RESUMEN DE LA MEMORIA  
PARA OPTAR AL TÍTULO DE  
INGENIERO CIVIL INDUSTRIAL  
POR: IGNACIO MENARES  
FECHA: ENERO 2017

PROF. GUÍA: SR. ÁNGEL JIMÉNEZ

El presente trabajo de título tiene como objetivo la medición cuantitativa de los tiempos de respuesta a notificaciones según el nivel teórico de carga cognitiva y el perfil de uso de una persona con su Smartphone. Esto se calcula gracias a la instalación de una aplicación dedicada a recolectar datos de contexto en las que se encuentra un usuario y la información entregada por un cuestionario diseñado especialmente para medir posibles casos de sobreuso de Smartphone de un usuario. El proyecto toma en consideración una desagregación de la forma en que se interactúa con una notificación junto con el perfil de uso del Smartphone, consideraciones que no han sido estudiadas en profundidad en el estado del arte.

Esta memoria está dentro del marco del proyecto Fondecyt “*A Cognitive Resource-Aware Mobile Service Framework to Support Human-Computer-Interactions in Ubiquitous Computing Environments*” liderado por el Profesor Ángel Jiménez. El problema tipo de estudio de este proyecto es cuando un usuario debe dividir su atención entre una actividad primaria física – por ejemplo, caminar, hablar – e interacciones del usuario con un computador, ya sea de escritorio, Tablet o Smartphone.

La aplicación mide el nivel teórico de carga cognitiva del usuario, tomando en consideración el nivel de ruido, la actividad física y el nivel de luminosidad. La investigación se desarrolla en terreno, solicitando al usuario instalar la aplicación y para luego como interactúa con esta y su Smartphone en el día a día. Se realizó el experimento en 2 ocasiones distintas debido a problemas con el instrumento de medición. Un total de 88 entregaron datos útiles que fueron estudiados y 150 personas completaron el cuestionario sobre el perfil de uso de Smartphone.

Se usaron análisis estadísticos para ver si existen diferencias significativas entre los tiempos de respuesta para las distintas variables recolectadas y se aplicó el proceso de Knowledge Discovery in Databases para obtener una correcta aplicación de los algoritmos de minería de datos. Son usados los algoritmos de Support Vector Machine, Regresiones Logísticas y un algoritmo de Deep Learning para hacer clasificaciones sobre el tipo de interacción con una notificación enviada y el perfil del usuario.

Los resultados indican que existen diferencias significativas en los tiempos de respuesta a una notificación según el nivel de carga cognitiva y el perfil de uso. Los mejores resultados para las clasificaciones son obtenidas por el algoritmo de Deep Learning, obteniendo un poder predictivo cercano al 90%.

# Tabla de contenido

<b>RESUMEN EJECUTIVO</b>	<b>II</b>
<b>TABLA DE CONTENIDO</b>	<b>III</b>
<b>1 INTRODUCCIÓN</b>	<b>5</b>
1.1 ANTECEDENTES GENERALES	5
1.2 CONTEXTO INSTITUCIONAL	6
1.3 DESCRIPCIÓN DEL PROYECTO	7
1.3.1 PROYECTO	7
1.3.2 OPORTUNIDAD DE INVESTIGACIÓN	7
1.4 OBJETIVOS	8
1.4.1 OBJETIVO GENERAL	8
1.4.2 OBJETIVOS ESPECÍFICOS	8
1.4.3 HIPÓTESIS DE INVESTIGACIÓN	9
1.5 RESULTADOS ESPERADOS	9
1.6 ALCANCES	10
1.7 METODOLOGÍA	10
<b>2 MARCO TEÓRICO</b>	<b>12</b>
2.1 COMPETENCIA DE RECURSOS COGNITIVOS Y MODELO DE WICKENS	12
2.2 MÉTODOS DE RECOLECCIÓN DE DATOS	17
2.2.1 CARGA COGNITIVA	17
2.2.2 INTERACCIÓN CON SMARTPHONE	19
2.2.3 METODOLOGÍAS TRADICIONALES	19
2.2.4 METODOLOGÍAS NATURALISTAS	20
2.2.5 CONSIDERACIONES ADICIONALES	24
2.3 GESTIÓN DE INTERRUPCIÓN Y SMARTPHONES	25
2.4 TRABAJOS ANTERIORES	28
2.4.1 FRAMEWORK DE ESTUDIO DE <i>LOGGERS</i>	31
2.5 PROCESO <b>KNOWLEDGE DISCOVERY IN DATABASES</b>	32
2.6 TÉCNICAS DE MINERÍA DE DATOS	33
2.7 ALGORITMOS DE MINERÍA DE DATOS	34
<b>3 DISEÑO E IMPLEMENTACIÓN</b>	<b>38</b>
3.1 INSTRUMENTACIÓN	38
3.1.1 APLICACIÓN DE CAPTURA DE DATOS	38
3.1.2 TEST DE SOBRE USO Y ADICCIÓN A SMARTPHONE	42
3.2 DISEÑO DE INVESTIGACIÓN	44

3.2.1	DISEÑO	44
3.2.2	CONSIDERACIONES INICIALES Y LIMITACIONES DEL DISEÑO	46
<b>3.3</b>	<b>GRUPO DE ESTUDIO</b>	<b>48</b>
<b>4</b>	<b>IMPLEMENTACIÓN</b>	<b>49</b>
<b>5</b>	<b>EXPERIMENTACIÓN Y ANÁLISIS DE RESULTADOS</b>	<b>50</b>
<b>5.1</b>	<b>GRUPO EXPERIMENTAL</b>	<b>50</b>
<b>5.2</b>	<b>FORMATO DE RESULTADOS</b>	<b>50</b>
<b>5.3</b>	<b>PROCESAMIENTO DE DATOS</b>	<b>51</b>
5.3.1	MICRÓFONO	51
5.3.2	SENSOR DE LUZ	52
5.3.3	SENSOR DE RADIO	53
5.3.4	SENSOR DE GPS	53
5.3.5	INTERACCIÓN CON LA APLICACIÓN	54
5.3.6	API DE GOOGLE	54
5.3.7	ESTADO DE PANTALLA	55
5.3.8	CONECTIVIDAD DEL SMARTPHONE	56
<b>5.4</b>	<b>ANÁLISIS ESTADÍSTICO</b>	<b>56</b>
5.4.1	ANÁLISIS EXPLORATORIO DE DATOS	56
5.4.2	TEST DE SAS Y SAPS	63
5.4.3	TEST DE HIPÓTESIS	67
<b>5.5</b>	<b>MINERÍA DE DATOS</b>	<b>69</b>
5.5.1	DEEP LEARNING	69
5.5.2	MACHINE LEARNING	70
5.5.3	MODELAMIENTO	73
<b>6</b>	<b>DISCUSIÓN</b>	<b>77</b>
<b>7</b>	<b>CONCLUSIONES Y TRABAJOS FUTUROS</b>	<b>79</b>
<b>8</b>	<b>BIBLIOGRAFÍA</b>	<b>80</b>
<b>9</b>	<b>ANEXOS</b>	<b>89</b>

# Capítulo 1

## Introducción

En este capítulo se introduce el trabajo realizado, indicando los antecedentes generales y el contexto institucional en el cual se desarrolla el trabajo de memoria. La introducción contiene una descripción del proyecto, los objetivos, las hipótesis de investigación, y los resultados esperados del trabajo. El capítulo finaliza indicando los alcances y la metodología usada para el desarrollo del proyecto.

### 1.1 Antecedentes generales

No es ninguna sorpresa que el Smartphone sea una de las herramientas más importantes de la sociedad actual. Larry Rosen PhD muestra su preocupación por este hecho con las siguientes palabras: “*La tecnología está cambiando nuestro mundo más que nunca antes. El catalizador de esto es el Smartphone*” [1], he incluso algunos investigadores han llegado a sugerir que en un futuro muchos usuarios preferirán un Smartphone como principal computador [2]. Esta visión se hace cada vez más presente gracias a la llegada de la telefonía móvil 4G y la preferencia de los países desarrollados por usar sus Smartphone para acceder a internet y a las redes sociales [3] [4]. Las altas tasas de adopción que ha tenido esta tecnología muestran una sociedad que está cada vez más conectada con servicios computacionales [5], logrando un mejor acceso a la información y comunicación entre usuarios, pero también produciendo una gran dependencia de las personas por sus Smartphone. Un ejemplo de esto es el caso de Chile donde estudios recientes afirman que aproximadamente 6 de cada 10 personas adultas sufre de nomofobia<sup>1</sup> y declaran que el Smartphone es su artículo tecnológico prioritario [6]. Esto es preocupante si se considera que cuando las personas interactúan con sus Smartphone o están usando distintos recursos

---

<sup>1</sup> Nomofobia: miedo irracional a salir del hogar sin un teléfono celular.

cognitivos<sup>2</sup> [7], los cuales tienen una capacidad limitada [8] y además compiten con otras tareas que pueda estar haciendo una persona, dificultando la coordinación de todas. En otras palabras, desde la perspectiva de la interacción, estar con un Smartphone es cognitivamente costoso y es importante darle un buen uso a esta tecnología.

En el marco de la computación ubicua, área de la computación que tiene como uno de sus principales objetivos minimizar la distracción del usuario [9] y hacer que la interacción entre un computador y el usuario sea lo más natural posible [10], las actuales notificaciones de un Smartphone son un problema. Aún la tecnología no hace una diferenciación que tome en cuenta el contexto del usuario, por lo que muchas notificaciones son presentadas de una manera molesta, ya sea con visualizaciones en la pantalla, vibraciones, sonidos o una luz LED parpadeante que suele continuar en caso de que el usuario no responda a la notificación [11].

Esto no solo está en contra de los principios de la tecnología ubicua, sino que al no considerar los factores externos e internos con los que interactúa un usuario, se producen problemas como: la pérdida de productividad, dificultad para realizar tareas, aumento en los niveles de estrés y ansiedad [12] [13] [14].

Múltiples estudios han comprobado la importancia de avanzar en el área de manejo de notificaciones e interrupción de los usuarios [15] [16] [17] [18]. Otros se han dedicado a proponer modelos de predicción de momentos adecuados o a diseñar interfaces gráficas más amigables e inteligentes para interrumpir lo menos posible [19].

Esto tiene un impacto no solo en la calidad y vida de las personas, sino que también permite desarrollar sistemas computacionales y oportunidades de negocio en el ámbito de la experiencia de usuarios.

## 1.2 Contexto institucional

El trabajo de título se desarrolla en el marco del proyecto Fondecyt 11130252: “Cognitive Resource-Aware Mobile Service Framework to Support Human-Computer-Interactions in Ubiquitous Computing Environments” [20] otorgado en el año 2013 al profesor del Departamento de Ingeniería Industrial, Ángel Jiménez Molina. El proyecto busca desarrollar un mecanismo de ingeniería cognitiva que seleccione, diseñe y desarrolle funcionalidades, durante el tiempo en que se ejecute el servicio, tomando en consideración el contexto situacional y los recursos cognitivos empleados por el usuario de acuerdo a las tareas y

---

<sup>2</sup> Recursos cognitivo: sensación, percepción, atención, control central, control motor, entre otros.

actividades de interacción humano computador realizadas. Estas tareas también son llamadas tareas HCI por sus siglas en inglés.

El objetivo general del proyecto Fondecyt es reducir el agotamiento de recursos cognitivos mientras se proveen servicios computacionales. Los objetivos específicos del proyecto son:

- Modelar relaciones entre recursos mentales, tareas HCI y actividades físicas;
- Definir métricas para evaluar el agotamiento de recursos cognitivos
- Crear algoritmos de Binding<sup>3</sup>
- Diseñar un modelo computacional para analizar servicios según demandas cognitivas e interferencias
- Desarrollar un framework para dispositivos móviles que englobe los puntos mencionados anteriormente.

## 1.3 Descripción del proyecto

### 1.3.1 Proyecto

El proyecto busca medir si existen diferencias significativas en la recepción e interacción de un usuario con una notificación, según su perfil de uso y adicción a los Smartphone, la actividad del usuario y su nivel teórico de carga cognitiva. Para lograr esto se estudia la recepción de las notificaciones que tiene un usuario según los datos que capturen distintos sensores integrados en un Smartphone y otros datos de contexto capturados por una aplicación diseñada especialmente para el proyecto. Además de estudiar la existencia de diferencias significativas en la forma de recepción a una notificación, se hace minería de datos para profundizar en los resultados obtenidos.

### 1.3.2 Oportunidad de investigación

Distintos autores proponen que uno de los momentos óptimos para entregar notificaciones es cuando el usuario finaliza la actividad principal en la que sus recursos cognitivos están ocupados. La teoría que hay detrás de esa afirmación es que se produce un

---

<sup>3</sup> Algoritmo capaz de seleccionar el servicio idóneo a entregar según el contexto en el que está inmerso el usuario.

relajo en la carga cognitiva de un usuario cuando se termina una tarea y se prepara para iniciar una nueva actividad [21].

El problema es que existen dificultades para entregar notificaciones cuando hay una baja en la carga cognitiva de las personas en un ambientes que no están controlados, ya que la falta de datos de contexto dificulta el proceso de identificación que tan receptivo puede estar una persona a una interrupción. A esto también se le suma las características propias de cada persona y el uso que ésta le da a su Smartphone.

La oportunidad de investigación que ofrece este trabajo ayuda a entender cómo reaccionan segmentos de usuarios con diferentes niveles de adicción y uso de Smartphone cuando se exponen a situaciones que deberían requerir un nivel de carga cognitiva distinta.

Los aportes de este estudio busca obtener son la identificación de momentos óptimos de interrupción dado el patrón de uso del usuario, sin la necesidad de usar sensores o recursos externos que no puedan ser obtenidos por el mismo dispositivo móvil. También se espera que los resultados obtenidos puedan ser integrados al trabajo propuesto en el proyecto Fondecyt 11130252: “A Cognitive Resource-Aware Mobile Service Framework to Support Human-Computer-Interactions in Ubiquitous Computing Environments” [22]

Los siguientes sensores integrados en un Smartphone son usados para la recolección de datos: micrófono, acelerómetro, GPS, giroscopio y sensor de luz. Además la aplicación diseñada para el experimento recolecta datos considera datos del estado del Smartphone, la hora, el estado de la pantalla.

## 1.4 Objetivos

### 1.4.1 Objetivo general

Medición cuantitativa sobre la forma de respuesta a notificaciones en Smartphone según carga cognitiva y perfil de uso y adicción del usuario a dispositivos móviles para futuras aplicaciones en computación ubicua.

### 1.4.2 Objetivos específicos

- 1) Investigar sobre gestión de interrupción en el contexto de notificaciones en dispositivos móviles, y distintos modelos para estudiar la carga cognitiva del usuario y el perfil de uso y adicción de un usuario con su Smartphone.



- 2) Diseñar e implementar la investigación en terreno del proyecto, fundamentando con la teoría cognitiva Wickens y el perfil de adicción de un usuario a su Smartphone.
- 3) Determinar si existen diferencias significativas en la recepción e interacción con una notificación de Smartphone, según el perfil de adicción de un usuario y actividades que requieran niveles de demanda cognitiva distintas.
- 4) Evaluar modelos de minería de datos y comparar los resultados con trabajos anteriores.

### 1.4.3 Hipótesis de investigación

En el área de gestión de notificaciones en tareas HCI los estudios muestran que existen distintos momentos óptimos y formas de notificar a un usuario según su contexto situacional. También, distintos estudios de psicología y medicina indican la existencia de diferentes tipos de usuarios de Smartphone y las correlaciones de éstos con patologías asociadas su uso excesivo. Esta memoria explora en los efectos que tiene el envío de notificaciones según el perfil de adicción de un usuario a un Smartphone y cuando los sensores de un Smartphone indican que un usuario se encuentran en situaciones que requieren distintos niveles de carga cognitiva para poder contestar un mensaje. Para esto se tienen las siguientes hipótesis de investigación:

H1: Según la carga cognitiva de un usuario, existe una diferencia en el tiempo de respuesta a una notificación.

H2: Existe una diferencia significativa en los tiempos de respuesta a una notificación según el perfil de adicción de un usuario.

## 1.5 Resultados esperados

Los trabajos esperados de esta memoria son:

- 1) Estado del arte sobre gestión de interrupción según perfil de adicción y carga cognitiva de un usuario de Smartphone.
- 2) Diseño experimental.
- 3) Aceptación o rechazo de las hipótesis de investigación.
- 4) Identificación o descubrimiento de patrones de uso de Smartphone y nivel de clasificación de algoritmos de minería de datos comparado con trabajos anteriores.

## 1.6 Alcances

Esta memoria no tiene considerada el desarrollo de la aplicación usada para la recolección de datos del uso de Smartphone del usuario, sólo propuestas de mejora en las funcionalidades y en el diseño de una aplicación previamente discutida entre los profesores Ángel Jiménez y Gonzalo Huerta. También se utilizan modificaciones de pruebas sobre el perfil de adicción y sobreuso desarrolladas en Corea del Sur e implementadas a nivel mundial en distintos países [23], otros test o variables psicológicas como es el caso del grado de introversión de un usuario, no serán consideradas en este estudio.

## 1.7 Metodología

La siguiente metodología usada en la memoria está basada en literatura clásica para el diseño de investigaciones y propuestas de recolección de datos en Smartphone. [24] [25]

- 1) Estudio del estado del arte: se recopila y explica la literatura relevante en tópicos relevantes de la gestión de interrupción de notificación de Smartphone, los problemas ocasionados por el sobreuso y adicción a esta tecnología, y el uso de recursos cognitivos compartidos al usar un Smartphone. También se estudian los procesos y modelos usados para tratar los datos y obtener resultados.
- 2) Selección de sensores y aplicaciones tecnológicas a utilizar: al implementar un logger<sup>4</sup> es necesario estudiar también las restricciones de los sensores e instrumentos que ayudan a recolectar datos de mejor forma.
- 3) Diseño experimental: una vez comprendido el estado del arte, se determinan los datos de interés para la investigación y la forma de recolectar la información según restricciones técnicas y de usabilidad.
- 4) Realización de un pre experimento: se explica a los participantes de la investigación el objetivo del estudio, el rol que le corresponde y el uso que se le dará a la información recolectada. Esto último es necesario para asegurar la privacidad y la confianza de los participantes con el fin de que actúen de forma natural. También se recolectan los datos del usuario que son pertinentes y no pueden recolectarse por medio del logger.
- 5) Realización del experimento: se aplica el logger previamente testeado a los participantes de la investigación.

---

<sup>4</sup> Dispositivo electrónico que registra datos de sensores , instrumentos o aplicaciones.

- 6) Recolección de datos post experimento: se interactúa con el usuario para recolectar datos cualitativos sobre la relación del usuario con el experimento. En esta fase se aplica el test de uso y adicción.
- 7) Análisis de datos: se utilizan técnicas estadísticas para aceptar o rechazar las hipótesis de investigación. También se usan técnicas de minería de datos para ver si es posible identificar o descubrir patrones, y predecir o clasificar el tipo de interacción que tendrá el usuario dado los datos obtenidos.
- 8) Resultados: se explican y visualizan los resultados procedentes de los análisis previos.
- 9) Discusión: contextualización de los resultados obtenidos y comparación de éstos con trabajos anteriores. Discutir las aplicaciones que tienen los hallazgos del estudio.
- 10) Conclusiones

## Capítulo 2

### Marco Teórico

Este capítulo tiene por objetivo indicar el marco teórico en el que se desarrolla la memoria, explicando en detalle conceptos que son necesarios para entender el marco en el que se desarrolla la memoria.

El capítulo comienza explicando el concepto de carga cognitiva y el Modelo de Múltiples Recursos de Wickens. Luego se explican formas de capturar la carga cognitiva de un usuario y distintas metodologías y consideraciones para el diseño de investigaciones usando Smartphone. Luego se hace una breve reseña histórica de los estudios relacionados con la interrupción de tareas y la gestión de interrupción en Smartphone, entregando un resumen de trabajos anteriores que son tomados como punto de comparación en la memoria. Se termina el capítulo con una descripción de los modelos y herramientas usadas para analizar y estudiar la información recolectada.

#### 2.1 Competencia de recursos cognitivos y modelo de Wickens

Los recursos cognitivos (o recursos mentales) son el principal activo usado para lograr cualquier tipo de trabajo mental, como por ejemplo: tomar decisiones, planificar y resolver problemas usando algún proceso reflexivo [7] [26]. Por ejemplo, para procesar información principalmente se usan los recursos de atención, percepción, memoria de trabajo, memoria de largo plazo, y control motor [27]. Identificar estos recursos es importante ya que al realizar distintas tareas, se necesita la coordinación de múltiples recursos que influyen en la carga cognitiva (o carga mental) de una persona [28] [29].

El concepto de carga cognitiva representa el nivel percibido de esfuerzo requerido para realizar una tarea en función del trabajo mental producido [30] [31]. Por lo tanto, si

hacemos una analogía con el cuerpo humano, notamos que el cuerpo necesita usar energía de los músculos para poder moverse y el cerebro necesita de recursos cognitivos para actuar de forma eficiente. Cabe destacar que el concepto de carga cognitiva no solo está limitado a actividades que requieran un alto nivel de esfuerzo mental. Éste es un constructo multidimensional que está determinado por las características de: la tarea a realizar (ej. demanda de recursos, nivel de desempeño), el usuario (ej. automatización, experiencia) y el contexto ambiental en el que ocurre la tarea que se busca realizar [29] [32].

En el marco de esta memoria, se toman en consideración los recursos cognitivos que Oulasvirta et al [27] indican relevantes para interacciones con un Smartphone. Estos recursos se observan en la siguiente tabla.

#	Recurso cognitivo	Detalle
1	Control motor	Sincronización, timing, control y finalización de acciones motoras
	(manos)	Manipulación de objetos físicos
	(piernas)	Posicionamiento y movimiento de sí mismo
2	Sensación	Consumo de estímulos externos
3	Percepción	Organización de información de los sentidos
4	Atención	Buscar, seleccionar e integrar
5	Control central	Control meta-nivel de las operaciones cognitivas – selección, inhibición, actualización, desplazamiento
6	Memoria de trabajo	Retención de información previa
7	Memoria prospectiva	Control proactivo y sincronización de acciones
8	Memoria episódica	“Tiempo de viaje” mental
9	Memoria semántica	Conocimiento adquirido
10	Pensamiento consciente	Manipulación consciente de los materiales de la memoria – abstracción, inferencia, razonamiento, resolución de problemas

Tabla 1: Recursos cognitivos relevantes al usar un Smartphone. Traducción literal extraída de [27]

Wickens creó la teoría de Múltiples Recursos (MRT<sup>5</sup> por sus siglas en inglés), teoría que permite modelar la carga cognitiva de una persona al crear una arquitectura que relaciona: la demanda de recursos de una tarea, la superposición de distintos recursos y las políticas de asignación de estos recursos [7].

Con este modelo es posible predecir los niveles de interferencia producidos en tareas que se ejecutan de forma simultánea y determinar la existencia de un agotamiento de recursos cognitivos (CRD<sup>6</sup> por sus siglas en inglés), fenómeno que puede producir, entre otras cosas: aumento de errores, estrés y frustración, reducción en la capacidad de planificación mental, dificultad para tomar decisiones y resolver de problemas [33] [34] [35]. Para evitar sufrir los problemas asociados con el CRD es importante saber gestionar las interrupciones y evitar estar constantemente haciendo múltiples tareas.

Esta teoría toma en consideración los siguientes fundamentos sobre los recursos cognitivos:

- 1) Modularidad funcional: el sistema cognitivo se divide en módulos que son funcionalmente distintos y que operan en diferentes niveles.
- 2) Operaciones con módulos paralelos: los módulos cognitivos pueden operar de forma paralela.
- 3) Capacidad limitada: los módulos cognitivos son limitados.
- 4) Operaciones centralizadas en serie: la coordinación entre los módulos está centralizada y ocurre en serie.

Y los siguientes supuestos se hacen sobre la competencia de los recursos:

- 1) Multitasking: en cualquier momento el sistema cognitivo puede realizar múltiples tareas.
- 2) Pool de recursos: las tareas en operación pueden reservar los recursos cognitivos hasta su término.
- 3) Tareas diferenciadas: diferentes tareas necesitan cantidades distintas de recursos cognitivos. Además, la automatización y habilidad del usuario para cada tarea puede modificar la cantidad de recursos necesarios.
- 4) División de recursos preferencial: los recursos no se distribuyen de forma equitativa sino que de forma jerárquica según motivaciones intrínsecas como las necesidades y metas de una persona.
- 5) Castigo por agotamiento de recursos: las tareas que no reciban la cantidad de recursos cognitivos necesarios son pospuestas, reducidas en velocidad, puestas en espera o terminadas sin ser completadas.

---

<sup>5</sup> MRC: multiple resource theory

<sup>6</sup> CRD: cognitive resource depletion.

El modelo de Wickens consta de 4 categorías principales: etapas de procesamiento, modalidades de percepción, canales visuales y códigos de procesamiento.

La siguiente figura indica la arquitectura propuesta por Wickens en su modelo de múltiples recursos.

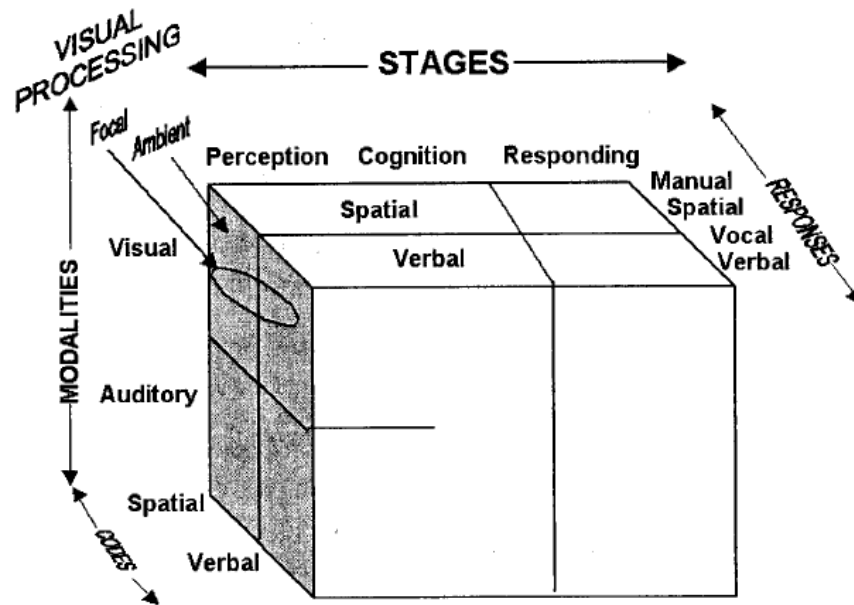


Figura 1: Arquitectura modelo de múltiples de recursos. Extraída de [7]

A continuación se detallan cada una de las dimensiones del modelo de múltiples recursos en la figura 1.

- Etapas de procesamiento

Esta dimensión indica que existen módulos diferenciados en los recursos necesarios en las etapas de percepción, cognición, y respuesta para concretar una tarea. Además, las tareas que se estén realizando de forma simultánea y requieran un alto uso de recursos cognitivos que se comparten tendrán problemas en su desempeño.

- Códigos de procesamiento

Dimensión que indica la distinción entre las actividades lingüísticas o verbales, y las actividades espaciales. Estas actividades se procesan de forma distinta, por lo que

mientras se estén realizando tareas que ocupen código espacial y verbal no habrá interferencia alguna.

- Modalidades de percepción

Dimensión que distingue la forma de percibir un estímulo. Se hace una división de la atención entre la vista y la audición, siendo estos los canales principales por el cual llega un estímulo (también puede ser por tacto pero tiene menor importancia en el modelo). Procesar estímulos de forma paralela que llegan vía visual-visual o auditivo-visual tiene distintas dificultad debido la interferencia que hay entre las modalidades de percepción. Esta dimensión no se manifiesta en la cognición ni en la respuesta.

- Canales visuales

Por último, se hace una separación en el canal visual, distinguiendo la visual focal y la visión ambiental. La visión focal se utiliza primordialmente para reconocer objetos y percibir sus detalles. La visión ambiental en cambio, es una visión periférica responsable de la percepción de la orientación y el movimiento.

Para ejemplificar de mejor forma el modelo de recursos cognitivos, a continuación se muestra una adaptación gráfica del modelo de Wickens [22] para el caso en que una persona se encuentra manejando y escribiendo en su Smartphone de forma simultánea.

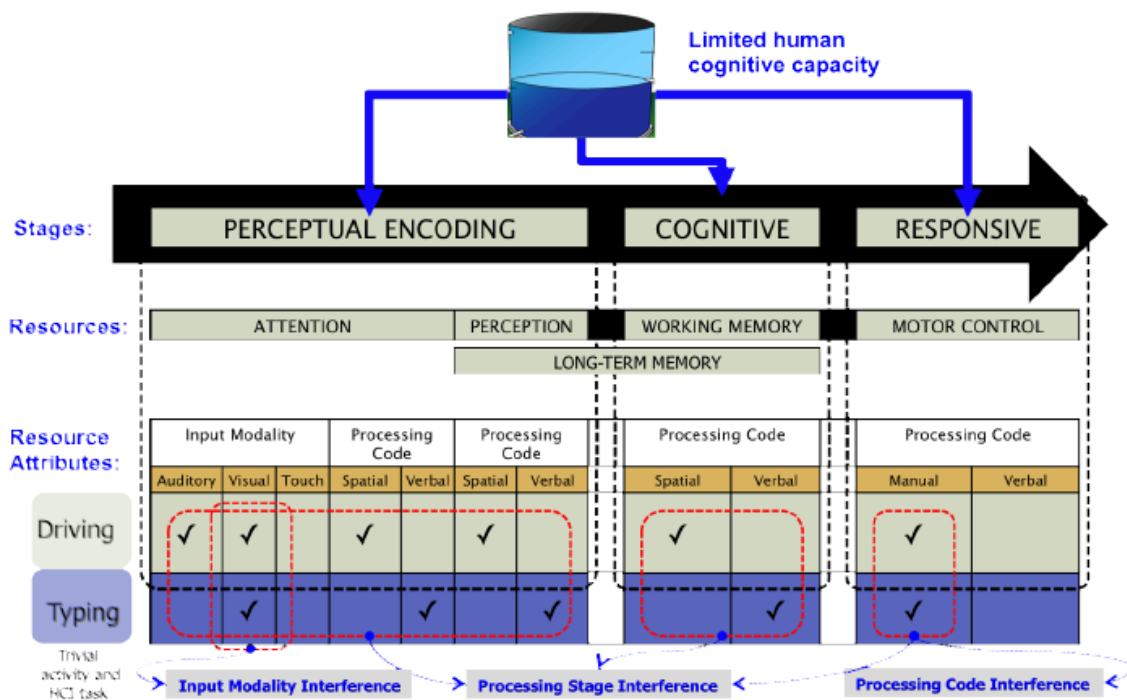


Figura 2: Sistema de procesamiento humano. Extraída de [22]



La figura muestra los tipos de interferencia que se producen cuando dos actividades que comparten recursos se hacen de forma simultánea. A continuación se detallan estas interferencias:

- Interferencia por el canal: interferencia producida cuando recursos de distintas tareas que se realizan simultáneamente comparten un mismo canal. Si esto ocurre la dimensión perceptual deja de procesar información, interrumpiendo alguna de las tareas. [22]
- Interferencia en la etapa de procesamiento: interferencia producida cuando distintas tareas que se desarrollan de forma simultánea piden usar la misma capa de procesamiento. Las capas de procesamiento pueden ser: perceptual, cognitiva o de respuesta.
- Interferencia en el código de procesamiento: interferencia producida cuando se comparte el código de procesamiento para distintas tareas. Esos códigos de procesamiento pueden ser espaciales o verbales, y se encuentran en las etapas de percepción, cognición y de respuesta.

En el marco de los recursos cognitivos utilizados cuando uno se encuentra en actividades de interacción humano computador (HCI) se destacan los recursos compartidos con actividades físicas. Es común que cuando se interactúa con un Smartphone, también se esté caminando, escuchando música, en medio de una conversación o trabajando, por lo que un Smartphone ayuda a que se produzcan distintas interferencias y así producir CRD.

La carga cognitiva es uno de los conceptos más usados en la investigación y práctica de la ergonomía<sup>7</sup> [36] [7] [37]. Este concepto ha adquirido mayor importancia en el último tiempo debido a que la alta exposición a la tecnología moderna impone una mayor demanda cognitiva a los usuarios [29].

## 2.2 Métodos de recolección de datos

### 2.2.1 Carga cognitiva

En la mayoría de los estudios sobre la carga cognitiva se distinguen tres formas de poder catalogar el nivel de carga cognitiva del usuario. A continuación se explica brevemente cada una de las categorías.

---

<sup>7</sup> Ergonomía: estudio de la adaptación de máquinas, muebles y utensilios a la persona que los usa, para lograr mayor comodidad y eficacia.

### 2.2.1.1 Análisis de tareas

El método basado en el análisis de tareas ha sido el método más usado para medir el nivel de carga cognitiva [29]. Este método se basa en técnicas de registro directo de la capacidad de un operador para realizar una tarea primaria y obtener un desempeño aceptable. El mayor problema de este tipo de estudios sobre la carga cognitiva, es que el sujeto de prueba tiene que estar inmerso en sólo una actividad primaria para medir correctamente la carga cognitiva. Este enfoque no es el más adecuado si es que se busca crear un ambiente de estudio de computación ubicua ya que el usuario cambia frecuentemente entre hacer una y múltiples tareas [38], pero tiene la ventaja de que ayuda a mejorar la validez interna de un experimento y son fáciles de implementar en comparación con los otros métodos mencionados a continuación.

### 2.2.1.2 Métodos subjetivos

Estos métodos subjetivos son métodos basados en el cual las personas pueden expresar abiertamente, mediante palabras o algún cuestionario, el nivel de carga cognitiva que sienten luego de haber realizado distintas tareas. Entre los reportes y cuestionarios más usados se encuentra el test de *NASA-Task-Load-index* (NASA-TLX), el *Subjective Workload Assesment Technique* (SWAT), y el Rating Scale Mental Effort (RSME) [29]. Todos estos test suelen tener un buen poder predictivo del nivel de carga cognitiva de un usuario.

Uno de los mayores problemas de este tipo de enfoques es que suelen ser difíciles de aplicar debido a que son pruebas extensas y que no permiten medir la carga cognitiva de forma continua, hecho fundamental en un sistema ubicuo donde se requiere información automática e inmediata para poder brindar el mejor servicio necesario [38].

### 2.2.1.3 Mediciones psicofisiológicas

Las métodos fisiológicos son una medida natural de medir la carga cognitiva ya que, por definición, realizar cualquier tipo de trabajo demanda una activación fisiológica<sup>8</sup> [38].

---

<sup>8</sup> Activación fisiológica o activación cerebral: desencadenamiento de mecanismos a nivel del tronco cerebral en los que participan el sistema nervioso autónomo y el sistema endocrino.

La ventaja que tienen los métodos de medición psicofisiológicas es que pueden medir en tiempo real la carga cognitiva al realizar una o múltiples tareas. También son capaces de detectar la carga cognitiva cuando no existe un cambio en el desempeño de una o más tareas. Para capturar mediciones psicofisiológicas es necesario una variedad de sensores, por lo que los estudios de mediciones psicofisiológicas suelen ser estudios en condiciones de laboratorio con un alto nivel de control [29]. Estos sensores pueden ser incómodos de utilizar y los datos procedentes de estos necesitan de un complejo procesamiento de datos para un análisis adecuado [39].

En esta memoria se usan métricas de análisis de tareas que se pide realizar al usuario y métodos subjetivos para ver el nivel de molestia percibido por una interrupción creada. Estas tareas son notificadas por medio del Smartphone y se usan los datos de los sensores del dispositivo para obtener datos del contexto en el cual se encuentra el usuario. Con los datos de los sensores del Smartphone se puede hacer un análisis de distintas actividades del usuario y obtener una mejor aproximación de la carga cognitiva del usuario.

### 2.2.2 Interacción con Smartphone

Para entender la forma que tienen las personas para relacionarse con un Smartphone existen diferentes metodologías de investigación, siendo las más características los estudios en terreno y los estudios en laboratorios. Cada uno de estos métodos tiene sus ventajas y limitaciones [40], y están asociadas a la forma en que se diseña el experimento y la interacción que tiene el sujeto de prueba con los observadores. Para ejemplificar algunas diferencias, los estudios de laboratorio tienen una mayor validez interna debido a que se tiene mayor control sobre los sucesos que le ocurren al sujeto de pruebas, mientras que los estudios en terreno tienen una mayor validez externa.

En el marco de esta memoria se investiga recolectando datos en terreno del uso de smartphones de distintos usuarios, por lo que se profundiza en las metodologías existentes para este tipo de investigación. Éstas se dividen en las siguientes dos categorías.

### 2.2.3 Metodologías tradicionales

En esta categoría se encuentran todas las formas de recolectar datos en las que el sujeto de pruebas tiene que entregar o contestar algún tipo de información especial o existe un observador presente que puede recolectar datos de interés sobre el usuario. Entre los más

famosos se encuentran los reportes personales, los estudios diarios, las observaciones y los estudios etnográficos [25].

Este tipo de metodologías tiene ciertas limitaciones cuando se aplican a investigaciones en terreno. Primero, se destaca el hecho de que la presencia de un observador puede sesgar la respuesta de los participantes del estudio. La presencia de un observador de forma invasiva impacta en la validez de la data que se quiere recolectar [41]. Un segundo limitante es que estos métodos requieren de una respuesta del usuario, por lo que además de interrumpir al usuario, se agrega una carga adicional al usuario al obligarlo a reportar algo.

Una forma de mitigar estos sesgos es entregando tareas que sean habituales y conocidas. Para mitigar los efectos del observador en las respuestas de los participantes se suele asegurar la anonimidad de la información y se intenta ocultar lo más posible la presencia del observador en el experimento.

#### 2.2.4 Metodologías naturalistas

Las metodologías naturalistas logran la recolección de información con una cantidad mínima o nula de sesgos en caso de ser bien implementadas [25]. Estas metodologías brindan acceso a información del usuario sin necesidad de que exista un observador presente o requerir que el usuario entregue un reporte propio sobre su situación. Cabe destacar que este tipo de metodología no necesariamente es mejor que las metodologías tradicionales. En caso de que se quiera medir el efecto de ciertas tareas en específico u obtener un mayor grado de control sobre la investigación para mejorar la validez interna, este tipo de metodologías no se puede aplicar en su totalidad, existiendo un *trade-off* entre el nivel de control y el nivel de naturalidad.

Para el caso específico de un Smartphone, es común usar registradores de datos o *loggers* para recolectar distintos datos. Los *loggers* son programas y dispositivos que recolectan información de sensores y datos del sistema operativo. Normalmente están integrados con aplicaciones del Smartphone que tienen un fin en particular.

Tosell et al propone los siguientes factores a considerar para llevar a cabo una metodología naturalista en un Smartphone usando *loggers* [25].

- Variables: las variables de interés para la investigación afectan fuertemente en la naturaleza de ésta. En una metodología naturalista se tiene que tener cuidado en que variables elegir ya que ciertos datos no se pueden recolectar sin exponer artificialmente

al sujeto de pruebas a distintas situaciones. También algunas variables son sensibles, por lo que recolectarlas puede llevar a prácticas no éticas o que incomoden al usuario.

- Privacidad: la privacidad se tiene que considerar en más de un nivel. Si la privacidad de su información no está asegurada, las personas pueden negarse a actuar o adaptar su comportamiento, disminuyendo o invalidando los resultados de la investigación [42]. Para asegurar la naturalidad de las respuestas del usuario es necesario que éstos sepan cómo se va a usar la información que se va a recolectar [25]. Otras medidas para asegurar la privacidad son el asignar una identificación nominal o numérica a un participante y no su nombre u otra información que pueda conectar los datos obtenidos de un participante, manteniendo así su anonimidad.
- Molestia: la molestia incrementa la reactividad<sup>9</sup>, por lo tanto es una de las variables más importantes para lograr una investigación que logre capturar datos de forma naturalista. Existen múltiples formas de que un *logger* moleste a un usuario y le recuerde que está siendo observado. Ejemplos típicos son con notificaciones que pidan al usuario responder alguna pregunta o que ejecute cierta acción. Esta variable es especialmente importante ya que existe un fuerte *trade-off* entre el valor obtenido por la información recolectada al molestar al usuario con alguna tarea, y la pérdida de naturalidad debido a que se interrumpió el normal actuar de éste. Una metodología completamente naturalista no debería requerir ninguna acción adicional del usuario.
- Interfaz: es importante conocer el tipo de interfaz con la cual interactúa el registrador de datos. Cuando se le pide al usuario interactuar con una interfaz que no es conocida se incrementa la variabilidad de los resultados. Para mitigar este problema es necesario usar una interfaz intuitiva para el usuario o estudiar los resultados luego de que el usuario se adapte a la nueva interfaz [43].
- Tareas: las tareas que una investigación busca estudiar pueden variar entre tareas construidas por el usuario en un ambiente con validez externa, a tareas construidas por el investigador en un ambiente de laboratorio controlado. Un enfoque naturalista busca investigar las tareas que normalmente haría un usuario con su Smartphone.
- Tecnología: los Smartphones suelen usarse en conjunto con otras tecnologías. Un ejemplo de esto es el uso complementario que se da entre un Smartphone y el computador de escritorio o notebook para leer y responder un correo electrónico. En esta metodología

---

<sup>9</sup> Reactividad: modificación en un comportamiento natural debido a que se está midiendo este comportamiento. [83]

se sugiere que el Smartphone sea la tecnología primaria con la cual se interactúe y que existan incentivos para que eso se mantenga.

- **Participantes:** en la metodología naturalista es importante seleccionar cuidadosamente los sujetos participantes de la investigación. Preferentemente es mejor evitar sujetos de prueba que tengan una relación con el diseño del experimento. Otras consideraciones ha tomar en cuenta son tratar de incluir participantes de otras regiones o países, eliminar o mantener al mínimo las reuniones con los investigadores durante la investigación, e informar a todos los participantes para que se usarán sus datos y que se mantiene anónima toda información personal de los resultados del experimento.
- **Duración del estudio:** los estudios que tienen una mayor duración permiten que el efecto de estar siendo observados desaparezca con el tiempo [44]. También hay sucesos que ocurren en ocasiones muy particulares, por lo que estudios de poca duración no lograrían captar esos datos. No existe una regla o consenso general de lo que debería durar un estudio para poder decir que es naturalista, sino que simplemente se considera que estudios de mayor duración en general son más naturales. Tosell et al recomienda considerar factores como el nivel de familiaridad con el dispositivo de estudio para elegir la duración del estudio.

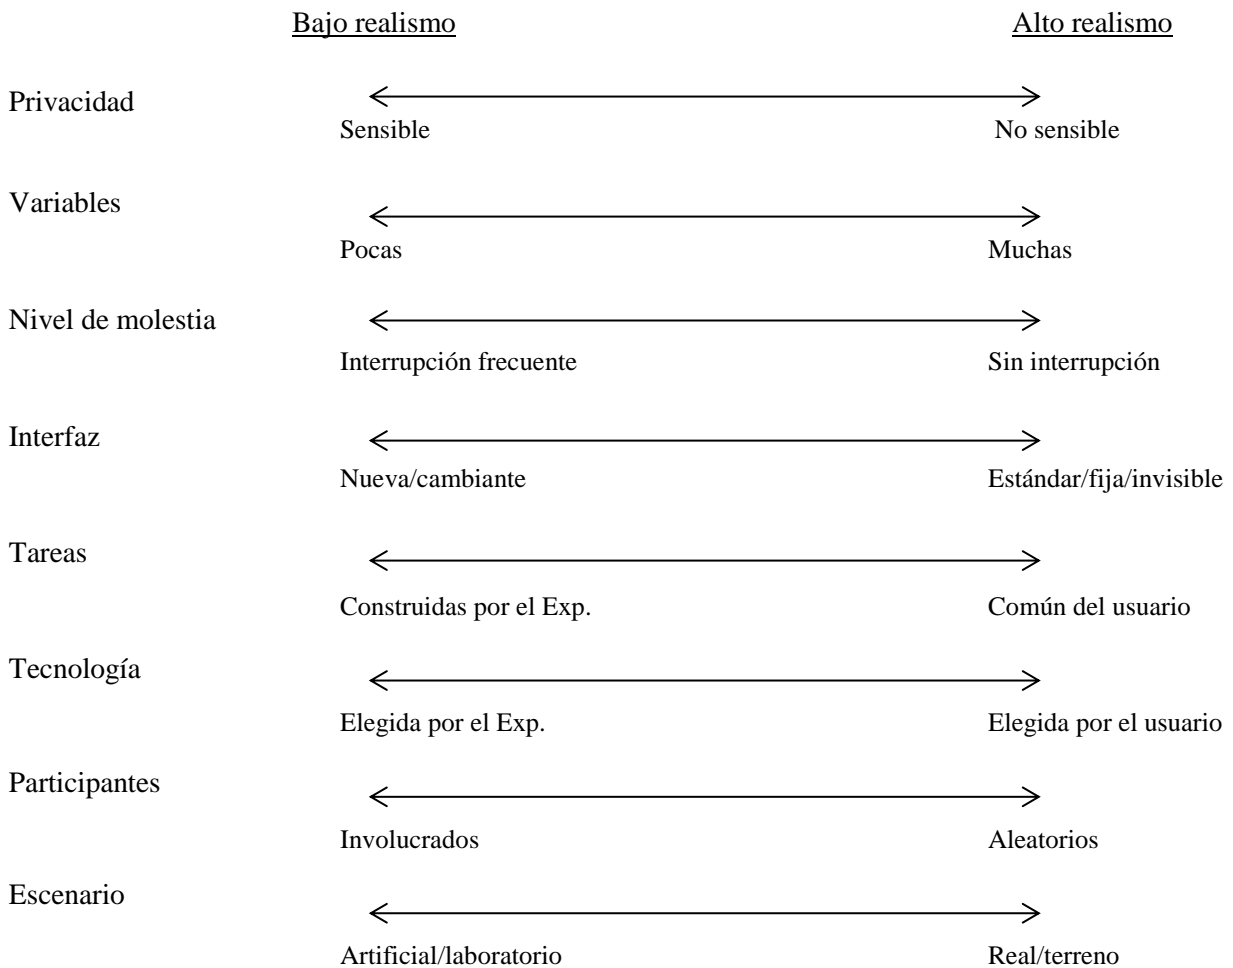
La siguiente tabla resume las 9 consideraciones que Tosell et al propone para diseñar una metodología naturalista usando registradores de datos (loggers) en smartphones.

Variables de diseño	Consideraciones
Variables de estudio	¿Qué variables son necesarias? ¿Qué variables se ignorará?
Privacidad	¿Son los datos capturados potencialmente sensibles para el sujeto de prueba?
Molestia	¿Cómo se recolecta la data? ¿Es de forma automatizada o se requiere que el participante reporte información?
Interfaz	¿Con qué interfaz interactuará el participante? ¿Es una interfaz nueva diseñada para el experimento o está oculta y se ejecuta sin que el participante se entere?
Tareas	¿Qué tareas tendrá que hacer el participante? ¿Son tareas naturales del usuario o artificiales diseñadas por el experimento?

Tecnología	¿Qué tecnologías se usan para el experimento? ¿El participante está familiarizado con los dispositivos usados?
Participantes	¿Quiénes son los participantes? ¿Están seleccionados al azar o están relacionados con la investigación?
Escenarios	¿Dónde se llevará a cabo el estudio? ¿Se hará en un laboratorio o en terreno?
Duración del estudio	¿Por cuánto tiempo se recolectarán datos? ¿Es un estudio transaccional o longitudinal?

Tabla 2: Consideraciones para el diseño de una investigación con loggers. Extraída de [25]

Tomando en consideración estas variables para el diseño de una investigación es posible identificar que tan naturalista es una investigación. La siguiente figura compara el nivel de realismo que tiene cada una de las variables.







Mortalidad	Participantes abandonan el experimento con el tiempo.
Difusión de tratamientos	Participantes de distintos grupos interactúen entre sí y afecten sus resultados.
Compensación	Participantes del grupo de control perciban que no reciben beneficios y eso los desmoralice y afecte los resultados.
Conducta del experimentador	Comportamiento del experimentador afecte los resultados.

Tabla 3: Principales fuentes de invalidación externa. Basado en [24]

## 2.3 Gestión de interrupción y Smartphones

Con la llegada de los dispositivos móviles las personas se encuentran potencialmente siempre accesibles para ser interrumpidos. Producto de esto ha incrementado la atención de áreas de investigación relacionadas con la psicología cognitiva, ergonomía, ciencias de la computación, y marketing [45]. La evidencia de estas investigaciones sugiere que las interrupciones y notificaciones suelen ser molestas, por lo que es importante lograr mecanismos para la mejora de la interrupción de las personas.

A continuación se realiza un breve repaso histórico de los distintos estudios realizados en el ámbito de la gestión interrupción en las personas.

En las décadas de 1990 e inicios de 2000, múltiples estudios se centraron en las características que hacen a una notificación molesta y los efectos de éstas en la productividad de las personas [45] [46] [21] [33], investigando principalmente interrupciones en el área de trabajo e interrupciones producidas por mensajes instantáneos en computadores y teléfonos celulares. Dentro de los estudios sobre las características de la interrupción, se destacan la investigación sobre la complejidad de la interrupción [47] [48], el contenido de la interrupción y su similitud con la actividad primaria [49] [34], el control sobre el mecanismo de interrupción [50] [51], y la disponibilidad para recuperar la actividad interrumpida otorgadas por la interrupción [34] [15]. En cambio los estudios de la época sobre los efectos de las interrupciones en la productividad se enfocaron en investigar cómo una interrupción afecta en el tiempo necesario para completar una actividad primaria y en la variación de desempeño luego de ser interrumpido [50] [33] [21] [35]. Estos estudios indicaron los problemas de ser interrumpidos en el área de trabajo y fueron desarrollados en diversas áreas

como por ejemplo en interacción humano-computador, aviación, medicina, marketing, y conducción de vehículos [45] [16] [52] [27].

También, en estos años se estudió la anatomía de una interrupción y los tipos de notificaciones que llevan a una interrupción. Trafton crea el siguiente diagrama para explicar el proceso en el que una persona es interrumpida de su actividad primaria por una notificación que tiene involucra una actividad o tarea a realizar [53].

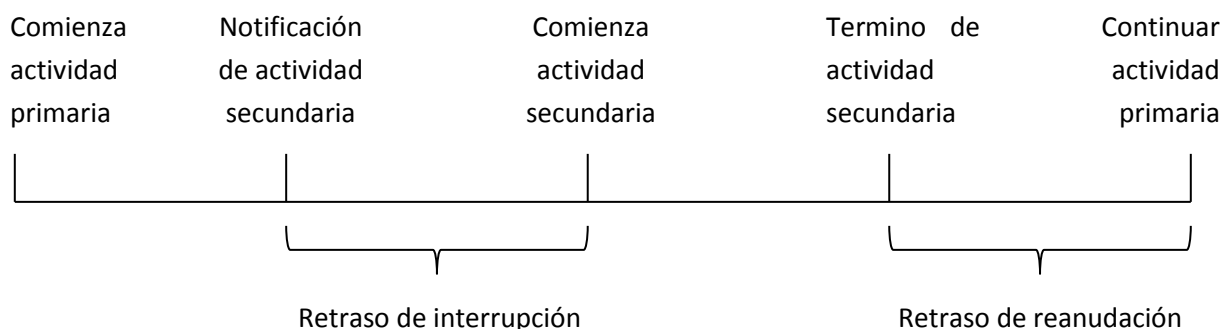


Figura 4: Anatomía de una interrupción. Elaboración propia a partir de postulado en [53]

La figura indica la línea de tiempo de un proceso en que la interrupción provoca un cambio en la tarea primaria de una persona.

Cabe destacar que no siempre que una persona reciba una notificación existirá un cambio en la actividad primaria o se llevará a cabo la tarea secundaria pedida por la notificación. Se identifican 4 tipos de formas en que se puede lidiar con una interrupción, éstas son: atención inmediata, atención negociada (persona es consciente de la interrupción y decide cuándo actuar), atención programada (tiempo en que se tiene una interrupción está predefinido) y atención mediada (agente inteligente determina cuando es mejor interrumpir al usuario) [50] [51]. También se identifican 11 factores que influyen la interrupción que pueda tener una persona [46], éstos son: 1) la actividad actual de un usuario, 2) la utilidad de un mensaje, 3) el estado emocional del usuario, 4) el modo en que se le interrumpe, 5) la frecuencia de las interrupciones, 6) el nivel de control sobre el agente interruptor, (7) las actividades previas y futuras en el momento de ser interrumpido, (8) el compromiso con la actividad actual del usuario, (9) el historial y probabilidad de respuestas anteriores, (10) la expectativas sociales del grupo cercano y (11) la tasa de eficiencia de las tareas del usuario.

Los estudios de esta época ayudaron a contextualizar la importancia de la gestión de interrupción al cuantificar el impacto negativo y efectos de distintos tipos de interrupciones en el trabajo de las personas [48] [54] [17], y también ayudaron a desarrollar distintas teorías para explicar la interrupción y reanudación de actividades (teoría de memoria para tareas, teoría de cambio de tareas, etc) [55] [56] [57] [58]. Estas teorías están basadas en el uso de

los recursos cognitivos de control central, memoria prospectiva y memoria de trabajo; y los códigos y etapas de procesamiento expuestos anteriormente en el modelo de múltiples recursos de Wickens.

En los últimos años, la alta demanda y tasa de adopción de los Smartphone ha logrado que estos dispositivos tomen más importancia de estudio a nivel mundial. Nuevos tópicos de investigaciones como por ejemplo el desarrollo de interfaces ergonómicas que no incrementen la carga cognitiva del usuario [59] [60] [19], o la identificación de momentos y creación de modelos para la entrega de notificaciones de forma inteligente [22] [18] [61] [62] [63] han ido en incremento. Estos estudios muestran la importancia y beneficios de lograr una interacción con los Smartphones de forma más ubicua y, además de profundizar en los problemas en la productividad de una persona, también se exponen los problemas psicofisiológicos que puede producir el sobreuso de un Smartphone y la sobreexposición a interrupciones producto de esto [64] [13] [23] [65] [66] [67].

A continuación se muestra un diagrama con los distintos tipos de interacción que una persona puede tener con un Smartphone [68]. Para complementar la información del diagrama, en cada uno de sus cuadrantes se explica cómo sería el tipo de interacción para el caso específico en que se tenga que actualizar una aplicación de un Smartphone.



Figura 5: Diagrama de interacción. Elaboración propia basado en [68]

Como la mayoría de las notificaciones de un Smartphone son de forma proactiva y ocurren en el primer plano para llamar la atención de un usuario, es común que éstos estén constantemente pendientes de sus Smartphones.

Existe poca literatura sobre la correlación entre diferentes patrones de conducta y problemas psicofisiológicos producidos por un Smartphone en las personas [69]. Esta memoria busca profundizar en el tema e identificar momentos propicios para la entrega de mensajes.

## 2.4 Trabajos anteriores

Esta memoria busca analizar la forma de respuesta de un usuario a distintas notificaciones según datos de contextos y su perfil de adicción. A continuación se indican estudios que profundizan de estas áreas, se muestran los resultados obtenidos y el tipo de estudio que se llevó a cabo.

- Oulasvirta et al. [27]

Objetivo	Diseño y validación de Framework para explicar naturaleza de recursos cognitivos en Smartphone.
Experimento	Tareas desarrolladas por experimento: realizar distintas actividades físicas y tareas de búsqueda Web con un Smartphone. N= 28; T= horas.
Resultado	Diferencia significativa entre tiempos de respuesta y frecuencia de recursos atencionales usados según carga cognitiva y localización.

De esta investigación se pudo ligar el modelo de carga cognitiva de Wickens con el uso de los Smartphone de manera clara, siendo una de las principales inspiraciones para el desarrollo de la memoria.

- Poppinga et al. [11]

Objetivo	Identificación de momentos oportunos para entregar notificaciones usando sensores del Smartphone.
Experimento	Tareas desarrolladas por experimento: responder a un mensaje que pregunta sobre estado anímico actual y nivel de molestia percibida. N= 79; T= 76 días; Notificaciones = 6.581

Resultado	Identificación de tiempos y variables significativas. Sobre 70% de precisión y recall usando Machine Learning.
-----------	--

El estudio de Poppinga et al. tiene similitudes en el diseño del instrumento de medición usado este trabajo de investigación, por lo que sus resultados sirven como un buen punto de comparación.

- Pejovic et al. [62]

Objetivo	Desarrollo de mecanismos para identificar momentos oportunos para interrupciones producidas por smartphones.
Experimento	Tareas desarrolladas por experimento: responder una notificación con preguntas de contexto sobre estado de ánimo e interrupción. N= 10; T= 30 días; Notificaciones = 1.285
Resultado	Aumento de satisfacción y baja en tiempo de respuesta a mensaje en comparación con asignación aleatoria.

Esta investigación comparte en cierto modo algunas de las hipótesis de investigación y el diseño experimental.

- Mehrotra et al. [70]

Objetivo	Identificación de factores que afectan en el tiempo de respuesta y aceptación a una interrupción
Experimento	Tareas desarrolladas por experimento: responder a preguntas sobre tipo de personalidad, razones por las cuales se respondió o no a un mensaje y el nivel de molestia de éstos. N= 20; T= 2 meses ; Notificaciones = 10.372
Resultado	Identificación de factores del mensaje y de las características del usuario.

De esta investigación se puede sacar una explicación teórica que ayude a entender la naturaleza de los resultados obtenidos al ligar ciertos factores con el diseño experimental.

- Mehrotra et al. [61]

Objetivo	Identificación de factores que afectan en el tiempo de respuesta y aceptación a una interrupción
Experimento	Instalación de aplicación que registra datos de todas las notificaciones y que a la vez manda sus propias notificaciones.

	Tareas desarrolladas por experimento: responder a pregunta sobre lugar donde se encuentra y relación social con remitentes de las distintas notificaciones.  N= 35; T= 3 semanas; Notificaciones = 4.069 generadas y sobre 70.000 notificaciones estudiadas.
Resultado	Identificación de factores del mensaje y de características de contexto social que influyen en la recepción a un mensaje. Predictor con sensibilidad de 70% y especificidad de un 80%.

- Ahn et al. [69]

Objetivo	Identificación de patrones de uso según adicción a Smartphone
Experimento	Testeo de nivel de adicción y luego instalación de aplicación que monitorea y analiza el uso del Smartphone.  N= 30; Notificaciones = 11.346
Resultado	Identificación de preferencia según tipo de aplicaciones y nivel de adicción a Smartphone.

Fuente de inspiración para el diseño y planteamiento de hipótesis del trabajo de título.

- Lee et al. [64]

Objetivo	Identificación de patrones de uso según adicción
Experimento	Testeo de nivel de adicción y luego instalación de aplicación que monitorea y analiza el uso del Smartphone.  N= 95 T= varía según usuario.
Resultado	Identificación de preferencia según tipo de aplicaciones, uso de aplicaciones y nivel de adicción a Smartphone.

- Turner et al. [71]

Objetivo	Propuesta y evaluación predictiva de Framework para el estudio de notificaciones usando sensores del Smartphone.
Experimento	Tareas desarrolladas por experimento: responder a notificaciones que indican de tareas pendientes previamente agregadas por el usuario.  N= 93; T= 6 meses; Notificaciones = 11.346

Resultado	Sobre 60% de precisión y recall para distintas etapas de respuesta a una notificación usando Machine Learning.
-----------	--

El diseño experimental de esta memoria toma en consideración las metodologías y resultados de estos estudios.

### 2.4.1 Framework de estudio de *loogers*

La siguiente figura explica el framework usado para estudiar las respuestas a una notificación en el estado del arte.

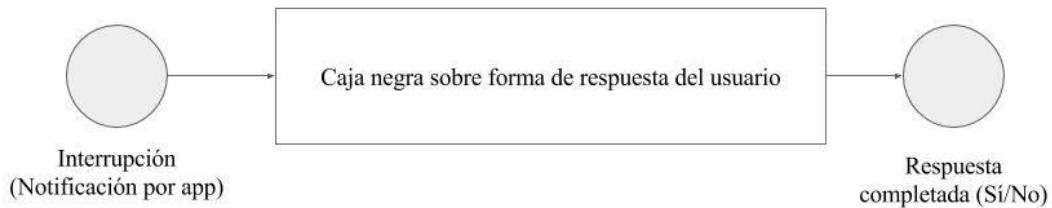


Figura 6: Convención sobre cómo determinar una interrupción en un Smartphone. Elaboración propia basado en

Turner et al profundiza en el framework mencionado, al dividir en distintas etapas la forma de respuesta a una notificación [71]. La forma propuesta para estudiar el proceso de respuesta a una notificación se observa en la siguiente figura.

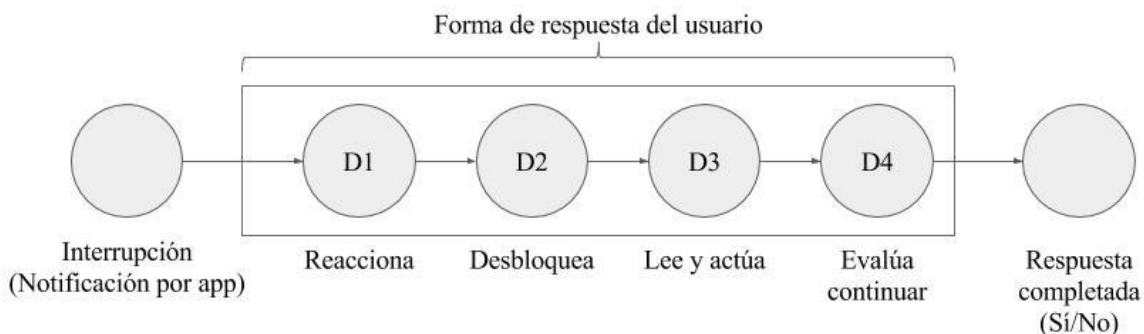


Figura 7: Framework sobre forma de respuesta a notificación en Smartphone. Elaboración propia basado en [71]

La figura 12 muestra 4 etapas de estudio en la que un usuario debe decidir qué hacer luego de ser interrumpido. Estas etapas son:

- D1: En esta etapa ocurre la interacción con una notificación y un usuario. Si la notificación logra llamar la atención de un usuario por medio de un sonido, vibración o señal visual, el usuario tendrá que decidir si prender el Smartphone para ver de qué se trata el mensaje.
- D2: Luego de prender el Smartphone, un ícono gráfico o mensaje indica la existencia de una o más notificaciones pendientes. El usuario al ver estos íconos o mensajes tendrá que decidir si el remitente o tipo de interrupción es lo suficientemente importante para continuar prestando atención a la interrupción. Si se cumplen estas condiciones se desbloquea el Smartphone para continuar a leer el contenido de la interrupción.
- D3: Al decidir reaccionar y atender la o las notificaciones, el usuario interactúa con el Smartphone. Aquí se abren las distintas notificaciones pendientes, se lee el contenido y se informa de los motivos por el cual se le interrumpió. Luego de esto, en caso de que se requiera, el usuario evalúa si responder o entregar algún input a la aplicación que interrumpió su actuar.
- D4: En esta fase se requiere un input del usuario para completar el ciclo pedido por la interrupción. Si el usuario completó todas las tareas pedidas por la interrupción, se considera que la respuesta del usuario es una respuesta completa. Caso contrario se considera una respuesta parcial.

## 2.5 Proceso Knowledge Discovery in Databases

Para el análisis exploratorio de datos se utilizará el proceso *Knowledge Discovery in Databases* (KDD), metodología que procesa, transforma, analiza y aplica minería de datos en los resultados obtenidos [72]. Son 9 las etapas principales de este proceso, las cuales se proceden a explicar brevemente a continuación:

- 1) Comprensión del problema y planteamiento de objetivos: Se desarrolla un entendimiento del problema y se establecen los objetivos estratégicos necesarios para poder llevar a cabo todo el proceso KDD.
- 2) Selección: Se estudia el tipo de datos disponibles y su calidad. Es necesaria una evaluación sobre la factibilidad de explicar el problema planteado con los datos disponibles. Si se da el caso en que los datos no logran esta condición, se estudia la posibilidad de recolectar más datos. Los datos que se seleccionan son el input para todo el posterior análisis del proceso KDD.



- 3) Preprocesamiento: Se trabaja con los datos disponibles para solucionar problemas existentes en la base de datos. Algunos ejemplos de preprocesamientos comunes con los datos son los tratamientos de valores perdidos, eliminación de datos fuera de rango y del ruido, entre otras.
- 4) Transformación: En esta etapa se intenta agregar valor a los datos al transformarlos en medidas acordes al problema de estudio para que se puedan ajustar mejor al problema.
- 5) Selección de la tarea de minería de datos: Se selecciona el tipo de minería de datos con el que se trabajará, dentro de los que se destaca una clasificación, regresión o cluzterización.
- 6) Selección de algoritmo de minería de datos: Se consideran los beneficios e inconvenientes de los distintos algoritmos y como se relaciona con el problema objetivo.
- 7) Implementación: Se aplica el o los algoritmos de minería de datos. En esta fase es recomendable correr los algoritmos reiteradas veces para no llegar a conclusiones apresuradas con respecto a los resultados.
- 8) Evaluación e interpretación: Se analizan los resultados obtenidos en relación con los objetivos planeados. Según los resultados obtenidos es posible que se tenga que re-evaluar los algoritmos y tratamientos de datos realizados.
- 9) Conocimiento descubierto: En caso de obtener algún *insight*, se obtuvo un conocimiento que es replicable y se finaliza el proceso.

## 2.6 Técnicas de minería de datos

De forma general, se pueden dividir las técnicas de minería de datos según su objetivo. Existen los algoritmos que buscan verificar una hipótesis y otros que intentan descubrir algún patrón o información adicional de los datos.

Las técnicas de descubrimiento son las que intenta crear algún modelo de comportamiento a partir de datos y modelos entrenados. Éstas se dividen en 2 categorías, las cuales son las técnicas de descripción y los de predicción. Las técnicas de descripción intentan explicar e interpretar datos al encontrar relaciones entre los distintos datos. En cambio, los métodos de predicción buscan crear algún modelo capaz de tomar datos de entrenamiento y predecir el comportamiento

de otros datos. Los modelos predictivos a su vez también se dividen en 2 categorías, los cuales son los algoritmos de clasificación y los de regresión. Los algoritmos de clasificación buscan predecir si un registro se puede clasificar en un grupo particular, mientras que los algoritmos de regresión intentan generar un pronóstico al encontrar la ponderación de distintas variables dentro de un modelo. [72]

## 2.7 Algoritmos de minería de datos

En esta memoria se utilizan algoritmos de minería de datos para poder clasificar el nivel de uso y el tipo de interacción que tendrá un usuario con su Smartphone y las notificaciones entregadas por el instrumento de investigación. A continuación se explican los algoritmos usados en esta memoria.

- Support Vector Machine [72]

Es un algoritmo famoso por su buen desempeño y flexibilidad de ajuste parámetros para obtener mejores resultados. En la mayoría de los casos SVM es un clasificador binario, pero en este trabajo se usará también como un clasificador multinomial.

Para el caso de un clasificador binario, se crea un set de entrenamiento  $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$  con  $x$  igual a los vectores de datos e  $y$  es la etiqueta de la clase que toma el valor de 1 o -1 si pertenece o no a la clase en cuestión.

Se crea una función lineal  $f(x) = \langle w \cdot x \rangle + b$  que cumpla que si  $x$  es positivo  $f(x) \geq 0$ . Esto produce la siguiente relación entre  $x$  e  $y$ .

$$y_i = \begin{cases} 1 & \text{si } \langle w \cdot x \rangle + b \geq 0, \\ -1 & \text{si } \langle w \cdot x \rangle + b \leq 0. \end{cases}$$

Con esta función, lo que hace el algoritmo es encontrar el hiperplano que clasifique los datos de entrenamiento en clases positivas y negativas.




Figura 8: Ejemplo de hiperplano SVM binario

Este hiperplano se suele calcular al resolver el siguiente problema de optimización:

$$\begin{aligned} \text{Min} : & \frac{\langle \mathbf{w} \cdot \mathbf{w} \rangle}{2} + C \sum_{i=1}^n \xi_i \\ \text{s.a.} : & y_i (\langle \mathbf{w} \cdot \mathbf{x} \rangle + b) \geq 1 - \xi_i \\ & \xi_i \geq 0. \end{aligned}$$

Pero dependiendo de la naturaleza de los datos utilizados para el modelo de SVM, existen modificaciones a esta función.

Para el caso de modelos multiclase de SVM, un enfoque que se suele usar es resolver múltiples clasificaciones binarias que logren entregar todas las combinaciones posibles de clasificación. [73]

- Regresión Logística [72]

Algoritmo utilizado para clasificar, el cual es un tipo de regresión lineal generalizada. La principal característica de este tipo de regresión es que predicen con cierta probabilidad la pertenencia o no a cierto grupo, por lo que sus valores se encuentran entre 0 y 1. Existen regresiones logísticas binarias y multinomiales.

La forma más simple de una regresión logística se define como:

$$\begin{aligned} \mathbf{f}\boldsymbol{\theta}(\mathbf{x}) &= \mathbf{h}(\boldsymbol{\theta}^T \mathbf{x}) \\ \mathbf{h}(y) &= \frac{1}{1 + \exp^{-y}} \end{aligned}$$

Con:

- $\mathbf{f}\boldsymbol{\theta}$ : es una regresión logística.
- $\mathbf{x}$ : caso que se quiere clasificar.
- $\boldsymbol{\theta}$  son los parámetros de la regresión.
- $\mathbf{h}$  es la función logística entre 0 y 1.

La función de costo que es la que se busca minimizar para encontrar los parámetros necesarios para clasificar se define así:

$$J(\theta) = -\frac{1}{n} [\sum z_i \log f_{\theta}(x_i) + (1 - z_i) \log (1 - f_{\theta}(x_i))]$$

Con:

$z$ : etiqueta de la clase y  $x$  los datos.

- Deep Learning [73]

Se usa el término Deep Learning para referirse a un conjunto de algoritmos que modelan una serie de transformaciones no-lineales. En esta memoria se usan modelos de multicapas de redes neuronales prealimentadas para modelos predictivos.

Para facilitar la explicación de qué es una red neuronal multicapa prealimentada, se explica primero que el concepto de una neurona en Machine Learning ya que ésta es la unidad básica dentro del modelo. La neurona representa la combinación ponderada de distintas variables tal como se observa en la figura 9.




Figura 9: Neurona. Extraído de [73]

Con:

$x$ : Variable de entrada (input)

$w$ : Peso de cada variable en la neurona.

$b$ : umbral de activación de una neurona (bias).

$$\alpha = \sum_{i=1}^n w_i x_i + b$$

La combinación de los pesos ponderados de cada input es agregada en una función de salida  $f(\alpha)$  transmitida por la neurona. Esta función  $f$  representa la función de activación no lineal usada luego en una red de neuronas, el cual genera un feature que es usado para explicar el modelo deseado.

Una red neuronal multicapa prealimentada consiste en muchas capas de neuronas interconectadas (Ver figura 10), partiendo por una capa de input que parte siendo los features del modelo, pero que luego de pasar por capas de activación no-lineal, se crean nuevos features. Esto se repite según la cantidad de capas del modelo, y se termina el algoritmo cuando en la última capa se hace una regresión o clasificación con los features.




Figura 10: Múltiples neuronas interconectadas

Para determinar el modelo óptimo se minimiza la siguiente función de costo.

$$L(\mathbf{W}, \mathbf{B} | \mathbf{j})$$

Con:

$\mathbf{W}$  es el conjunto de  $\{W_i\}_{1:N-1}$

$W_i$ : matrix de pesos conectado en la capa  $i$  e  $i+1$  para una red de  $N$  capas.

$\mathbf{B}$  es el conjunto  $\{b_i\}_{1:N-1}$

$b_i$  columna de los bias para la capa  $i+1$

## Capítulo 3

### Diseño e Implementación

Este capítulo indica la instrumentación para recolectar datos, el diseño de investigación realizado, las limitaciones de la investigación y otros aspectos relevantes en la implementación del estudio.

#### 3.1 Instrumentación

Para la investigación sobre el uso de Smartphone se utilizan dos instrumentos. El primer instrumento es una aplicación para dispositivos Android diseñada especialmente para la captura de datos de contexto usando distintos sensores que se encuentran integrados en un Smartphone. El segundo es una traducción de un test diseñado para medir el nivel de uso y adicción de un usuario hacia su Smartphone. A continuación se detallan ambos instrumentos:

##### 3.1.1 Aplicación de captura de datos

Se creó una aplicación para la recolección de datos llamada ActivityMonitor. Esta aplicación fue desarrollada en Android y tiene como principales funciones 1) capturar datos de contexto en el que se encuentra el Smartphone de un usuario y 2) capturar el tiempo y forma en que un usuario responde a distintas notificaciones generadas artificialmente. La aplicación una vez instalada funciona de la siguiente forma:

Lo primero que hace la aplicación es solicitar el correo electrónico y el teléfono del usuario para poder identificar al usuario. Una vez completada la información se entrega un

mensaje que confirma la participación del usuario en el experimento y también indica instrucciones básicas acerca del funcionamiento de la aplicación, el rol del usuario en el experimento, políticas de privacidad y un correo de contacto.



Figura 11: Formulario de inicio



Figura 12: Mensaje de confirmación

Luego la aplicación empieza a mandar notificaciones de forma aleatoria, siguiendo una ponderación de la distribución de notificaciones mencionada en el trabajo de Dingler et al [74]. La notificación indica que hay un nuevo mensaje (Fig. 8) y una vez que se accede a éste se abre una interfaz gráfica que pregunta acerca de cómo se siente uno (Fig. 9). La interfaz permite al usuario indicar su estado de ánimo entregando el *emotición* que más lo identifique en ese momento. Para finalizar con la interacción, se pide deslizar el dedo en la pantalla hacia una dirección aleatoria.




Figura 13: Mensaje de la notificación



Figura 14: Interfaz de interacción

Cinco segundos antes de que se envié la notificación, se capturan datos del micrófono y del nivel de luz capturado por el sensor de luz. También se captura el dato sobre la interacción que tuvo el usuario con la notificación, siendo las opciones posibles: ignorar, borrar o responder.

La aplicación además está constantemente capturando datos registrados por el sensor de WiFi, el sensor de geolocalización, el acelerómetro y el sensor de radio del Smartphone.

La siguiente figura explica a grandes rasgos el flujo del proceso de captura de datos de la aplicación.




Figura 15: Proceso general de entrega y respuesta de notificaciones

A continuación se hace una descripción más clara de los datos recolectados el sistema operativo y por cada sensor:



### Estado del Smartphone

- Phone Status: guarda el estado del dispositivo en determinado tiempo. Los estados posibles son: On (Smartphone prendido) y Off (Smartphone apagado).
- WiFi Status: indica si el usuario está conectado a una red WiFi.
- Conectividad: indica si el usuario tiene su Smartphone en servicio y si se encuentra intercambiando datos con alguna red.

### Sensores

- Giroscopio: sensor que registra la orientación espacial del Smartphone.
- Micrófono: graba los sonidos cercanos al dispositivo.
- Acelerómetro: mide la aceleración en el movimiento del dispositivo con respecto al vector de gravedad.
- GPS: indica la geolocalización del usuario, el tipo de conexión que se está usando para obtener las coordenadas correspondientes, y precisión del dato.
- Radio: la aplicación recolecta datos de la radio de cada Smartphone, pero en este caso particular el valor obtenido fue siempre nulo, por lo que no se considera en el análisis.

Para ayudar a contextualizar los datos capturados por los sensores, la aplicación se conecta con una API (interfaz de programación de aplicaciones por sus siglas en inglés) de Google llamada Google's Activity Recognition API [75]. Esta API permite detectar las siguientes actividades en las que se encuentra el usuario:

Situación detectada	Descripción
In_Vehicle	El dispositivo se encuentra en un vehículo.
On_Bicycle	El dispositivo se encuentra trasladándose en bicicleta.
On_Foot	El dispositivo está con un usuario que se encuentra corriendo o caminando.
Running	El dispositivo está con un usuario que se encuentra corriendo.
Still	El dispositivo no se encuentra moviendo.
Tilting	La orientación espacial cambió significativamente con respecto al vector de gravedad.
Unknown	No es posible detectar la actividad actual del dispositivo.
Walking	El dispositivo está con un usuario que se encuentra caminando.

Tabla 4: Actividades reconocidas por la API de detección de actividades de Google. [75]

Todos los datos recolectados por los sensores, el sistema de Android, y los patrones de actividad que reconoce la API de Google se guardan en un servidor que indica la fecha y hora en la que ocurrieron los distintos eventos.

### 3.1.2 Test de sobre uso y adicción a Smartphone

Además de los datos recolectados por la aplicación, este trabajo administra un test que mezcla una modificación del *Smartphone Addiction Scale (SAS)* [23] y el *Smartphone Addiction Propeneness Scale (SAPS)* [77] que son cuestionarios usados para medir el nivel de dependencia y uso a esta tecnología.

El cuestionario SAS consiste en 33 preguntas que buscan representar seis factores de análisis asociados con el nivel de uso y adicción del usuario. Para cada pregunta se tiene que responder el nivel de representación con una pregunta asociada mediante una escala Likert del 1 al 6 (Muy en desacuerdo a Muy de acuerdo).

A continuación se explica cada uno de los seis factores que se logran identificar mediante el test:

#### 1. Perturbación en la vida cotidiana

Explica problemas causados por el Smartphone relacionados con dolores corporales y dificultades para realizar tareas o actividades cotidianas. Entre estos problemas se encuentran: dificultades para dormir, trabajar y concentrarse; sufrir de aturdimiento o visión borrosa; y tener dolor en las muñecas y en la parte posterior del cuello por uso excesivo del dispositivo.

#### 2. Anticipación positiva

Mide la sensación de satisfacción al estar usando un Smartphone, la facilidad que el dispositivo tiene para aliviar el estrés mediante su uso, y la sensación de vacío cuando uno se encuentra sin un Smartphone.

#### 3. Retiro

Estudiar la sensación de retiro involucra estar impaciente, inquieto e intolerante sin un Smartphone; estar constantemente pensando en el dispositivo móvil, incluso cuando no se está usando; e irritarse cuando se es molestado cuando se está usando el dispositivo.

#### 4. Relación con el ciberespacio

Dimensión que mide la relación que tiene un usuario con sus amigos y contactos por medio de servicios de redes sociales (SNS por sus siglas en inglés) y servicios de mensajería instantánea en su Smartphone, en comparación con las relaciones que se tienen en la vida real. Estar constantemente revisando un Smartphone para ver si se tienen notificaciones de algún SNS o servicio de mensajería instantánea y preferir la interacción con personas por Smartphone en vez de en la vida real, dan señales de que se tiene una relación de dependencia con el ciberespacio.

#### 5. Uso excesivo

Se refiere al incontrolable uso que tiene un usuario con su Smartphone. Esto se puede evidenciar cuando el usuario muestra una necesidad de usar el Smartphone inmediatamente después de que lo dejó de usar o cuando éste se procura de llevar siempre un cargador ya la carga diaria del Smartphone no le es suficiente para sus necesidades.

#### 6. Tolerancia

La tolerancia indica el nivel de control que se tiene sobre el uso consiente de un smartphone. Se dice que un usuario tiene poca tolerancia en caso de que reiteradas veces intenta controlar la cantidad de uso de su smartphone pero falla en llegar a ese objetivo.

El test SAPS consiste en un cuestionario de 15 preguntas que busca identificar cuatro factores asociados con el uso de un smartphone. La escala de la encuesta es una Likert del 1 al 4 (nunca a siempre). Los factores que identifica incluyen el Retiro, Relación con el ciberespacio, Tolerancia, y Perturbación de funciones adaptativas. La perturbación de funciones adaptativas mide tanto uso excesivo como la Perturbación en la vida cotidiana.

## 3.2 Diseño de investigación

### 3.2.1 Diseño

El diseño de la investigación consiste en la recolección de datos sobre la forma de respuesta de distintos usuarios al ser expuestos a notificaciones artificiales, siguiendo la lógica de negocios previamente explicada en la sección de aplicación de captura de datos. Estas notificaciones tienen por objetivo simular las notificaciones que el usuario recibe día a día en su Smartphone. La idea del estudio es que bajo esta simulación de notificaciones, se puedan identificar correlaciones entre los datos entregados por el sistema y los sensores de un Smartphone, y la forma de respuesta de un usuario a estas notificaciones.

Para diferenciar la forma de respuesta de un usuario, se estudian los siguientes parámetros:

- 1) Tiempo de respuesta: representa el tiempo que el usuario se demora en responder a una de las notificaciones entregadas por la aplicación.
- 2) Tiempo por sesión: mide el tiempo de actividad de un usuario entre que un usuario prende su celular y luego este se apaga.
- 3) Tiempo de finalización: se define como el tiempo de uso de aplicación, es decir el tiempo que el usuario se demora en completar las tareas solicitadas por la aplicación.
- 4) Tasa de aceptación: indica la cantidad de notificaciones aceptadas y respondidas del total de notificaciones enviadas.
- 5) Tasa de cancelación: mide la proporción de notificaciones eliminadas de la barra de notificaciones del total de notificaciones enviadas.

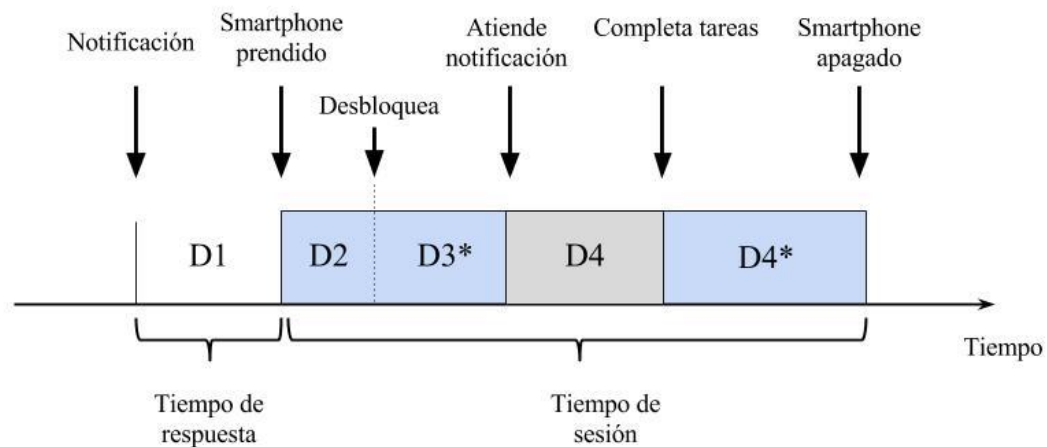


Figura 16: Tiempos de respuesta y situaciones de análisis. Elaboración propia

La figura 13 indica los tiempos de medición usados en la literatura y la subdivisión por decisiones consideradas en esta memoria. Las decisiones que tienen un \* (D3 y D4) indican momentos en que el usuario puede no priorizar las notificaciones entregadas por la aplicación y usar sus Smartphone para interactuar con otras aplicaciones.

Como las tareas que el usuario tiene que hacer son artificiales, es posible que existan sesgos en las respuestas y en la forma de interactuar con la aplicación. Para identificar los factores de los sesgos se dividen las fases del experimento en tres categorías:

### 1. Inicio de la aplicación y primeros pasos

Esta categoría se caracteriza por ser el tiempo en que el usuario se familiariza con la aplicación e indica su sexo y edad dentro de ésta. Se espera que en este periodo las tasas de respuestas sean mayores y los tiempos respuesta sean menores ya que el usuario tiene muy presente que se le está midiendo su comportamiento [76]. Para eliminar este sesgo, se estudiarán los datos dejando un periodo de entrenamiento para el usuario.

### 2. Interacción continua con la aplicación

Esta categoría se caracteriza porque el usuario ya interioriza el hecho de estar siendo monitoreado y puede que incluso ignore deliberadamente las notificaciones al identificar que son enviadas por la aplicación [70]. Una forma de reducir este sesgo es usando el framework explicado en la figura 8 para estudiar si una notificación fue respondida de forma parcial y además estudiar el tiempo de uso del Smartphone debido a la influencia de la notificación.

### 3. Terminación y aplicación de test

Terminado el estudio los usuarios completarán un formulario para determinar el nivel de adicción a los Smartphone que tenga cada uno. Debido a que el usuario es consciente de que el test busca medir su nivel de adicción, es posible que el usuario no conteste de forma sincera debido a la sensibilidad de los datos que se piden [77]. Para minimizar esta posibilidad, se tiene que explicar al usuario que toda información recolectada es de forma anónima y no se puede hacer una conexión entre los datos recolectados por la aplicación y el test con el usuario.

Usando el diagrama de realismo y naturalidad de la Fig.2, y tomando en consideración el diseño de la investigación, se propone el siguiente esquema para ejemplificar el nivel de naturalidad del experimento.

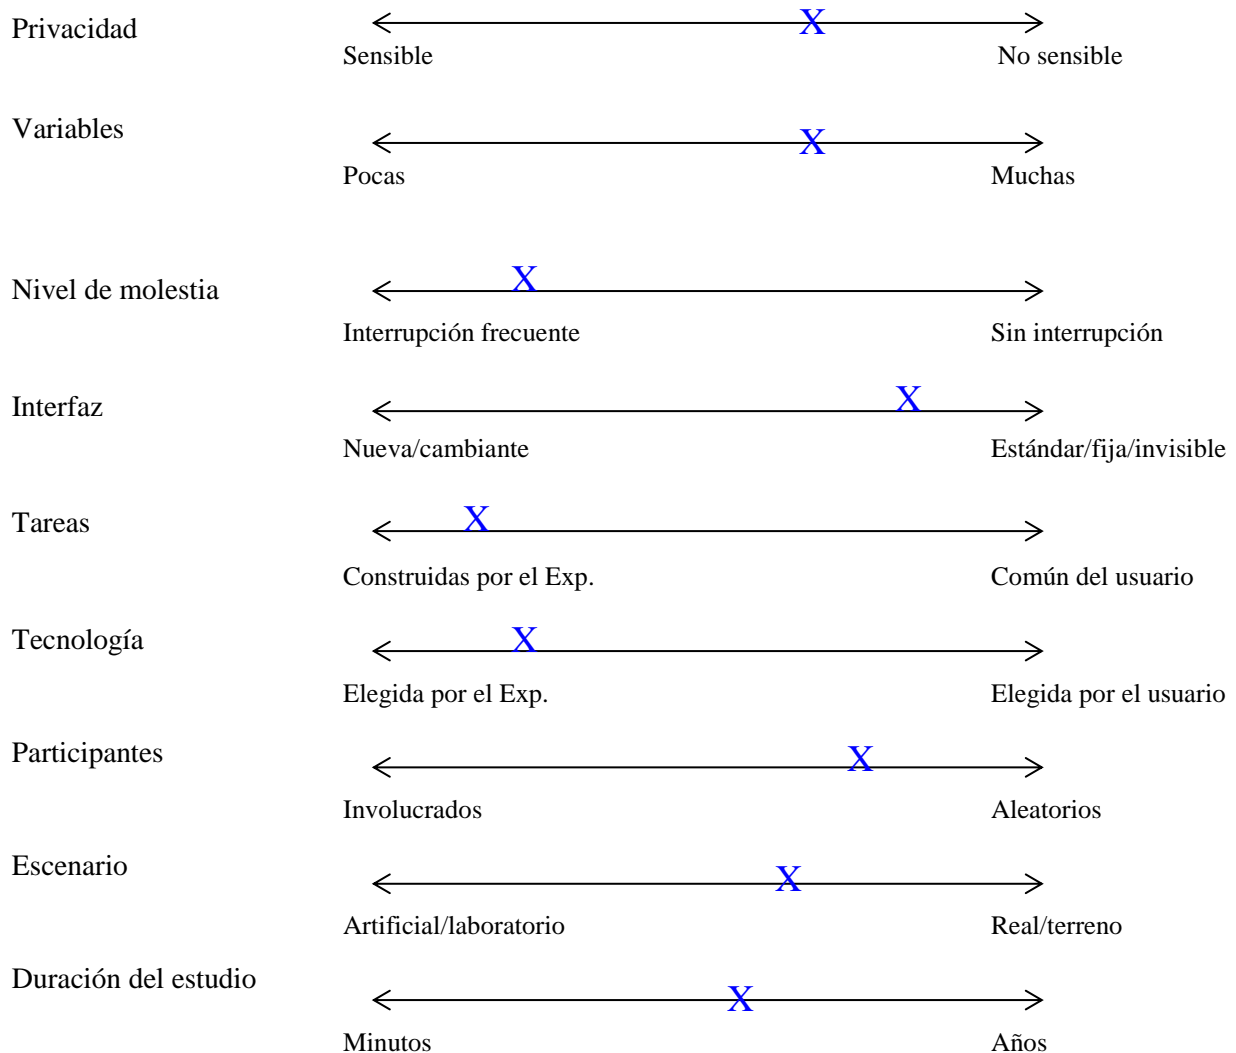


Ilustración 1: Diagrama de realismo a naturalidad proyectado

### 3.2.2 Consideraciones iniciales y limitaciones del diseño

Debido a la naturaleza de la aplicación, el tipo de investigación que se realiza se conoce como una investigación no experimental longitudinal. Esto implica que no se puede hacer una manipulación intencional de las variables independientes, el nivel de control que se tiene sobre los resultados de la investigación son limitados y la recolección de datos no es en un momento único, sino que es continuo a través del tiempo. [24]. Este tipo de estudios logran establecer relaciones entre variables sin precisar sentido de causalidad. Por lo tanto, todos los resultados obtenidos para validar las hipótesis y planteamientos son del tipo correlacional.

Las variables dependientes de la investigación son el tiempo de respuesta a una notificación, la tasa de aceptación y el grado de molestia percibida. Se usan como variables independientes todos los datos capturados por la aplicación y el test de nivel de adicción a Smartphones. También estos datos se usan en el proceso KDD, por lo que cualquier correlación o resultado exploratorio encontrado queda sujeto los tratamientos y minería de datos realizados.

Los datos capturados son de situaciones en las que el usuario está en terreno, no en un ambiente controlado por la investigación. Esto implica que existe una mayor variabilidad esperada de los resultados, pero a la vez aumenta la validez ecológica y ayuda desarrollar aplicaciones para casos en que no se tenga control de las actividades del individuo de estudio.

Cabe destacar que no se conocen los motivos por los que un usuario responde o no a las notificaciones entregadas por la aplicación, siendo posible que exista un sesgo en los datos obtenido de las tasas de respuestas a las notificaciones. Para mitigar este error una opción es estudiar el tiempo de duración de una sesión –tiempo en que una persona prende su Smartphone, interactúa con él y luego lo apaga–, producto de una notificación entregada por la aplicación y no solo la respuesta a lo que pide la notificación. Otra opción es hacer un tratamiento de datos y filtros adecuados para poder evaluar los resultados. Según la distribución de los resultados se harán las correcciones necesarias para disminuir estos sesgos.

Los escenarios de estudio para el nivel de carga cognitiva tienen que ver con actividades físicas y estímulos sensoriales que puedan ser captadas por los Smartphone que tengan instalada la aplicación desarrollada para la investigación. Los casos en que el usuario esté expuesto a una carga cognitiva alta pero se encuentre quieto trabajando, estudiando o poniendo atención en clases no podrán ser identificados. También casos en que el usuario este sufriendo de estrés, ansiedad, frustración o algún otro problema psicológico que perjudique la forma en que responda a distintos estímulos no puede ser capturada y estudiada por la aplicación. Sólo se estudian situaciones con distinto nivel de carga cognitiva basadas la actividad física y nivel de ruido ambiental. Todas estas situaciones necesitan un mayor nivel de recursos cognitivos para poder llevarse a cabo tareas de forma simultanea según el modelo de Múltiples Recursos de Wickens [7]

Al usar como base teórica el modelo de Múltiple Recursos de Wickens, se asumen todos los supuestos mencionados en el marco teórico (capítulo 2).

### 3.3 Grupo de estudio

La investigación se llevó a cabo con la colaboración de estudiantes de ingeniería de la Facultad de Ciencias Físicas y Matemáticas. La selección de este grupo de estudio está fundamentada debido a que existe un grandes facilidades de poder reclutar participantes, la alta tasa de adopción de Smartphones de este segmento, y existente vulnerabilidad al uso excesivo a los Smartphones [78] [42] [79].



## Capítulo 4

### Implementación

Se hizo un llamado público en la plataforma electrónica usada para fines docentes de la Universidad de Chile, U-cursos, y se pegaron afiches en la facultad invitando a participar. El llamado consistió en una invitación para ayudar en una investigación a cargo del profesor Ángel Jiménez del Departamento de Ingeniería Civil Industrial. Dentro del llamado y el afiche se indica el tiempo de duración del experimento, se menciona la necesidad de que los interesados tengan un Smartphone con un sistema operativo Android, se asegura la anonimidad de la información recolectada, y se explica el incentivo económico por participar, incentivo que consiste en tres premios de \$50.000 a repartir entre los participantes que hayan bajado la aplicación y completado la encuesta mencionada en la sección anterior.

Debido a errores en la transferencia de datos de la aplicación, muchos datos que la aplicación debía recolectar no se integraron a la base de datos a la cual se tenía acceso. Es por eso que se tuvo que recurrir a un segundo llamado, bajo las mismas condiciones, a participar en la investigación. Cuando se hizo este llamado, se dio también la posibilidad de dejar de ser parte del experimento y hacer la encuesta, debido a la insistencia de ciertos participantes.

Cabe mencionar que por problemas técnicos, la aplicación no logra capturar el momento en que un usuario desbloquea su Smartphone, por lo que las etapas D1 y D2 no podrán distinguirse. Tampoco se logró capturar el input sobre el estado emocional del usuario.

## Capítulo 5

# Experimentación y Análisis de Resultados

En este capítulo se presentan los resultados obtenidos del experimento. Para esto se siguen las etapas del modelo KDD con el fin de detallar tanto la preparación de los datos como la aplicación de modelos estadísticos y de minería de datos.

### 5.1 Grupo experimental

Un total de 109 personas bajaron la aplicación pero por errores de software solo se consideraron 88 personas que capaces de aportar con alguna información para la investigación. El parámetro considerado para esto es que el usuario tengo al menos datos de micrófonos y del estado de la pantalla por al menos 3 días. De las 88 personas consideradas, sólo 43 personas tienen registros de la variable interacción.

### 5.2 Formato de resultados

Todos los datos de los sensores siguen la misma estructura general en la base de datos en la que son alojados. Cada dato de sensor en la base de datos tiene las siguientes columnas:

- `Sense_start_time`: es el timestamp UNIX en milisegundos, el cual es el número de milisegundos totales transcurridos desde el 1 de enero de 1970.
- `Data_type`: indica el sensor del cual proviene le dato.
- `User_id`: indica el usuario de los datos entregados por el sensor.
- `Data`: es un string que contiene toda la información capturada por el sensor, incluyendo también los datos de las 3 columnas mencionadas con anterioridad. Esta

información depende fuertemente de cada sensor, por lo que se tuvieron que hacer scripts separados para poder separar la información relevante de cada sensor.

## 5.3 Procesamiento de datos

A continuación se explica el procedimiento para analizar los distintos sensores y de los datos obtenidos por el sistema operativo de Android recolectados gracias a la aplicación ActivityMonitor.

### 5.3.1 Micrófono

#### 5.3.1.1 Selección

Los datos del sensor del micrófono representan la amplitud del ruido registrado en el ambiente, por lo que elegir esta variable es útil para conocer el contexto auditivo en el que está un usuario.

#### 5.3.1.2 Pre-procesamiento

Los datos del micrófono son los únicos datos que se guardan como una lista de strings en vez de un dato único dentro de una celda en la base de datos. Se hizo un script en MySQL que identifica la lista de valores guardados en un periodo dado, obteniéndose en el proceso muchos valores repetidos. Obtenidos los datos en MySQL, se hizo un script en R para romper la lista y obtener cada uno de los datos del sensor para ese determinado instante. También se limpiaron los primeros datos entregados por el sensor, siendo siempre una serie de datos nulos.

#### 5.3.1.3 Transformación

Debido a la alta variabilidad de información de este sensor, se optó por hacer un análisis exploratorio para intentar clusterizar el nivel de ruido y poder dividirlo en categorías según el nivel de ruido.

## 5.3.2 Sensor de luz

### 5.3.2.1 Selección

El nivel de luz indica la luminosidad en lux al cual está expuesto el Smartphone del usuario. Se seleccionó esta variable ya que ayuda a entender posibles lugares en donde el Smartphone está expuesto.

### 5.3.2.2 Pre-procesamiento

Se obtuvieron los datos del sensor de luz que se encuentran en la base de datos separando el valor de la luminosidad capturada y el máximo de luminosidad que el sensor puede capturar.

Los datos que no tenían un valor negativo o con un valor de luminosidad superior a su rango máximo fueron eliminados. Debido a que este sensor entrega muchos datos con diferencias de 1 segundo o menos, se estudió la posibilidad de hacer un match entre los datos del sensor de luz y los datos del micrófono que tuvieran exactamente la misma fecha, esto ya que vendrían siendo los datos pareados según como está pensada la aplicación, pero debido a que al implementar este tratamiento se redujo significativamente la cantidad de datos a estudiar, no se hizo una unión condicionada.

### 5.3.2.3 Transformación

Se mantuvo el valor original del sensor y además se hizo una transformación para normalizar los datos. Esta normalización corresponde a la división entre el valor detectado de luminosidad y el máximo rango de luminosidad que detecta cada dispositivo, siendo entonces el porcentaje de luminosidad la nueva variable de estudio del sensor de luz.

Al igual que en el caso del micrófono, se hizo un análisis exploratorio para intentar clusterizar el nivel de luz y poder dividir en categorías el nivel de luz.

### 5.3.3 Sensor de radio

#### 5.3.3.1 Selección

Debido a que la gran mayoría de los datos recolectados por la aplicación sobre este sensor tenían datos nulos, no se seleccionó esta variable para analizarla.

### 5.3.4 Sensor de GPS

#### 5.3.4.1 Selección

El sensor de GPS entrega datos sobre el tipo de conexión por la cual se está recibiendo la señal de GPS y la velocidad con la cual se mueve el usuario. Los posibles valores son GPS, Network o Fused. Estos valores indican ayudan a entender si un usuario se encuentra conectado a una red o se encuentra utilizando un paquete de datos para obtener su localización.

No se seleccionó la latitud ni longitud de los datos obtenidos por motivos de privacidad y temas éticos. Tampoco se seleccionó la precisión ya que no fue posible normalizar de forma correcta los datos, mostrando una diferencia entre los datos de varios órdenes de magnitud.

#### 5.3.4.2 Pre-procesamiento

Se obtuvieron los datos de geolocalización que se encuentran en la base de datos, separando con un script en MySQL los datos del proveedor de la señal de localización y la velocidad.

El único tratamiento de datos realizado fue eliminar los duplicados.

## 5.3.5 Interacción con la aplicación

### 5.3.5.1 Selección

Se seleccionó a la variable interacción para poder hacer análisis básicos y estudiar el comportamiento de la variable con respecto a los otros datos de los sensores.

### 5.3.5.2 Pre-procesamiento

Se obtuvieron los datos del tipo de interacción según el tipo de respuesta indicada en la base de datos. Las respuestas guardadas no hacían mención a el tipo de emoticón el usuario ingresaba, si no que indicaban si había un caso igual a *dismiss* o que no se respondió.

### 5.3.5.3 Transformación

Se transformó el tipo de respuesta a un factor más fácil de estudiar, dejando como posibles respuestas: Borrado y Visto. También, en caso de que haya llegado una notificación y el usuario no haya interactuado con una notificación anterior, se cambió el valor anterior de interacción a Acumulado, para indicar que es un tipo de interacción diferente.

## 5.3.6 API de Google

### 5.3.6.1 Selección

El dato entregado por la API de Google indica la actividad del usuario que registra el Smartphone. Se seleccionó esta variable ya que es la principal variable que se tiene para poder identificar la actividad física en la que se encuentra un usuario.

### 5.3.6.2 Pre-procesamiento

Se hizo un script en MySQL que separara la precisión y el tipo de dato obtenido. Se eliminaron los datos repetidos y que registraran una misma actividad de forma consecutiva. También se eliminaron todos los datos con un precisión bajo 75% y los datos con indicaran type = unknown.

### 5.3.7 Estado de pantalla

#### 5.3.7.1 Selección

El estado de pantalla se seleccionó para entender de mejor forma el tipo de interacción que un usuario tiene en su Smartphone por lo que se hizo un script en MySQL para recolectar el dato de estado de pantalla.

#### 5.3.7.2 Pre-procesamiento

Los datos que registraran indicaran una continuidad en el estado del Smartphone se eliminaron, tomando solo en consideración los primeros registros de un determinado estado de la pantalla.

#### 5.3.7.3 Transformaciones

Se crearon 2 variables adicionales al hacer distintas transformaciones de los datos del estado de la pantalla. La primera es el tiempo en que el smartphone pasa prendido por día y hora. La segunda es la cantidad de veces que se enciende la pantalla de un Smartphone por día y hora.

## 5.3.8 Conectividad del Smartphone

### 5.3.8.1 Selección

A pesar de que saber el estado de la conectividad del Smartphone puede ayudar a saber si se está interactuando o compartiendo información por internet, no se seleccionó este dato ya que la granularidad por segundo y el constante cambio de los datos hizo imposible poder concluir el estado de la conectividad del Smartphone. Se hicieron transformaciones para poder simplificar el análisis de este dato pero de todas formas no se pudo llegar a un consenso producto que cada segundo registraba múltiples estados diferentes.

## 5.4 Análisis Estadístico

El siguiente apartado presenta estadísticos descriptivos los datos obtenidos por la aplicación ActivityMonitor y el cuestionario sobre el perfil de adicción y uso que un usuario le da a su Smartphone. También se muestran los resultados de los test de hipótesis usados para validar las hipótesis de investigación.

### 5.4.1 Análisis exploratorio de datos

#### 5.4.1.1 Micrófono y sensor de luz

Debido a que el micrófono y el sensor de luz son los únicos valores con múltiples datos distintos en un rango corto de tiempo, y además no tienen una forma de poder ser interpretados intuitivamente, se hicieron análisis estadísticos enfocados en poder encontrar alguna forma de interpretar los resultados.

La figura 14 muestra la distribución de los datos del micrófono. De la gráfica se observa la existencia de unos pocos valores extremos, debido a estos se procedió a transformar el dato al aplicar un logaritmo natural.



## Histograma datos de micrófono

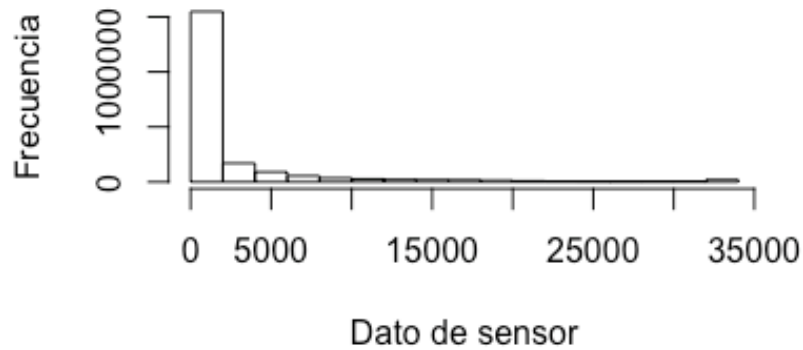


Figura 17: Histograma datos micrófono

Debido a la presencia de valores extremos, se transformó los datos del micrófono.

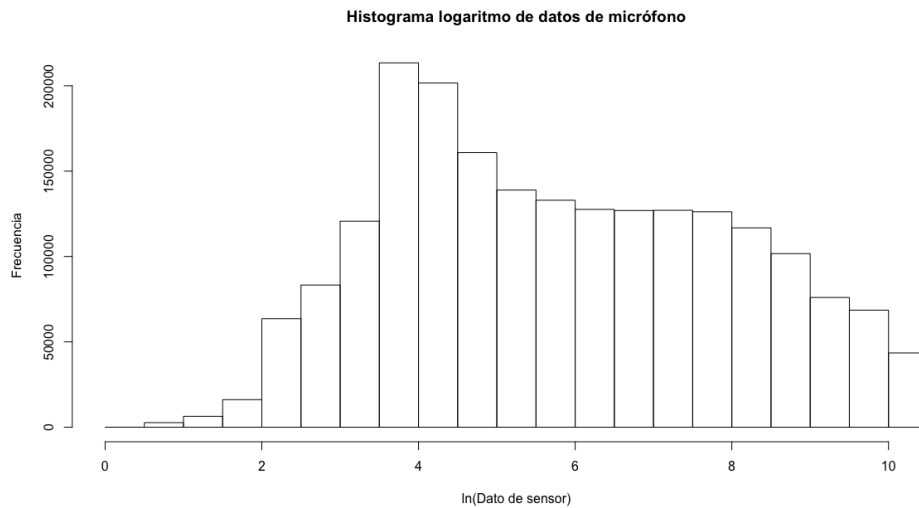


Figura 18: Histograma logaritmo micrófono

Se hicieron tests de normalidad para ver si se puede usar un enfoque paramétrico y usar ANOVA para los valores obtenidos en distintas situaciones usando el micrófono. Analizando el gráfico de Cullen y Frey (Fig.16) y el resumen de test de normalidad (Fig.17) se observa que la distribución con mejor ajuste es la distribución uniforme, a pesar de tener

buenos resultados en el test QQ. La tabla 5 en cambio, indica un alto kurtosis, lo que dificulta asumir un enfoque paramétrico para esta variable. Por ahora no se asumirá normalidad y se volverá a hacer el análisis con los nuevos datos recolectados.

min:	0
max:	10,39
median	5,57
mean	5,81
stand. dev	2,16
skewness	0,23
Kurtosis	2,04

Tabla 5: Resumen datos log-micrófono

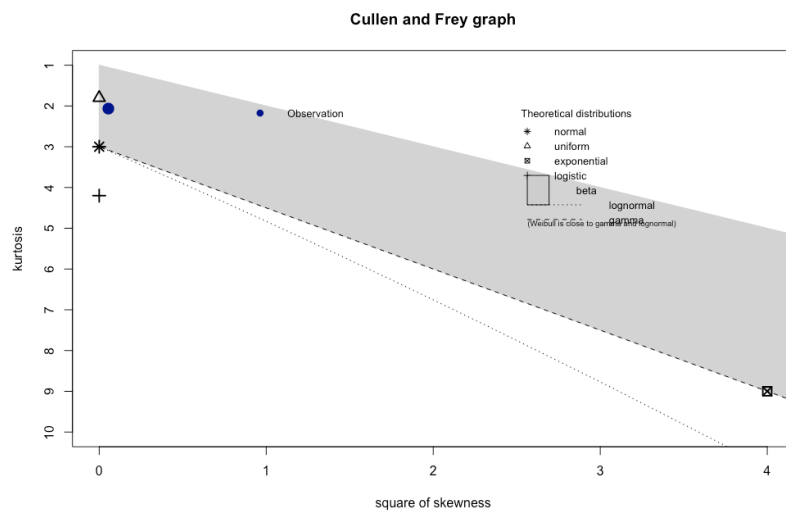


Figura 19: Gráfico de Cullen y Frey - Micrófono

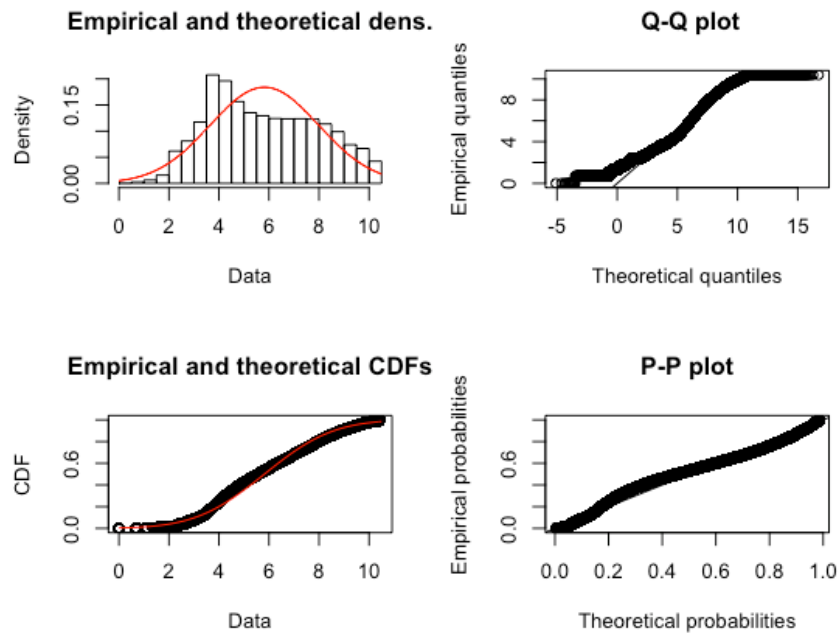


Figura 20: Resumen tests de normalidad

Para terminar con el análisis descriptivo de micrófono, se clusterizan los datos del micrófono con el fin de poder categorizar de manera intuitiva los resultados obtenidos. Para esto se usó el algoritmo k-means, entregando los resultados que se observan en la figura 18.




Figura 21: Selección cluster micrófono

Se eligieron 3 clusters ya que la disminución de la suma de cuadrados no es tan pronunciada en el cuarto cluster en comparación con los 3 primeros casos. Al tomar esta cantidad de clusters los resultados del logaritmo de los datos del micrófono se pueden clasificar de la siguiente forma:

	Silencio o poco ruido	Ruido	Mucho ruido
Ln(Micrófono)	[0 - 4,91)	[4,91-7,30]	(7,30 - inf)

Para el caso del sensor de luz se usó el mismo tipo de análisis que para en los datos del micrófono. El histograma en esta ocasión muestra una menor probabilidad de que se siga una distribución normal, y el gráfico de Cullen y Frey no muestra cercanía con ninguna distribución.




Figura 22: Histograma porcentaje luminocidad




Figura 23: Gráfico de Cullen y Frey - Porcentaje de luminocidad

Por lo tanto se descarta la posibilidad de usar enfoques paramétricos con el porcentaje de luz captada. Solo falta ahora intentar clusterizar la cantidad de luz que se obtiene, usando los mismos algoritmos del análisis del micrófono.

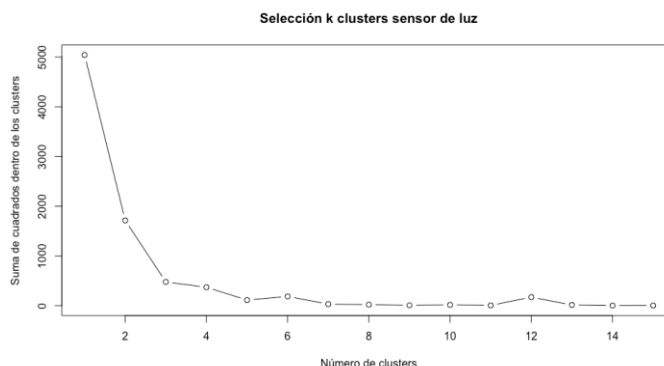


Figura 24: Selección cluster- Sensor de luz

Se utilizaron 3 clusters para poder categorizar los datos del porcentaje lumínico captado. Los resultados de los clusters se observan a continuación:

	En bolsillo o poca luz	Luz ambiente	Exterior o expuesto al sol
Porcentaje(Luz)	[0- 42,85 )	[42,85-80]	[80, 100]

#### 5.4.1.2 Pantalla

El análisis de los datos de pantalla toma en consideración el tiempo promedio total que un celular pasa prendido por día y la cantidad de veces promedio que se prende el celular por día. Para eso se utilizaron funciones de agregación de datos y se hizo el cálculo de tiempo entre un teléfono pasa de un estado prendido a uno apagado para cada caso.

	Prom (min)	Std.dev(min)	Prom(Sesiones)	Std.dev(Sesiones)
Lunes	299.16	171.81	109.54	75.90
Martes	337.22	198.00	102.36	68.43
Miércoles	341.22	185.59	113.90	64.60
Jueves	327.11	163.86	108.36	53.60

Viernes	271.13	176.81	106.55	70.62
Sábado	286.47	183.41	96.64	94.27
Domingo	321.26	210.80	81.30	51.38

Tabla 6: Media y desviación estandar por día

Si se comparan estos resultados con los de otros estudios que examinan el tiempo de uso de Smartphones en estudiantes universitarios [69] [64], se observa que en el caso chileno los usuarios de Smartphones tienen un comportamiento levemente menor al del caso coreano para la cantidad de minutos usando su dispositivo, pero es significativamente menor para el caso de la cantidad de sesiones por día.

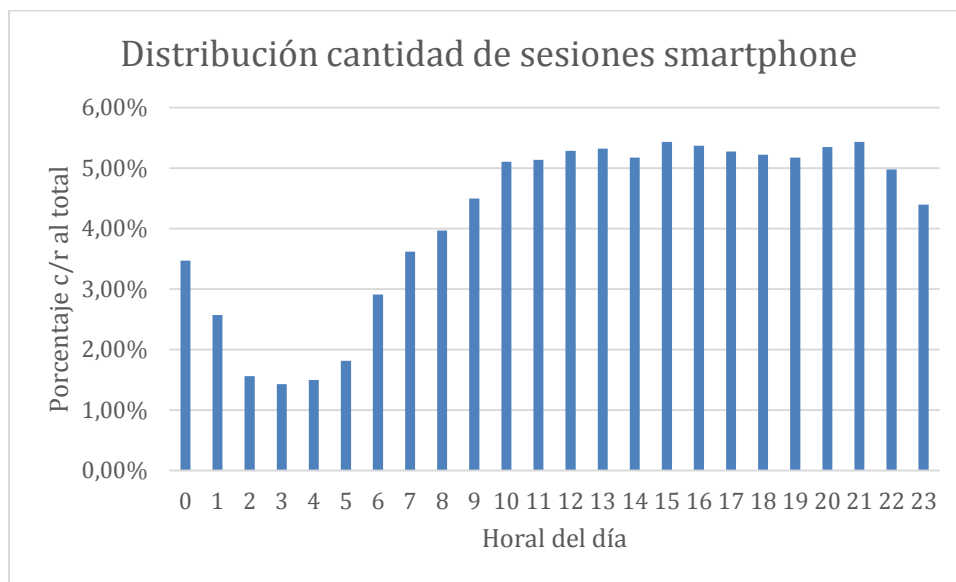


Figura 25 Distribución sesiones




Figura 26 Distribución tiempo de uso

Analizando la distribución de sesiones y minutos con respecto a su total, se observa que existe un incremento la cantidad de tiempo que se está en usando un Smartphone entre las 22 y 23 hrs. Esto también se observa en otros estudios similares [69], y muestra que la recolección de los datos de tiempo de uso tiene un comportamiento similar entre los jóvenes de Chile y Corea del Sur.

#### 5.4.2 Test de SAS y SAPS

Se hicieron traducciones para los test de SAS y SAPS de inglés a español los cuales fueron revisados y validados por 2 magister en traducción de la Pontificia Universidad Católica de Chile. Traducido el test se realizó a el cuestionario a un grupo de control de 20 personas, las cuales dieron feedback sobre preguntas que no se entendían o que no tenían sentido. Se realizaron los cambios pertinentes y se creó un nuevo test el cual contiene 33 preguntas las cuales mezcla preguntas del test SAS y el test SAPS.

El test fue respondido por 150 personas, con 93 respuestas de hombres (62%) y 57 respuestas de mujeres (38%). El promedio de edad de los que contestaron la encuesta es de  $22.32 \pm 3.26$

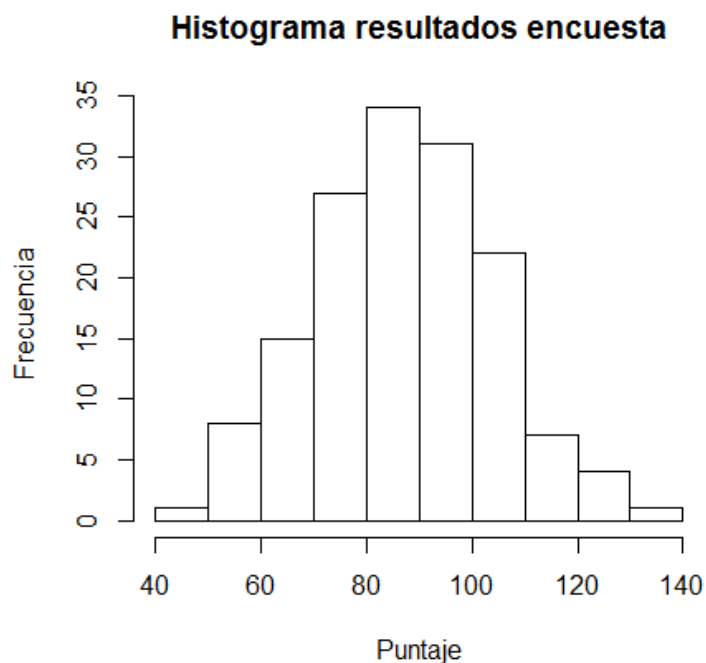


Figura 27 : Histograma resultados encuesta

Se hizo un test de Shapiri-Wilk dando como resultado un p-valor de 0.9053, lo que muestra que los resultados distribuyen de forma normal. Al realizar un análisis de componente, se observó que con 6 componentes se logra explicar el 54% de la varianza, resultado que no es favorable para usar los mismos factores usados internacionalmente. También se realizó un test de Scree para determinar la cantidad de factores dado el valor de los eigenvalues, donde el test indicó que el óptimo son 9 factores (Ver anexo 2) y al realizar un análisis exploratorio de factores con una rotación oblicua Oblimin, se demostró que no es posible homologar el test SAS en Chile.

Del test realizado, se procedió a estudiar las 15 preguntas correspondientes al test SAPS de sobreuso. Al realizar el mismo tipo de análisis mencionado anteriormente, se observa que cuatro componentes explican un 65% de la varianza, lo cual es consistente con el estado del arte para este tipo de test [82].

El test de Scree indicó que al menos 3 factores pueden ser suficientes (Ver anexo 3) y los resultados del análisis exploratorio con rotación oblicua Oblimin indican 4 factores los cuales se pueden observar en la sección de anexos.



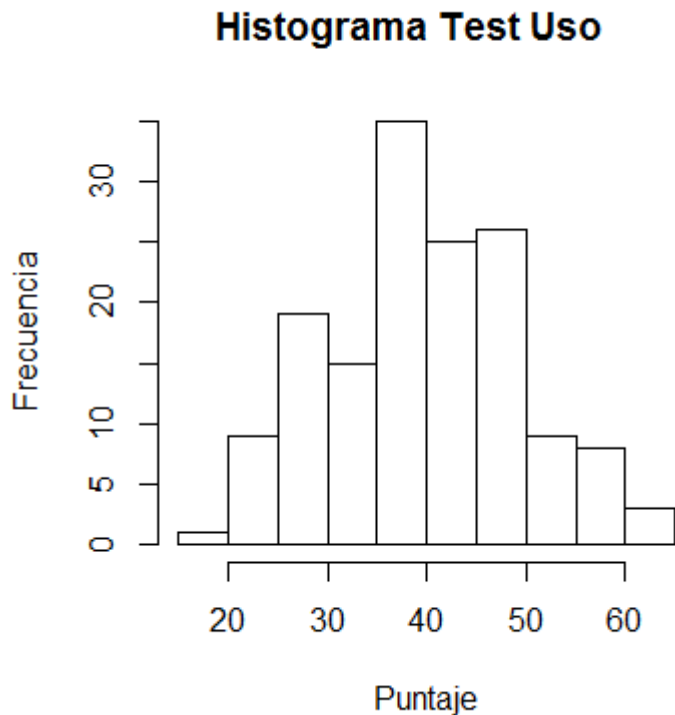


Figura 28: Histograma test uso (SAPS)

También se probó la validez interna del test, entregando un Alfa de Cronbach igual a 0.73, lo cual se considera confiable [83].

Por último, se realizó un test de Kaiser-Mayer-Olkin para medir que la muestra con la que se hicieron los análisis es adecuada para comprobar la validez del test [84]. El resultado del test 0.82, lo que indica que la muestra es significativa.

Como los resultados del test de uso fueron favorables, se usarán los resultados de este test para dividir la muestra de usuarios según usuarios activos y usuarios normales de Smartphone. Para hacer la distinción entre tipos de usuarios se usó la metodología propuesta por Lee et al [64], en donde se considerará como una persona que es potencialmente adicta a un Smartphone si tiene un puntaje total en el test mayor a 46 o en el factor correspondiente a la Perturbación en la vida cotidiana tiene una puntuación mayor a 14.

La cantidad de personas adictas bajo esas condiciones es igual a 33 (38%) y son 54 (62%) la cantidad de personas que usan su Smartphone de forma más moderada. Este resultado es consistente con lo expuesto por Lee et al [64], el cual es un 37% de adictos y 63% de uso común.

Las siguientes figuras muestran la cantidad de sesiones y el tiempo promedio de uso de Smartphone según el perfil de uso del Smartphone mencionado anteriormente.




Figura 29: Tiempo de uso por día según perfil de adicción

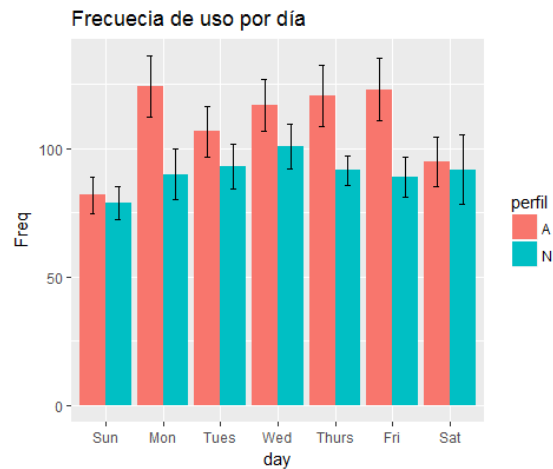


Figura 30: Frecuencia de uso por día según perfil de adicción

De las figuras se observa que hay una notoria diferencia entre el modo de un Smartphone entre los distintos perfiles.

### 5.4.3 Test de Hipótesis

El objetivo de esta sección es comprobar estadísticamente que existen diferencias significativas entre los tiempos de respuestas a notificaciones según carga cognitiva y perfil de adicción, y otras variables que sirven para explicar el contexto de un usuario a la hora de interactuar con una notificación.

Cabe mencionar que se comprobó usando un paquete estadístico en R que la distribución de los datos no sigue una distribución normal, se tienen que hacer test de hipótesis no paramétricos para testear las distintas hipótesis de investigación. Se hizo un Mann-Whitnet U test para los test de hipótesis relacionados con el perfil de adicción y un Kruskall-Wallis Rank Sum test para las otras variables que no son binarias.

Para ser consistente con el framework propuesto por Turner et al es necesario testear según las distintas fases de una respuesta, es decir, cuando se prende un celular, luego cuando se desbloquea, y por último cuando se interactúa con la notificación. En este caso particular no se puede diferenciar la acción de desbloquear, por lo que se reducen los casos a testear.

Primero se testea el tiempo de respuesta a prender el Smartphone. Para esto se modifica la base de datos para solo estudiar los casos en que el Smartphone haya estado apagado cuando llegó la notificación.

Tiempo de respuesta para prender el celular. N = 9,906							
Variable	Perfil	Tipo Actividad	Nivel Ruido	Nivel Luz	Proveedor GPS	Día Semana	Etapas del día
P-Value	0.02559	2.2e-16	2.2e-16	0.5761	2.2e-16	5.319e-07	2.2e-16

Se rechaza la hipótesis nula para todas las variables con excepción del nivel de luminosidad.

Calculado la primera fase se procede a estudiar el tiempo de demora en interactuar con la notificación y ver si existen diferencias significativas entre estos tiempos de demora dadas las variables estudiadas con anterioridad.

Tiempo de respuesta para prender el celular e interactuar con una notificación. N = 2.836							
Variable	Perfil	Tipo Actividad	Nivel Ruido	Nivel Luz	Proveedor GPS	Día Semana	Etapas del día
P-Value	2.2e-16	0.05007	1.758e-07	0.9637	0.005157	0.4048	1.512e-10

Se rechaza la hipótesis nula para el tipo de actividad, el nivel de ruido y la etapa del día.

De los resultados obtenidos se puede concluir que ciertas variables de contexto influyen tanto en el tiempo de demora para reaccionar a una notificación, como en el tiempo demorado para interactuar con esta.

Las variables que ayudan a entender el contexto cognitivo de una persona y que además muestran significancia cercana al 95% en los tiempos de reacción e interacción son el tipo de actividad captado por la API de Google y el nivel de ruido en el ambiente.

También se realizó un test de hipótesis para ver si existen diferencias significativas en el tiempo tomado para interactuar con una notificación cuando se tiene el Smartphone prendido.

Tiempo de respuesta para interactuar con una notificación dado que el celular está prendido. N = 1,407							
Variable	Perfil	Tipo Actividad	Nivel Ruido	Nivel Luz	Proveedor GPS	Día Semana	Etapa del día
P-Value	2.348e-14	0.04245	8.161e-06	0.1865	0.03124	0.1687	0.001039

Se rechazan las hipótesis nulas para todas las variables con excepción del nivel luminosidad y el día de la semana.

Por último, como complemento a las hipótesis de investigación mencionadas en la sección 1, se estudió la existencia de diferencias significativas entre la duración de una sesión producto de la llegada de una notificación dado las variables mencionadas anteriormente.

Tiempo de respuesta para prender el celular e interactuar con una notificación. N = 9,906							
Variable	Perfil	Tipo Actividad	Nivel Ruido	Nivel Luz	Proveedor GPS	Día Semana	Etapa del día
P-Value	0.06707	1.932e-13	2e-16	0.1417	2.2e-16	3.218e-06	2.2e-16

Se rechazan las hipótesis nulas para todas las variables con excepción del nivel luminosidad y el perfil de adicción del usuario.

## 5.5 Minería de datos

Esta sección tiene como objetivo mostrar el proceso utilizado en distintos algoritmos de minería de datos con el fin de clasificar el tipo de interacción que tendrá un usuario con una notificación y el perfil de adicción de un usuario.

La clasificación del tipo de interacción del usuario con una notificación se divide además en 2 partes. La primera es el caso en que se busca clasificar dado que el usuario puede ver, borrar o ignorar la notificación. El segundo caso sólo clasifica con una base de datos en la que el usuario vio o borró la notificación entregada.

### 5.5.1 Deep Learning

Como se mencionó en la sección 2.7, el modelo de Deep Learning utilizado en esta memoria es una red neuronal multicapa prealimentada. Se tomaron consideraciones adicionales para no lograr un sobreajuste (overfitting en inglés) del modelo. Estas consideraciones incluyen una modificación a la función de costo a la siguiente función:

$$L'(W, B | j) = L(W, B | j) + \lambda_1 R_1(W, B | j) + \lambda_2 R_2(W, B | j)$$

Con

$\lambda_1 R_1(W, B | j)$  : suma de todos los pesos y umbrales de activación del modelo.

$\lambda_2 R_2(W, B | j)$  : suma de los pesos y umbrales de activación del modelo al cuadrado.

$\lambda_1, \lambda_2$ : constantes muy pequeñas.

Estas restricciones hacen que muchos pesos se conviertan en 0, lo que añade estabilidad y mejora la generalización del modelo.

También se usó una función de *Dropout* la cual desactiva neuronas con cierta probabilidad [85] y se limitó el máximo peso que puede tener la suma de un peso al cuadrado.

## 5.5.2 Machine Learning

A diferencia del caso de Deep Learning, en los algoritmos de Machine Learning no crean sus propios features, por lo que es necesario entregar una serie de posibles features y luego usar algún tipo de algoritmo que seleccione los más adecuados.

### 5.5.2.1 Features

Como se clasifican 2 modelos distintos, se crearon distintos sets de features para cada caso particular. Los features propuestos para la clasificación de la interacción con una notificación son las siguientes variables:

- Fecha en que llegó la notificación.
- Etapa del día.
- Cantidad de notificaciones acumuladas por el usuario.
- Frecuencia promedio de sesiones.
- Mediana del tiempo de uso del Smartphone.
- Tiempo de sesión.
- Sexo del usuario.
- Nivel de luminosidad.
- Dato de luminosidad.
- Nivel de amplitud.
- Dato de amplitud del sonido.
- Fechas de registro de los sensores.
- Perfil de adicción.
- Estado de la pantalla.

Para la clasificación se usó el mismo set de variables mencionadas anteriormente pero excluyendo todo dato correspondiente a una fecha, ya que no se busca condicionar el análisis a un periodo en particular, si no que con respecto a los datos capturados por los sensores y forma de uso del Smartphone.

### 5.5.2.2 Selección de features

Para seleccionar los features en cada modelo se usó el algoritmo y paquete estadístico Boruta de R. Este es un algoritmo que encuentra todas las variables relevantes, del tipo wrapper basado en un algoritmo de clasificación tipo Random Forest. Se seleccionó este algoritmo debido a que puede detectar posibles interacciones entre variables y no necesita que todas los features sean del tipo numérico con el fin de sacar correlaciones. El algoritmo entrega una medida de la importancia de cada feature, la cual indica la pérdida de la exactitud en la clasificación del Random Forest causada por la permutación aleatoria de cada feature. [86]

Los resultados de la selección de features y la importancia de cada uno para los modelos que se buscan clasificar se observan en las siguientes figuras.




Figura 31: Selección de features con su importancia – Modelo: Interacción

## Importancia de Variables - Perfil Uso




Figura 32: Selección de features con importancia – Modelo: perfil de adicción

Para el caso de los features sobre la interacción, se observa que la cantidad de notificaciones acumuladas es la variable más importante, seguida por las fechas en que se mandó la notificación y si estaba prendido el Smartphone para esa fecha. No se seleccionó el estado de la pantalla previo a la notificación (screen1) y el nivel de luminosidad (nivelL). Una explicación para intentar explicar el hecho de que el estado de la pantalla previo al mensaje no sea de importancia que existen otras variables que logra explicar el estado del teléfono pero con más información (fechaS1) y que al saber el estado de la pantalla en el momento siguiente (screen2) se puede inferir el estado de screen1.

Todos los features para el perfil de uso fueron seleccionados, donde se observa que la frecuencia de uso y la mediana del tiempo de uso son los más importantes.



### 5.5.3 Modelamiento

Se utilizan 3 algoritmos de Minería de datos. Support Vector Machine, Regresiones Logísticas y Redes Neuronales Prealimentadas. Estos modelos son usados para clasificar el tipo de respuesta a una notificación y el perfil de adicción de un usuario. Para incorporar el framework de Turner et al. se dividieron las clasificaciones de la interacción con la notificación para un caso general, un caso en que el Smartphone se encontrara prendido y otro en el que estuviera apagado.

La proporción de datos para testear los modelos de clasificación son de 30% del total, quedando el otro 70% como entrenamiento, y se tomaron medidas para mitigar el balanceo de clases para el caso de clasificación de interacción con 3 clases.

#### 5.5.3.1 Interacción - 3 clases

- Caso Gral

	Precisión	Recall	Spec	Accuracy
Deep Learning	92,8%	93,6%	96,2%	96,8%
SVM	93,6%	93,6%	93,6%	93,6%
Logit	93,6%	93,6%	93,6%	93,6%

Figura 33: Comparación de modelos - Interacción 3 clases, caso general

- Caso Prendido

	Precisión	Recall	Spec	Accuracy
Deep Learning	89,7%	87,4%	91,3%	94,5%
SVM	41,6%	51,8%	86,2%	78,5%
Logit	49,0%	74,0%	82,0%	82,40%

Figura 34: Comparación de modelos – Interacción 3 clases, caso prendido

- Caso Apagado

	Precisión	Recall	Spec	Accuracy
Deep Learning	89,9%	89,1%	94,3%	95,4%
SVM	62,0%	69,7%	84,4%	71,9%
Logit	42,4%	64,3%	79,2%	67,5%

Figura 35: Comparación de modelos - Interacción 3 clases, caso apagado

Los mejores resultados se observan con el algoritmo de Deep Learning, seguido por el modelo de SVM y por último el modelo Logit Multinomial.

La baja precisión de los modelos de SVM y Logit para el caso de que el Smartphone este prendido se puede explicar por el desbalanceo de los datos y la alta reducción de datos producto de estudiar un caso particular. La alta especificidad muestra una preferencia hacia elegir que se acumulará un mensaje-

#### 5.5.3.2 Interacción - 2 clases

- Caso General

	Precisión	Recall	Spec	Accuracy
Deep Learning	94,7%	94,4%	89,7%	92,8%
SVM	93,2%	91,7%	89,9%	92,1%
Logit	89,0%	95,1%	92,0%	86,0%

Figura 36 : Comparación de modelos – Interacción 2 clases, caso general

- Caso Prendido

	Precisión	Recall	Spec	Accuracy
Deep Learning	92,8%	93,6%	96,2%	96,8%

SVM	92,6%	92,2%	84,9%	89,8%
Logit	89,0%	95,1%	92,0%	86,0%

Figura 37: Comparación de modelos – Interacción 2 clases, caso prendido

- Caso Apagado

	Precisión	Recall	Spec	Accuracy
Deep Learning	92,8%	93,6%	96,2%	96,8%
SVM	98,9%	94,7%	91,7%	94,4%
Logit	96,0%	93,0%	92,4%	92,0%

Figura 38 : Comparación de modelos – Interacción 2 clases, caso apagado

Como era de esperar, se observa que al reducir la clase de la variable de interacción los resultados promedios mejoraron. Los mejores resultados para especificación y exactitud fueron obtenidos por el modelo de Deep Learning, pero en precisión y recall el modelo de SVM logra un mejor ajuste.

### 5.5.3.3 Perfil de usuario

	Precisión	Recall	Spec	Accuracy
Deep Learning	84,4%	85,8%	89,1%	87,7%
SVM	81,4	79,4	83,4	83,4
Logit	68,4	72,4	74,4	78,4

Figura 39: Comparación de modelos - Perfil del usuario

Siguiendo la línea de los resultados anteriores, el modelo de Deep Learning entrega los mejores resultados. Cabe destacar que los resultados entregados por el SVM son similares a los resultados obtenidos por Lee et al[64] al buscar clasificar el tipo de adicción entre usuarios.

Como el modelo de Deep Learning es el que entrega mejores resultados, se calculó el tiempo de demora en testear los resultados para ver si es posible hacer una predicción en tiempo real. Para cada uno de los diferentes modelos de interacción y el modelo sobre el perfil del usuario, se obtuvo en promedio un tiempo de demora inferior a 0.05ms por lo que es factible implementar el modelo en tiempo real.

## Capítulo 6

### Discusión

El estudio tenía como objetivo estudiar el comportamiento de los usuarios al recibir notificaciones bajo distinto nivel de carga cognitiva teórica. Se creó la aplicación para recolectar datos, y se implementó el estudio en dos ocasiones diferentes debido a que el desempeño de la aplicación no fue el esperado una vez implementado por primera vez. Posterior a la experimentación se hizo un test a los participantes para poder identificar una posible adicción y su nivel de sobreuso de la tecnología de Smartphone. Luego de eso se implementó el cuestionario de forma masiva para mejorar la validez interna de los resultados obtenidos por el cuestionario. A pesar de que la segunda aplicación sí entregó mejores resultados que la primera, también se observó información incompleta e incoherente entre los distintos sensores. Después de múltiples filtros se estudió un total de 22.310 mensajes.

El análisis estadístico demostró que existe una diferencia significativa en el tiempo de respuesta a una notificación, tanto en demorado en prender el Smartphone, como en el tiempo usado para responder, según la actividad del usuario y el nivel de ruido detectado por la aplicación. Esto logra comprobar la importancia de la carga cognitiva a la hora de interactuar con un Smartphone, validando la hipótesis de investigación.

El test realizado para medir la adicción y sobreuso de un usuario a un Smartphone no entregó los factores deseados, por lo que se procedió a estudiar las 15 preguntas que corresponden al test de sobreuso, test que sí entregó resultados consistentes con la literatura. Una de las razones por las que se estima que el test de 33 preguntas no funcionó, es debido a que contiene un factor que la mayoría de los identificaron como algo que nunca ocurría. Este factor es el que corresponde a problemas fisiológicos por el sobreuso del Smartphone, como dolor de cuello u ojos y mareos. El test de 15 preguntas sí logra identificar los factores como era de esperarse y al ponderar los puntajes se obtiene un resultado consistente con el del estado del arte. El test de hipótesis si comprueba una significancia estadística en el tiempo de reacción a una notificación tanto en el tiempo demorado para prender el celular como en interactuar con el mensaje cuando el Smartphone se encuentra apagado según el perfil de adicción, pero cuando se encuentra prendido no exista dicha diferencia. Una razón que puede

explicar este fenómeno es que el tipo de notificación que envía la aplicación no entrega mayor utilidad al usuario, por lo que un usuario adicto si puede estar más atento a su Smartphone y prender y/o interactuar con una notificación de forma más rápida, pero una vez que sabe qué tipo de mensaje tiene, no hay incentivos para contestar de forma apresurada.

Luego de limpiar y mezclar los datos obtenidos por el test con los obtenidos por la aplicación, y realizar el tratamiento de datos correspondiente, se hicieron modelos de clasificación cuyo objetivo es discriminar el tipo de interacción que el usuario tendrá con una notificación para un caso general, y cuando el Smartphone se encuentra prendido o apagado. También se usaron modelos de clasificación para identificar el tipo de interacción que un usuario tiene con su Smartphone dado sus resultados del test de sobreuso diseñado.

Al aplicar los modelos, en la mayoría de los casos los mejores resultados fueron obtenidos por el modelo de Deep Learning. Este resultado no es sorprendente dado la naturaleza del algoritmo y las restricciones asociadas a los modelos de Machine Learning sobre la necesidad de datos completos para usar modelos cada etiqueta a clasificar. Esta condición dejaba con un total de hasta 700 casos a estudiar, en comparación con el modelo de Deep Learning que nunca restringe datos.

También cabe destacar que los datos están desbalanceados, tanto en la proporción entre hombres y mujeres, como en la proporción entre el tipo de interacción con las notificaciones. A pesar de que se hicieron tratamientos para intentar balancear los resultados y evitar overfitting, es posible que haya existido algún sesgo que ayudó en los resultados obtenidos, ya que están sobre un 10% mejor en accuracy que con respecto al estado del arte. Como no se han estudiado casos en los que se hayan usado algoritmos de Deep Learning, se hace difícil poder comparar bien los resultados obtenidos. Para el caso de los resultados obtenidos para la clasificación del perfil de adicción, los resultados del modelo de Deep Learning son de un 6% mejor que con respecto al estado del arte.

Como cada uno de los modelos de clasificación tuvo un tiempo de ejecución con los datos de testeo inferior a 0.05ms, es posible implementar el modelo en tiempo real y así predecir si un usuario interactuará con un mensaje. Esto tiene una gran utilidad dentro de cualquier industria que busque mejorar la conversión de sus notificaciones. Sin embargo, se destaca el hecho de que el tipo de notificaciones entregadas es altamente invasiva y no entrega mayor utilidad a el usuario, por lo que los motivos para interactuar con el usuario son un misterio y por lo tanto no es homologable el estudio para notificaciones con un alto valor, como por ejemplo un mensaje de texto de un relativo.

## Capítulo 7

### Conclusiones y trabajos futuros

El lograr mecanismos no invasivos para poder interactuar con un usuario por Smartphone es uno de los desafíos de la Computación Ubicua, tanto porque no produce un aumento drástico en la carga cognitiva, como por el hecho de que existe una tendencia mundial de usar cada vez más el Smartphone [87], lo que produce problemas como el ciberstress, dependencia frustración o baja en el desempeño de una actividad, entre otros factores mencionados en la sección 2.

En este trabajo se comprobó que existen diferencias en los tiempos de respuesta a una notificación según la carga cognitiva. Además este análisis se hizo no solo estudiando el tiempo entre que llega una notificación y el usuario interactúa con ésta, sino que también toma en consideración el tiempo demorado en prender el Smartphone y los tiempos cada sesión según la carga cognitiva.

También se comprobó que existe una diferencia significativa a la hora de interactuar con una notificación según el perfil de uso de un usuario, pero esta diferencia solo se observa cuando el Smartphone se encuentra apagado.

Los modelos de clasificación para el tipo de interacción son superiores a los del estado del arte y son similares para el perfil de uso de un usuario.

Algunos posibles pasos futuros son crear notificaciones con contenido variable que se asemeje al tipo de notificaciones invasivas que recibe diariamente una persona, y buscar mecanismos para estudiar el tipo de notificaciones con las que el usuario interactúa. También agregar el tipo de sonido y estado de vibración con el cual está configurado el Smartphone, y detectar si un usuario desbloqueó el Smartphone.

# Bibliografía

- [1] L. Rosen, *iDisorder: Understanding Our Obsession with Technology and Overcoming Its Hold on Us*, 2012.
- [2] R. Want, «When cell phones become computers,» *IEEE Pervasive Computing*, 2009.
- [3] K. McGrane, «The Rise of the Mobile-Only User,» *Harvard Business Review*, 2013.
- [4] O. o. C. o. t. U. Kingdom. [En línea]. Available: <http://consumers.ofcom.org.uk/news/uk-now-a-smartphone-society/>.
- [5] Statista, 2016. [En línea]. Available: <http://www.statista.com/statistics/203734/global-smartphone-penetration-per-capita-since-2005/>.
- [6] G. A. -. Entel, Enero 2016. [En línea]. Available: <http://www.adimark.cl/es/estudios/documentos/estudio%20nomofobia.pdf>.
- [7] C. Wickens, «Multiple Resources and Mental Workload,» *Human Factors and Ergonomics Society*, 2008.
- [8] D. Navon, «On the economy of the human processing system,» *Psychological Review*, vol. 86, pp. 214-255, 1979.
- [9] M. Satyanarayanan, «Pervasive computing: vision and challenge,» *Personal Communications, IEEE*, pp. 10-17, 2001.
- [10] M. Weiser y J. S. Brown, «The coming age of calm technology,» *Springer*, 1997.
- [11] B. Poppinga, W. H. Boll y Susanne, «Sensor-Based Identification of Opportune Moments for Triggering Notifications,» *Attention Management, IEEE CS*, 2014.
- [12] A. Bianchi y J. G. Phillips, «Psychological Predictors of Problem Mobile Phone Use,» *CyberPsychology & Behavior*, nº 8, 2005.
- [13] A. Oulasvirta, T. Rattenbury, L. Ma y E. Raita, «Habits make smartphone use more pervasive,» *Personal and Ubiquitous Computing*, vol. 16, nº 1, pp. 105-114, 2012.



- [14] M. Takao, S. Takahashi y M. Kitamura, «Addictive personality and problematic mobile phone use».
- [15] E. Altmann y J. G. Trafton, «Task Interruption: Resumption Lag and the Role of Cues,» de *Proceedings of the 26th Annual Conference of the Cognitive Science Society*, Chicago, 2004.
- [16] C. Chisholm, A. Dornfeld, D. Nelson y W. Cordell, «Work Interrupted: A Comparison of Workplace Interruptions in Emergency Departments and Primary Care Offices,» *Annals of Emergency Medicine*, vol. 38, n° 2, p. 146–151, Agosto 2001.
- [17] M. Czerwinski, E. Cutrell y E. Horvitz, «Instant Messaging: Effects of Relevance and Timing,» de *People and Computers XIV: Proceedings of HCI*, Springer-Verlag London, 2000.
- [18] H. Lopez-Tovar, A. Charalambous y J. Dowell, «Managing Smartphone Interruptions through Adaptive Modes and Modulation of Notifications,» de *20th International Conference on Intelligent User Interfaces*, Atlanta, USA, 2015.
- [19] T. Okoshi, J. Ramos, H. Nozaki, A. K. D. Jin Nakazawa y H. Tokuda, «Reducing Users' Perceived Mental Effort due to Interruptive Notifications in Multi-Device Mobile Environments,» de *International Joint Conference on Pervasive and Ubiquitous Computing*, Osaka, Japan, 2015.
- [20] P. C. 2. -. C. N. d. I. C. y. Tecnológica, 2014. [En línea]. Available: <http://www.conicyt.cl/fondecyt/files/2015/11/Panorama-Cient%C3%ADfico-2014.pdf>.
- [21] P. Adamczyk y B. Bailey, «If not now, when?: the effects of interruption at different moments within task execution,» *SIGCHI Conference on Human Factors in Computing Systems*, 2004.
- [22] A. Jimenez-Molina y I.-Y. Ko, «Cognitive Resource-Aware Mobile Service Framework to Support Human-Computer-Interactions in Ubiquitous Computing Environments,» *Journal of Ambient Intelligence and Smart Environments*, pp. 37-57, 2015.

- [23] M. Kwon, J.-Y. Lee, W.-Y. Won, J.-W. Park, J.-A. Min, C. Hahn, X. Gu, J.-H. Choi y D.-J. Kim, «Development and Validation of a Smartphone Addiction Scale (SAS),» *PLOS ONE*, vol. 8, n° 2, 2013.
- [24] R. Hernández, C. Fernández y M. d. P. Batista, Metodología de la Investigación.
- [25] C. Tosell, P. Kortum, C. Shepard, A. Rahmati y L. Zhong, «Getting Real: A Naturalistic Methodology for Using Smartphones to Collect Mediated Communications,» *Advances in Human-Computer Interaction*, 2012.
- [26] P. Lemaire, H. Abdi y M. Fayol, «The Role of Working Memory Resources in Simple Cognitive Arithmetic,» *European Journal of Cognitive Psychology*, vol. 8, n° 1, pp. 73-103, 1996.
- [27] A. Oulasvirta, S. Tamminen, V. Roto y J. Kuorelahti, «Interaction in 4-Second Bursts: The Fragmented Nature of Attentional Resources in Mobile HCI,» de *In Proceedings of SIGCHI Conference on Human Factors in Computing Systems*, New York, 2005.
- [28] A. Welford, «Mental Work-load as a Function of Demand, Capacity, Strategy and Skill,» *Ergonomics*, vol. 21, n° 3, pp. 151-167, 1978.
- [29] M. Young, K. Brookhuis, C. Wickens y P. Hancock, «State of science: mental workload in ergonomics,» *Ergonomics*, vol. 58, n° 1, pp. 1-17, 2015.
- [30] F. Pass, J. Tuovinen, H. Tabbers y P. V. Gerven, «Cognitive Load Measurement as a Means to Advance Cognitive Load Theory,» *Educational Psychologist*, vol. 38, n° 1, pp. 63-71, 2003.
- [31] B. Y. F. Chen, N. Ruiz y E. Ambikairajah, «Speech-based Cognitive Load Monitoring System,» de *IEEE International Conference on Acoustics, Speech and Signal Processing*, Las Vegas, NV, 2008.
- [32] M. Young y N. Stanton, Handbook of Human Factors and Ergonomics Methods, N. Stanton, A. Hedge, K. Brookhuis, E. Salas y H. Hendrick, Edits., 2005, p. capítulo 29.

- [33] B. Bailey y J. Konstan, «On the Need for Attention-Aware Systems: Measuring Effects of Interruption on Task Performance Error Rate, and Affective State,» *Computers in Human Behavior*, vol. 22, pp. 685-708, 2005.
- [34] E. Cutrell, M. Czerwinski y E. Horvitz, «Notification, Disruption, and Memory: Effects of Messaging Interruptions on Memory and Performance,» de *Interact 2001: IFIP Conference on Human-Computer Interaction*, Tokyo, 2001.
- [35] M. Czerwinski, E. Horvitz y S. White, «A Diary Study of Task Switching and Interruptions,» de *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, New York, 2004.
- [36] S. Loft, P. Sanderson, A. Neal y M. Mooji, «Modeling and Predicting Mental Workload in En Route Air Traffic Control: Critical Review and Broader Implications,» *Human Factors*, vol. 49, n° 3, pp. 376-399, 2007.
- [37] M. Vidulich y P. Tsang, «Mental Workload and Situation Awareness,» de *Handbook of Human Factors and Ergonomics*, G. Salvendy, Ed., 2006.
- [38] E. Haapalainen, S. Kim, J. Forlizzi y A. Dey, «Psycho-Physiological Measures for Assessing Cognitive Load,» de *UbiComp*, Copenhagen, Denmark, 2010.
- [39] S. Chen, J. Epps y F. Chen, «A Comparison of Four Methods for Cognitive Load Measurement,» de *23rd Australian Computer-Human Interaction Conference*, Canberra, Australia, 2011.
- [40] J. Kjeldskov y J. Stage, «New techniques for usability evaluation of mobile systems,» *HCI Issues in Mobile Computing*, vol. 60, n° 5-6, pp. 599-620, Mayo 2004.
- [41] N. Eagle y A. Pentland, «Reality mining: sensing complex social systems,» *Journal of Personal and Ubiquitous Computing*, vol. 10, p. 255–268, 2006.
- [42] J. J. Kandell, «Internet Addiction on Campus: The Vulnerability of College Students,» *CyberPsychology & Behavior*, 1998.
- [43] P. Adler y P. Adler, «Observational Techniques,» de *Handbook of Qualitative Research.*, N. Denzin y Y. Lincoln, Edits., Thousand Oaks, Sage Publications, 1994.

- [44] S. Haynes y W. Horn, «Reactivity in behavioral observation: A review,» *Behavioral Assessment*, vol. 4, n° 4, pp. 369-385, 1982.
- [45] J. G. Trafton y C. Monk, «Task Interruption,» de *Reviews of Human Factors and Ergonomics*, vol. 3, D. A. Boehm-Davis, Ed., Santa Monica, Human Factors and Ergonomics Society, 2008, pp. 111-126.
- [46] J. Ho y S. Intille, «Using Context-Aware Computing to Reduce the Perceived Burden of Interruptions from Mobile Devices,» de *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, New York, USA, 2005.
- [47] J.-M. Cellier y H. Eyrolle, «Interference Between Switched Tasks,» *Ergonomics*, vol. 35, n° 1, pp. 25-36, 1992.
- [48] F. R. H. Zijlstra, R. Roe, A. Leonora y I. Krediet, «Temporal Factors in Mental Work: Effects of Interrupted Activities,» *Journal of Occupational and Organizational Psychology*, vol. 72, pp. 163-185, 1999.
- [49] T. Gillie y D. Broadbent, «What makes interruptions disruptive? A study of length, similarity, and complexity,» *Psychological Research*, vol. 50, n° 4, pp. 243-250, 1989.
- [50] D. C. McFarlane, «Comparison of Four Primary Methods for Coordinating the Interruption of People in Human-Computer Interaction,» *Journal of Human-Computer Interaction*, vol. 17, n° 1, pp. 63-139, 2002.
- [51] D. C. McFarlane, «Coordinating the Interruption of People in Human-Computer Interaction,» *Human-Computer Interaction - Interact*, pp. 295-303, 1999.
- [52] Y. Miyata y D. Norman, «Psychological Issues in Support of Multiple Activities,» de *User Centered System Design: New Perspectives on Human-Computer Interaction*, Erlbaum, 1986, p. 265-284.
- [53] J. G. Trafton, E. Altmann, D. Brock y F. Mintz, «Preparing to Resume an interrupted Task: Effects of Prospective Goal Encoding and Retrospective Rehearsal,» *International Journal of Human-Computer Studies*, vol. 58, pp. 583-603, 2003.

- [54] C. Speier, J. Valacich y I. Vessey, «The Influence of Task Interruption on Individual Decision Making: An Information Overload Perspective,» *Decision Sciences*, vol. 30, n° 2, pp. 337- 360, 1999.
- [55] A. Oulasvirta y P. Saariluoma, «Long-term Working Memory and Interrupting Messages in Human-Computer Interaction,» *Behaviour and Information Technology*, vol. 23, pp. 53-64, 2004.
- [56] A. Oulasvirta y P. Saariluoma, «Surviving Task Interruptions: Investigating the Implications of Long-term Working Memory Theory,» *International Journal of Human-Computer Studies*, vol. 64, pp. 941-961, 2006.
- [57] E. M. Altmann y .. G. Trafton, «Memory for Goals: An Activation-Based Model,» *Cognitive Science*, vol. 26, pp. 39-83, 2002.
- [58] S. Monsell, «Task Switching,» *Trends in Cognitive Sciences*, vol. 7, n° 3, pp. 134-140, Marzo 17.
- [59] M. Böhmer, C. Lander, S. Gehring, D. P. Brumby y A. Krüger, «Interrupted by a Phone Call: Exploring Designs for Lowering the Impact of Call Notifications for Smartphone Users,» de *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, Toronto, Canada, 2014.
- [60] I. Wassink, O. Kulyk, B. v. Dijk, G. v. d. Veer y P. v. d. Vet, «Applying a User-centered Approach to Interactive Visualisation Design,» de *Trends in Interactive Visualization*, R. Liere, T. Adriaansen y E. Zudilova-Seinstra, Edits., Springer London, 2008, pp. 175-199.
- [61] A. Mehrotra, M. Musolesi, R. Hendley y V. Pejovic, «Designing content-driven intelligent notification mechanisms for mobile applications,» de *International Joint Conference on Pervasive and Ubiquitous Computing*, Osaka, Japan, 2015.
- [62] V. Pejovic y M. Musolesi, «InterruptMe: Designing Intelligent Prompting Mechanisms for Pervasive Applications,» de *International Joint Conference on Pervasive and Ubiquitous Computing*, Seattle, USA, 2014.
- [63] J. Smith y N. Dulay, «RingLearn: Long-term mitigation of disruptive smartphone interruptions,» de *Pervasive Computing and Communications Workshops*, Budapest, 2014.

- [64] U. Lee, J. Lee, M. Ko, C. Lee, Y. Kim, S. Yang, K. Yatani, G. Gweon, K.-M. Chung y J. Song, «Hooked on Smartphones: An Exploratory Study on Smartphone Overuse among College Students,» *One of a CHIInd, Session: Emotions and Mobiles*, 2014.
- [65] A. J. v. Deursen, C. L. Bolle, S. M. Hegner y P. A. Kommers, «Modeling habitual and addictive smartphone behavior: The role of smartphone usage types, emotional intelligence, social stress, self-regulation, age, and gender,» *Computers in Human Behavior*, vol. 45, p. 411–420, Abril 2015.
- [66] J.-L. Wang, H.-Z. Wangb, J. Gaskinc y L.-H. Wanga, «The role of stress and motivation in problematic smartphone use among college students,» *Computers in Human Behavior*, vol. 53, p. 181–188, Diciembre 2015.
- [67] M. Samaha y N. S. Hawi, «Relationships among smartphone addiction, stress, academic performance, and satisfaction with life,» *Computers in Human Behavior*, vol. 57, p. 321–325, 2016.
- [68] W. Ju, «The Design of Implicit Interactions: Making Interactive Systems Less Obnoxious,» *Design Issues*, vol. 24, n° 3, pp. 72-84, 2008.
- [69] H. Ahn, M. E. Wijaya y B. Esmero, «A Systemic Smartphone Usage Pattern Analysis: Focusing on Smartphone Addiction Issue,» *International Journal of Multimedia and Ubiquitous Engineering*, vol. 2014, n° 6, pp. 9-14, 9.
- [70] A. Mehrotra, V. Pejovic, J. Vermeulen y R. H. M. Musolesi, «My Phone and Me: Understanding People's Receptivity to Mobile Notifications,» 2016.
- [71] L. Turner, S. Allen y R. Whitaker, «Push or Delay? Decomposing Smartphone Notification Response Behaviour,» *Springer International Publishing Switzerland 2015*, pp. 68-83, 2015.
- [72] O. Maimon y L. Rokach, Edits., *The Data Mining and Knowledge Discovery Handbook*, 2ª edición ed., Springer US, 2010.
- [74] D. Tilman y M. Pielot, «I'll be there for you: Quantifying Attentiveness towards Mobile Messaging,» Copenhagen, Denmark, 2015.

- [75] G. A. R. API. [En línea]. Available: <https://developers.google.com/android/reference/com/google/android/gms/location/ActivityRecognitionApi>.
- [76] G. Miller, «The smartphone psychology manifesto,» *Perspectives on Psychological Science*, pp. 221-237, 2012.
- [77] K. Purcell y K. Brady, «Adaptation to the invasion of privacy: monitoring behavior with a miniature radio transmitter,» *Merrill-Palmer Quarterly of Behavior and Development*, vol. 12, pp. 242-254, 1966.
- [78] T. N. Company, «The Mobile Consumer: A Global Snapshot,» 2013.
- [79] R. J. J. M. v. d. Eijnden, G.-J. Meerkerk, R. C. M. E. Engels, R. Spijkerman y A. A. Vermulst, «Online Communication, Compulsive Internet Use, and Psychosocial Well-Being Among Adolescents: A Longitudinal Study,» *Developmental Psychology*, vol. 44, 2008.
- [80] N. Park y H. Lee, «Social implications of smartphone use: Korean college students' smartphone use and psychological well-being. Cyberpsychology, Behavior, and Social Networking,» *Cyberpsychology, Behavior, and Social Networking*, vol. 15, nº 9, 2012.
- [81] M. Beranuy, U. Oberst, X. Carbonell y A. Chamarro, «Problematic Internet and mobile phone use and clinical symptoms in college students: The role of emotional intelligence,» *Computers in Human Behavior*, 2009.
- [82] C.-F. Yena, T.-C. Tang, J.-Y. Yen, H.-C. Lin, C.-F. Huang y C.-H. K. Shu-Chun Liua, «Symptoms of problematic cellular phone use, functional impairment and its association with depression among adolescents in Southern Taiwan,» *Journal of Adolescence*, nº 32, 2009.
- [83] R. Sykes, «Toward a theory of observer effect in systematic field observation,» *Human Organization*, vol. 37, nº 2, pp. 148-156, 1978.
- [84] C. Monk, D. Boehm-Davis y J. G. Trafton, «The Attentional Costs of Interrupting Task Performance at Various Stages,» *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 46, nº 22, pp. 1824-1828, Septiembre 2002.

- [85] C. Chisholm, E. Collison, D. Nelson y W. Cordell, «Emergency Department Workplace Interruptions: Are Emergency Physicians "interrupt-driven" and "multitasking"?», *Academic Emergency Medicine*, vol. 7, n° 11, pp. 1239-1243, Noviembre 2000.
- [86] K. Hinckley, J. Pierce, M. Sinclair y E. Horvitz, «Sensing Techniques for Mobile Interaction,» de *proceedings of the 13th annual ACM symposium on User interface software and technology* , 2000.
- [87] H. Lira, «Medición de Cargas Cognitivas Durante Actividades de Interacción Humano Computador en Ambiente Móvil Usando Sensores Psico-fisiológicos,» Santiago, 2015.



# Anexos

## Anexo 1: Afiche del llamado a participar en la investigación

**Ayúdanos y Participa \$ 50.000**  
POR UN PREMIO DE

**¿TIENES UN SMARTPHONE CON ANDROID? ¿TE INTERESARÍA PARTICIPAR POR 3 SORTEOS DE \$50.000 Y DE PASO AYUDAR CON UN ESTUDIO? MUY FÁCIL!**  
SÓLO INGRESA AL LINK DISPONIBLE EN EL EL CÓDIGO QR, COMPLETA EL FORMULARIO Y YA ESTÁS PARTICIPANDO.

**¿CÓMO PARTICIPAR?**

- Inscríbete con el link que te da el código QR. Luego sólo tienes que instalar una aplicación diseñada especialmente para el proyecto. Terminando el estudio estudio, contestas un cuestionario y ya está!**
- ¿CUÁNTO DURA EL ESTUDIO?**  
Un máximo de 2 meses, pero contestar una notificación no te tomará más de 15 segundos. Completar la encuesta final sólo demora un máximo de 7 minutos.
- ¿QUIÉNES PUEDEN PARTICIPAR?**  
Mayores de 18 años que tengan un smartphone con un sistema operativo Android y que estudien en la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile o en la Facultad de Ingeniería y Ciencias de la Universidad Adolfo Ibáñez.

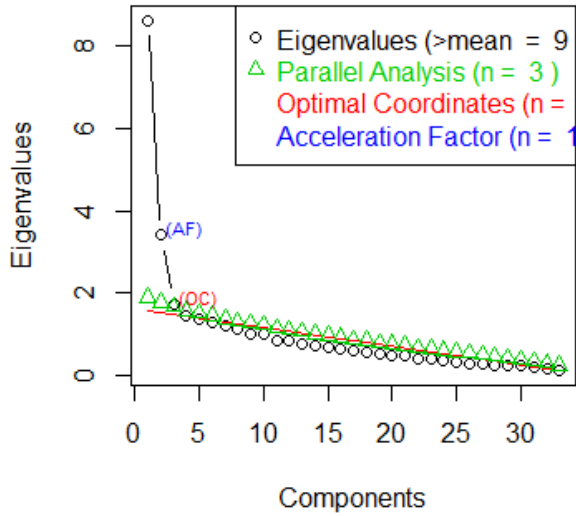
**fcfm** FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS UNIVERSIDAD DE CHILE

**UAI** UNIVERSIDAD ADOLFO IBÁÑEZ FACULTAD DE INGENIERÍA Y CIENCIAS

Para más información ingresar al link por medio del código QR

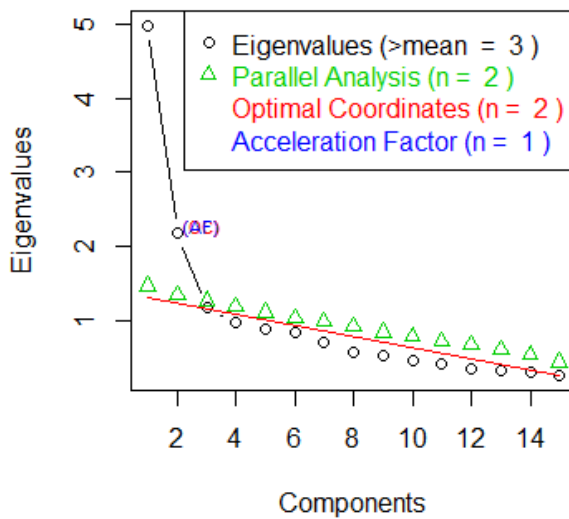
Anexo 2: Resultado test de Scree para selección de factores. Test con 33 preguntas

### Non Graphical Solutions to Scree Test



Anexo 3: Resultado test de Scree para selección de factores. Test con 15 preguntas

### Non Graphical Solutions to Scree Test



Anexo 4: Análisis factorial. Test con 33 preguntas

	TC1	TC2	TC5	TC6	TC3	TC4	h2	u2	com
P1	0.78	-0.11	0.15	-0.08	-0.10	-0.16	0.63	0.37	1.2
P2	0.82	0.00	0.08	0.05	-0.03	-0.14	0.68	0.32	1.1
P3	0.33	0.10	0.10	-0.43	0.18	0.21	0.37	0.63	3.1
P4	0.38	0.08	0.23	-0.36	0.26	0.18	0.48	0.52	4.1
P5	-0.12	0.78	0.00	-0.05	0.17	-0.16	0.62	0.38	1.3
P6	-0.02	0.80	-0.04	0.13	0.08	-0.05	0.70	0.30	1.1
P7	0.15	0.53	0.04	0.06	-0.27	-0.01	0.38	0.62	1.7
P8	0.19	0.60	0.20	-0.05	-0.29	0.09	0.56	0.44	2.0
P9	0.04	0.34	0.06	0.54	0.04	0.14	0.61	0.39	1.9
P10	-0.12	0.48	0.22	0.42	-0.11	0.02	0.60	0.40	2.7
P11	0.09	0.56	-0.13	0.03	-0.05	0.37	0.52	0.48	2.0
P12	0.00	0.24	0.12	0.49	0.24	0.14	0.58	0.42	2.3
P13	0.10	0.02	0.06	0.68	0.06	0.08	0.58	0.42	1.1
P14	0.27	0.10	0.10	0.51	0.04	0.20	0.60	0.40	2.1
P15	0.60	0.07	0.14	-0.06	0.10	0.12	0.52	0.48	1.3
P16	0.26	-0.03	0.33	0.23	0.14	0.12	0.45	0.55	3.6
P17	-0.01	0.09	0.13	-0.11	0.43	0.43	0.47	0.53	2.4
P18	-0.11	0.05	0.09	-0.04	-0.09	0.76	0.58	0.42	1.1
P19	-0.04	-0.22	0.00	0.19	-0.01	0.74	0.60	0.40	1.3
P20	-0.06	0.19	0.65	-0.02	0.10	0.06	0.52	0.48	1.3
P21	0.05	-0.03	0.76	-0.07	0.08	0.03	0.61	0.39	1.1
P22	0.04	-0.04	0.65	0.24	-0.32	0.07	0.58	0.42	1.8
P23	-0.03	0.32	0.25	0.12	0.14	0.08	0.30	0.70	2.8
P24	0.13	0.14	-0.14	0.02	0.56	0.11	0.40	0.60	1.5
P25	0.57	0.13	-0.02	0.06	0.27	0.18	0.62	0.38	1.8
P26	0.42	0.06	0.40	0.11	0.14	-0.04	0.55	0.45	2.4
P27	0.51	-0.08	0.19	0.21	0.18	0.12	0.59	0.41	2.1
P28	0.58	-0.16	0.13	-0.06	0.20	0.15	0.56	0.44	1.7
P29	0.46	-0.15	-0.01	0.26	0.29	0.05	0.49	0.51	2.6
P30	-0.63	-0.05	0.18	-0.34	-0.18	-0.08	0.66	0.34	2.0
P31	0.01	0.02	0.20	0.21	0.61	-0.23	0.55	0.45	1.8
P32	-0.72	-0.12	0.22	0.06	0.31	-0.05	0.54	0.46	1.7
P33	0.29	-0.06	0.29	0.05	0.34	0.01	0.42	0.58	3.0

Anexo 5: Análisis factorial. Test con 15 preguntas

	TC3	TC2	TC1	TC4	h2	u2	com
P13	0.85				0.65	0.35	1.3
P5	0.78				0.73	0.27	1.1
P1	0.71				0.61	0.39	1.2
P11	0.49				0.56	0.44	2.1
P4	0.42				0.58	0.42	2.9
P3		0.88			0.76	0.34	1.0
P7		0.78			0.60	0.40	1.0
P6		0.75			0.68	0.32	1.2
P2		0.27			0.24	0.76	2.9
P12			0.84		0.66	0.34	1.1
P9			0.72		0.59	0.41	1.0
P15			0.49		0.63	0.37	3.4
P8			0.41	-0.12	0.61	0.39	3.1
P10				0.82	0.72	0.28	1.1
P14				0.70	0.69	0.31	1.4