UNIVERSIDAD AUTÓNOMA DE CHIHUAHUA

FACULTAD DE INGENIERÍA

SECRETARÍA DE INVESTIGACIÓN Y POSGRADO



UNIVERSIDAD AUTÓNOMA DE
CHIHUAHUA

MODELADO COMPUTACIONAL DE LA TOMA DE DECISIONES PARA DETECCIÓN MÓVIL DEL DETERIORO COGNITIVO LEVE

POR:

HEBER ABRAHAM ZAPATA ROBLES

TESIS PRESENTADA COMO REQUISITO PARA OBTENER EL GRADO DE

MAESTRO EN INGENIERÍA EN COMPUTACIÓN

DIRECTOR DE TESIS: DR. RAYMUNDO CORNEJO GARCÍA

CHIHUAHUA, CHIH,. MÉXICO **4 de septiembre de 2026**

Modelado computacional de la toma de decisiones para detección móvil del deterioro cognitivo leve. Tesis presentada por Heber Abraham Zapata Robles como requisito parcial para obtener el grado de Maestro en Ingeniería en Computación, ha sido aprobado y aceptado por:

M.I. Fabián Vinicio Hernández Martínez
Director de la Facultad de Ingeniería

M.I. Rodrigo de la Garza Aguilar
Secretario de Investigación y Posgrado

M.S.I. Karina Rocío Requena Yáñez
Coordinadora Académica

Dr. Raymundo Cornejo García
Director de Tesis

Junio 2026

25 de junio de 2026

COMITÉ
Dr. Raymundo Cornejo García
Dr. Raúl Loera Valencia
Dra. Graciela María de Jesús Ramírez Alonso
Dr. Fernando Martínez Reyes

UNIVERSIDAD AUTÓNOMA DE
CHIHUAHUA

05 de agosto de 2026.

LIC. HEBER ABRAHAM ZAPATA ROBLES
Presente. -

En atención a su solicitud relativa al trabajo de tesis para obtener el grado de Maestría en Ingeniería en Computación, nos es grato transcribirle el tema aprobado por esta Dirección, propuesto y dirigido por el director **Dr. Raymundo Cornejo García** para que lo desarrolle como Tesis, con el título **"Modelado computacional de la toma de decisiones para detección móvil del deterioro cognitivo leve"**.

Índice de Contenido

Dedicatoria

Agradecimientos

Introducción

Adaptación de tareas asociativas al fenotipado digital.

Marco Teórico

Aprendizaje por Refuerzo.

Psiquiatría computacional.

Antecedentes

Metodología

Cuantitativa.

Cualitativa.

Resultados

Análisis Comportamental.

FACULTAD DE INGENIERÍA
Circuito No. 1, Campus Universitario 2
Chihuahua, Chih., México. C.P. 31125
Tel. (614) 442-95-00
www.fing.uach.mx

Por un 2026 con salud mental

+uach

UNIVERSIDAD AUTÓNOMA DE
CHIHUAHUA

Modelado Computacional.

Análisis Estadístico.

Grupos Focales

Conclusiones

Análisis Cuantitativo.

Análisis Cualitativo.

Anexos

Glosario

A T E N T A M E N T E

"naturam subiecit aliis"

EL DIRECTOR

M.I. FABIÁN VINICIO HERNÁNDEZ MARTÍNEZ

FACULTAD DE INGENIERÍA
U.A.CH.

DIRECCIÓN

SECRETARIO DE INVESTIGACIÓN Y POSGRADO

M.I. RODRIGO DE LA GARZA AGUILAR

Dedicatoria

Dedico esta tesis a Yolanda Armendáriz Roacho †, mi tita. Gracias por ser el motor de todo esto.
También dedico esta tesis a mi madre, la persona que ha confiado en mí desde el primer día. Gracias mamá, te amo.
Por último, a mi bela Juana, quien me ha acompañado durante el desarrollo de esta tesis.

Agradecimientos

Agradezco, en primer lugar, a mi director de tesis, Ray, por la confianza y el apoyo brindados desde el primer momento en que lo contacté. Gracias por creer en mí y acompañar este proceso.

A mi co-director de tesis, Raúl, por su acompañamiento a lo largo de este trabajo, así como por su cercanía y confianza.

Al Dr. Favela, por abrirme las puertas de su laboratorio y brindarme su confianza.

A Emmanuel, por ser la primera persona en transmitirme su pasión por la ciencia.

A mi madre, por todo lo que ha hecho para que hoy pueda presentar este trabajo.

A mi padre, Alejandro Aceves, sin tus esfuerzos y sacrificios no podría ser la persona que soy. Gracias por tanto amor.

A mis hermanos, Iram, Jano y Ahmed; ustedes saben qué onda, gracias por todo su apoyo.

A mi pareja, Grecia, por estar presente en todo momento; sin tu apoyo, esto no habría sido posible.

A mi padre, Heber Zapata, por decidir formar parte de este proceso y apoyarme.

A mis hermanas, Aymara y Alexia. Por su apoyo incondicional.

A mis amigos, Ale, Many y Pooh, por estar siempre al pie del cañón.

A mis demás amigos, Jacqui, Moni, Arcadio, Diego, David, Dayvid, Pau, Marisela y Oleksiy, por recordarme que siempre puedo contar con ustedes.

A Diego, Mateo, Lili y Víctor, por siempre estar para mí.

Al Ing. Jorge Montañez, por su apoyo en la programación de la app utilizada en este proyecto.

A los psicólogos, Sofia y Daniel, por su apoyo en la implementación del test MoCA.

A las casas del abuelo, tanto a sus miembros como coordinadores y directores, por colaborar en este proyecto.

A los profesores de ELPAC, CEIC, CICESE y la UACH, por contribuir a mi formación académica.

A la Secretaría de Ciencia, Humanidades, Tecnología e Innovación, por el apoyo brindado a través de la beca que hizo posible el desarrollo de esta tesis.
En la preparación de este documento se contó con apoyo de herramientas de inteligencia artificial orientadas a mejorar la claridad y estructura de la redacción.

Índice

Dedicatoria **3**

Agradecimientos **4**

Resumen **10**

Abstract **12**

1 Introducción **14**

1.1 Adaptación de tareas asociativas al fenotipado digital 17

2 Marco Teórico **19**

2.1 Aprendizaje por Refuerzo 19

2.2 Psiquiatría Computacional 24

2.2.1 RL y PC 26

3 Antecedentes **31**

4 Metodología **37**

4.1 Cuantitativa 37

4.1.1 Reclutamiento 38

4.1.2 Selección 38

4.1.3 Tareas Experimentales 39

4.1.4 Análisis de Datos 42

4.2 Cualitativa 46

4.2.1 Reclutamiento y selección 46
4.2.2 Grupos Focales 48
4.2.3 Análisis de Datos 48

5 Resultados **49**
5.1 Análisis Comportamental 49
5.2 Modelado Computacional 51
5.3 Análisis Estadístico 57
5.4 Grupos Focales 58

6 Conclusiones **64**
6.1 Análisis Cuantitativo 64
6.2 Análisis Cualitativo 67

Anexos **77**

Glosario **78**

Currículum Vitae **80**

Índice de Figuras

4.1 Pipeline de metodología cuantitativa. 38
4.2 Ensayo a ensayo de tarea experimental. 40
4.3 Protocolo de tarea experimental. 41
4.4 Descripción del proceso de metodología cualitativa. 47

5.1 Curvas de aprendizaje promediadas por tamaño de conjunto y ensayo. 49
5.2 Curvas del tiempo de reacción promediadas por tamaño de conjunto y ensayo. . . . 51
5.3 Coeficientes de Pearson obtenidos para cada valor de β en el proceso de selección del mejor modelo. 53
5.4 Distribución de los valores estimados de cada parámetro RLWM por fase. 54
5.5 Distribución de los valores estimados de cada parámetro RLWM por fase, con gráficos de cajas. 55
5.6 Correspondencia entre parámetros. 56

Índice de Tablas

4.1 Cruce de variables independientes y manipulación de variables. 42
4.2 Descripción de parámetros y bounds para implementar L-BFGS-B. 45

5.1 Resultados de los parámetros con distintos valores de β. 52
5.2 Medianas e IQR de cada parámetro por fase. 54
5.3 Agrupación de códigos en temáticas, y sus conceptos. 59
5.4 Frecuencia de códigos. 61

Resumen

El modelado computacional de la toma de decisiones ha cobrado relevancia en el campo de la psiquiatría computacional para explicar patrones cognitivos en psicopatologías. Las tareas experimentales que se utilizan para obtener los datos del modelado se implementan en entornos controlados para aislar los procesos cognitivos que se buscan medir. Sin embargo, controlar las variables implica reducir la complejidad del comportamiento. Por lo tanto, buscar métodos que midan el comportamiento en su entorno natural es una prioridad para poder comprender de mejor manera las psicopatologías. Con el objetivo de detectar de manera temprana el deterioro cognitivo leve en entornos naturales, el presente estudio busca implementar en un dispositivo móvil la tarea experimental de aprendizaje por refuerzo y memoria de trabajo; la cual se ha demostrado que es sensible al deterioro cognitivo leve. Adicionalmente, se busca reducir dicha tarea experimental, para reducir su tiempo de implementación. Para esto, se seleccionó una muestra de 37 estudiantes universitarios de la UACH y se realizó un diseño intrasujeto. Cada participante pasó por 3 fases experimentales: línea base, tarea experimental original implementada en computadora; fase 2, tarea experimental implementada en celular y reducción de 37 % de la tarea original; por último, fase 3, tarea experimental implementada en celular y reducción de 79 % de la tarea original. Una vez recolectados los datos, se simuló un agente artificial basado en el modelo de aprendizaje por refuerzo y memoria de trabajo para cada participante. Por lo que cada agente arrojó una solución algorítmica a las tareas experimentales, asemejándose a la solución que realizó cada participante para las mismas tareas. De esta manera, se corroboró la validez de la tarea y se evaluó cuál reducción mantiene estable la sensibilidad de la tarea al deterioro cognitivo leve. Se obtuvo que la fase 2 mantiene estabilidad en los parámetros del modelo y en el desempeño conductual, representando un equilibrio entre reducción de tiempo y validez de la tarea. La fase 3 muestra degradación en algunos parámetros, pero mantiene cualidades relevantes para detección del deterioro cognitivo le-

ve. En conclusión, se muestra evidencia de que la tarea de aprendizaje por refuerzo y memoria de trabajo mantiene su sensibilidad al ser implementada en dispositivos móviles. La fase 2 representa la reducción óptima en términos de validez, mientras que la fase 3 sugiere que reducciones amplias preservan características psicométricas. Sin embargo, a pesar de que se muestra evidencia a favor de la implementación móvil y las reducciones de la tarea, aún es importante implementar el diseño experimental con personas de la tercera edad.

Palabras clave: Deterioro cognitivo leve, Fenotipo computacional, Aprendizaje por refuerzo, Memoria de trabajo

Abstract

Computational modeling of decision-making has become increasingly relevant in the field of computational psychiatry to explain cognitive patterns in psychopathologies. Experimental tasks used to obtain modeling data are implemented in controlled environments to isolate the cognitive processes being measured. However, controlling variables involves reducing the complexity of behavior. Therefore, seeking methods to measure behavior in its natural environment is a priority for better understanding psychopathologies. With the aim of early detection of mild cognitive impairment in naturalistic settings, the present study seeks to implement an experimental task of reinforcement learning and working memory on a mobile device; this task has been shown to be sensitive to mild cognitive impairment. Additionally, the task is intended to be reduced to decrease its implementation time. For this purpose, a sample of 37 university students from UACH was selected and an within-subjects design was conducted. Each participant went through 3 experimental phases: baseline, the original experimental task implemented on a computer; phase 2, the experimental task implemented on a mobile device with a 37 % reduction of the original task; and finally, phase 3, the experimental task implemented on a mobile device with a 79 % reduction of the original task. Once data were collected, an artificial agent based on the reinforcement learning and working memory model was simulated for each participant. Thus, each agent produced an algorithmic solution to the experimental tasks, resembling the solution that each participant performed on the same tasks. In this way, the validity of the task was corroborated and it was evaluated which reduction maintains stable sensitivity of the task to mild cognitive impairment. It was found that phase 2 maintains stability in model parameters and behavioral performance, representing a balance between reduction of time and task validity. Phase 3 shows degradation in some parameters, but maintains relevant qualities for detection of mild cognitive impairment. In conclusion, evidence is presented that the reinforcement learning and working memory task maintains its sensitivity when

implemented on mobile devices. Phase 2 represents the optimal reduction in terms of validity, while phase 3 suggests that substantial reductions preserve psychometric properties. However, despite showing evidence in favor of mobile implementation and task reductions, it is still important to implement the experimental design with older adults.

Keywords: Mild cognitive impairment, Computational phenotyping, Reinforcement Learning, Working Memory

Capítulo 1

Introducción

El Alzheimer es una enfermedad neurodegenerativa que afecta procesos cognitivos como la memoria, la atención y la cognición social; hasta la fecha no se tiene una cura [1]. Este presenta aumentos en su incidencia, tanto a nivel mundial como nacional. A nivel global, en 2020 se reportaron 50 millones de casos de Alzheimer y se pronostica un aumento a 152 millones en 2050 [2]. En México, en 2014, se estimaba que 86,000 personas padecían esta demencia y se proyecta que la cifra aumentará a 3.5 millones para 2050 [3]. De manera específica, Chihuahua ocupa el sexto lugar a nivel nacional en muertes registradas por Alzheimer [4].

El pronóstico de aumento de casos de Alzheimer, sumado a la falta de cura, sitúan a esta demencia en una prioridad para la salud pública [5]. En 2017, la Organización Mundial de la Salud aprobó el plan de acción mundial de salud pública contra el Alzheimer, atendiendo a la creciente problemática que representa esta demencia para los sistemas de salud global [5]. Una de las medidas sugeridas en 2018 por la Asociación de Alzheimer, debido a que esta demencia no tiene cura, es detectar síntomas que faciliten su detección temprana [2].

El deterioro cognitivo leve (DCL), en ocasiones, es una etapa prodrómica del Alzheimer. Este se caracteriza por afecciones a un menor grupo de procesos cognitivos y en menor severidad que el Alzheimer [6]. El DCL no siempre culmina en Alzheimer, pero posibilita la detección comportamental de esta demencia. Por lo tanto, su detección es crucial para un diagnóstico temprano del Alzheimer, ya que permitiría una intervención temprana. Por ejemplo, en el campo de la neuropsicología se han desarrollado pruebas psicométricas como el Examen Cognitivo Mini-Mental [7] o la Evaluación Cognitiva Montreal (MoCA, por su nombre en inglés, *Montreal Cognitive Assessment*)

[8]; que ayudan a cribar el DCL.

Sin embargo, estas pruebas psicométricas presentan dos problemas. Primero, únicamente brindan un puntaje global del estado cognitivo [9]. Esto hace que no sean sensibles a pequeños cambios en la cognición, y en la detección de etapas tempranas de enfermedades, esta característica es primordial. Segundo, necesitan de estrategias para mitigar que los participantes aprendan a responder de manera correcta la prueba (efecto de aprendizaje) [10]. Esto imposibilita el seguimiento de la trayectoria de la enfermedad de Alzheimer. Estas deficiencias resaltan la necesidad de métodos que sean interpretables a nivel cognitivo y que permitan un seguimiento longitudinal de la demencia.

Con el avance tecnológico creciente, la implementación de algoritmos a la detección temprana de DCL es un área que ha ganado relevancia. El uso de inteligencia artificial, principalmente de aprendizaje máquina (ML, por sus siglas en inglés, *Machine Learning*) y aprendizaje profundo (DL, por sus siglas en inglés, *Deep Learning*), ofrece herramientas capaces de identificar DCL a través de patrones en datos, imágenes y señales [11, 12].

Sin embargo, ML y DL presentan un problema, la cantidad de datos que necesitan para ser entrenados es grande [13]. Esto representa un reto, ya que la recolección de datos en pacientes con enfermedades crónico-degenerativas no es un proceso sencillo; el acceso a esta población y la toma de datos representan un desafío debido a múltiples factores. Entre ellos, se encuentran las limitaciones éticas y legales al recopilar información de pacientes, así como las dificultades logísticas asociadas al seguimiento y monitoreo de la población específica. Además, la variabilidad en los contextos de los pacientes puede hacer que los datos sean menos homogéneos, lo que complica el entrenamiento de los modelos.

Para solucionar este problema, se ha propuesto el fenotipado digital (FD), una estrategia que es menos invasiva para los pacientes y permite recabar la mayor cantidad de datos posibles [14]. El FD es una metodología que aprovecha el uso de dispositivos móviles y sensores para recopilar datos en tiempo real y en entornos naturales. El objetivo es recolectar datos sobre el comportamiento digital de los usuarios desde sus dispositivos móviles o sus sensores, para luego extraer patrones que se relacionan con la evolución de la enfermedad mental [14]. El FD busca apoyar al diagnóstico de enfermedades mentales y se ha implementado para recolectar datos de diversos trastornos, por lo que representa una oportunidad para la detección temprana del DCL [15].

Sin embargo, el FD depende directamente de la Interacción Humano-Computadora (IHC) para

extraer los datos de interés y, en poblaciones en las que el uso de tecnología es reducido, esto representa un problema [16]. En este contexto, las personas de la tercera edad en México son una población particularmente vulnerable, tanto por su edad como por la brecha tecnológica que limita su acceso a herramientas digitales [17]. Por lo tanto, implementar el FD en este sector poblacional requiere una adaptación tecnológica. Dicha adaptación tecnológica debe de considerar las motivaciones, barreras y preferencias de las personas de la tercera edad respecto al uso de la tecnología. Este enfoque garantiza que las tecnologías digitales destinadas a la evaluación cognitiva no solo sean válidas y confiables; sino también aceptadas por la población mexicana de la tercera edad. Sin embargo, adicional a esta adaptación, es necesario que la tecnología extraiga información equivalente a la de pruebas psicométricas como el MoCA, para garantizar la calidad de los datos.

Por otro lado, de manera paralela al desarrollo de herramientas que posibiliten el desarrollo de fenotipos digitales, se han desarrollado otros métodos que faciliten la detección de enfermedades mentales de manera temprana [18, 19]. Entre estos métodos, el modelado de la toma de decisiones a través de algoritmos de aprendizaje por refuerzo (RL, por sus siglas en inglés, *Reinforcement Learning*) es una propuesta que ha demostrado ser eficaz [20, 21].

Los algoritmos de RL son capaces de aprender a tomar decisiones interactuando con el entorno, ya que reciben retroalimentación de este. La idea central de estos algoritmos es que pueden emular la toma de decisiones animal [20]. Por lo tanto, se puede hacer un acercamiento a los procesos latentes a la toma de decisiones a través de los cómputos del algoritmo [22].

Los cálculos necesarios para tomar una decisión, así como los parámetros utilizados en el modelo; se interpretan como un conjunto de expresiones fenotípicas del organismo. A este conjunto de cálculos y parámetros se le conoce como fenotipo computacional. Por lo tanto, si se modela la toma de decisiones en una enfermedad mental, podemos concluir que se obtiene un fenotipo computacional de dicha enfermedad mental [23, 24].

La obtención de un fenotipo computacional sigue los siguientes pasos: implementación de tareas computarizadas, recuperación de los parámetros del modelo a partir de los datos conductuales recopilados de las tareas computarizadas, simulaciones con los parámetros recuperados y, por último, recuperación de los parámetros del modelo en las simulaciones [23]. Si los parámetros recuperados en las simulaciones no muestran diferencias significativas a los recuperados en la primera recuperación de parámetros, se considera que los fenotipos computacionales son válidos [23].

Sin embargo, generar un fenotipo computacional implica entornos controlados para realizar mediciones más precisas. A pesar de esta ventaja, los entornos controlados no contempaln la complejidad del contexto de los participantes [25]. Por tanto, conviene acercar las tareas a la vida diaria de las personas, sin sacrificar la calidad de la medición [25]. De esta manera, proponemos tomar las ventajas del método de recolección de datos del fenotipado digital activo y de la generación de fenotipos computacionales. De esta manera, se integrarían al día a día de los participantes, permitiendo una implementación de las tareas en entornos naturales.

1.1. Adaptación de tareas asociativas al fenotipado digital

Anteriormente se abordaron dos maneras de extraer expresiones fenotípicas de enfermedades mentales. Por un lado, los fenotipos digitales, que se generan a través de la interacción con dispositivos móviles. Por otro lado, los fenotipos computacionales, cálculos y parámetros de modelos que representan procesos latentes a la toma de decisiones.

Para generar un fenotipo digital se pueden utilizar dos vías: pasiva o activa. En la primera se extraen datos de la huella digital del usuario y se correlacionan con enfermedades mentales [14]. La segunda es un método en el que es necesaria la participación del usuario con tareas específicas o encuestas [14].

Las tareas que se utilizan en la extracción activa de datos suelen ser actividades que involucran la toma de decisiones y su relación con otros procesos cognitivos, por ejemplo, rompecabezas, memoramas o emparejamiento de imágenes con texto. Sin embargo, estas actividades carecen de métodos precisos y estandarizados para relacionar la toma de decisiones con otros procesos cognitivos [26]. Por lo tanto, utilizar tareas que ya cuenten con evidencia para analizar procesos cognitivos resulta esencial para garantizar la validez de los datos recopilados.

A partir de este planteamiento surge nuestra propuesta, adaptar tareas computarizadas que logren extraer fenotipos computacionales a través de dispositivos móviles. Nuestra opción son las tareas computarizadas de aprendizaje por refuerzo y memoria de trabajo (RLWM, por sus siglas en inglés, *Reinforcement Learning Working Memory*) y su formalización computacional, que han sido validadas en poblaciones con DCL y han demostrado ser efectivas para identificar la interacción entre la memoria y la toma de decisiones [27, 28, 29, 30, 31].

Estas tareas son aplicadas en computadora en 10 bloques (versión reducida de Master y colaboradores [27]). Por lo tanto, el objetivo de este estudio es adaptar las tareas RLWM a un dispositivo móvil, así como explorar la posibilidad de reducirlas. Esto, con el propósito de evaluar si la versión móvil y reducida conserva la estabilidad de los parámetros del modelo.

En la literatura revisada, se encontró que los estudios sobre las tareas RLWM se han realizado principalmente en entornos controlados de laboratorio y mediante el uso de computadoras. Esto limita la accesibilidad en la vida cotidiana de las personas de la tercera edad. Además, no se han identificado investigaciones, dentro de la literatura revisada, que implementen las tareas con población mexicana de la tercera edad. Por tanto, la implementación móvil y reducida para personas mexicanas de la tercera edad, representa un avance tanto en el campo de la psiquiatría computacional como en el de la IHC, ya que promueve el desarrollo de herramientas para el estudio de alteraciones cognitivas en etapas tempranas de la enfermedad de Alzheimer.

De esta manera, la contribución del presente trabajo es implementar las tareas experimentales RLWM en un entorno externo al laboratorio (controlado) y reducir el tiempo de implementación de las mismas.

Capítulo 2

Marco Teórico

A continuación, se revisa la teoría del aprendizaje por refuerzo, ya que es el tipo de aprendizaje propuesto para modelar el comportamiento y, a partir de este, inferir variables cognitivas.

2.1. Aprendizaje por Refuerzo

El RL tiene sus orígenes en dos corrientes metodológicas; ambas desarrollaron este tipo de algoritmos de manera independiente hasta converger en lo que hoy conocemos como RL [20, 32]. Por un lado, los psicólogos del aprendizaje animal; por otro, quienes buscaban una solución al problema de control óptimo. Ambas posturas resultan valiosas para el desarrollo de RL; sin embargo, por lo que aquí compete, se abordará el desarrollo de la primera corriente.

Thorndike [33], en 1911, propuso la Ley del Efecto; misma que es considerada como un principio básico para el entendimiento del comportamiento. En su propuesta, Thorndike desarrolla que, bajo las mismas condiciones, aquellas conductas que son seguidas inmediatamente de la satisfacción son más probables de ocurrir que aquellas que son seguidas de algo que disguste [33].

A pesar de que Thorndike aún no utilizaba la palabra reforzamiento, la idea central de su propuesta resultó ser un momento decisivo para las teorías psicológicas que buscaban explicar cómo aprenden los animales a través del ensayo-error.

Dejando de lado a otros precursores (cuyos aportes son valiosos, pero no relevantes para la formalización teórico-matemática de RL), el primero en utilizar el concepto de reforzamiento fue Iván Pavlov [34]. Este autor desarrolló una propuesta teórica y metodológica para explicar cómo los

animales aprenden a predecir estímulos a partir de la aparición de otros [34]. Su experimento clásico consistió en analizar la relación entre estímulos. Para esto, en un cuarto aislado de estímulos se realizaban experimentos con perros. El procedimiento consistió en presentar 2 estímulos al perro: alimento y el sonido de un metrónomo. Luego de determinado número de ensayos únicamente se presentaba el sonido del metrónomo. Si el sonido del metrónomo producía la misma respuesta que el alimento (salivar) sin presencia del alimento, se infiere que hubo una asociación entre ambos estímulos. La respuesta que produce el alimento es llamada respuesta incondicionada. Una vez que esta respuesta es producida cuando se presenta únicamente el sonido del metrónomo, se le llamó respuesta condicionada. Ambas respuestas fueron medidas a través de un conducto que recolectaba la saliva, y que fue añadido al perro a través de una cirugía [34].

Para profundizar, analicemos un ejemplo. Un animal puede aprender a tenerle miedo a los sonidos fuertes. Imaginemos a un venado, mientras come bayas de un arbusto. De pronto, comienza a escuchar sonidos a su alrededor, quizá haya un puma (un depredador natural del venado). Sin embargo, el venado sigue comiendo de las bayas del árbol. De pronto, escucha un rugido fuerte y ve al puma balancearse contra él. De alguna manera, logra reaccionar y puede escapar del puma. Meses después, el venado se encuentra comiendo pasto, en un lugar distinto. Enseguida tiene un árbol de frutos medianos. Mientras come, uno de los frutos cae y genera un sonido fuerte al impactar con el suelo. El venado reacciona y ya se encuentra a una velocidad de 40 km/h, escapando de un peligro ... inexistente.

En este ejemplo, podemos observar que los animales pueden aprender el valor predictivo de un estímulo. El animal asoció el sonido fuerte (estímulo condicionado, EC) a un malestar (estímulo incondicionado, EI). Por lo tanto, es capaz de predecir que un sonido fuerte tiene la probabilidad de generarle malestar (ser un depredador), por lo que se activan sus comportamientos de escape.

De esta manera, el EC predice respuestas que el EI genera. En este caso, correr de manera descontrolada al ver un puma es óptimo. Sin embargo, correr cuando hay un sonido fuerte que no es un depredador, también es óptimo. Ya que, al ser un sonido fuerte, existe la posibilidad de que ese sonido provenga de un depredador ... y debe escapar corriendo. Si los animales no aprendieran de los valores predictivos de los estímulos en su entorno, no podrían sobrevivir. Es un mecanismo que les permite adaptarse al ambiente en el que se encuentran. Por lo que el condicionamiento pavloviano es una explicación al cómo los animales aprenden el valor predictivo de un estímulo

sobre otro; cómo el EC predice al EI, cómo el sonido fuerte predice al puma.

Por otro lado, en 1953, Skinner [35] propuso otro tipo de aprendizaje animal. En el condicionamiento pavloviano, el animal aprende el valor predictivo de un estímulo sobre otro. En el aprendizaje operante, propuesto por Skinner, el animal aprende a operar en el ambiente para optimizar las recompensas que recibe [35]. Skinner introducía ratas privadas de su alimentación a cajas experimentales. Dentro de estas cajas se encontraban dos componentes principales: la palanca y el comedero. El comedero proporcionaba alimento al animal siempre y cuando este presionara la palanca. Por tanto, se esperaba que la conducta de presionar la palanca aumentara con el tiempo, debido a que la rata aprendería a que operar sobre la palanca le permitía acceso al comedero [36].

Por ejemplo, un animal tiene un entredicho entre si buscar comida a un lugar nuevo o ir a donde la ha conseguido últimamente (problema exploración vs explotación, también abordado en los algoritmos de RL). Este entredicho no es menor, de este dependerá si el animal come o no. Por lo tanto, el animal tomará su decisión en función de las recompensas que recibe. Ir a un lugar nuevo (explorar) implica exponerse a depredadores, abandonar por más tiempo su hogar y arriesgarse a no encontrar nada. Por el otro lado, ir al lugar de siempre implica comida segura. Por lo que es más probable que decida ir al lugar de siempre, a menos que las condiciones de ese lugar cambien (llegue un depredador, se agote la comida, entre otros).

De esta manera, Pavlov y Skinner son los autores del condicionamiento pavloviano y operante, respectivamente. Sin embargo, no son los primeros en intentar explicar el aprendizaje animal en términos computacionales. El primer modelo formal del comportamiento fue propuesto por Rescorla y Wagner en 1972 [37].

Rescorla y Wagner desarrollaron un modelo para explicar un fenómeno en condicionamiento pavloviano, el bloqueo. Propusieron que los animales únicamente aprenden cuando sus expectativas no son similares a lo que esperaban, en otras palabras, cuando son sorprendidos. La formalización matemática se muestra a continuación (véase Ec. 2.1):

$$V_{t+1} = V_t + \Delta V_t \tag{2.1}$$

$$\Delta V_t = \alpha\beta(\lambda - V_t) \tag{2.2}$$

Donde V, representa la sorpresa del animal, o sea, el valor de predicción. Si un animal resulta ser sorprendido, aumentará el poder de la asociación. Por lo que aumentará el valor de predicción. Por

tanto, al inicio, el valor de V puede crecer de manera rápida, pero ensayo a ensayo reduce su tasa de crecimiento hasta generar una asíntota en 1. De esta manera, el cálculo de V en el momento temporal $t+1$ depende del valor de V en el momento temporal t más el valor calculado en la regla de aprendizaje.

En la regla de aprendizaje ΔV (Ec. 2.2), α y β son parámetros asociados a las propiedades del EC y del EI. Luego, λ representa el valor de la recompensa que el animal recibió. Por lo tanto, la diferencia entre λ y V resulta en la expectativa del animal.

Aunque el modelo Rescorla-Wagner es una aproximación a la toma de decisiones animal y es un modelo que ha influido en la comprensión del aprendizaje, este cuenta con dos problemas: 1) no se contempla un mecanismo que mapee los valores de V a conductas específicas, y 2) no es sensible a la temporalidad de los eventos.

Partiendo de la segunda problemática, Sutton y Barto, en 1990, proponen el aprendizaje por diferencia temporal (TD, por sus siglas en inglés, *Temporal Difference*) [38]. Que es una extensión del modelo Rescorla-Wagner, pero considera la temporalidad de los eventos. La formalización matemática es la siguiente:

$$VS_{t+1} = VS_t + \eta \cdot \delta_t \tag{2.3}$$

$$\delta_t = r_t + \gamma(VS_{t+1} - VS_t) \tag{2.4}$$

En este modelo, como se puede observar, la actualización de V es similar a la del modelo Rescorla-Wagner. A diferencia de que se agrega el parámetro η, el cual modula cuánto valor se le da a la nueva experiencia, calculada en la regla de aprendizaje δ.

En δ (Ec. 2.4), el parámetro r_t corresponde a si hubo o no recompensa por la transición del estado anterior al estado actual. Luego, γ es un parámetro que posibilita la convergencia al valor de la recompensa. Por último, la diferencia en el valor de transición del estado siguiente entre el estado actual representa el núcleo de TD, ya que es la manera en la que se tienen en cuenta los aprendizajes previos. En la regla de aprendizaje de TD, se considera el valor del estado siguiente, por lo que el aprendizaje no se concentra en un solo estado, sino que se retropropaga.

Como se observa, el modelo es capaz de solucionar una de las problemáticas presentes en el modelo Rescorla-Wagner; la de no considerar momentos temporales de los eventos. Sin embargo, al ser

representaciones del condicionamiento pavloviano, en ninguno de los modelos se considera la toma de decisiones del agente. Ambos modelos solo buscan explicar cómo se asocian los estímulos (valor predictivo), pero no agregan una estrategia para mapear conductas.

Por lo tanto, en la corriente del problema de optimización se desarrolló lo que se conoce como la ecuación de Bellman[39]. En 1957, Bellman, formuló un enfoque para resolver problemas de control óptimo mediante la resolución recursiva de dicha ecuación, método que actualmente se conoce como programación dinámica [39]. En trabajos posteriores, el mismo autor introdujo la versión estocástica discreta de estos problemas, los procesos de decisión de Markov [40]. Más adelante, Ronald Howard (1960) desarrolló el método de iteración de políticas para resolver procesos de decisión de Markov [41]. En conjunto, estos desarrollos constituyen los fundamentos matemáticos sobre los que se construyen la teoría y los algoritmos de RL.

La ecuación es la siguiente:

$$V^{\pi}(s) = E^{\pi}[R_{t+1} + \gamma V^{\pi}(S_{t+1})|S_t = s] \tag{2.5}$$

donde s representa el estado. π es la política; o sea, la estrategia del algoritmo para maximizar recompensas. R corresponde a la recompensa que se recibe por haber elegido una acción en el estado s. El factor de descuento γ modera la relevancia del valor del estado siguiente. Por tanto, el valor actual $V^{\pi}(s)$ se calcula a partir de la recompensa recibida dado a la acción, más el producto del factor de descuento por el valor del siguiente estado.

La ecuación anterior describe la actualización del valor de cada estado, sin embargo, el mapeo de conductas se realiza a partir del valor Q, desglosado en la siguiente ecuación:

$$Q^{\pi}(s,a) = E^{\pi}[R_{t+1} + \gamma Q^{\pi}(S_{t+1},A_{t+1})|S_t = s, A_t = a] \tag{2.6}$$

A diferencia del cálculo del valor del estado, la función Q calcula la viabilidad de elegir una acción dado que se está en un estado específico. Por tanto, se calcula el valor del par (s,a).

Q es el valor del par acción-estado, y es el valor que brinda una solución al mapeo de conductas. Los parámetros s, π, R y γ son similares a la función valor (Ec. 2.5). Únicamente se agrega A, que corresponde a la acción tomada. Por tanto, el valor Q es igual a la suma de la recompensa inmediata dada una acción a en el estado s, más el producto de γ por el valor Q de la siguiente decisión.

Sin embargo, aun teniendo los valores Q surge la pregunta: ¿cuál acción tomar? Para esto, se desarrolló la ecuación de Bellman óptima, la cual implementa un mecanismo para seleccionar la acción conveniente [39]. La ecuación es la siguiente:

$$Q^*(s,a) = E[R_{t+1} + \gamma \max_{a'} Q^*(S_{t+1}, a') | S_t = s, A_t = a] \tag{2.7}$$

A diferencia de la ecuación anterior (Ec. 2.6), esta incorpora la selección del máximo valor de los valores Q posibles en el futuro. Por esta razón, el algoritmo siempre buscará maximizar las recompensas y encontrar la política que se lo permita.

Desde una perspectiva del aprendizaje instrumental, la implementación de esta ecuación (Ec. 2.7) ofrece un método para modelar la toma de decisiones considerando un mapeo de conductas. El agente es capaz de aprender no solo de su entorno, sino de las decisiones que toma y de la retroalimentación que recibe debido a la acción elegida [42].

2.2. Psiquiatría Computacional

La psiquiatría tradicional se enfrenta a desafíos teóricos y metodológicos. Estos desafíos afectan la comprensión de las psicopatologías, y la precisión de su diagnóstico y tratamientos [43]. Entre estos problemas se encuentran la superposición de síntomas entre diferentes trastornos y la variabilidad individual dentro de un mismo diagnóstico [44, 45].

El primer problema, la superposición de síntomas entre diferentes trastornos, se refiere a lo siguiente: 1) dentro de los manuales diagnósticos, existen por lo menos dos trastornos que tienen 4 síntomas parecidos, y 2) si esos dos trastornos tienen como requisito presentar por lo menos 4 síntomas de los que se enumeran para estos, existe la posibilidad de que la persona con el trastorno 1 tenga los mismos 4 síntomas que la persona con el trastorno 2.

El segundo problema, la variabilidad individual dentro de un mismo diagnóstico, hace referencia al siguiente caso. Primero, supóngase que los síntomas enumerados para diagnosticar un trastorno son 7. Segundo, como requisito para diagnosticar, la persona debe de presentar al menos 4 síntomas de los 7 enumerados. Tercero, la persona 1 presenta la combinación de síntomas del 1 al 4. Y finalmente, cuarto, la persona 2 tiene la combinación de síntomas del 5 al 7 más el síntoma 1. Esto quiere decir que existe la posibilidad de que 2 personas dentro de la misma psicopatología tengan

síntomas completamente distintos.

Estos problemas evidencian que, mientras dos personas que comparten una patología pueden tener síntomas diferentes, hay personas que pueden estar dentro de trastornos completamente distintos, pero compartiendo sintomatología. Esta falta de sistematicidad y homogeneidad en el diagnóstico de enfermedades mentales pone en evidencia la necesidad de enfoques más precisos [43].

En este contexto, la psiquiatría computacional (PC) surge como una propuesta que aporta soluciones puntuales a la falta de sistematicidad y homogeneidad [46]. En PC se busca integrar herramientas de las ciencias computacionales a la psiquiatría para abordar las limitaciones mencionadas [47].

La propuesta dentro de la PC es modelar computacionalmente aquellos procesos que se relacionan con las enfermedades mentales. Para esto existen tres vías, la primera consiste en generar modelos computacionales de circuitos neuronales para analizar cómo interactúan en patologías específicas. La segunda, aquí el modelado computacional se implementa para inferir estados neuronales y/o cognitivos en trastornos mentales a partir de datos comportamentales. La tercera es la combinación de los anteriores [48].

Para implementar la segunda vía, en PC se identifican 4 niveles de análisis [43]. El primero es el nivel de tareas cognitivas (por sus siglas en inglés, *cognitive tasks*, CT). En este nivel se recopilan datos sobre procesos cognitivos aislados, recopilados a través de tareas diseñadas para saturar dicho proceso cognitivo. Su nivel de análisis es conductual, Por ejemplo, latencia de la respuesta, frecuencia de la respuesta, tiempo de reacción, entre otros [43].

El segundo nivel es el de modelos computacionales, que busca formalizar matemáticamente cómo los procesos cognitivos latentes son calculados y procesados en la mente a partir de su semejanza con algoritmos. El tercer nivel es el de estimar parámetros; aquí se cuantifican los procesos latentes a partir de parámetros computacionales, los cuales fueron inferidos con los datos recopilados con CT. Los parámetros del modelo se interpretan como expresiones del proceso cognitivo latente, y estas expresiones son interpretadas como fenotipos computacionales [43].

El cuarto nivel corresponde al aprendizaje supervisado y no supervisado, donde los parámetros estimados se utilizan como input para algoritmos de clasificación o agrupamiento. Se busca identificar patrones con el objetivo de generar información útil para estratificación clínica. Como se observa en los niveles descritos, la PC propone una metodología sistemática que busca explicar

procesos cognitivos en trastornos mentales específicos [43].

Para modelar los procesos cognitivos existen dos métodos: basado en datos y basado en teoría. El método basado en datos consiste en utilizar algoritmos de ML y DL para clasificar o predecir una psicopatología. Este método se basa en convertir distintos inputs en outputs relevantes para el diagnóstico y tratamiento de psicopatologías específicas. Por ejemplo, se puede entrenar un modelo de máquina de soporte vectorial para clasificar pacientes sanos contra pacientes no sanos. Este método es eficiente, ya que, si se cuenta con una base de datos validada, el algoritmo podrá desempeñarse de manera conveniente. Sin embargo, su principal problema es el de "la caja negra", ya que no se analiza cómo el algoritmo llegó a la clasificación, lo que importa es que sea capaz de clasificar [49].

Por otro lado, el método basado en teoría busca modelar procesos neuronales, cognitivos o comportamentales a través de algoritmos. En este método, los algoritmos buscan replicar procesos biológicos con el fin de poder analizar cómo se llegó a un output específico. Por ejemplo, se le pide a una persona realizar una CT y los datos recopilados son con los que se entrena el modelo. Sin embargo, no es entrenado para clasificar, sino para comportarse similar a los datos con los que fue entrenado; es decir, para predecir el comportamiento de un sistema biológico. De esta manera, si el algoritmo fue entrenado para solucionar una CT, se pueden realizar análisis de cómo llegó a dicha solución. Por lo tanto, este enfoque parte de la visión de la cognición como una máquina de cómputos, ya que busca explicar algorítmicamente cómo se ven afectados procesos cognitivos en enfermedades mentales [49].

2.2.1. RL y PC

Como se mencionó anteriormente, los métodos basados en datos y teoría son eficientes, la elección de uno u otro (o su combinación) depende directamente del problema de investigación. En particular, en esta investigación se utilizó el método basado en teoría y es el que se describirá a profundidad a continuación.

Este método parte de suponer que el comportamiento de los organismos puede ser entendido gracias a un conjunto de procesos que no se pueden medir de manera directa. Por lo tanto, el desarrollo de métodos que permitan la cuantificación de estos procesos es de gran relevancia. En consecuen-

cia, la PC se ha apropiado de los algoritmos de RL e inferencia Bayesiana para poder modelar estos procesos [50].

La idea central parte del mismo supuesto mencionado anteriormente. Se puede interpretar que un modelo de RL tiene dos partes. Por un lado, la parte del comportamiento observable, que es la interacción con su entorno. Por ejemplo, acción, recompensa y actualización del entorno. Sin embargo, también cuenta con procesos latentes, que corresponden a cálculos que le permiten optimizar sus decisiones. Por ejemplo, el cálculo de los valores Q.

De esta manera, el algoritmo es análogo al funcionamiento del organismo. Hay un comportamiento observable el cual podemos medir. En el caso de los humanos y los algoritmos, es la acción ejecutada. Y hay un conjunto de procesos que no se pueden medir de manera directa, en el caso de los organismos es algún proceso cognitivo; en el caso de los algoritmos, el cálculo de las funciones que lo llevan a ejecutar una acción. De esta manera, se busca que el algoritmo se comporte de manera similar a los humanos, para interpretar el cálculo de las funciones del algoritmo como la solución algorítmica que ejecuta el proceso cognitivo que se busca medir [51]. A continuación, se describe el procedimiento para lograr esta meta.

Primero, si buscamos que el algoritmo se comporte de manera similar al organismo, se tiene que generar un entorno en el que ambos puedan interactuar. En psicología experimental se han desarrollado un gran conjunto de entornos controlados que promueven la toma de decisiones y aíslan los procesos cognitivos que la influenciaron. Estos entornos son conocidos como tareas experimentales. Las tareas experimentales se diseñan en función del proceso cognitivo que se pretende medir, ya que el objetivo es saturar dicho proceso para poder asegurar la confianza de la medición [52]. En general, estas tareas tienen dos características principales. La primera es que se diseñan ensayo a ensayo, por lo que son secuenciales. La segunda es que, después de cada ensayo, los participantes reciben una retroalimentación de su decisión. Gracias a estas características es que las tareas experimentales son un entorno en el que un algoritmo de RL puede desplegarse [51].

El propósito es aislar la toma de decisiones y recolectar información que nos apoye a cuantificar los procesos cognitivos que la influencian. Una vez que las tareas se implementan con participantes, se busca explicar su comportamiento mediante algún modelo especifico. El modelo debe de pertenecer a los clasificados como RL y pueden modificarse según el fenómeno cognitivo que se busca modelar [53, 54].

Estas tareas recolectan ensayo a ensayo datos del entorno y de las acciones del participante, obteniendo un conjunto de datos que permite modelar procesos cognitivos a partir del comportamiento. Sin embargo, esto implica que los modelos que se utilicen son dependientes del diseño de la tarea, ya que la tarea genera los datos con los que serán entrenados [55].

Para modelar el comportamiento se parte de los algoritmos clásicos de RL y se realizan adaptaciones que permiten modelar el fenómeno específico. Por ejemplo, para modelar el fenómeno de evitación en la ansiedad, Zorowitz et al. (2020), modificaron la ecuación de Bellman (Ec. 2.7) y agregaron el parámetro ω [53]. Dicho parámetro se muestra en Ec. 2.8:

$$Q^{\omega}(s,a) = r(s,a) + \gamma \sum_{s'} p(s'|s,a) \left[\omega \max_{a'} Q^{\omega}(s',a') + (1-\omega) \min_{a'} Q^{\omega}(s',a') \right] \tag{2.8}$$

Similar a Ec. 2.7, los parámetros Q, r, γ y p representan el valor del par acción-estado, la recompensa inmediata, el factor de descuento y la probabilidad de transición al siguiente estado; respectivamente. El parámetro ω modifica la manera en que el agente evalúa el futuro.

En Ec. 2.7, el agente siempre selecciona el máximo valor posible en el siguiente estado. En Ec. 2.8 cuando $\omega = 1$, el agente es completamente optimista y calcula el futuro como en Ec. 2.7. Cuando $\omega = 0$, el agente es totalmente pesimista y asume que en el futuro elegirá la acción de menor valor posible, es decir, la peor decisión. En términos conductuales, esto implica que un agente con ω bajo sobreestima la probabilidad de consecuencias negativas futuras, a pesar de que no representen una amenaza. Este mecanismo ha sido propuesto como análogo computacional de la ansiedad, ya que reproduce fenómenos clínicamente observados en esta [53].

En el ejemplo anterior se puede observar cómo el fenómeno cognitivo que se busca modelar condiciona el diseño de las tareas experimentales y el tipo de algoritmo que se utilizará para simular las respuestas del participante. Por lo tanto, el modelado computacional cognitivo parte de la deducción; la teoría cognitiva es quien guía al investigador en el diseño experimental y la formalización algorítmica que implementará.

Recapitulando el procedimiento; primero se define el fenómeno cognitivo a modelar, después se diseña una tarea experimental que sature el proceso cognitivo que se pretende medir, y se formaliza un algoritmo de RL que pueda interactuar con la tarea diseñada. Una vez se cuenta con estos tres requisitos, se aplica la tarea con humanos y se recopilan los datos comportamentales necesarios para la inferencia de los procesos cognitivos. Ya que se cuenta con los datos comportamentales

ensayo a ensayo, el siguiente paso es ajustar el modelo a los datos de cada participante [51].

Al proceso de ajustar el modelo a los datos de cada participante se le conoce como ajuste del modelo (*model fitting*). Este consiste en encontrar los parámetros que mejor describen el comportamiento de cada participante. En cada ensayo, se recolecta el estímulo que el participante observó, su acción y la retroalimentación que recibió. A partir de estos datos, en el ajuste del modelo se busca el conjunto de parámetros, representado por θ, que maximiza la probabilidad de haber observado la secuencia de elecciones de cada participante [23].

Para cada ensayo, el modelo asigna una probabilidad a la acción que el participante eligió. De esta manera, se busca optimizar el producto de las probabilidades de cada ensayo para asegurar que θ maximiza la probabilidad de haber observado la secuencia de elecciones de cada participante. Al producto de todas las probabilidades se le conoce como estimación por máxima verosimilitud (MLE, por sus siglas en inglés, *Maximum Likelihood Estimation*) [56].

Debido a que la función de verosimilitud puede presentar varios mínimos locales, MLE se implementa en múltiples ocasiones, cada una con distinto punto de inicio, y se guarda la solución óptima. Este método aumenta la probabilidad de encontrar el mínimo global. Como resultado, se genera un conjunto de parámetros θ por participante, donde cada valor cuantifica un proceso cognitivo específico.

Sin embargo, obtener los parámetros ajustados para cada participante no es suficiente para asegurar que los valores representan lo que pretenden representar (los procesos cognitivos de cada individuo). Por lo tanto, es necesario verificar que el modelo puede predecir los valores ajustados de los parámetros. A este proceso se le conoce como recuperación de parámetros (*parameter recovery*), y es la prueba de validez de los parámetros obtenidos [23].

La recuperación de parámetros consta de tres pasos. El primero, se genera un agente por cada participante, cada agente estará configurado con los valores de los parámetros del participante que busca emular. El agente interactuará con el mismo entorno que el participante hizo, por lo tanto, el agente recibe la misma secuencia de estímulos que el participante. Segundo, una vez recolectados los datos generados por el modelo, estos son ajustados con el procedimiento de ajuste del modelo. Esto genera un segundo conjunto de parámetros recuperados. Por último, el tercer paso corresponde a la evaluación de la correspondencia entre parámetros “reales” y parámetros sintéticos [57].

Como se ha mencionado a lo largo de este capítulo, es importante destacar que recuperar correctamente un parámetro no depende únicamente del modelo, sino también de la tarea experimental. Por lo tanto, el proceso de recuperación de parámetros no solo valida el modelo, sino que también nos brinda información de la sensibilidad del diseño experimental.

Capítulo 3

Antecedentes

Como se mencionó en el capítulo anterior, la elección del modelo y tareas experimentales es dependiente del fenómeno cognitivo que se busca modelar. Debido a que en el DCL uno de los procesos cognitivos que se ve afectado primero es la memoria [58], en este capítulo se describirá el estado del arte referente al modelo RLWM; ya que su objetivo es modelar la memoria de trabajo y RL en la toma de decisiones. La formalización matemática se describe a continuación.

El modelo RLWM mezcla dos sistemas, el de RL y el de memoria de trabajo. Primero se describe el sistema de RL. Que, similar a Ec. 2.7, calcula el aprendizaje incremental. Ec. 3.1 corresponde a la actualización de los valores Q en RLWM. Donde $\delta_t = r_t - Q_t(s,a)$, que es el error de predicción; r_t representa la recompensa observada. Y el parámetro α es la tasa de aprendizaje del sistema RL. En Ec. 3.2 se presenta la función softmax, la cual asigna probabilidades a cada elección. En esta, β regula el grado de determinismo en la elección.

$$Q_{t+1}(s,a) = Q_t(s,a) + \alpha\delta_t \tag{3.1}$$

$$p(a|s) = \frac{\exp(\beta \cdot Q(s,a))}{\sum_i \exp(\beta \cdot Q(s,a_i))} \tag{3.2}$$

El sistema de memoria de trabajo también funciona con una tasa de aprendizaje, pero esta es fija, igual a 1. Esto le permite actualizar asociaciones en un solo ensayo, pero pierde información con el avance de los ensayos. En cada ensayo los valores Q de la memoria de trabajo decaen hacia la política aleatoria uniforme $(\frac{1}{n_A})$ según el parámetro φ (Ec. 3.3). El peso de la memoria de trabajo

para la acción tomada (política), depende de dos parámetros. El primero, la capacidad de retención de estímulos, K. Y, segundo, el grado de confianza en la memoria de trabajo al decidir, ρ. Si el número de estímulos del bloque (n_S) no excede K, todos pueden almacenarse; si lo excede, tiene $\frac{K}{n_S}$ probabilidad de ser retenida. Esto se observa en Ec. 3.4, correspondiente al cálculo del peso $w(t)$.

$$Q_{WM,t+1}(s,a) = Q_{WM,t}(s,a) + \varphi \left(\frac{1}{n_A} - Q_{WM,t}(s,a) \right) \tag{3.3}$$

$$w(t) = \rho \cdot \text{mín}\left(1, \frac{K}{n_s}\right) \tag{3.4}$$

Por último, la política de decisión se calcula a partir de una mezcla ponderada entre el sistema RL y el sistema memoria de trabajo (Ec. 3.5). Para mantener aleatoriedad en las decisiones, se añade ε, un parámetro de ruido no dirigido (Ec. 3.6).

$$p(a) = (1 - w(t)) \cdot p_{RL}(a) + w(t) \cdot p_{WM}(a) \tag{3.5}$$

$$p^*(a) = (1 - \varepsilon) \cdot p(a) + \varepsilon \cdot \frac{1}{n_A} \tag{3.6}$$

El modelo RLWM y sus tareas experimentales fueron propuestos por Collins y Frank en el 2012 [28]. El objetivo era analizar la relación entre la memoria de trabajo y RL en procesos de toma de decisiones. Para lograrlo, se diseñó una tarea experimental en la que los participantes debían de descubrir cuál de tres teclas era la correcta para diferentes estímulos visuales. Para aprender, los participantes recibieron retroalimentación determinista. Las tareas se diseñaron con el propósito de saturar la memoria de trabajo, por lo que se manipuló la cantidad de estímulos que debía de recordar el participante. El estudio se llevó a cabo con un tamaño de muestra de 78, los participantes tenían entre 18 y 40 años.

Luego, se hizo una comparación entre modelos, algunos de RL, otros únicamente con el componente de memoria de trabajo y otros de RL con componente de memoria de trabajo (RLWM). El modelo RLWM explicó mejor el comportamiento de los participantes que cualquier modelo utilizado. Los autores demostraron que no incluir a la memoria de trabajo lleva a interpretaciones erróneas de los datos [28]. Esto, debido a que el aprendizaje por refuerzo depende de la memoria

de trabajo para la resolución de estas tareas. Esto tiene un correlato anatómico con la coactivación de dos áreas del encéfalo: la corteza prefrontal y el sistema corticoestriatal dopaminérgico [28]. La primera media la función de la memoria de trabajo, y la segunda el aprendizaje por refuerzo.

Una vez identificado que el modelo RLWM es el que mejor se ajusta a los datos de las tareas experimentales, el siguiente paso fue intentar explicar estos procesos cognitivos en psicopatologías específicas. De manera reciente, se había demostrado que los pacientes con esquizofrenia presentaban dificultades en tareas de memoria de trabajo y tareas de RL [59], por lo que el modelo era una oportunidad para entender esta problemática.

Por lo tanto, en 2014, Collins y colaboradores, buscaron explicar si los impedimentos en el aprendizaje observados en pacientes con esquizofrenia se deben a fallas en el sistema de RL o en el sistema de memoria de trabajo [29]. El estudio se realizó con 49 participantes con esquizofrenia y 36 sanos. La tarea experimental fue la misma que la implementada por Collins y Frank, 2012 [28]. Encontraron que los pacientes con esquizofrenia fallan en tareas de RL porque no pueden retener la información en su memoria de trabajo, aunque su capacidad para aprender de forma incremental (RL) se mantiene intacta. Esto lo concluyeron debido a la presencia de diferencias, en los valores de los parámetros asociados al sistema de memoria de trabajo, entre grupos.

Después, en 2017, Collins y colaboradores expandieron el alcance del modelo RLWM. La premisa fue relacionar las funciones de predicción de error y del peso de la memoria de trabajo con activación encefálica mediante resonancia magnética funcional (fMRI, por sus siglas en inglés, *functional Magnetic Resonance Imaging*) [60].

Para esto se realizó un experimento de fMRI con 26 participantes. Se investigó si las activaciones neuronales de RL (específicamente la señal de predicción de error, δ) en la sección del estriado y la corteza prefrontal lateral eran modulados por la carga en la memoria de trabajo. Se utilizaron las mismas tareas experimentales que Collins y Frank, 2012 [28]; pero mientras las resolvían, los participantes fueron sometidos a fMRI. Se encontró que δ era más débil cuando la cantidad de estímulos estaba dentro del parámetro K (la capacidad de la memoria de trabajo), y más fuerte cuando le excedía. Esto indica que, si la memoria de trabajo es suficiente para ejecutar una tarea, el sistema RL no aprenderá del entorno. Por lo tanto, RL y memoria de trabajo, interactúan en conjunto, a nivel neuronal y no de forma independiente [60].

Collins, 2017, llevó a cabo un experimento para resolver cómo interactúan memoria de trabajo y

aprendizaje por refuerzo. Su estudio incluyó un tamaño de muestra de 85, con rango de edad entre 18 y 40 años [61]. El diseño de este experimento consistió en 3 fases. La primera corresponde a la tarea experimental de Collins y Frank, 2012 [28], pero solo con tamaños de conjunto de 3 y 6; para analizar el contraste de la carga de la memoria de trabajo. En la segunda fase se realizó otra tarea de memoria de trabajo como intervalo temporal entre la fase de aprendizaje y la fase de prueba. La tarea experimental utilizada fue N-back [62]. Por último, en la tercera fase se repitieron los estímulos de la primera, a manera de prueba. Pero en esta fase se retiró la retroalimentación, para evaluar la retención de los estímulos en la primera fase.

El principal hallazgo de este estudio fue al que la autora llamó efecto de tortuga y liebre. Este explica que las asociaciones aprendidas más fácilmente y, por tanto, requieren menos carga de la memoria de trabajo, se retienen peor que aquellas aprendidas con más esfuerzo. Esto debido a que las aprendidas con mayor esfuerzo son asociaciones que saturaron la memoria de trabajo y se utilizó el sistema de RL. Y el sistema RL aprende de forma incremental; esto implica que, cuando es requerido, hace que los aprendizajes permanezcan en el tiempo. Esto implica que la interacción entre sistemas es asimétrica; la memoria de trabajo interfiere con las computaciones de RL, debilitando el aprendizaje incremental cuando el problema puede resolverse con memoria de trabajo [61].

Hasta este estudio, las investigaciones entorno al modelo RLWM y sus tareas experimentales se dirigieron hacia el análisis de la interacción entre RL y la memoria de trabajo, así como su interacción en la esquizofrenia. En 2020, Master y colaboradores analizaron cómo evolucionan los sistemas de RL y memoria de trabajo durante el desarrollo. El objetivo fue explorar cómo cambian las contribuciones de RL y la memoria de trabajo durante la adolescencia [27].

El estudio incluyó 241 participantes. La muestra se dividió en 187 participantes de entre 8 y 17 años; y un grupo de comparación de 54 participantes de entre 25 y 30 años. Se empleó una tarea adaptada a la de Collins y Frank, 2012 [28]. La adaptación se hizo en dos aspectos: la reducción de la tarea experimental y la modificación de la interfaz, la cual incluyó el uso de un control de videojuego en lugar de teclado. Anteriormente, la tarea se aplicaba sin introducción previa, Master y colaboradores agregaron una interfaz de usuario extra. En esta interfaz se explica a los participantes que los alienígenas llegaron a la tierra y quieren enseñarles su idioma. Es importante hacer notar que, desde la perspectiva del presente estudio, esta adaptación representa un antecedente pa-

ra IHC. Esto debido a que fue el primer esfuerzo por adaptar las tareas RLWM para que fueran accesibles al usuario objetivo.

En general, el estudio demuestra que el desarrollo del sistema RL es el factor que más contribuye a los cambios en el aprendizaje durante la adolescencia. Los parámetros de memoria de trabajo mostraron efectos de edad débiles, y los cambios en capacidad de memoria de trabajo se asociaron a niveles de testosterona, más que a la edad cronológica [27]. Sin embargo, este trabajo no es el único que ha incorporado la adaptación de las tareas para hacerlas accesibles para su público objetivo.

En 2022, Weydmann y colaboradores, buscaron replicar los efectos de la carga de la memoria de trabajo sobre el rendimiento del RL. Pero el estudio se realizó en pandemia, así que se implementó en línea [63]. La muestra del estudio fue de 30 participantes, seleccionados aleatoriamente de un grupo de 242 voluntarios. Con rango de edad entre 18 y 24 años. Se utilizó la tarea experimental de Collins, 2017 [61]. El estudio logró replicar los efectos reportados de la memoria de trabajo sobre RL reportados por Collins en 2017 [61].

Este hallazgo indica que las tareas RLWM pueden ser aplicadas de manera remota. Justificado a partir de mostrar evidencia de que las tareas RLWM siguen midiendo eficazmente la interacción entre el aprendizaje por refuerzo y la memoria de trabajo, a pesar de ser implementadas en línea. Si bien, el estudio destacó la relevancia de la supervisión para garantizar la calidad de los datos, los resultados obtenidos representan una posibilidad de aplicar la tarea experimental sin monitorización activa, lo cual también representa un antecedente para IHC. Sin embargo, en la literatura revisada no se encontró que las tareas hayan sido aplicadas sin monitorización o se hayan implementado en dispositivos distintos a computadoras.

En 2024, Hassanzadeh y colaboradores, analizaron cómo la interacción entre la memoria y el aprendizaje se ve afectada por el envejecimiento y el DCL [31]. Los autores implementaron la tarea experimental de Master y colaboradores [27], con un grupo de 48 participantes de entre 25 y 65 años. Asignaron a los participantes en diferentes grupos por rangos de edad; al grupo de jóvenes (18-40 años) se asignaron 22 participantes, al grupo de adultos de edad mediana (41-65 años) se asignaron 26 participantes. El grupo de adultos de edad mediana se dividió en dos en función de la puntuación de los participantes en el MoCA, 11 sanos y 15 con DCL.

Para confirmar que el punto de corte elegido era correcto, aplicaron un modelo de regresión logísti-

ca. El modelo utilizó métricas de desempeño conductual (la precisión y los tiempos de reacción) para predecir la edad. El análisis indicó que el punto de corte de 40 años lograba la mayor exactitud (85.7 %), validando así el inicio de la edad mediana a los 40 años [31].

Los hallazgos de este estudio demostraron que el envejecimiento y el DCL afectan de manera distinta a los parámetros del modelo. Respecto al envejecimiento, se observó que el tiempo de reacción y la precisión decrecen en función de la edad. Para analizar efectos de la edad y no del DCL, se compararon jóvenes contra adultos de mediana edad sanos, encontrando diferencias en los parámetros α, φ y ε, que representan la tasa de aprendizaje, el decaimiento de la memoria de trabajo y el ruido de decisión, respectivamente [31].

El peso inicial de la memoria de trabajo (ρ), se mantuvo estable en todos los grupos, lo que sugiere que el uso de la memoria de trabajo no se ve afectado por la edad o el DCL. Lo anterior evidencia que existe una diferencia entre los participantes en función de la edad. Por otro lado, los participantes con DCL mostraron una precisión menor y tiempos de reacción significativamente más lentos que los adultos de mediana edad sanos. Adicionalmente, el parámetro de ruido de decisión (ε) fue el único que diferenció a los adultos de mediana edad sanos de aquellos con DCL. Esto sugiere que el el modelo RLWM es capaz de diferenciar DCL mediante el aumento de la incertidumbre en la elección más que por una falla del aprendizaje incremental o la memoria de trabajo [31].

El recorrido bibliográfico presentado en este capítulo muestra que el modelo RLWM y sus tareas experimentales han sido validados en distintas poblaciones y contextos. Sin embargo, ninguno de estos estudios ha abordado una reducción de la tarea adicional a la de Master y colaboradores, no la han adaptado a dispositivos móviles, ni la han implementado en población mexicana de la tercera edad. Por lo tanto, el presente trabajo busca reducir la tarea RLWM de Master y colaboradores, adaptarla a un dispositivo móvil, y evaluar si conserva la estabilidad de los parámetros del modelo. Adicionalmente, se explorarán las motivaciones, preferencias y necesidades de los usuarios de la tercera edad respecto a la interacción con las tareas.

Capítulo 4

Metodología

Debido a que se buscan dos objetivos distintos (1. La reducción y adaptación móvil de las tareas RLWM y, 2. Aplicar diseño centrado en el usuario para explorar motivaciones, preferencias y necesidades de la población) se implementaron dos metodologías distintas. Cabe mencionar que el estudio fue sometido y aprobado por el Comité de Ética de la Facultad de Nutrición y Enfermería de la Universidad Autónoma de Chihuahua (UACH), garantizando que todos los procedimientos cumplieran con los lineamientos éticos correspondientes (Véase Anexo 1).

Para la reducción y adaptación móvil de las tareas de RLWM, se implementó una metodología cuantitativa. Para abordar la integración de las necesidades, motivaciones y preferencias de la población mexicana de la tercera edad en un prototipo móvil que despliegue las tareas de RLWM, se siguió una metodología cualitativa. A continuación, se describe cada una de ellas.

4.1. Cuantitativa

El proceso utilizado para llevar a cabo esta metodología inició con el reclutamiento de los participantes, se siguió de la selección de estos, para luego aplicar las tareas experimentales, por último, se llevó a cabo el análisis de los datos. El proceso se describe en la Figura 4.1. A continuación, se detalla cada proceso.

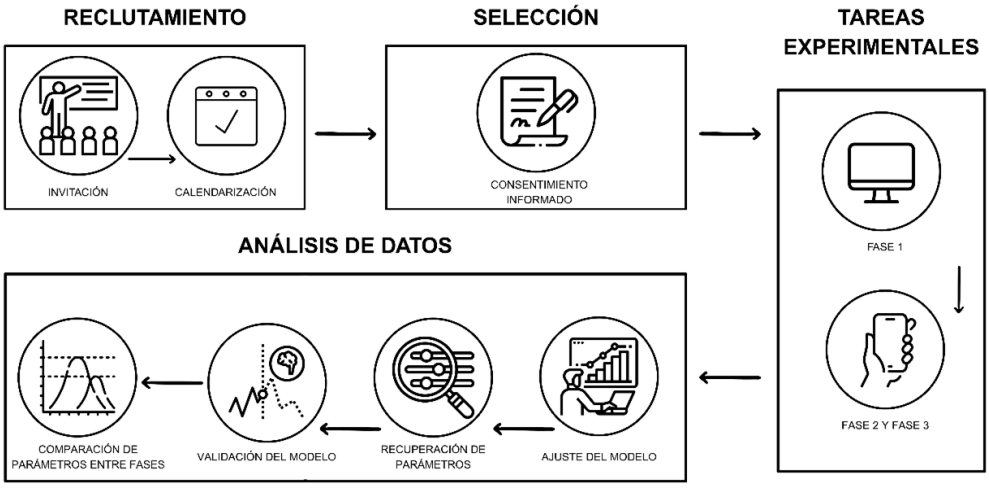


Figura 4.1: Pipeline de metodología cuantitativa.

4.1.1. Reclutamiento

El reclutamiento se inició con la invitación de los participantes al estudio. A pesar de que el objetivo es implementar una tarea experimental sensible al DCL, no se incluyó a población de la tercera edad. Esto debido a que con una población mayor a 40 años se podría presentar variabilidad en los datos ya que el modelo RLWM es sensible al envejecimiento [31]. Por lo tanto, la invitación se extendió a población universitaria, menor de 25 años.

La invitación se realizó en las facultades de ingeniería, ciencias políticas y sociales, y ciencias de la cultura física de la UACH. La invitación se realizó en persona de manera grupal, durante las horas clase de los estudiantes. Durante la invitación se explicó el proyecto y sus objetivos, se recalcó el por qué era importante su participación y se les brindó un medio de contacto (enlace a un grupo de WhatsApp).

Luego, mediante el grupo de WhatsApp, se les hizo llegar un enlace para agendar sus sesiones. El enlace los dirigía a Calendly, una herramienta en línea para agendar reuniones automáticamente. La fase de reclutamiento concluía una vez que el participante había agendado sus sesiones.

4.1.2. Selección

Como se observa en la Figura 4.1, la fase de selección únicamente está compuesta por la firma del consentimiento informado. La fase de selección se llevó a cabo en tres distintos lugares, según la

facultad a la que pertenecía el participante: 1) Laboratorio de Realidad Virtual y Aumentada de la Facultad de Ingeniería de la UACH, 2) Salón de cómputo 2 de la Facultad Ciencias de la Cultura Física de la UACH, y 3) Salón de conexión joven de la Facultad de Ciencias Políticas y Sociales de la UACH. En cada espacio se aseguró la privacidad de los participantes siguiendo las medidas correspondientes (revise Anexo 1).

En la primera sesión, previo al inicio de las sesiones experimentales, se solicitó a los participantes firmar el consentimiento informado. Este se implementó mediante Google Forms. El usuario debía de ingresar con su cuenta institucional y esta se registraba al enviar la respuesta, para verificar que la persona era estudiante de la UACH. Luego se le solicitaba al usuario su nombre completo. Después de leer el consentimiento, debía de rellenar 2 celdas, la primera para declarar que al contestar el consentimiento era mayor de edad y la otra para consentir participar en la investigación. La fase de selección finalizaba una vez que el usuario enviaba el consentimiento y el investigador responsable se aseguraba de que le llegara una copia al correo del participante. El contenido del consentimiento informado se encuentra en el Anexo 2. Se concluyó esta etapa con 40 participantes.

4.1.3. Tareas Experimentales

Las tareas experimentales de RLWM son ejercicios en los que se presenta un estímulo y 3 opciones al participante, el participante debe de elegir una de las opciones. Una de estas opciones, de manera aleatoria, es la correcta al estímulo presentado. Una vez que el participante elige, se le da una retroalimentación en función de si la elección fue correcta o incorrecta. En la Figura 4.2 se puede observar un ensayo experimental, que consiste en 3 etapas: presentación del estímulo, elección del participante y retroalimentación. El objetivo es que el participante aprenda la relación estímulo – respuesta correcta a lo largo de sus intentos.

El mensaje de retroalimentación se fija en pantalla durante 0.75 segundos. Luego de la retroalimentación inicia un nuevo ensayo. Si el participante no elige dentro de 7 segundos, se marca como respuesta invalida e inicia un nuevo ensayo. El tiempo entre la retroalimentación y el nuevo ensayo (intervalo entre ensayos, IEE) es de 0.5 segundos, durante el IEE no se presenta ningún estímulo en pantalla.

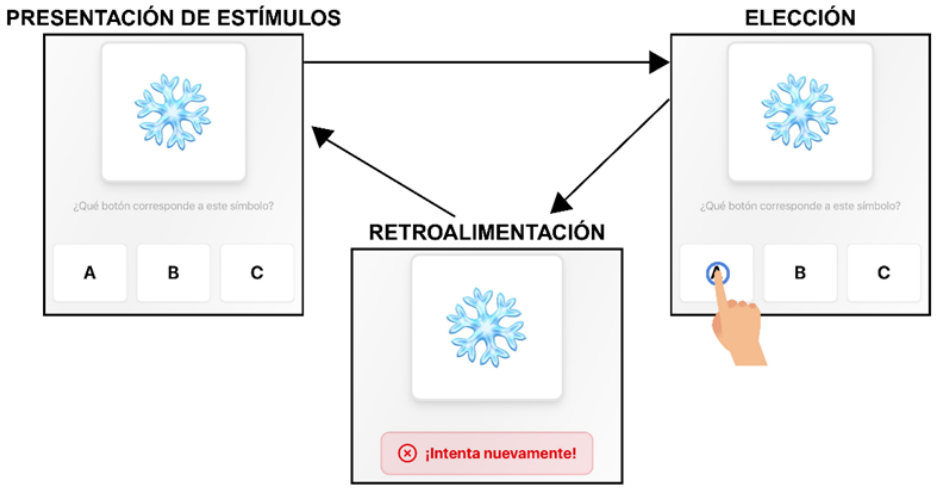


Figura 4.2: Ensayo a ensayo de tarea experimental.

Un ensayo es la unidad mínima en estas tareas experimentales. Sin embargo, se componen por más factores que se describirán a continuación. El experimento se compone por 429 ensayos. Este se divide en 10 bloques. Cada bloque tiene una cantidad de ensayos determinada por el tamaño de conjunto (TC) del mismo. El tamaño de conjunto puede variar entre 2 y 5. De manera aleatoria, a cada bloque se le asigna un TC, sin embargo, el algoritmo solo puede asignar a 3 bloques TC = 2, a 3 bloques TC = 3, a 2 bloques TC = 4 y a 2 bloques TC = 5. Por ejemplo, en la Figura 4.3 se muestran distintos bloques, cada uno con TC distinto. El TC determina la cantidad de estímulos que serán asignados al bloque. Igualmente, de manera aleatoria, a cada bloque se le asigna una categoría distinta (Ej. medios de transporte, alimentos, colores, formas, entre otros). Por lo tanto, como se muestra en la Figura 4.3, si al bloque 1 se le asignó la categoría colores y el TC = 3, se tomarán 3 colores distintos de una lista que contiene mínimo 5 colores diferentes. Por último, cada estímulo es presentado en pantalla al usuario 13 veces, esto quiere decir que la cantidad de ensayos de un bloque es el resultado del TC multiplicado por 13.

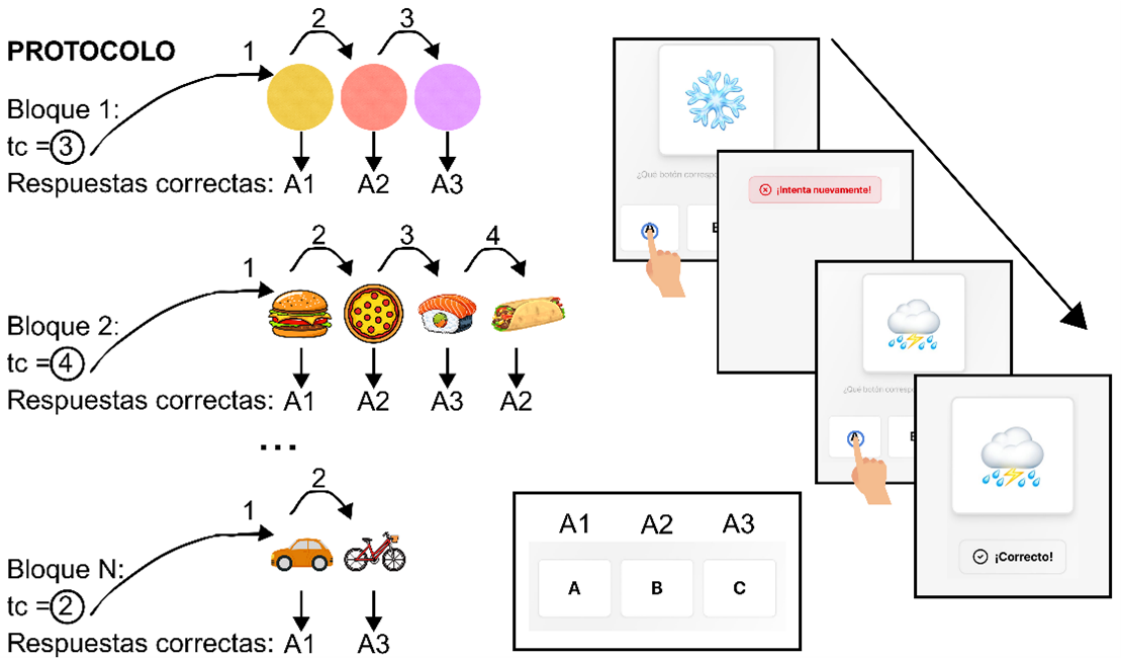


Figura 4.3: Protocolo de tarea experimental.

Una vez definidas las tareas experimentales RLWM, a continuación, se describen los objetivos del diseño experimental: 1) validar la implementación de las tareas de RLWM en dispositivos móviles, y, 2) validar la reducción de las tareas de RLWM. Por lo tanto, en el diseño experimental implementado, la variable dependiente son los parámetros del modelo computacional RLWM. Las variables independientes son: 1) el dispositivo en el que se implementan las tareas de RLWM y, 2) variables de reducción: cantidad de bloques, ensayos por estímulo y tamaño del conjunto.

Para llevar a cabo los experimentos se agendaron tres sesiones. En la primera se firmó el consentimiento informado y se aplicó la primera fase experimental. Las fases experimentales dos y tres correspondes a la sesión dos y tres, respectivamente. El cruce de variables independientes genera las distintas fases experimentales que se implementaron, este cruce se puede observar en la Tabla 4.1. La fase 1 corresponde a la tarea reducida por Master y colaboradores [27], implementada en computadora. La fase 2, implementada en dispositivo móvil y con una reducción de aproximadamente el 40 % de ensayos totales. Y la fase 3, implementada en dispositivo móvil y con una reducción de aproximadamente 80 % de ensayos totales.

Tabla 4.1: Cruce de variables independientes y manipulación de variables.

	Computadora	**Celular**	**Celular**
Bloques: 10; Ensayos: 13; TC: 2,3,4 y 5	Fase 1	–	–
Bloques: 9; Ensayos: 10; TC: 2,3 y 4	–	Fase 2	–
Bloques: 3; Ensayos: 10; TC: 2,3 y 4	–	–	Fase 3

Se empleó un diseño intrasujeto de medidas repetidas con tres condiciones A-B-C (donde A es la tarea "original", B es la implementación en celular con nivel bajo de reducción, y C es la implementación en celular con nivel alto de reducción). Cada participante actuó como su propio control. La reducción de las variables de reducción se justifica en la experiencia de expertos en el área de PC.

4.1.4. Análisis de Datos

Previo al análisis de datos, se llevó a cabo el siguiente procedimiento para limpiar los datos: 1) se eliminaron los bloques duplicados. 2) se aplicó un filtro para conservar a los participantes que completaron el número de bloques requerido por fase (10 para fase 1, 9 para fase 2, y 3 para la última fase). 3) Se estableció un límite para los tiempos de respuesta a 7,000 ms. Si el participante excedía ese tiempo, la respuesta se tomó como incorrecta. Después del proceso de limpieza, los datos de 37 participantes fueron los seleccionados para realizar el análisis de datos.

Análisis comportamental

Antes del modelado computacional, se verificó que la tarea capturó los patrones conductuales esperados. Para el análisis comportamental se obtienen dos métricas: la precisión de los participantes y el tiempo de reacción. Ambas son independientes al modelado computacional. Pero son los datos crudos del comportamiento de los participantes, mismos datos que se utilizarán para inferir variables cognitivas. Por tanto, es importante analizar y conocer estas métricas para entender el comportamiento del modelo.

La precisión se obtiene al calcular la cantidad de aciertos sobre la cantidad de ensayos. Se puede

obtener a nivel bloque, por TC o de la tarea completa. Esta métrica nos informa sobre el desempeño del participante, por tanto, que tantas veces acertó en escoger la asociación estímulo-acción correctas. La precisión, si se grafica en función de los ensayos, puede mostrar la curva de aprendizaje de cada individuo o de un grupo. Debido a que el RL es incremental, se espera que esta curva incremente de manera positiva.

El tiempo de reacción se refiere al tiempo que tarda un participante en ejecutar una acción una vez que el estímulo aparece en pantalla, que como máximo es de 7 segundos. El que un individuo tarde más que otro puede deberse a múltiples factores, como la velocida de procesamiento de información o la capacidad de la memoria de trabajo. Por lo tanto, es una métrica que puede ayudar a comprender los datos incluyendo procesos cognitivos dependientes del tiempo. Si se grafica en función de los ensayos, se puede observar una curva descendente de cada individuo o de un grupo.

Modelado computacional

El análisis computacional se realizó en una laptop con Windows, Python 3.13 en entorno conda, con 20 núcleos disponibles. Para reducir los tiempos de cómputo, el modelado se ejecutó en paralelo, utilizando todos los núcleos disponibles.

Una vez verificado el comportamiento conductual, se procedió a la obtención de los fenotipos computacionales mediante el ajuste del modelo RLWM. Primero se realizó el ajuste del modelo, para estimar los parámetros individuales; después, se recuperaron los parámetros para verificar que los valores estimados fueran confiables.

Para el ajuste del modelo, se utilizó el método MLE. Este proceso busca encontrar el conjunto de parámetros θ que maximice la probabilidad de observar las respuestas reales de los participantes. Aunque el objetivo es maximizar MLE, su implementación requiere una adaptación debido a dos razones: 1) al multiplicar las probabilidades de cada ensayo se obtendrían números infinitesimales, por lo tanto, al aplicar el logaritmo se transforman los productos en sumas; y 2) La mayoría de los algoritmos de búsqueda, como el utilizado en este estudio (L-BFGS-B), están diseñados para minimizar funciones de costo. Por lo tanto, se buscó minimizar log-verosimilitud negativa (NLL, por sus siglas en inglés, *Negative Log-Likelihood*), donde el valor mínimo de NLL empata con el punto de máxima verosimilitud:

$$NLL(\theta) = -\sum_{t=1}^{T} \log P(a_t|s_t, \theta) \tag{4.1}$$

Donde θ corresponde al conjunto de parámetros que se busca recuperar. La sumatoria representa todos los ensayos realizados por el sujeto. a_t y s_t corresponden a la acción y el estado. En este caso, el participante solo puede realizar 3 acciones: A, B y C; y los estados son los estímulos que se presentan en pantalla. $P(a_t)$ representa la probabilidad de la acción elegida por el participante en el ensayo t, predicha mediante la función softmax:

$$P(a = i|s_t) = \frac{\exp(\beta \times Q(s_t, i))}{\sum_{j=1}^{K} \exp(\beta \times Q(s_t, j))} \tag{4.2}$$

Donde i es la acción de la cual se calcula la probabilidad. El parámetro β regula la sensibilidad a la diferencia entre las acciones. Si β tiende a infinito, implica una elección determinista (explotación), mientras que si tiende a 0 se toma una acción aleatoria uniforme. El valor utilizado para este parámetro se evaluó para 100 y 25, según la literatura [27, 64].

Adicionalmente, se evaluó para 17, 10 y 5; ya que el modelo con $\beta = 25$ arrojó mejores resultados que $\beta = 100$. Debido a que β se encuentra en un rango de 0 a ∞, hacer una búsqueda por fuerza bruta no era viable computacionalmente. Por esto, se fijó un valor de $\beta = 10$, y se tomó el valor medio entre 10 y 25, y así se probó $\beta = 17$. Para $\beta = 5$ se tomó el valor medio entre 0 y 10. Para seleccionar el mejor modelo basado en el parámetro β se generaron parámetros sintéticos bajo una distribución uniforme y se evaluó cuál modelo los recuperaba mejor. El criterio de selección de β se basó en la recuperabilidad de parámetros, se seleccionó aquel que permitió recuperar de manera más confiable los parámetros sintéticos en el proceso de recuperación de parámetros.

El modelo RLWM propuesto por Collins y Frank, 2012, incluye cinco parámetros libres [28]. Sin embargo, en este estudio se excluyó el parámetro de sesgo de aprendizaje (bias), manteniendo α, φ, ρ, K y ε. Esta simplificación responde a mantener concordancia metodológica con Hassanzadeh y colaboradores, 2024, quienes también excluyeron dicho parámetro en su implementación [31].

Tabla 4.2: Descripción de parámetros y bounds para implementar L-BFGS-B.

Parámetro	Descripción	Bound
α	Determina la velocidad a la que el sistema de RL actualiza los valores de Q	0.01 – 0.99
K	Límite de almacenamiento de la memoria de trabajo	1 – Máximo TC
φ	Tasa de pérdida de información en el sistema WM	0.01 – 0.99
ε	Ruido en la decisión	0.01 – 0.99
ρ	Confianza al sistema WM al inicio del aprendizaje	0.01 – 0.99

La búsqueda del mínimo global de NLL se realizó con el algoritmo L-BFGS-B. Este algoritmo permite establecer límites (bounds) para cada parámetro. Los bounds utilizados se reportan en la Tabla 4.2. Adicionalmente, para evitar permanecer en un mínimo local, se realizó la búsqueda con 25 puntos de inicio aleatorios, seleccionando como estimación final el conjunto de parámetros que produjo el menor valor de NLL.

Del ajuste del modelo se generó un conjunto de parámetros por cada participante, los parámetros buscados corresponden a los mencionados en la Tabla 4.2. Después, se siguió a la recuperación de parámetros. En esta fase se utilizaron los parámetros de cada participante para generar un agente (instancia de RLWM) por cada participante. Este agente, conocido como modelo generativo, es el encargado de emular el comportamiento de los participantes para validar los parámetros obtenidos.

La recuperación de parámetros está compuesta por 3 pasos: la simulación, el ajuste del modelo y la comparación de parámetros. Para el primer paso, la simulación, se utilizó el modelo con $\beta = 17$, ya que fue el que mejor ajuste tuvo a los datos. Para asegurar que los resultados no se deben al azar, se realizaron 20 simulaciones por cada agente. En cada simulación, los agentes fueron configurados con el mismo conjunto de parámetros y la misma secuencia de ensayos del participante que emularon.

El ajuste del modelo, el segundo paso, fue similar al descrito anteriormente. Se aplicó el mismo procedimiento de minimización de NLL mediante L-BFGS-B, con 25 puntos de inicio aleatorios y los mismos bounds reportados en la Tabla 4.2. La diferencia radica en que, en lugar de ajustar el modelo a los datos reales de los participantes, se ajustó a los datos simulados generados en el paso 1 [57]. Este proceso se repitió para cada una de las 20 simulaciones por participante por fase (37

participantes $\times$ 3 fases $\times$ 20 simulaciones).

Por último, para el paso final (la comparación de parámetros), se analizó la correspondencia entre los parámetros obtenidos de los participantes ("originales") y los parámetros obtenidos de las simulaciones ("sintéticos"). Para esto se calculó el coeficiente de correlación de Pearson entre ambos conjuntos de parámetros, por fase y por parámetro. Un parámetro se consideró recuperable cuando la correlación entre el valor del parámetro original y el sintético fue estadísticamente significativa. Este análisis permitió evaluar si el modelo es capaz de identificar de forma confiable los parámetros que generaron los datos [23].

4.2. Cualitativa

El proceso utilizado para llevar a cabo esta metodología inició con el reclutamiento de los participantes, se siguió de la selección de estos, para luego implementar grupos focales, y análisis temático de los datos generados por los grupos focales. El proceso se describe en la Figura 4.4. A continuación, se detalla cada proceso.

4.2.1. Reclutamiento y selección

El estudio se implementó a través del programa Casas del Abuelo de la Dirección de Grupos Vulnerables y Prevención a la Discriminación, de la Secretaría de Bienestar Humano y Bien Común del municipio de Chihuahua. Se organizaron sesiones informativas en cada una de las 4 Casas del Abuelo de la ciudad de Chihuahua, Chihuahua para explicar el proyecto a los asistentes y ofrecer detalles sobre la participación en el estudio.

A quienes manifestaron interés en participar se les explicó con mayor detalle el propósito, los procedimientos y los alcances del estudio. Luego, se les solicitó firmar la carta de consentimiento informado (véase Anexo 3). Posteriormente, se recopilaron datos sociodemográficos y clínicos, así como información relacionada al uso, pericia y aceptación de tecnologías. A continuación, se aplicó la prueba cognitiva Montreal (MoCA, por sus siglas en inglés, *Montreal Cognitive Assessment*) [8] para cribar DCL. La prueba se aplicó por estudiantes de la carrera de psicología que realizan sus prácticas profesionales en el ITESM, con una duración aproximada de 20 a 30 minutos.

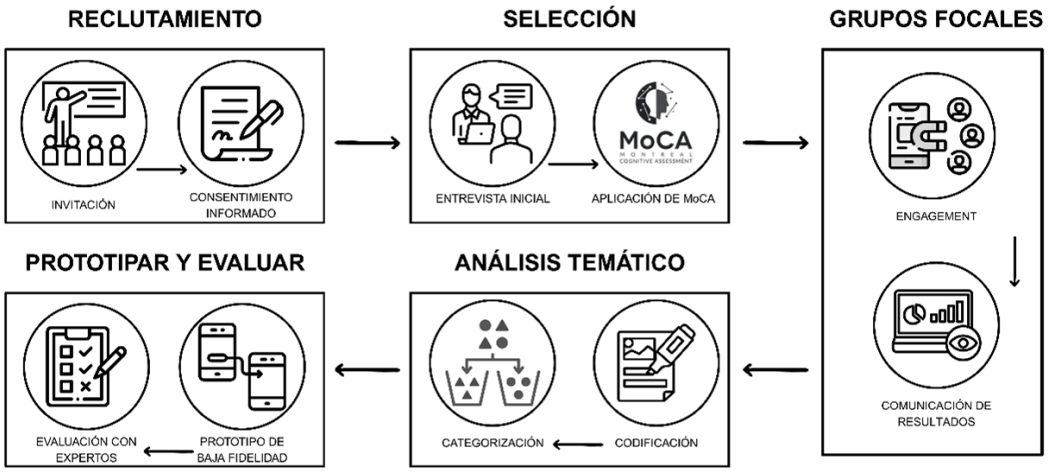


Figura 4.4: Descripción del proceso de metodología cualitativa.

A continuación, se describe el planteamiento y criterios de inclusión. Los criterios de inclusión se definieron con base en consideraciones metodológicas y prácticas del estudio. Estudios científicos sobre el diseño de tecnologías y detección temprana de deterioro cognitivo establecieron edades de 55 años, asegurando así que la población sea representativa de los primeros indicadores de riesgo [65, 66, 67]. Asimismo, los participantes debían de ser miembros de la casa del abuelo debido a un mejor control del seguimiento.

Adicionalmente, los participantes no debían de presentar un resultado equivalente a DCL en el cribado con el MoCA (menor a 24). Esto se debe a que el objetivo no es detectar DCL, sino predecirlo de manera temprana. Por lo tanto, la población objetivo son personas adultas sanas. En resumen, los criterios de inclusión son:

1. Tener 55 años o más.
2. Ser miembro de la casa del abuelo de la ciudad de Chihuahua.
3. Obtener una puntuación igual o mayor a 24 en el MoCA.
4. No tener problemas médicos al exponerse a pantallas de computadoras o celulares.

Se reclutaron 40 participantes, aquellos que no cumplieron con los criterios de inclusión fueron integrados en las sesiones de diseño. Esto siempre y cuando no se pusiera en riesgo su integridad (Ej. problemas neurológicos al exponerse a pantallas de dispositivos electrónicos). Al realizar el

análisis de datos se eliminaron los datos obtenidos de los participantes que no cumplieron con los criterios de inclusión. Esta medida se tomó para evitar la discriminación de los participantes.

4.2.2. Grupos Focales

En el Diseño Centrado en el Usuario (DCU), metodología implementada, se busca que el proceso de desarrollo de un sistema esté guiado por las necesidades, preferencias y necesidades de las personas que lo utilizarán. Este enfoque promueve la participación del usuario, pero no lo convierte en diseñador. Es decir, el usuario es un colaborador, proporciona información valiosa sobre su contexto de uso. Sin embargo, la toma de decisiones sigue siendo responsabilidad del equipo de diseño, el cual traduce los aportes de los usuarios en soluciones. De esta forma, DCU busca un equilibrio entre la voz del usuario y la experiencia del diseñador.

En este estudio se empleó un enfoque de investigación cualitativa y exploratoria, centrada en el usuario. El objetivo principal fue levantar requerimientos del *engagement* con la tarea RLWM. Este proceso se implementó con participantes sin DCL, con el objetivo de sentar las bases para el diseño de una herramienta orientada a la detección temprana del DCL. La técnica de recolección de datos fue a través de grupos focales. Cada sesión de grupo focal tuvo una duración aproximada de 60 a 90 minutos y fue dirigida por un moderador capacitado. La discusión se centró en los requerimientos de *engagement*.

4.2.3. Análisis de Datos

Para el análisis de datos se implementó el análisis temático. En primer lugar, se transcribieron las grabaciones de cada sesión de grupo focal. Después, se realizó una codificación de los datos, asignando etiquetas a fragmentos relevantes del texto. Una vez generados los códigos, se agruparon por temáticas. Por último, con base en estas temáticas, se propusieron ideas de diseño para la aplicación móvil. Cabe señalar que dichas propuestas no fueron sometidas a un proceso de validación formal, por lo que solo representan un punto de partida para estudios posteriores.

Capítulo 5

Resultados

5.1. Análisis Comportamental

La primera métrica es la precisión, que genera la curva de aprendizaje, obtenida del promedio de aciertos ensayo a ensayo de cada participante. La segunda es el tiempo de reacción, referente a la diferencia temporal entre la aparición en pantalla del estímulo y la ejecución de la decisión del participante.

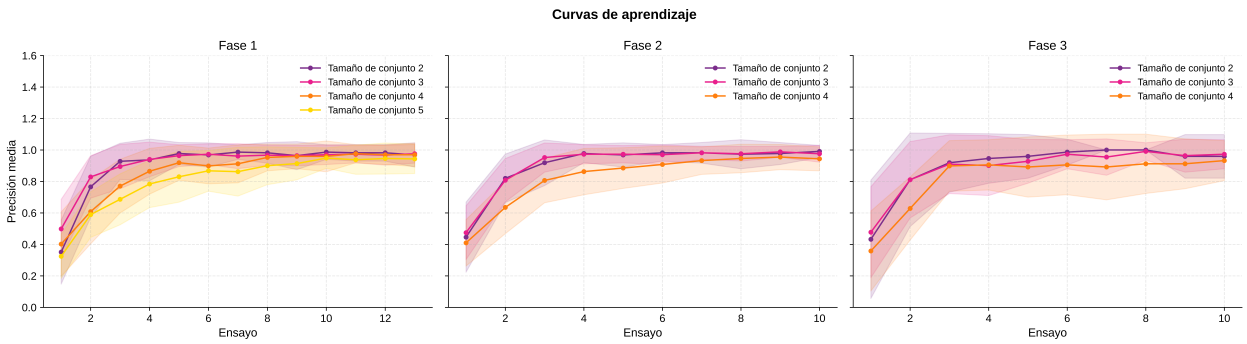


Figura 5.1: En la gráfica del panel izquierdo, correspondiente a la fase 1, se presentan 4 curvas de aprendizaje, la amarilla corresponde al tamaño de conjunto 5, la naranja al 4, rosa a 3 y morado a 2. En las gráficas del centro y derecha los colores se asignan de manera similar, a excepción de que no hay tamaño de conjunto 5.

La Figura 5.1, presenta la comparación de las curvas de aprendizaje entre fases. En el panel izquierdo, la gráfica muestra las curvas de aprendizaje de la fase 1, la gráfica del panel central las de

la fase 2, y la gráfica derecha las de la fase 3. Cada gráfica muestra una curva de aprendizaje por tamaño de conjunto en esa fase.

En la gráfica izquierda se aprecian las curvas de la fase 1; para recordar, en esta fase el rango de valores para el TC fue de 2-5. Por tanto, se observan 4 curvas de aprendizaje, que siguen un orden escalonado según el tamaño de conjunto, en orden descendente del menor TC al mayor. En las gráficas central y derecha se presenta el mismo patrón decreciente; pero en estas gráficas únicamente se muestran 3 curvas de aprendizaje ya que se eliminó el TC de 5. Para recordar, la fase 3 únicamente tuvo un bloque por tamaño del conjunto, esto implica que no se promedian bloques en cada iteración.

El patrón descendente encontrado en las curvas de aprendizaje era el esperado según lo reportado en la literatura. Esto es una señal de que la tarea experimental se ejecutó de manera similar a Hassanzadeh y colaboradores [31]. Esto implica, además, que los participantes son sensibles al tamaño del conjunto y que los procesos cognitivos implicados en la toma de decisiones se están saturando debido al TC.

La Figura 5.2 muestra la comparativa de tiempos de reacción entre fases. De izquierda a derecha las gráficas corresponden a fase 1, fase 2 y fase 3. Cada gráfica muestra una curva del tiempo de reacción por TC en esa fase. En la gráfica izquierda se ve un efecto de escalonamiento en función de los TC, similar al de las curvas de aprendizaje, pero inverso. Este efecto era esperado ya que mayor TC supone mayor tiempo en la toma de decisión. El mismo efecto se replica en las gráficas del centro y la derecha, solo sin el TC de 5.

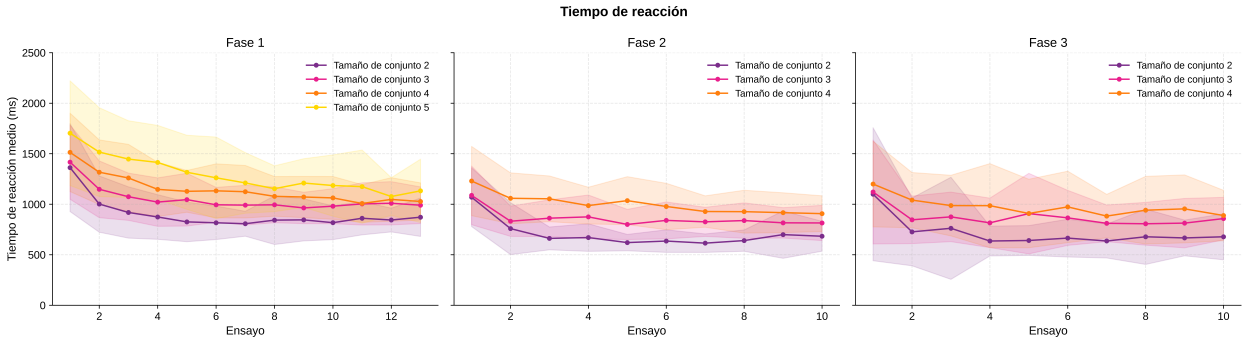


Figura 5.2: En la gráfica del panel izquierdo, correspondiente a la fase 1, se presentan 4 curvas de aprendizaje, la amarilla corresponde al tamaño de conjunto 5, la naranja al 4, rosa a 3 y morado a 2. En las gráficas del centro y derecha los colores se asignan de manera similar, a excepción de que no hay tamaño de conjunto 5.

5.2. Modelado Computacional

El modelado computacional inició con la selección del mejor modelo. Para esto, se entrenaron distintas instancias de RLWM con diferentes valores del parámetro β, mencionados en el capítulo de Metodología. En la Tabla 5.1 se presentan los valores de β y el coeficiente de Pearson para la recuperación de cada parámetro. Para seleccionar el modelo se dividió el rango del coeficiente de Pearson en 4: muy leve, con valores de 0-0.1, representados de rojo en la tabla; leve, con valores de 0.1-0.40, representados de negro en la Tabla 5.1; moderado, con valores de 0.40-0.70, representados de verde en la Tabla 5.1; y alto, con valores de 0.70-1, representados de azul en la Tabla 5.1. Además, se tomaron en cuenta dos factores; el primero, que ε estuviera en un rango alto (ya que en la literatura es el parámetro que se relaciona con el DCL); segundo, el modelo que tuviera más efectos altos y moderados, en consecuencia, menos leves o muy leves.

Tabla 5.1: Resultados de los parámetros con distintos valores de β.

Parámetro/Fase	$\beta = 100$	$\beta = 25$	$\beta = 17$	$\beta = 10$	$\beta = 5$
α/1	0.052	0.287	0.333	0.380	0.375
α/2	0.029	0.233	0.297	0.366	0.297
α/3	0.071	0.165	0.181	0.232	0.221
φ/1	0.419	0.429	0.435	0.447	0.407
φ/2	0.382	0.383	0.395	0.355	0.328
φ/3	0.296	0.268	0.257	0.284	0.237
ρ/1	0.547	0.513	0.510	0.499	0.436
ρ/2	0.515	0.475	0.491	0.437	0.409
ρ/3	0.352	0.345	0.366	0.356	0.292
ε/1	0.984	0.954	0.920	0.847	0.726
ε/2	0.971	0.907	0.845	0.738	0.682
ε/3	0.919	0.794	0.768	0.705	0.630

Como se observa en la Tabla 5.1, ningún modelo cumple con ambos criterios. Los modelos con β alto (100 y 25) mantienen ε en rango alto, pero los demás parámetros tienden a los rangos moderado, leve o muy leve. En los modelos con β bajo (10 y 5) desciende ε, pero mejoran los parámetros restantes (en especial de α). En particular, $\beta = 5$ sitúa ε en rango moderado, lo que confirma que a menor β, menor recuperabilidad de ε; efecto consistente con lo reportado en la literatura. El modelo con $\beta = 17$ representa el mejor equilibrio entre ambos criterios. Ya que mantiene ε en rango alto en las tres fases y, comparado con valores más altos de β, mejora la recuperación de α, φ y ρ. Por lo tanto, para el ajuste del modelo y la recuperación de parámetros, se implementó RLWM con $\beta = 17$.

Adicionalmente, se observa un patrón visual en la Tabla 5.1. El valor del coeficiente de Pearson decrece en función de la fase en todos los parámetros, excepto α en la fase 1. Pero este parámetro en dicha fase fue el único que alcanzó valores del coeficiente de Pearson categorizados como muy leves. En la Figura 5.3 se puede observar este patrón.

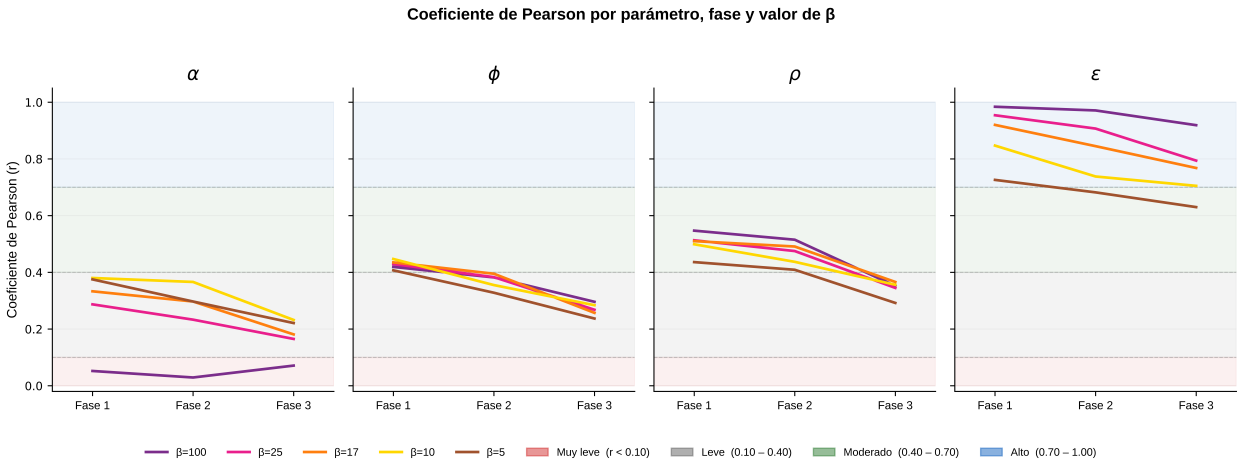


Figura 5.3: Coeficientes de Pearson obtenidos para cada valor de β en el proceso de selección del mejor modelo.

Una vez seleccionado el mejor modelo, el siguiente paso fue realizar el ajuste de este. Para esto, se siguió el procedimiento de ajuste del modelo, descrito en el capítulo de Metodología. En la Figura 5.4 se presenta la distribución de los parámetros estimados por fase. El parámetro α mostró un incremento de fase 1 a fase 3, con una distribución concentrada hacia valores altos en la fase 3. Este patrón sugiere que el modelo asigna mayor peso RL ante una menor cantidad de ensayos. El parámetro φ presentó un aumento de fase 1 a fase 2, manteniéndose en niveles similares en fase 3, lo que indica un mayor olvido del sistema de memoria de trabajo en las manipulaciones experimentales. Además, ρ disminuyó de la fase 1 a fase 2 y se mantuvo bajo en fase 3. Esto indica que, con la reducción de la tarea, el sistema de memoria de trabajo se utiliza menos.

El parámetro K disminuyó entre fases, pero era esperable porque cada fase tiene un máximo de TC que limita el rango posible de K. Por último, el parámetro ε se mantuvo estable en las tres fases, con poca variabilidad. Este hallazgo es relevante, dado que ε es el parámetro más sensible al DCL según Hassanzadeh et al. [31]. Su estabilidad entre fases indica que la reducción de la tarea no distorsiona el parámetro de mayor relevancia clínica.

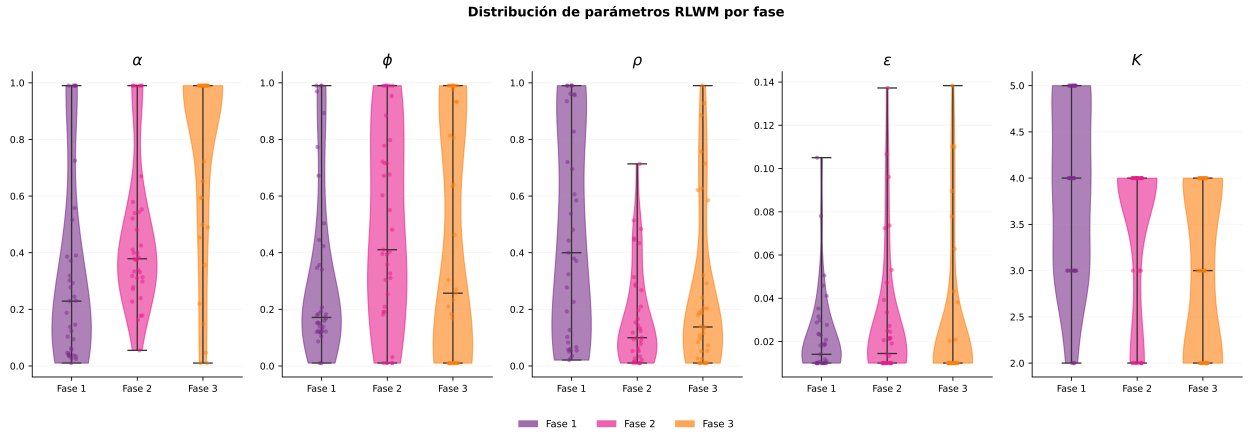


Figura 5.4: Distribución de los valores estimados de cada parámetro RLWM por fase.

Sin embargo, en la Tabla 5.2 se observa otro patrón. En dicha tabla se presentan las medianas e IQR de cada parámetro por fase. Estas medidas representan la tendencia central y la dispersión de los parámetros estimados para cada condición experimental. Se implementó IQR en lugar de desviación estándar dado que los parámetros presentan distribuciones con valores acumulados en los límites del rango posible, y esto hace que la desviación estándar sobreestime la dispersión real.

Tabla 5.2: Valores expresados como: mediana [Q1 – Q3].

Parámetro	**Fase 1**	**Fase 2**	**Fase 3**
α	0.229 [0.046 – 0.390]	0.378 [0.310 – 0.543]	0.990 [0.593 – 0.990]
φ	0.171 [0.124 – 0.423]	0.411 [0.209 – 0.778]	0.257 [0.010 – 0.933]
ρ	0.400 [0.083 – 0.935]	0.100 [0.033 – 0.268]	0.138 [0.027 – 0.292]
ε	0.014 [0.010 – 0.028]	0.014 [0.010 – 0.027]	0.010 [0.010 – 0.020]
K	4.000 [3.000 – 5.000]	4.000 [3.000 – 4.000]	3.000 [2.000 – 4.000]

El parámetro α en la fase 3 alcanzó una mediana de 0.990, coincidiendo con el límite superior del bound. Esto sugiere que en la versión más reducida de la tarea el optimizador tiende a saturar este parámetro. Esto podría reflejar una limitación de la fase 3 para capturar la variabilidad real en la tasa de aprendizaje del sistema RL. Para el parámetro φ en la fase 3 se presentó el rango intercuartílico más amplio de los parámetros y fases. Lo que indica una alta variabilidad en el decaimiento de la memoria de trabajo cuando la tarea se reduce. En conjunto, estos patrones sugieren

que la fase 3 introduce mayor inestabilidad en algunos parámetros, particularmente en aquellos asociados al sistema RL y al decaimiento de la memoria de trabajo. Más adelante se abordará el análisis estadístico pertinente para examinar este efecto.

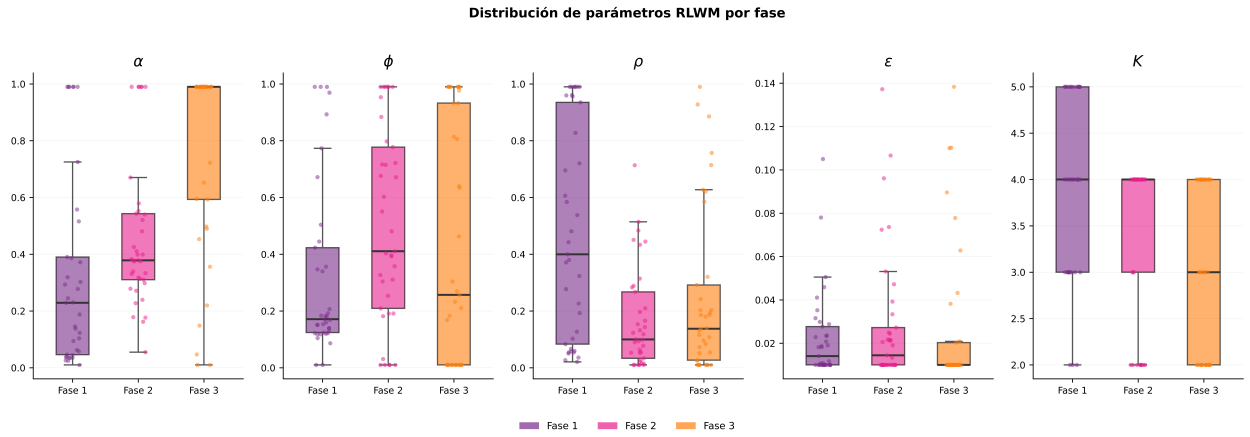


Figura 5.5: Distribución de los valores estimados de cada parámetro RLWM por fase, con gráficos de cajas.

En la Figura 5.5 se presenta una gráfica de cajas que, como sugiere la Tabla 5.2, ofrece una mejor representación visual de los datos que la Figura 5.4. La Figura 5.5 contempla los cuartiles de la distribución. En ella se observan los patrones descritos anteriormente (Tabla 5.2). El parámetro α aumenta entre fases con una caja más amplia en la fase 3, lo que refleja la saturación del parámetro hacia el límite superior. En el parámetro φ se observa una caja amplia en la fase 3, consistente con el IQR más alto observado en la Tabla 5.2. Para el parámetro ρ se presenta un decremento de fase 1 a fases 2 y 3, con cajas compactas en las últimas. El parámetro ε se mantiene con cajas pequeñas y estables en las tres fases, lo que confirma su baja variabilidad.

Por último, se realizó la recuperación de parámetros. Según lo descrito en el capítulo de Metodología, este análisis corresponde a la validación de los parámetros recuperados en el ajuste del modelo. A manera de recuento, se seleccionó el mejor modelo (instancia de RLWM con $\beta = 17$), se extrajeron los parámetros de cada individuo (ajuste del modelo). Una vez se contó con un conjunto de parámetros para cada participante, se entrenó un agente con los parámetros de cada individuo; por tanto, había un agente por cada participante. Cada agente interactuó en un entorno simulado de las tareas experimentales de RLWM, con la misma secuencia de estímulos del participante que el agente emuló. Una vez que el agente finalizó de interactuar con el entorno, se realizó un ajuste de modelo con los datos generados por el mismo. Esto se realizó 20 veces para cada agente, para

disminuir el efecto de la aleatoriedad en la simulación.

El objetivo fue analizar la correspondencia de los parámetros originales y sintéticos. Para esto, se empleó el coeficiente de Pearson, el cual calcula la correlación lineal entre dos variables continuas. Por tanto, en el contexto de este análisis, mide qué tan bien los parámetros sintéticos predicen los parámetros originales de los participantes. Un r alto indica que el modelo es capaz de predecir de forma confiable el valor original del parámetro.

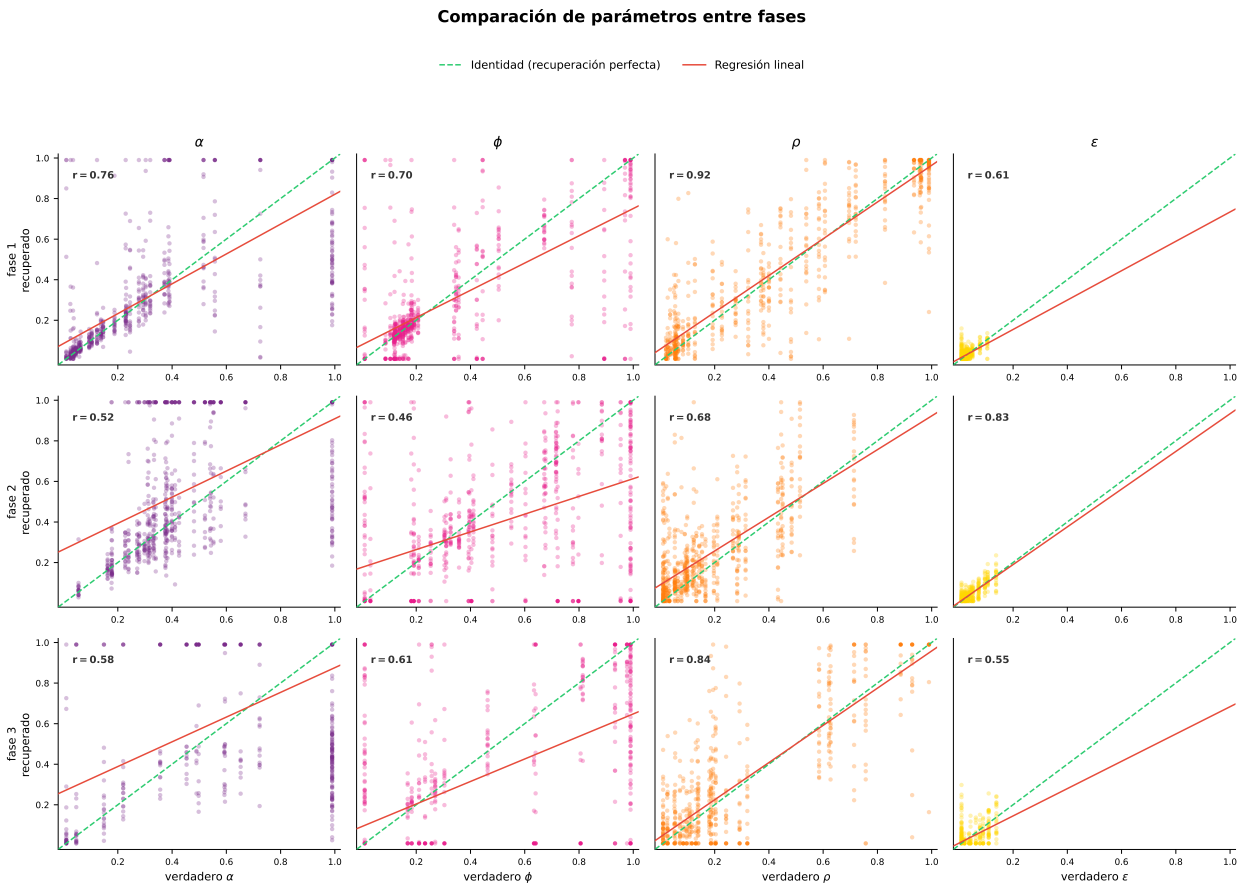


Figura 5.6: Correspondencia entre parámetros.

En la Figura 5.6 se presenta el diagrama de dispersión de la correspondencia entre parámetros originales y sintéticos, por parámetro y fase. Cada punto representa una simulación de un participante (37 participantes $\times$ 3 fases $\times$ 20 simulaciones, N=2,220). La línea verde punteada representa la identidad, es decir, la recuperación perfecta; y la línea roja corresponde a la regresión lineal de los datos.

Respecto a la fase 1, que corresponde a la línea base del estudio y replica la tarea de Master y

colaboradores, los parámetros se recuperaron de manera consistente con lo reportado en la literatura [27]. ρ alcanzó $r = 0{,}92$, α $r = 0{,}76$ y φ $r = 0{,}70$, valores en rango alto. ε obtuvo $r = 0{,}61$, situándose en rango moderado, lo cual es consistente con lo reportado en la literatura para este parámetro. Esto confirma que la línea base del estudio es metodológicamente sólida.

En la fase 3, la recuperación de α, φ y ρ es superior a la de la fase 2 (α: $r = 0{,}58$ vs $r = 0{,}52$; φ: $r = 0{,}61$ vs $r = 0{,}46$; ρ: $r = 0{,}84$ vs $r = 0{,}68$), lo que sugiere que la reducción más agresiva no limita al modelo para identificar estos parámetros. Sin embargo, ε muestra el patrón inverso: su recuperación es mayor en la fase 2 ($r = 0{,}83$) que en la fase 3 ($r = 0{,}55$). Esto indica que la fase 2 captura mejor la incertidumbre en la toma de decisiones. Este hallazgo es relevante porque ε es el principal predictor del DCL según Hassanzadeh y colaboradores, por lo que su menor recuperabilidad en la fase 3 representa una limitación importante [31].

En conjunto, estos resultados indican que la fase 2 presenta equilibrio entre reducción de la tarea y recuperabilidad de los parámetros clínicamente relevantes. Por otro lado, la fase 3, recupera adecuadamente los parámetros del sistema RL y WM, pero compromete la estimación de ε. Más adelante se abordará el análisis estadístico para examinar si estas diferencias son significativas.

5.3. Análisis Estadístico

Primero, se realizó el análisis de los datos comportamentales. Se compararon la precisión y el tiempo de reacción entre fases mediante la prueba de Friedman. Esto debido a que los datos no siguieron una distribución normal en las fases (Shapiro-Wilk, $p < 0{,}05$). Luego, se implementó Wilcoxon con corrección de Bonferroni ($n = 3$ comparaciones) para las comparaciones post-hoc.

La precisión no mostró diferencias significativas entre fases ($\chi^2 = 0{,}164$, $p = 0{,}921$). Lo que indica que los participantes se mantuvieron a un nivel de desempeño similar, independientemente de la fase. El tiempo de reacción sí presentó diferencias significativas ($\chi^2 = 50{,}000$, $p < 0{,}001$). El análisis post-hoc mostró que la fase 1 presentó tiempos de reacción significativamente mayores que la fase 2 ($W = 0{,}0$, $p < 0{,}001$, $r = 0{,}872$) y la fase 3 ($W = 13{,}0$, $p < 0{,}001$, $r = 0{,}840$), ambos con tamaño de efecto grande. No se encontraron diferencias significativas entre las fases 2 y 3 ($W = 268{,}0$, $p = 0{,}640$). Estos resultados pueden sugerir que la implementación en dispositivo móvil redujo los tiempos de reacción respecto a la computadora.

Luego, para comparar los parámetros estimados entre fases se aplicó la prueba de Friedman. Los parámetros α, ρ y K mostraron diferencias significativas entre fases ($\chi^2 = 18{,}100$, $p < 0{,}001$; $\chi^2 = 17{,}808$, $p < 0{,}001$; $\chi^2 = 18{,}500$, $p < 0{,}001$, respectivamente). Los parámetros φ y ε no mostraron diferencias significativas ($p = 0{,}085$ y $p = 0{,}240$).

Para el análisis post-hoc se implementó Wilcoxon y corrección de Bonferroni ($n = 3$). Se observó que el parámetro α fue significativamente mayor en la fase 3 respecto a la fase 1 ($W = 38{,}0$, $p < 0{,}001$, $r = 0{,}695$) y respecto a la fase 2 ($W = 118{,}0$, $p < 0{,}01$, $r = 0{,}530$). Esto es consistente con el patrón de saturación del parámetro hacia el bound superior, reportado en la Tabla 5.2. El parámetro φ mostró una diferencia entre fases 1 y 2 ($W = 190{,}0$, $p < 0{,}05$, $r = 0{,}401$), con tamaño de efecto moderado. El parámetro ρ fue mayor en la fase 1 respecto a la fase 2 ($W = 95{,}0$, $p < 0{,}001$, $r = 0{,}636$) y respecto a la fase 3 ($W = 131{,}0$, $p < 0{,}01$, $r = 0{,}547$). Esto indica una reducción progresiva en la confianza en el sistema de memoria de trabajo según se reduce la tarea. K mostró una diferencia significativa entre fases 1 y 3 ($W = 75{,}0$, $p < 0{,}01$, $r = 0{,}550$), consistente con la reducción del TC entre fases.

Por último, ε no mostró diferencias significativas en ninguna comparación, confirmando su estabilidad entre fases. En particular, la estabilidad de ε confirma que la reducción de la tarea no afecta la precisión con la que se estima el parámetro de mayor relevancia clínica.

5.4. Grupos Focales

Los resultados que se presentan a continuación son de carácter preliminar y corresponden a dos grupos focales de *engagement* realizados en la Casa del Abuelo Norte y la Casa del Abuelo Suroeste de la ciudad de Chihuahua.

El primer grupo focal (GF1) se llevó a cabo el 30 de octubre de 2025 en la Casa del Abuelo Norte. Estuvo conformado por 4 participantes, todas mujeres, con edades entre 65 y 76 años. Todas cumplieron los criterios de inclusión: puntuación superior a 24 en el MoCA y ausencia de dificultades para interactuar con alguna tecnología. El nivel educativo fue medio-alto, con al menos educación secundaria o carrera técnica.

El segundo grupo focal (GF2) se realizó el 24 de octubre de 2025 en la Casa del Abuelo Suroeste. Participaron 12 mujeres, con edades entre 62 y 80 años. Todas cumplieron los criterios de inclusión.

El nivel educativo abarcó desde participantes sin escolaridad hasta con licenciatura concluida.
El análisis temático implementado fue mixto. Por una parte, inductivo, ya que a partir de los datos se generaron códigos y temáticas emergentes. Por otra parte, deductivo, ya que algunas temáticas fueron tomadas de la literatura para explicar los datos [65]. En total, se identificaron 16 códigos agrupados en 7 temáticas (véase Tabla 5.3).

Tabla 5.3: Agrupación de códigos en temáticas, y sus conceptos.

Temática	Concepto	Código	Concepto
Estimulación cognitiva	Potencial de la aplicación para activar procesos mentales.	Agilidad mental	
		Mejorar memoria	Uso de la app para ejercitar la memoria.
		Sistemas de puntos	Mecanismos de recompensa que motiven la continuidad.
Aspecto lúdico	Características que hacen atractiva la aplicación.	Creatividad	Variedad y originalidad.
		Diversión	Entretenimiento.
		Emotividad	Involucramiento afectivo.
Comprensión y dificultad	Nivel de entendimiento y ajuste de la dificultad.	Entendimiento	Grado de comprensión de reglas.
		Dificultad progresiva	Niveles de reto graduales.
		Facilidad de uso	Accesibilidad e intuición de la interfaz.

Temática	Concepto	Código	Concepto
Interacción social	Posibilidad de compartir la experiencia.	Cooperación con nietos	Fortalecer vínculos familiares.
Relación con la tecnología	Experiencias y percepciones sobre tecnología.	Pericia tecnológica	Dominio de habilidades digitales.
		Uso de otros dispositivos	Interés en integrar otras plataformas.
Preferencias	Características personales que determinan atractivo.	Gustos personales	Temáticas o estilos preferidos.
		Relación con actividades diarias	Conexión con rutinas cotidianas.
Regulación de la experiencia	Ajuste para una experiencia equilibrada.	Retroalimentación temporal	Manejo del tiempo como estímulo o presión.
		Restricciones	Contenidos no deseados según valores.

En la Tabla 5.4 se reportan las frecuencias de aparición de cada código por grupo focal, así como la postura de los participantes respecto a cada código (a favor o en contra). La postura se obtuvo mediante papeles anónimos, donde las participantes escribían su opinión respecto a las ideas de sus compañeras. A continuación, se describe cada temática con base en dichas frecuencias.

Tabla 5.4: Frecuencia de códigos.

Temática	Código	Mención		A favor	En contra
		GF1	GF2		
Estimulación cognitiva	Agilidad mental	4	0	6	0
	Mejorar memoria	5	2	10	0
	Sistemas de puntos	5	2	1	0
Aspecto lúdico	Creatividad	2	1	4	0
	Diversión	2	0	3	0
	Emotividad	1	0	0	0
Comprensión y dificultad	Entendimiento	7	0	6	0
	Dificultad progresiva	3	0	2	0
	Facilidad de uso	1	0	4	0
Interacción social	Cooperación con nietos	5	0	2	2
Relación con la tecnología	Pericia tecnológica	3	3	3	0
	Uso de otros dispositivos	1	2	0	0
Preferencias	Gustos personales	6	6	0	0
	Relación con actividades	5	4	0	0
Regulación de la experiencia	Retroalimentación temporal	0	2	0	0
	Restricciones	0	1	0	0

La temática de estimulación cognitiva fue la más mencionada en ambos grupos focales, con 18 menciones. Los tres códigos que la componen reflejan que las participantes perciben la aplicación principalmente como una herramienta para mantener activas sus capacidades cognitivas. El código mejorar memoria y el código sistemas de puntos concentraron el mayor número de menciones (7 cada uno). Las posturas indican que mejorar memoria generó 10 expresiones a favor, siendo el código con mayor respaldo. Agilidad mental sumó 6 expresiones a favor. Sistemas de puntos fue frecuentemente mencionado, pero solo obtuvo 1 expresión a favor. Esto sugiere que, aunque el

tema surgió recurrentemente en la discusión, no generó un consenso entre las participantes.

La temática de aspecto lúdico agrupa los códigos creatividad, diversión y emotividad, con 6 menciones. Creatividad fue el código más mencionado (3 menciones), seguido de diversión (2 menciones). Emotividad tuvo una sola mención sin posturas registradas a favor ni en contra. En conjunto, esta temática refleja que las participantes valoran el entretenimiento y la originalidad en la aplicación, aunque con menor intensidad que la estimulación cognitiva.

La temática de comprensión y dificultad agrupa los códigos entendimiento, dificultad progresiva y facilidad de uso, con 11 menciones. El código entendimiento fue el más mencionado (7 menciones y 6 expresiones a favor), lo que indica que la claridad de las instrucciones y la comprensión de la mecánica de la aplicación fue un tema recurrente y relevante para las participantes. El código dificultad progresiva obtuvo 3 menciones y 2 expresiones a favor, sugiriendo que las participantes prefieren que la aplicación ajuste gradualmente su nivel de exigencia. El código facilidad de uso, aunque con una sola mención, concentró 4 expresiones a favor, lo que refleja un consenso positivo respecto a la importancia de que la aplicación sea sencilla de operar. Esta temática evidencia que la accesibilidad y la adaptabilidad de la aplicación son aspectos prioritarios para las participantes.

La temática de interacción social solo contiene el código cooperación con nietos, con 5 menciones. Es la única temática que registró expresiones tanto a favor (2) como en contra (2), lo que indica que el uso de la aplicación como actividad compartida con los nietos generó opiniones divididas entre las participantes. Cabe destacar que todas las menciones provienen del GF1, lo que podría reflejar diferencias en el contexto social y familiar entre ambos grupos.

La temática de relación con la tecnología se compone por los códigos pericia tecnológica y uso de otros dispositivos, con 9 menciones. El código pericia tecnológica fue el más mencionado (6 menciones, distribuidas equitativamente entre GF1 y GF2), con 3 expresiones a favor y ninguna en contra. El código uso de otros dispositivos obtuvo 3 menciones sin posturas registradas, lo que sugiere que el tema surgió de manera exploradora en la discusión, sin generar un consenso claro.

La temática de preferencias agrupa los códigos gustos personales y relación con actividades diarias, con 21 menciones, siendo la segunda temática más mencionada después de estimulación cognitiva. Ninguno de los dos códigos registró posturas a favor ni en contra. El código gustos personales fue el más mencionado (12 menciones, distribuidas equitativamente entre ambos grupos). El código relación con actividades diarias obtuvo 9 menciones entre ambos grupos, sugiriendo que las

participantes valoran que el contenido de la aplicación se vincule con sus rutinas y actividades cotidianas.

La temática de regulación de la experiencia de juego contiene los códigos retroalimentación temporal y restricciones, con 3 menciones, siendo la temática menos frecuente del análisis. Ambos códigos surgieron únicamente en GF2 y sin posturas registradas. La baja frecuencia de esta temática sugiere que no representa una preocupación central para las participantes.

Estos hallazgos preliminares representan un insumo para el diseño de la aplicación móvil y sus implicaciones se abordarán en el capítulo de Conclusiones.

Capítulo 6

Conclusiones

6.1. Análisis Cuantitativo

A continuación se abordarán las implicaciones de haber reducido las tareas RLWM y haberlas implementado en un dispositivo móvil. Por un lado, se analizarán sus alcances para el campo de IHC, luego sus consecuencias en PC y el área clínica (para el estudio de DCL). Luego, se tomarán en cuenta las limitaciones del estudio y se establecerán trabajos a futuro.

Primero, similar a Weydmann et al. [63], se validó la implementación de las tareas RLWM fuera de un entorno controlado. Resultado obtenido al implementar las tareas RLWM en un dispositivo móvil. La supervisión durante la aplicación fue mínima, solo se resolvían dudas técnicas por parte del participante, sin intervención en la ejecución de la tarea. Esto representa un paso hacia la autoadministración de las tareas RLWM.

Para validar el procedimiento, se implementó la tarea en una población con desempeño cognitivo estable, por lo que se usaron participantes jóvenes. Con el objetivo de acercar el estudio a la población objetivo, se realizó el análisis exploratorio cualitativo mediante grupos focales, cuyos resultados se describieron en la sección anterior.

Los resultados de la recuperación de parámetros ofrecen hallazgos relevantes para evaluar el potencial clínico de las versiones reducidas. La fase 2 representa la reducción más estable, con correlaciones moderadas a altas en todos los parámetros y el mejor equilibrio entre reducción de ensayos y recuperación de parámetros. Sin embargo, la fase 3 mantiene una recuperabilidad moderada de ε, el parámetro más sensible al DCL según la literatura [31]. Este hallazgo plantea una

pregunta de investigación relevante: si ε es el principal diferenciador entre adultos sanos y adultos con DCL, ¿podría la fase 3, aplicada de manera aislada, ser suficiente para detectar DCL? Es importante señalar que esta posibilidad es únicamente una hipótesis para investigaciones futuras y no una conclusión del presente estudio. Como advierten Eckstein et al. [55], los parámetros de los modelos no deben sobreinterpretarse ni generalizarse fuera del contexto de la tarea en que fueron estimados.

Por otro lado, más allá de las implicaciones clínicas, la reducción de la tarea tiene relevancia metodológica. Una tarea más corta implica menor carga para el participante, lo que puede traducirse en mayor *engagement*, por tanto, menor tasa de abandono. Esto es relevante en la recolección de datos longitudinal, donde se busca que los participantes realicen la tarea de manera repetida en un periodo de tiempo extendido. La tarea reducida e implementada en un móvil abre la posibilidad de recolectar datos en el día a día de las personas, mientras realizan sus actividades cotidianas, lo que generaría datos ecológicamente válidos y longitudinales.

Esta dirección es consistente con el marco del RL naturalista propuesto por Wise et al. [25], quienes argumentan que el campo del RL debe avanzar hacia paradigmas que integren la complejidad del mundo real, alejándose de tareas artificiales de laboratorio. Asimismo, Putica et al. [68] señalan que la validez ecológica es uno de los principales retos de la PC, y que el fenotipado digital activo mediante dispositivos móviles es una manera de superarlo. La reducción desarrollada en el presente estudio constituye un breve paso para ese objetivo, incluso en investigaciones que no tengan como fin la detección del DCL.

Adicionalmente, los resultados señalan varias direcciones para investigaciones futuras. En primer lugar, como se mencionó anteriormente, explorar modelos alternativos que ajusten mejor al comportamiento generado por las tareas reducidas es una prioridad. En segundo, avanzar hacia paradigmas más naturalistas representa una oportunidad para mejorar la validez ecológica de los fenotipos computacionales. Wise et al. [25] proponen que el diseño de tareas y modelos debe integrar progresivamente la complejidad del mundo real.

En tercer lugar, en el presente estudio se limitó la implementación en una población joven. El siguiente paso sería aplicar las tareas reducidas con adultos mayores con y sin DCL. En este contexto, el estudio del envejecimiento cognitivo en México requiere estrategias metodológicas innovadoras que consideren las particularidades sociodemográficas y de acceso a la salud de la población, lo

que refuerza la pertinencia de desarrollar herramientas adaptadas a este contexto específico.

Por último, el presente estudio presenta diversas limitaciones que deben considerarse al interpretar sus resultados. En primer lugar, el diseño es transversal, lo que impide establecer relaciones causales entre las variables analizadas ni rastrear la evolución de los parámetros computacionales a lo largo del tiempo. En segundo lugar, la muestra cuantitativa estuvo compuesta exclusivamente por jóvenes, lo que limita la generalización de los hallazgos a la población con DCL. Si bien esta decisión fue metodológicamente justificada, los resultados no pueden transferirse a personas de la tercera edad ni a personas con DCL sin un estudio previo. En tercer lugar, el tamaño muestral ($N = 37$), aunque acorde a la literatura, es reducido para un análisis de modelado computacional; lo que puede afectar la estabilidad de las estimaciones de parámetros, particularmente en las fases con menor número de ensayos.

Adcionalmente, el modelo RLWM no ajusta de manera óptima en las fases reducidas. Esto puede deberse a dos razones no mutuamente excluyentes. La primera es de carácter computacional: al reducir el número de ensayos, el modelo recibe menos datos para estimar los parámetros, lo que puede resultar en estimaciones de los parámetros poco confiables. La segunda razón es de carácter cognitivo: aunque en apariencia las tareas reducidas son versiones más cortas de la tarea original, la reducción implica una modificación estructural que puede alterar los procesos cognitivos que los participantes utilizan para resolverlas. En este sentido, aunque similares, las fases reducidas podrían constituir tareas cognitivamente distintas a la línea base, para las cuales el modelo RLWM no es el más adecuado [55]. Esta interpretación es consistente la literatura [55], donde se argumenta que la interpretación de los parámetros depende directamente del contexto de la tarea. Como se mencionó a lo largo del trabajo, los modelos son dependientes de las tareas; esto implica que al reducir la tarea, RLWM ya no sea el mejor modelo para explicar los datos de esa tarea. Por lo tanto, se debe de ser cuidadoso al interpretar los parámetros estimados en las fases reducidas. Al ser comparadas con la línea base, se debe considerar este problema. Se sugiere explorar modelos alternativos que puedan ajustarse mejor al comportamiento generado por las tareas reducidas. Para futuros trabajos, el modelo WMH de Collins, 2026, es una opción viable. Ya que incorpora un tercer sistema al modelo RLWM, el motor, cuya contribución podría ser relevante cuando la cantidad de ensayos es menor [64].

En conjunto, los resultados del presente estudio sugieren que es posible reducir y adaptar las tareas

RLWM a un dispositivo móvil manteniendo la validez del modelo. La fase 2 resultó ser, como desde su diseño, una reducción conservadora. La fase 3, aunque menos estable, conserva ε, parámetro de mayor relevancia clínica. Estos hallazgos sugieren, para investigaciones futuras, que se apliquen estas tareas reducidas en poblaciones con DCL. Esto, con el objetivo de desarrollar herramientas de detección temprana accesibles, ecológicamente válidas y menos invasivas.

6.2. Análisis Cualitativo

La sección cualitativa del presente estudio presenta limitaciones que deben considerarse al interpretar sus hallazgos. Los resultados reportados corresponden únicamente a dos de los 8 grupos focales realizados, por lo que no pueden considerarse representativos de la muestra total. Además, el tamaño reducido de GF1 ($n = 4$) limita la generalización de sus hallazgos particulares. Adicionalmente, la naturaleza cualitativa y exploratoria del análisis temático no permite establecer relaciones causales ni generalizaciones estadísticas, sino identificar patrones y tendencias que orienten decisiones de diseño en trabajos posteriores. Por último, ambos grupos focales estuvieron conformados exclusivamente por mujeres, lo que limita la representatividad de los hallazgos respecto a la población general de adultos mayores.

A pesar de su carácter preliminar, los resultados de los grupos focales de engagement ofrecen información valiosa para el diseño de la aplicación móvil. La temática de estimulación cognitiva fue la más mencionada en ambos grupos, con especial énfasis en el ejercicio de la memoria, lo que sugiere que las participantes perciben la aplicación principalmente como una herramienta para mantener activas sus capacidades cognitivas. Este hallazgo es consistente con lo reportado por Diaz-Orueta et al. [65], quienes identificaron el desafío cognitivo y el aprendizaje como motivadores centrales para el uso de tecnologías digitales en adultos mayores europeos, lo que sugiere que esta motivación podría trascender contextos culturales.

Por otro lado, la comprensión de la mecánica y la facilidad de uso fueron aspectos prioritarios, reforzando la importancia del diseño accesible para esta población. Adicionalmente, las preferencias personales y la relación con actividades cotidianas emergieron como la segunda temática más mencionada, lo que indica que la aceptación de la aplicación depende en parte de que su contenido resulte significativo y cercano a la vida diaria de las usuarias.

Por tanto, los hallazgos de la temática de preferencias abren una dirección de investigación futura relevante. Las participantes expresaron interés en contenidos cercanos a su vida cotidiana, como recetas, información de salud, manualidades y actividades del día a día. Esta diversidad de preferencias sugiere que una solución única de diseño difícilmente podría satisfacer las necesidades de toda la población objetivo. En este sentido, un agente conversacional basado en LLM's podría representar una vía para personalizar la experiencia de la aplicación. Esta propuesta constituye únicamente una dirección especulativa para investigaciones futuras, y no un prototipo validado ni una solución probada. Su desarrollo requeriría estudios específicos que evalúen su viabilidad, aceptación y pertinencia ética en población de la tercera edad en México.

En conjunto, los resultados cuantitativos y cualitativos del presente estudio representan un avance hacia el desarrollo de herramientas de evaluación cognitiva accesibles, ecológicamente válidas y adaptadas a la población mexicana de la tercera edad. La reducción y adaptación móvil de las tareas RLWM, combinada con la exploración de las necesidades y preferencias de los usuarios, sienta las bases para una línea de investigación que integra la PC e IHC en función de un objetivo común: la detección temprana del DCL de manera menos invasiva y a través de actividades de la vida cotidiana de las personas.

Bibliografía

[1] M. J. Toro Paca, D. R. Parra Parra, N. V. Pacheco Mena y A. G. Alvarado Galarza, «Enfermedad de Alzheimer,» *RECIMUNDO*, vol. 6, n.º 4, págs. 68-76, 2022. DOI: 10.26820/recimundo/6.(4).octubre.2022.68-76

[2] Alzheimer's Disease International, *World Alzheimer Report 2018. The state of the art of dementia research: New frontiers*, 2018. dirección: https://apo.org.au/sites/default/files/resource-files/2018-09/apo-nid260056.pdf

[3] L. Gutiérrez-Robledo e I. Arrieta-Cruz, «Demencias en México: la necesidad de un Plan de Acción,» *Gaceta Médica de México*, vol. 151, n.º 5, págs. 667-673, 2015.

[4] A. Celis-De la Rosa, C. Cabrera-Pivaral y M. Báez-Báez, «Mortalidad por enfermedad de Alzheimer en México de 1980 a 2014,» *Gaceta Médica de México*, vol. 154, n.º 5, págs. 550-554, 2018.

[5] World Health Organization. «Dementia.» Fact sheet, World Health Organization, visitado 8 de jun. de 2026. dirección: https://www.who.int/news-room/fact-sheets/detail/dementia

[6] J. Lee, «Mild cognitive impairment in relation to Alzheimer's disease: An investigation of principles, classifications, ethics, and problems,» *Neuroethics*, vol. 16, n.º 2, pág. 16, 2023. DOI: 10.1007/s12152-023-09522-5

[7] M. F. Folstein, S. E. Folstein y P. R. McHugh, «"Mini-Mental State". A practical method for grading the cognitive state of patients for the clinician,» *Journal of Psychiatric Research*, vol. 12, n.º 3, págs. 189-198, 1975. DOI: 10.1016/0022-3956(75)90026-6

[8] Z. S. Nasreddine et al., «The Montreal Cognitive Assessment, MoCA: A brief screening tool for mild cognitive impairment,» *Journal of the American Geriatrics Society*, vol. 53, n.º 4, págs. 695-699, 2005. DOI: 10.1111/j.1532-5415.2005.53221.x

[9] E. Pellegrini et al., «Machine learning of neuroimaging for assisted diagnosis of cognitive impairment and dementia: A systematic review,» *Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring*, vol. 10, págs. 519-535, 2018. DOI: 10.1016/j.dadm.2018.07.004

[10] T. E. Goldberg, P. D. Harvey, K. A. Wesnes, P. J. Snyder y L. S. Schneider, «Practice effects in longitudinal cognitive tests: Implications for injury and dementia clinical trials,» *Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring*, vol. 1, n.º 4, págs. 512-521, 2015. DOI: 10.1016/j.dadm.2015.10.003

[11] S. Grueso y R. Viejo-Sobera, «Machine learning methods for predicting progression from mild cognitive impairment to Alzheimer's disease dementia: a systematic review,» *Alzheimer's Research & Therapy*, vol. 13, n.º 1, pág. 162, 2021. DOI: 10.1186/s13195-021-00900-w

[12] B. Jiao et al., «Neural biomarker diagnosis and prediction to mild cognitive impairment and Alzheimer's disease using EEG technology,» *Alzheimer's Research & Therapy*, vol. 15, n.º 1, pág. 32, 2023. DOI: 10.1186/s13195-023-01181-1

[13] J. Lu, P. Gong, J. Ye, J. Zhang y C. Zhang, *A survey on machine learning from few samples*, 2020. DOI: 10.48550/ARXIV.2009.02653

[14] J.-P. Onnela, «Opportunities and challenges in the collection and analysis of digital phenotyping data,» *Neuropsychopharmacology*, vol. 46, n.º 1, págs. 45-54, 2021. DOI: 10.1038/s41386-020-0771-3

[15] C. Montag y J. D. Elhai, «Digital Phenotyping – A Case for Cognitive Functions and Dementia?» *Digital Psychology*, vol. 1, n.º 1, págs. 44-51, 2020. DOI: 10.24989/dp.v1i1.1810

[16] M. R. Geddes, M. E. O'Connell, J. D. Fisk, S. Gauthier, R. Camicioli y Z. Ismail, «Remote cognitive and behavioral assessment: Report of the Alzheimer Society of Canada Task Force on dementia care best practices for COVID-19,» *Alzheimer's & Dementia: Diagnosis, Assessment & Disease Monitoring*, vol. 12, n.º 1, e12111, 2020. DOI: 10.1002/dad2.12111

[17] ENDUTIH e INEGI, *Encuesta Nacional sobre Disponibilidad y Uso de Tecnologías de la Información en los Hogares (ENDUTIH) 2023*, 2024. dirección: https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2024/ENDUTIH/ENDUTIH_23.pdf

[18] M. Treviño, S. Castiello, B. De La Torre-Valdovinos, P. Osuna Carrasco, R. Medina-Coss Y León y O. Arias-Carrión, «Two-stage reinforcement learning task predicts psychological traits,» *PsyCh Journal*, vol. 12, n.º 3, págs. 355-367, 2023. DOI: 10.1002/pchj.633

[19] M. Treviño, B. Beltrán-Navarro, R. Medina-Coss Y León y E. Matute, «Clustering of neuropsychological traits of preschoolers,» *Scientific Reports*, vol. 11, n.º 1, pág. 6533, 2021. DOI: 10.1038/s41598-021-85891-2

[20] Y. Niv, «Reinforcement learning in the brain,» *Journal of Mathematical Psychology*, vol. 53, n.º 3, págs. 139-154, 2009. DOI: 10.1016/j.jmp.2008.12.005

[21] I. M. Berwian et al., «Computational mechanisms of effort and reward decisions in patients with depression and their association with relapse after antidepressant discontinuation,» *JAMA Psychiatry*, vol. 77, n.º 5, pág. 513, 2020. DOI: 10.1001/jamapsychiatry.2019.4971

[22] M. R. Delgado, E. A. Phelps y T. W. Robbins, *Decision making, affect, and learning*. Oxford University Press, 2011. DOI: 10.1093/acprof:oso/9780199600434.001.0001

[23] R. C. Wilson y A. G. Collins, «Ten simple rules for the computational modeling of behavioral data,» *eLife*, vol. 8, e49547, 2019. DOI: 10.7554/eLife.49547

[24] E. H. Patzelt, C. A. Hartley y S. J. Gershman, «Computational phenotyping: Using models to understand individual differences in personality, development, and mental illness,» *Personality Neuroscience*, vol. 1, e18, 2018. DOI: 10.1017/pen.2018.14

[25] T. Wise, K. Emery y A. Radulescu, «Naturalistic reinforcement learning,» *Trends in Cognitive Sciences*, vol. 28, n.º 2, págs. 144-158, 2024. DOI: 10.1016/j.tics.2023.08.016

[26] D. J. Simons et al., «Do 'Brain-Training' programs work?» *Psychological Science in the Public Interest*, vol. 17, n.º 3, págs. 103-186, 2016. DOI: 10.1177/1529100616661983

[27] S. L. Master, M. K. Eckstein, N. Gotlieb, R. Dahl, L. Wilbrecht y A. G. E. Collins, «Disentangling the systems contributing to changes in learning during adolescence,» *Developmental Cognitive Neuroscience*, vol. 41, pág. 100 732, 2020. DOI: 10.1016/j.dcn.2019.100732

[28] A. G. E. Collins y M. J. Frank, «How much of reinforcement learning is working memory, not reinforcement learning? A behavioral, computational, and neurogenetic analysis,» *European Journal of Neuroscience*, vol. 35, n.º 7, págs. 1024-1035, 2012. DOI: 10.1111/j.1460-9568.2011.07980.x

[29] A. G. E. Collins, J. K. Brown, J. M. Gold, J. A. Waltz y M. J. Frank, «Working memory contributions to reinforcement learning impairments in schizophrenia,» *Journal of Neuroscience*, vol. 34, n.º 41, págs. 13 747-13 756, 2014. DOI: 10.1523/JNEUROSCI.0989-14.2014

[30] A. H. Yoo y A. G. E. Collins, «How working memory and reinforcement learning are intertwined: A cognitive, neural, and computational perspective,» *Journal of Cognitive Neuroscience*, vol. 34, n.º 4, págs. 551-568, 2022. DOI: 10.1162/jocn_a_01808

[31] Z. Hassanzadeh, F. Bahrami y F. Dortaj, «Exploring the dynamic interplay between learning and working memory within various cognitive contexts,» *Frontiers in Behavioral Neuroscience*, vol. 18, pág. 1 304 378, 2024. DOI: 10.3389/fnbeh.2024.1304378

[32] R. S. Sutton y A. Barto, *Reinforcement learning: An introduction*, 2.ª ed. Cambridge, Massachusetts: The MIT Press, 2020.

[33] E. L. Thorndike, *Animal intelligence: Experimental studies*. New York: The Macmillan Company, 1911.

[34] I. P. Pavlov, *Conditioned reflexes: An investigation of the physiological activity of the cerebral cortex*. Oxford University Press, 1927.

[35] B. F. Skinner, *Science and human behavior*. New York: Macmillan, 1953.

[36] M. Domjan, *Principios de aprendizaje y conducta*, 6.ª ed., trad. por M. E. Ortiz Salinas. Cengage Learning, 2010.

[37] R. A. Rescorla y A. Wagner, «A theory of Pavlovian conditioning: Variations in the effectiveness of reinforcement and nonreinforcement,» en *Classical conditioning: Current research and theory*, Appleton-Century-Crofts, 1972.

[38] R. S. Sutton y A. Barto, *Time-derivative models of Pavlovian reinforcement*, 1990. dirección: http://incompleteideas.net/papers/sutton-barto-90.pdf

[39] R. E. Bellman, *Dynamic programming*. Princeton, Nueva Jersey: Princeton University Press, 1957.

[40] R. Bellman, «A Markovian decision process,» *Indiana University Mathematics Journal*, vol. 6, n.º 4, págs. 679-684, 1957. DOI: 10.1512/iumj.1957.6.56038

[41] R. A. Howard, *Dynamic programming and Markov processes*. New York: The Technology Press of The Massachusetts Institute of Technology y John Wiley & Sons, 1960.

[42] S. J. Gershman, «Reinforcement learning and causal models,» en *The Oxford handbook of causal reasoning*, Oxford University Press, 2017. DOI: 10.1093/oxfordhb/9780199399550.013.20

[43] T. V. Wiecki, *Computational psychiatry: Combining multiple levels of analysis to understand brain disorders*, 2010. dirección: https://ski.clps.brown.edu/papers/wiecki_phd_thesis.pdf

[44] J. M. Simmons, B. Cuthbert, J. A. Gordon y M. Ferrante, «Introduction: Toward a computational approach to psychiatry,» en *Computational psychiatry: A primer*, Peggy series, 2020.

[45] M. K. Forbes et al., «Elemental psychopathology: distilling constituent symptoms and patterns of repetition in the diagnostic criteria of the DSM-5,» *Psychological Medicine*, vol. 54, n.º 5, págs. 886-894, 2024. DOI: 10.1017/S0033291723002544

[46] P. R. Montague, R. J. Dolan, K. J. Friston y P. Dayan, «Computational psychiatry,» *Trends in Cognitive Sciences*, vol. 16, n.º 1, págs. 72-80, 2012. DOI: 10.1016/j.tics.2011.11.018

[47] B. S. Fernandes, L. M. Williams, J. Steiner, M. Leboyer, A. F. Carvalho y M. Berk, «The new field of 'precision psychiatry',» *BMC Medicine*, vol. 15, n.º 1, pág. 80, 2017. DOI: 10.1186/s12916-017-0849-x

[48] X.-J. Wang y J. H. Krystal, «Computational psychiatry,» *Neuron*, vol. 84, n.º 3, págs. 638-654, 2014. DOI: 10.1016/j.neuron.2014.10.018

[49] D. Bennett, S. M. Silverstein e Y. Niv, «The two cultures of computational psychiatry,» *JAMA Psychiatry*, vol. 76, n.º 6, pág. 563, 2019. DOI: 10.1001/jamapsychiatry.2019.0231

[50] Q. J. M. Huys, M. Browning, M. P. Paulus y M. J. Frank, «Advances in the computational understanding of mental illness,» *Neuropsychopharmacology*, vol. 46, n.º 1, págs. 3-19, 2021. DOI: 10.1038/s41386-020-0746-4

[51] N. D. Daw, «Trial-by-trial data analysis using computational models: (Tutorial Review),» en *Decision making, affect, and learning*, Oxford University Press, 2011. DOI: 10.1093/acprof:oso/9780199600434.001.0001

[52] R. L. Lewis, A. Howes y S. Singh, «Computational rationality: Linking mechanism and behavior through bounded utility maximization,» *Topics in Cognitive Science*, vol. 6, n.º 2, págs. 279-311, 2014. DOI: 10.1111/tops.12086

[53] S. Zorowitz, I. Momennejad y N. D. Daw, «Anxiety, avoidance, and sequential evaluation,» *Computational Psychiatry*, vol. 4, n.º 0, pág. 1, 2020. DOI: 10.1162/CPSY_a_00026

[54] Q. J. M. Huys, N. Eshel, E. O'Nions, L. Sheridan, P. Dayan y J. P. Roiser, «Bonsai trees in your head: How the Pavlovian system sculpts goal-directed choices by pruning decision trees,» *PLoS Computational Biology*, vol. 8, n.º 3, e1002410, 2012. DOI: 10.1371/journal.pcbi.1002410

[55] M. K. Eckstein, S. L. Master, L. Xia, R. E. Dahl, L. Wilbrecht y A. G. Collins, «The interpretation of computational model parameters depends on the context,» *eLife*, vol. 11, e75474, 2022. DOI: 10.7554/eLife.75474

[56] M. Rescorla, *Bayesian models of the mind*, 1.ª ed. Cambridge University Press, 2025. DOI: 10.1017/9781108955973

[57] L. Danwitz, D. Mathar, E. Smith, D. Tuzsus y J. Peters, *Parameter and model recovery of reinforcement learning models for restless bandit problems*, 2021. DOI: 10.1101/2021.10.27.466089

[58] H. Jahn, «Memory loss in Alzheimer's disease,» *Dialogues in Clinical Neuroscience*, vol. 15, n.º 4, págs. 445-454, 2013. DOI: 10.31887/DCNS.2013.15.4/hjahn

[59] D. M. Barch y A. Ceaser, «Cognition in schizophrenia: core psychological and neural mechanisms,» *Trends in Cognitive Sciences*, vol. 16, n.º 1, págs. 27-34, 2012. DOI: 10.1016/j.tics.2011.11.015

[60] A. G. E. Collins, B. Ciullo, M. J. Frank y D. Badre, «Working memory load strengthens reward prediction errors,» *Journal of Neuroscience*, vol. 37, n.º 16, págs. 4332-4342, 2017. DOI: 10.1523/JNEUROSCI.2700-16.2017

[61] A. G. E. Collins, *The tortoise and the hare: interactions between reinforcement learning and working memory*, 2017. DOI: 10.1101/234724

[62] S. Huang et al., «Exploring the n-back task: insights, applications, and future directions,» *Frontiers in Human Neuroscience*, vol. 19, pág. 1 721 330, 2025. DOI: 10.3389/fnhum.2025.1721330

[63] G. Weydmann et al., «Switching to online: Testing the validity of supervised remote testing for online reinforcement learning experiments,» *Behavior Research Methods*, vol. 55, n.º 7, págs. 3645-3657, 2022. DOI: 10.3758/s13428-022-01982-6

[64] A. G. E. Collins, «A habit and working memory model as an alternative account of human reward-based learning,» *Nature Human Behaviour*, vol. 10, n.º 2, págs. 357-369, 2025. DOI: 10.1038/s41562-025-02340-0

[65] U. Diaz-Orueta, D. Facal, H. H. Nap y M.-M. Ranga, «What is the key for older people to show interest in playing digital learning games? Initial qualitative findings from the LEAGE project on a multicultural European sample,» *Games for Health Journal*, vol. 1, n.º 2, págs. 115-123, 2012. DOI: 10.1089/g4h.2011.0024

[66] S. Valladares-Rodriguez, R. Perez-Rodriguez, D. Facal, M. J. Fernandez-Iglesias, L. Anido-Rifon y M. Mouriño-Garcia, «Design process and preliminary psychometric study of a video game to detect cognitive impairment in senior adults,» *PeerJ*, vol. 5, e3508, 2017. DOI: 10.7717/peerj.3508

[67] S. Valladares-Rodríguez, M. J. Fernández-Iglesias, L. E. Anido-Rifón y M. Pacheco-Lorenzo, «Evaluation of the predictive ability and user acceptance of Panoramix 2.0, an AI-based e-health tool for the detection of cognitive impairment,» *Electronics*, vol. 11, n.º 21, pág. 3424, 2022. DOI: 10.3390/electronics11213424

[68] A. Putica, M. Yurtbasi y R. Khanna, «Integrating digital health technologies for ecological validity in computational psychiatry: challenges and solutions,» *AI & Society*, vol. 40, n.º 7, págs. 5509-5525, 2025. DOI: 10.1007/s00146-025-02336-4

Anexos

Anexo 1. Carta Comité de Ética

https://drive.google.com/file/d/1KZieaNaa3hmXjQYJBsmYf3DXegtD-uc2/view?usp=sharing

Anexo 2. Consentimiento Informado Universitarios

https://drive.google.com/file/d/1CIsQB8Q-hvR34atLxO1QRDzC6aONVPqP/view?usp=sharing

Anexo 3. Consentimiento Informado Casas del Abuelo

https://docs.google.com/document/d/1LNz5ul74oIRocLOXUJqRRm2Hu_i9AXHrU0k7Z5wCzCI/edit?usp=sharing

Glosario

CT Cognitive Tasks (Tareas cognitivas)

DCL Deterioro Cognitivo Leve

DCU Diseño Centrado en el Usuario

DL Deep Learning (Aprendizaje profundo)

EC Estímulo Condicionado

EI Estímulo Incondicionado

FD Fenotipado Digital

fMRI Functional Magnetic Resonance Imaging

GF1 Grupo Focal 1

GF2 Grupo Focal 2

IEE Intervalo Entre Ensayos

IHC Interacción Humano-Computadora

IQR Interquartile Range

ITESM Instituto Tecnológico de Monterrey

L-BFGS-B Limited-memory BFGS with Bound constraints

LLM Large Language Model

ML Machine Learning

MLE Maximum Likelihood Estimation

MoCA Montreal Cognitive Assessment

NLL Negative Log-Likelihood

PC Psiquiatría Computacional

RL Reinforcement Learning

RLWM Reinforcement Learning Working Memory

TC Tamaño de Conjunto

TD Temporal Difference

UACH Universidad Autónoma de Chihuahua

WM Working Memory

WMH Working Memory and Habit model

Currículum Vitae

Heber Abraham Zapata Robles es licenciado en psicología por la ELPAC-UCC, maestro en Ingeniería en Computación por la Universidad Autónoma de Chihuahua, y doctorante en Ciencias de la Computación en el CICESE. Ha realizado estancias de investigación en el CICESE y en el CEIC de la Universidad de Guadalajara. Su trabajo se orienta a la intersección entre psicología experimental y ciencias computacionales para el desarrollo de tecnologías de evaluación cognitiva; en especial, en el modelado computacional del aprendizaje y la toma de decisiones como aproximación al fenotipado digital del deterioro cognitivo leve en adultos mayores.

Ha publicado en el área de inteligencia artificial aplicada al diagnóstico de Alzheimer y ha presentado investigaciones en congresos internacionales como la Society for Neuroscience (San Diego, 2025), el Timing Research Forum 4 (Tokio, 2025) y la International Society for Comparative Psychology (Bogotá, 2025). Además de foros nacionales de psicología y análisis de la conducta. Adicionalmente, tiene experiencia como docente en las materias de psicometría y neurocognición de la carrera de psicología de la UACH.

Correo electrónico: heberzapata17@gmail.com

Esta tesis fue mecanografiada por Heber Abraham Zapata Robles