



UNIVERSIDAD DE BUENOS AIRES

FACULTAD DE CIENCIAS EXACTAS Y NATURALES

Maestría en Explotación de Datos y Descubrimiento del Conocimiento

**Exploración del acceso
metacognitivo a la vividez en la
imágenes motora**

Tesis Presentada para Optar al Título de Magíster de la Universidad
de Buenos Aires en Explotación de Datos y Descubrimiento de
Conocimiento

Tesista: Ing. Alejandra Lis Fusco
Directora: Dra. Elisa Filevich
Co-Director: Dr. Andrés Farall
Buenos Aires, 3 de septiembre de 2025

Índice general

1. Introducción	5
1.1. Antecedentes	7
1.2. Objetivos de la Tesis	9
1.3. Hipótesis del Trabajo	10
2. Materiales y Métodos	11
2.1. Experimento metacognitivo	11
2.1.1. Materiales	13
2.1.2. Medidas	15
2.1.3. Procedimiento	15
2.2. Descripción general de los datos	16
2.3. Creación de variables	17
2.3.1. Variables objetivo	31
2.4. Análisis exploratorio de los datos	32
2.4.1. Expectativas en relación a Priming Motor	32
2.4.2. Análisis de Tiempo de Reacción y Duración del Movimiento	33
2.4.3. Correlación de variables numéricas	38
2.4.4. Balance de variables discretas	41
2.5. Técnicas estadísticas y de aprendizaje automático utilizadas	44
2.5.1. Modelos estadísticos	44
2.5.2. Modelos de clasificación	45
3. Resultados	47
3.1. Modelos Lineales Mixtos	47
3.1.1. Análisis de la Vividez	47
3.1.2. Análisis de la Congruencia	48
3.1.3. Interacción entre Vividez y Congruencia	49
3.1.4. Análisis del Priming Motor Binario	51
3.2. Modelos de Regresión Logística	54
3.3. Árboles de Decisión	58
3.3.1. Modelo general	58
3.3.2. Modelo por participante	60
4. Anexos	65
4.1. Estructura de los datos	65

4.1.1.	Por Ensayo	65
4.1.2.	Por Sujeto	66
4.1.3.	Nuevos campos calculados	67
4.2.	Análisis preliminar de los datos	69
4.2.1.	Boxplot y violín de Priming Motor Binario	69
4.2.2.	Test de Dunn para Tiempo de reacción	70
4.2.3.	Análisis de Tiempo de Reacción y Duración del Movimiento	72
4.3.	Modelos Lineales Mixtos	74
4.3.1.	Estructura de los modelos LMM en R	74
4.3.2.	Detalle de resultados de Modelos Lineales Mixtos	75
4.3.3.	Gráfica de Modelos Lineales Mixtos Desagregados	76
4.4.	Regresiones logísticas	77
4.4.1.	Importancia de características por Clase de Pri- ming Motor	77
4.5.	Árboles de Decisión	79
4.5.1.	Rango de búsqueda y valores finales de los hiper- parámetros de LightGBM	79

Referencias **80**

Resumen

La imaginería motora es la capacidad de representar mentalmente un movimiento sin llevarlo a cabo físicamente. Esta habilidad involucra la activación de áreas cerebrales similares a las que participan en la ejecución real de movimientos, lo que la convierte en un proceso clave para la planificación, el aprendizaje y la mejora del rendimiento motor. En el ámbito de la neurociencia y la psicología cognitiva, el estudio de la imaginería motora ha permitido comprender cómo las personas visualizan y ajustan sus acciones antes de realizarlas, así como las diferencias individuales en la claridad y vividez de esas imágenes mentales. Este estudio tiene como objetivo explorar la construcción mental del score de vividez y, para ello, investiga la relación entre la imaginería motora, la vividez percibida de las imágenes mentales y el desempeño del movimiento efectuado. Treinta y dos participantes realizaron tareas de imaginación y ejecución motora de movimientos en la mano, mientras se registraban datos de 13 sensores colocados en la misma. Las variables principales incluyeron el tiempo de reacción, la duración del movimiento, la posición de los sensores a lo largo del ensayo, la vividez reportada, la acción imaginada y la ejecutada, con el objetivo de analizar cómo la claridad de las imágenes mentales influye en el comportamiento motor. Se desarrollaron Modelos Lineales Mixtos (LMM) que revelaron que una mayor vividez reportada se asocia con tiempos de reacción y movimiento más cortos, mientras que la incongruencia entre el movimiento imaginado y el ejecutado incrementa estos tiempos de reacción y duración del movimiento. Por otro lado, se implementó una técnica novedosa para resumir las observaciones captadas por los sensores en curvas que representan las trayectorias, validado con modelos de clasificación para distinguir los movimientos en los ensayos, logrando precisiones de hasta el 94%. Se realizaron ajustes de regresiones logísticas y métodos basados en árboles de decisión (LightGBM) para intentar predecir tanto la vividez de las imágenes mentales como su interferencia cuando la acción imaginada y la ejecutada son incongruentes, aunque estos modelos no lograron obtener resultados robustos en estas tareas específicas. Estos hallazgos indican que, si bien las trayectorias capturadas por los sensores resultaron efectivas para clasificar los movimientos, ni esta representación ni otras variables del dataset lograron predecir de manera completa la vividez reportada. Esto sugiere que la falta de una relación robusta con la vividez puede deberse a factores como la variabilidad individual en la percepción de la vividez o la posible dificultad de los participantes para distinguir de manera consistente los niveles de claridad en sus imá-

genes mentales. Además, si bien se esperaba observar un patrón en el que la incongruencia entre la imagen mental y el movimiento realizado impactara de forma negativa y progresiva en los tiempos de reacción y duración del movimiento conforme se incrementan los niveles de vividez, esta hipótesis no pudo validarse con los datos obtenidos, lo que abre nuevas preguntas sobre la influencia real de la vividez en el priming motor y sus diferencias con la imagería visual.

Abstract

Exploration of metacognitive access to vividness in motor imagery

Motor imagery is the ability to mentally represent a movement without physically executing it. This skill involves the activation of brain areas similar to those that participate in the actual execution of movements, making it a key process for planning, learning, and improving motor performance. In the field of neuroscience and cognitive psychology, the study of motor imagery has provided insights into how people visualize and adjust their actions before performing them, as well as individual differences in the clarity and vividness of these mental images. This study aims to explore the mental construction of the vividness score by investigating the relationship between motor imagery, the perceived vividness of mental images, and the performance of executed movements. Thirty-two participants completed motor imagery and execution tasks while data were recorded from 13 sensors placed on their hands. The main variables included reaction time, movement duration, sensor position throughout the trial, reported vividness, imagined action, and executed action, with the goal of analyzing how the clarity of mental images influences motor behavior. Linear Mixed Models (LMMs) were developed, revealing that higher reported vividness is associated with shorter reaction and movement times, while incongruence between imagined and executed movements increases both reaction and movement duration times. Additionally, an innovative technique was implemented to summarize sensor-captured observations into curves representing trajectories, validated with classification models to distinguish movements in the trials, achieving accuracies of up to 94%. Logistic regression adjustments and decision tree-based methods (LightGBM) were used to attempt to predict both the vividness of mental images and its interference when the imagined and executed actions were incongruent, although these models did not yield robust results in these specific tasks. These findings indicate that, while the trajectories captured by the sensors were effective for classifying movements, neither this representation nor other variables in the dataset were sufficient to fully predict the reported vividness. This suggests that the lack of a strong relationship with vividness may be due to factors such as individual variability in vividness perception or participants' potential difficulty in consistently distinguishing levels of clarity in their mental images. Moreover, while a pattern was expected in which incongruence between the mental image and the executed movement would progressively and negatively impact

movement efficiency as vividness levels increased, this hypothesis could not be validated with the data obtained, raising new questions about the real influence of vividness on motor priming and its differences from visual imagery.

Capítulo 1

Introducción

Las ciencias cognitivas han centrado sus esfuerzos en comprender los complejos mecanismos que subyacen al comportamiento humano. Una parte esencial de este entendimiento radica en la capacidad de separar y analizar las diferentes fuentes de información que contribuyen a la toma de decisiones y la generación de acciones [Metcalf and Shimamura, 1994]. La metacognición, entendida como la capacidad de reflexionar y evaluar los propios procesos cognitivos, ha surgido como un área de interés particular, especialmente en el contexto de la cognición motora [Fleming and Dolan, 2012]. Dentro de esta área, la metacognición motora involucra el monitoreo y la regulación consciente de los movimientos en relación con las intenciones y percepciones internas, así como la integración de señales aferentes y eferentes [Gentsch et al., 2015].

Un aspecto destacado en la investigación de la metacognición motora es la imaginiería motora, un proceso que permite a los individuos visualizar mentalmente movimientos sin realizar físicamente las acciones [Decety and Grezes, 2006]. Estudios han demostrado que la imaginiería motora activa redes cerebrales que se solapan en gran medida con las involucradas en la ejecución real de movimientos, incluyendo no sólo áreas de la corteza cerebral (corteza premotora) sino también el cerebelo y estructuras subcorticales (los ganglios basales [Kilintari et al., 2016]; [Héту et al., 2013]). Sin embargo, a diferencia de la ejecución motora real, la imaginiería motora no implica la generación de movimientos que daría lugar a señales aferentes (es decir, señales provenientes de los husos musculares y potencialmente de mecanorreceptores cutáneos; [Solodkin et al., 2004]). Esta distinción es crucial, ya que permite estudiar los procesos metacognitivos en un entorno controlado, donde se puede aislar la influencia de las señales eferentes y centrarse en la contribución de la vividez y el control de las imágenes mentales.

La relevancia de la imaginiería motora se ha explorado en varios contextos, como en la planificación de acciones y la simulación interna de movimientos, contribuyendo a la optimización del rendimiento motor [Grezes and Decety, 2001]; [Pearson and Logie, 2015]. Además, se ha de-

mostrado que la capacidad de generar y manipular imágenes mentales está relacionada con el desempeño motor y la precisión de las acciones [Hardwick et al., 2018]. Este proceso involucra una interacción compleja entre las áreas cerebrales responsables del movimiento y las regiones asociadas con la introspección y el monitoreo cognitivo, como el córtex prefrontal dorsolateral [Voss et al., 2019].

El presente trabajo se basa en un experimento que intenta comprender los mecanismos detrás de la formación de un score o calificación de imaginería motora. Al aislar las fuentes de información, se busca analizar cómo la vividez de la imaginería y la congruencia entre la imagen mental y la acción ejecutada influyen en el tiempo de reacción y en la precisión del movimiento. Investigaciones previas han demostrado que la congruencia entre la imaginería y la ejecución motora puede afectar significativamente el rendimiento y la eficiencia de las acciones [Cohen et al., 2017]. Además, la vividez de la imaginería motora se ha asociado con la actividad en áreas específicas del cerebro, como la corteza parietal superior y el córtex prefrontal [Lorey et al., 2013]; [Wang et al., 2014].

La motivación principal de este estudio reside en modelar la información obtenida en el trabajo de investigación de imaginería motora mencionado (como trayectorias, tiempos de movimiento, distancia recorrida, entre otras) para obtener una intuición de cómo los participantes del estudio determinan el score de vividez en los ensayos (*trials*). Esto implica la aplicación de técnicas estadísticas y de aprendizaje automático (*machine learning*) para analizar y modelar los datos, identificando patrones que contribuyan a la comprensión de cómo las personas monitorean y regulan sus imágenes mentales en ausencia de señales eferentes.

A través de esta investigación, buscamos contribuir al campo de la metacognición motora al ofrecer una metodología que permite evaluar la precisión del monitoreo metacognitivo de la imaginería motora. Los resultados obtenidos no solo tienen implicaciones teóricas para el entendimiento de los procesos cognitivos involucrados en la imaginería motora, sino que también podrían ser aplicados en campos como la rehabilitación física y el entrenamiento deportivo, donde la práctica mental es utilizada como herramienta para mejorar el rendimiento y la recuperación de habilidades motoras [Decety, 1996]; [Lotze and Halsband, 2006].

1.1. Antecedentes

El artículo *Evaluating the Mind's Eye: The Metacognition of Visual Imagery* [Pearson et al., 2011] investiga cómo las personas evalúan y comprenden la calidad de sus propias imágenes mentales. En el estudio se les pidió a los participantes que imaginaran un patrón visual y evaluaran su claridad, luego se les presentó un patrón de rivalidad binocular incompatible o uno compatible con lo que habían imaginado. Finalmente se les solicitó que reportaran qué patrón habían observado. Los resultados confirmaron un efecto de priming de la imaginería visual, donde imaginar un patrón incrementaba la probabilidad de que fuera percibido inicialmente durante la rivalidad binocular [Pearson et al., 2008]. Además, se encontró que la claridad de la imagen mental, evaluada por los participantes, estaba relacionada con la probabilidad de percibir el patrón imaginado, demostrando un acceso metacognitivo confiable sobre la calidad de su propia imaginería visual. Basándose en este paradigma, se llevó a cabo un estudio sobre la metacognición de la imaginería motora [Koš and Filevich, 2020]. En este trabajo, los participantes debían imaginar uno de dos posibles movimientos: uno implicaba principalmente fuerza, y el otro precisión de la mano. Posteriormente, calificaban la vividez de su imaginería y ejecutaban una de dos acciones posibles, indicadas por el experimento. Los resultados mostraron que los tiempos de reacción y movimiento eran más cortos cuando el movimiento imaginado coincidía con el ejecutado, evidenciando un efecto de congruencia. Sin embargo, a diferencia de los hallazgos en la imaginería visual [Pearson et al., 2011], la interacción estadística esperada entre la vividez de la imaginería motora y el efecto de congruencia no fue significativa. En lugar de ello, se observó un efecto directo de la vividez en los tiempos de reacción y premotores, independientemente de la congruencia. Esta discrepancia podría explicarse por la similitud entre los movimientos utilizados en el experimento de Koš y Filevich, lo que pudo haber facilitado la ejecución de ambos movimientos independientemente del que se imaginó. Para explorar esta posibilidad, se llevó a cabo un segundo experimento en el que se eligieron movimientos más diferenciados. En lugar de utilizar movimientos de agarre genéricos, se seleccionaron movimientos de escalada: un agarre vertical y un agarre lateral. Estos movimientos fueron elegidos por su distinción y porque investigaciones previas han demostrado que están asociados con representaciones mentales diferenciadas en escaladores experimentados [Bläsing et al., 2014]. Al seleccionar posiciones de la mano que son lo suficientemente distintas, se pretende evaluar con mayor precisión la relación entre la vividez de la imaginería motora y su influencia en la ejecución del movimiento.

Esta tesis se basa en éste último experimento, el cual busca replicar y ampliar el paradigma experimental adaptado por Koß y Filevich, utilizando un enfoque que permite aislar mejor las representaciones mentales de los movimientos imaginados. De esta forma, se intenta avanzar en la comprensión de cómo las evaluaciones metacognitivas de la imaginería motora se relacionan con la ejecución subsecuente, y cómo estos procesos pueden diferir de la imaginería visual previamente estudiada.

1.2. Objetivos de la Tesis

El estudio de la imaginación motora y el experimento que da origen a los datos para esta tesis presentan una oportunidad única para el uso de técnicas avanzadas de ciencia de datos. La detección de patrones relevantes en este contexto no es trivial, dada la complejidad de los procesos cognitivos y motores involucrados. Aquí es donde los modelos estadísticos y de aprendizaje automático pueden contribuir significativamente, al proporcionar explicaciones intuitivas sobre cómo los diferentes componentes influyen en la duración y precisión de los movimientos, o al predecir la relación entre la percepción de los participantes y las acciones que ejecutan.

El primer objetivo es desarrollar modelos predictivos que sean capaces de inferir la puntuación de vividez de la imaginación reportada a partir de las características de los movimientos ejecutados. La capacidad de predecir la vividez de la imaginación motora es particularmente interesante, ya que ofrece la posibilidad de adentrarse en la comprensión de los procesos internos de percepción e imaginación humana y validar, de alguna forma, que los sujetos son capaces de distinguir y reportar correctamente los diferentes niveles de vividez percibidos.

El segundo objetivo de esta tesis es analizar y explicar los factores que influyen en la duración y el tiempo de reacción de los movimientos en función de los niveles de vividez. Esto implica identificar cómo la vividez en la imaginación motora afecta la ejecución de los movimientos y qué patrones surgen en la relación entre la calidad de la imagen mental y la respuesta motora. Además, se busca evaluar si el comportamiento de interferencia en el priming motor se alinea con los hallazgos en la imaginación visual documentados en estudios previos, explorando si el impacto de la incongruencia sobre la eficiencia del movimiento varía de manera progresiva con el aumento de la vividez.

1.3. Hipótesis del Trabajo

El presente trabajo se sustenta en un conjunto de hipótesis que orientan tanto el análisis de los tiempos de reacción como la interpretación de los patrones de movimiento y la vividez de la imaginería motora. Estas hipótesis derivan de la evidencia previa en la literatura sobre imaginería visual y motora, así como de los objetivos planteados en la sección anterior.

1. La congruencia entre la acción imaginada y la ejecutada resultará en una mayor eficiencia motora, reduciendo tiempos de reacción y la duración del movimiento, ya que la correspondencia entre ambos procesos optimiza la planificación del movimiento.
2. De manera inversamente proporcional a la ventaja esperable en casos congruentes, la incongruencia generará un efecto de interferencia que resulte en un detrimento de la eficiencia de los movimientos.
3. Las características de la trayectoria del movimiento, estimadas mediante polinomios tridimensionales, podrían estar asociadas con la vividez y la congruencia, de modo que trayectorias más complejas (grados polinomiales más altos) reflejen interferencia o menor claridad de la imagen mental.
4. Será posible desarrollar modelos predictivos capaces de inferir con un nivel aceptable de precisión el nivel de vividez reportado por los participantes a partir de las características cinemáticas de los movimientos.

Capítulo 2

Materiales y Métodos

2.1. Experimento metacognitivo

El estudio actual utilizó una versión del paradigma experimental para medir el acceso metacognitivo de la imaginería visual según [Pearson et al., 2011], pero adaptado al ámbito motor. En cada repetición de la tarea de imaginería motora (Figura 2.1), se les presentaron dos señales de imaginería (1.5 segundos) a cada participante, mostrando uno de dos tipos posibles de agarres de escalada (agarre de borde, tirón lateral). Posteriormente se les solicitó a los participantes que imaginen realizar el movimiento de escalada indicado (6 segundos) mientras miraban una cruz de fijación y mantenían la mano relajada en un punto de partida.

Los participantes luego proporcionaron dos calificaciones separadas en una escala Likert de 4 puntos: la vividez de la imaginería motora, por un lado, y el esfuerzo empleado para crear esa imaginería motora, por otro. La escala Likert iba desde 1 (casi ninguna imaginería/casi ningún esfuerzo) hasta 4 (imaginería fuerte, casi como realizar la acción/intento muy fuerte de formar una imagen mental) [Pearson et al., 2011]. Los participantes proporcionaron las calificaciones de vividez y esfuerzo con su mano izquierda presionando los botones correspondientes en un teclado.

Después de un intervalo de longitud aleatoria (entre 0.5 y 1.5 segundos) muestreado de una distribución uniforme, se presentaba una de las dos posibles señales de acción, mostrando uno de los dos movimientos de escalada (agarre de borde, tirón lateral) (1.5 s). Los participantes tenían que realizar la acción indicada con su mano derecha tan rápido y precisamente como fuera posible después de que se presentara la señal de acción. Si los participantes realizaban el agarre incorrecto, se mostraba una señal de advertencia. Si los participantes levantaban la mano durante la fase de imaginería se presentaba un mensaje de error.

Por último, los participantes tenían la opción de continuar con la siguiente repetición del ensayo (presionando la barra espaciadora) o marcar la

repetición anterior como un error (presionando Enter); por ejemplo, en caso de olvidar la identidad de la señal de imaginería, no prestar atención durante el ensayo, perder el agarre de escalada, moverse durante la imaginería en lugar de la fase de acción o pensar que el aparato de movimiento no registró el agarre.

En total había 10 bloques, cada uno conteniendo 20 ensayos (un total de 200 ensayos). Un bloque tomaba aproximadamente 6 minutos. En total la tarea de imaginería motora tomó aproximadamente 70 minutos, incluyendo descansos. Se crearon cuatro condiciones de ensayo, diferenciadas por la acción a realizar (es decir, agarre de borde, tirón lateral) y la congruencia (es decir, congruente, donde la imaginería y la señal de acción coincidían; incongruente, donde la imaginería y la señal de acción eran diferentes). Para fomentar la imaginería motora el 60 % de las repeticiones fueron congruentes, mientras que el 40 % fueron incongruentes. El orden de las repeticiones fue mixto y aleatorio entre los participantes.

Además, hubo dos bloques de entrenamiento (10 ensayos de práctica por bloque) para familiarizar a los participantes con la tarea de imaginería motora antes de comenzar la tarea experimental principal. La mitad de los participantes se asignaron a un mapeo de colores donde la cruz de fijación y la señal tenían un marco verde durante la fase de imaginería y un marco azul durante la fase de acción. Para la otra mitad el mapeo de colores se invirtió. Este mapeo de colores estaba diseñado para ayudar a los participantes a distinguir entre las fases de imaginería y acción.

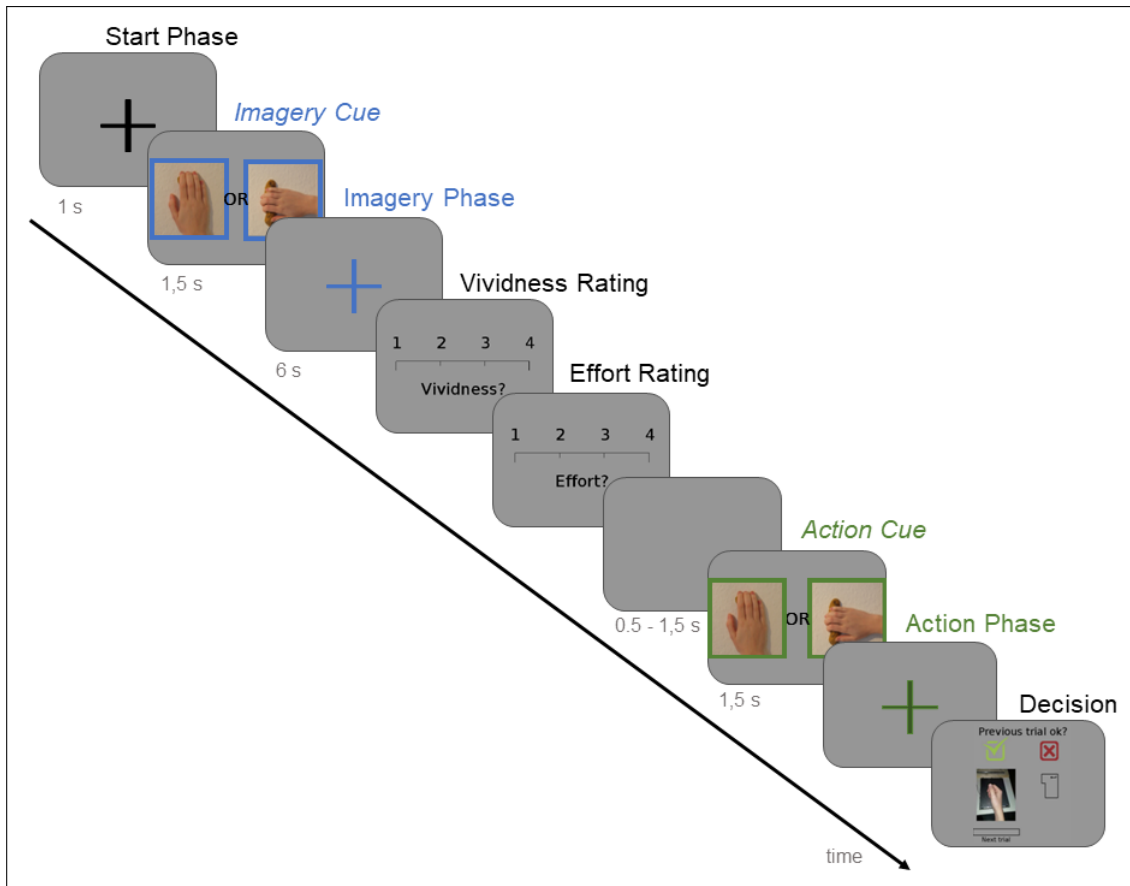



Figura 2.1: **Visualización de una Repetición de Tarea de Imaginación Motora.** En cada ensayo, se presenta una señal de imaginación (1.5 s) que indica uno de dos movimientos de escalada (agarre de borde o tirón lateral). El participante imagina el movimiento (6 s), evalúa la vividez y el esfuerzo en una escala Likert de 4 puntos (1 = casi ninguna imaginación/esfuerzo, 4 = imaginación fuerte/esfuerzo alto) y luego realiza el movimiento indicado lo más rápida y precisamente posible. Tras completar el ensayo, puede decidir si continuar o marcarla como error [Hoffmann, 2022]


2.1.1. Materiales

Aparato de agarre

El aparato de agarre utilizado contenía un punto de inicio y dos presas de escalada fijadas en dos tablas de madera. Al inicio de cada ensayo, los participantes colocaban su mano derecha de manera relajada en la posición de inicio. Cada presa de escalada permitía solo la realización de un movimiento de escalada (agarre en pinza, tirón lateral). En total, se colocaron tres resistores sensibles a la fuerza (RSF) en el aparato de agarre: uno constituía el punto de inicio para medir el momento en que los participantes levantaban la mano desde el punto de inicio (es decir, tiempo de reacción) y un RSF adicional para cada presa de escalada para medir el momento en que los participantes finalizaban su movimiento de agarre (es decir, tiempo de movimiento). Se midieron los levantamientos de mano y el toque de las presas de escalada con un mínimo retraso utilizando los RSF emparejados con un Arduino Uno.



(a) Agarre en pinza (*Crimp*)



(b) Tirón lateral (*Sideway*)

Figura 2.2: Agarres utilizados en el montaje experimental.

Imágenes y señales de acción

Se utilizaron fotos de ambas presas de escalada (agarre en pinza, tirón lateral) con las posiciones correspondientes de las manos como imágenes y señales de acción (Figura 2.2). Específicamente, un agarre en pinza requiere la flexión de la tercera y/o segunda falange, para colocar las yemas de los dedos en una pequeña superficie de agarre orientada hacia arriba. Para ejercer fuerza, el cuerpo (incluido el brazo) tira hacia abajo. En cambio, un tirón lateral requiere que el brazo se acerque a la presa de escalada desde el lado, ya que la superficie de agarre está girada lateralmente. Para ejercer fuerza, el cuerpo (incluido el brazo) desplaza el peso en la dirección opuesta a la superficie que se está enfrentando [Markey, 2022].

Cuestionario de Imaginación Cinestésica y Visual - 10 (KVIQ-10)

El Cuestionario de Imaginación Kinestésica y Visual - 10 (KVIQ-10; [Malouin et al., 2007]) es un cuestionario administrado por el experimentador para evaluar la habilidad de la imaginación motora reportada. El KVIQ-10 consta de 10 ítems, con cinco ítems formando la subescala visual y cinco ítems formando la subescala cinestésica. Cada subescala consiste en realizar, y posteriormente imaginar, un movimiento del tronco, uno proximal y uno distal de las extremidades superiores e inferiores, alternando entre los lados dominante y no dominante del cuerpo.

Después de la ejecución del movimiento, se recopilan calificaciones sobre

la claridad de la imagen mental (es decir, subescala visual), así como la intensidad de las sensaciones que acompañan a la imagen mental (es decir, subescala cinestésica). Los participantes calificaron todos los ítems en una escala Likert de 5 puntos, que va desde 1 (sin imagen/sensación) hasta 5 (imagen tan clara como ver/tan intensa como ejecutar la acción).

Las calificaciones se sumaron por subescala y en total para medir la habilidad de la imaginación motora autoinformada, con puntajes más altos indicando una mayor habilidad autoinformada de la imaginación motora (subescala) [Malouin et al., 2007].

2.1.2. Medidas

Principales medidas

Se midieron el tiempo de reacción, definido como el tiempo entre la presentación de la señal de acción y la liberación de la mano desde el punto de inicio y el tiempo de movimiento, definido como el tiempo entre la liberación de la mano desde el punto de inicio y el movimiento de escalada terminado. Además, se recopilaron calificaciones reportadas de vividez y esfuerzo después de la fase de imaginación motora.

Medidas secundarias

Se recopilaron las calificaciones visuales y cinestésicas del KVIQ-10 [Malouin et al., 2007]. Además, se les pidió a los participantes que contaran cuántos años de experiencia en escalada o bouldering tenían, así como la estrategia de la imaginación utilizada durante la tarea de imaginación motora, ya sea una perspectiva en primera persona (es decir, imaginando como si estuvieran realizando el movimiento ellos mismos) o en tercera persona (es decir, imaginando como si estuvieran viendo a otra persona realizar el movimiento).

2.1.3. Procedimiento

Al inicio de cada sesión experimental, los participantes leyeron información general sobre el estudio y dieron su consentimiento informado para participar en el estudio. Posteriormente, el experimentador explicó detalladamente la tarea de imaginación motora. Se alentó a todos los participantes a familiarizarse con las presas de escalada y los movimientos de agarre correspondientes antes de comenzar el experimento. Los participantes practicaron la tarea de imaginación motora. Posteriormente,

te, los participantes realizaron la tarea experimental principal. Después, realizaron el KVIQ-10 [Malouin et al., 2007]. Al final de la sesión experimental, los participantes completaron el cuestionario de dominancia manual de Edimburgo [Oldfield, 1971].

2.2. Descripción general de los datos

En la sección anterior se detalló el procedimiento experimental y se mencionaron algunos de los datos recolectados durante el mismo. En esta sección, nos enfocaremos específicamente en los datasets proporcionados para el análisis de este trabajo.

Los datos suministrados por el laboratorio, resultado del experimento descrito previamente se presentan en dos archivos planos. El primer archivo contiene información general de cada participante, mientras que el segundo archivo recoge los datos comportamentales correspondientes a cada ensayo.

En cuanto a los datos por participante, se obtuvo el registro de su edad, género, habilidad visual y cinestésica y experiencia en actividades deportivas que involucren escalada, que hemos mencionado anteriormente, con un rango progresivo de uno a cinco.

Respecto a los datos comportamentales por ensayo, podemos categorizar la información como de trayectoria, temporal e inherente al ensayo.

Acerca de las trayectorias se almacenó un registro por cada observación espacial obtenida con los sensores desde que comienza el movimiento hasta su finalización a intervalos de 16 ms, teniendo un total de entre 18 y 193 líneas por ensayo. La información recolectada concretamente es la posición tridimensional en los ejes “x”, “y” y “z” de cada uno de los trece sensores colocados en la mano según el sistema detallado en la figura 2.3 al momento del registro de la observación. A su vez se dejó asentado bajo el sistema de cuaterniones la orientación o ángulo de cada sensor.




Figura 2.3: Disposición de sensores en la mano

Respecto a datos temporales, además de la identificación de cada observación en el tiempo, se dejaron asentados datos como el tiempo de reacción desde que se comanda la acción hasta que efectivamente comienza el movimiento y duración del mismo, entre otros datos relacionados.

Por último, algunos de los datos inherentes a cada ensayo más relevantes son la acción imaginada y la acción realizada, siendo las opciones para ambas *crimp* y *sideway*, la congruencia que indicará congruente o incongruente dependiendo si coincide o no la acción ejecutada y la imaginada, respectivamente y la evaluación de esfuerzo y vividez declarada por el participante que como ya hemos dicho en secciones anteriores, utiliza un rango de números enteros del uno al cuatro.

2.3. Creación de variables

En *machine learning* y técnicas estadísticas la fase de *feature engineering* es crucial para mejorar el rendimiento de los modelos, ya que la calidad de los atributos suele tener un impacto mayor en la precisión que el propio algoritmo utilizado [Domingos, 2012]. La creación de nuevas características permite representar de manera más efectiva los patrones subyacentes en los datos, lo que a menudo resulta en una mayor capacidad predictiva y generalización de los modelos [Bengio et al., 2013]. Esta etapa consiste en seleccionar, transformar y generar atributos relevantes que faciliten el aprendizaje y la interpretación de los modelos [Guyon and Elisseeff, 2003].

Con este objetivo en mente, se calcularon y adicionaron nuevos atributos para evaluar su efectividad en los distintos modelos a construir. Un ejemplo de esto es el cálculo de la media de la posición de cada sensor, lo cual se rotuló como un sensor adicional (sensor 14) a los efectos de una mejor manipulación durante la construcción de los algoritmos. La motivación detrás de este conjunto de atributos es resumir el movimiento mediante un centroide, evitando así las particularidades individuales de cada sensor.

También fue calculado a nivel de ensayo la distancia recorrida por cada sensor teniendo en cuenta la posición tridimensional entre una observación y la siguiente. Este cálculo también se realizó para el sensor 14 y en ningún caso se tuvo en cuenta la rotación o ángulo de los sensores.

De forma análoga, se calculó la velocidad por sensor entre cada observación, teniendo en cuenta la diferencia de tiempo en cada una. Pero al ser un atributo a nivel de ensayo y pudiendo cambiar la velocidad entre observaciones, se decidió obtener un promedio de velocidades como valor final para cada atributo.

Con la finalidad de extraer de manera eficiente los patrones espacio-temporales derivados de las trayectorias de la mano, se presentó la dificultad de construir modelos a partir de las observaciones de puntos espaciales a lo largo del tiempo para cada ensayo realizado que además variaba en la cantidad de registros para cada ensayo, dependiendo de la duración del movimiento. De aquí surge la motivación para modelar las trayectorias espaciales de manera suave y parsimoniosa, mediante el uso de funciones continuas (tipo polinomios), conservando los coeficientes que reconstruyen la trayectoria como campos de un único registro por ensayo. Esto último permite además una mejor manipulación del dataset resumiendo la información de cada ensayo en una única línea.

Para el modelado de las trayectorias por ensayo, se construyeron inicialmente polinomios independientes para cada sensor y cada eje espacial ("x", "y", "z"), así como para la variable tiempo ("t"). Estos polinomios fueron parametrizados en función de un nuevo valor lambda que varía entre cero y uno. Este enfoque permite normalizar el rango de los datos y generar trayectorias que son comparables entre los ensayos, independientemente de la duración o el número de observaciones. La normalización mediante la parametrización lambda es una técnica comúnmente utilizada en problemas de modelado paramétrico y cubic splines para garantizar que los modelos resultantes sean comparables, eliminando variaciones artificiales debidas a la escala temporal o espacial de las observaciones [Hastie et al., 2009].


En primera instancia, con la finalidad de evaluar el ajuste producido por los polinomios a los datos de posicionamiento registrados, se utilizaron regresiones lineales simples calculando el coeficiente de determinación (R^2) como medida de calidad del ajuste para determinar los grados del polinomio a utilizar para todas las trayectorias. El coeficiente R^2 es ampliamente utilizado en el análisis de regresión para medir la proporción de la variabilidad total explicada por el modelo y es particularmente útil cuando se busca determinar la precisión con la que un polinomio ajusta una serie de puntos observados. Este coeficiente proporciona una métrica sencilla e intuitiva para comparar diferentes modelos y grados de polinomios, donde un valor más cercano a 1 indica un mejor ajuste [Draper and Smith, 1998].

Para evaluar los resultados se generó un lote de prueba con participantes que tuvieran ensayos con todas las combinaciones de movimientos realizados (*sideway* y *crimp*), congruencia (congruente e incongruente) y vividez reportada (con todos los valores de 1 a 4). A continuación se modelaron y graficaron los polinomios tanto en función de λ como en función del tiempo probando con grados tres, cuatro y cinco; siempre evaluando sus R^2 .

Se evaluó qué tan bien se conservaban las trayectorias en cada uno de los ejes y tipos de movimiento. Se observó que en líneas generales el eje “z”, que representa el movimiento vertical, capturaba de forma apropiada el movimiento incluso con un grado 3 de polinomio y en contraposición el eje “y” requería un grado 5 y aún así no se capturaban los extremos del movimiento con demasiada rigurosidad.

Este ejercicio consiguió además detectar varios ensayos con observaciones algo erráticas donde en algunos casos se decidió conservar los ensayos y entender a los polinomios como una forma de suavizar la trayectoria y eliminar el ruido. Y en otros casos se optó por eliminar el ensayo completo. El análisis para la eliminación de ensayos se hizo sobre la base completa y tomando como criterio la cantidad de valores distintos captados por el sensor en comparación con la cantidad total de observaciones y en función de un punto de corte.

A fines ilustrativos, la figura 2.4a muestra dos ensayos que sirven como ejemplos. Se puede observar el ensayo 71 para el sensor 1 del participante 4, que teniendo 32 observaciones tan solo tiene 5 valores distintos. Casos como éstos son los que fueron eliminados. En cambio en la figura 2.4b podemos ver otro caso donde las observaciones siguen un movimiento suave y por ende se conservó el ensayo.



(a) Ejemplo de ensayo excluido por tener una poca variabilidad de valores en el movimiento. (b) Ejemplo de ensayo no excluido por tener variabilidad de valores y un movimiento suave.

Figura 2.4: Ejemplo de ensayos evaluados en el eje “x”.

Es interesante mencionar una prueba exploratoria realizada donde se trabajó con polinomios simples que consistió en guardar el menor grado posible de polinomio tridimensional para cada ensayo que alcanzara un número mínimo de corte de coeficiente de determinación predeterminado. La motivación de este enfoque se basaba en la hipótesis de que la complejidad de la trayectoria, reflejada en un grado polinomial más alto, podría asociarse con situaciones de mayor interferencia motora. En particular, se esperaba que los ensayos incongruentes mostraran trayectorias más sinuosas o con correcciones intermedias debido a la necesidad de cambiar el plan motor, mientras que los movimientos congruentes se esperaban más directos y fluidos. De forma análoga, se consideró que una mayor vividez subjetiva podría vincularse con ejecuciones más consistentes y, por tanto, con polinomios de menor grado. Esta expectativa se fundamenta en evidencia previa que muestra que la trayectoria espacial de un movimiento puede reflejar procesos cognitivos y conflictos de decisión que no se manifiestan necesariamente en la respuesta final, como se observa en estudios de seguimiento del cursor en tareas de juicio perceptivo, de confianza o de resolución aritmética [Di Palma et al., 2022, Faivre et al., 2021, Pinheiro-Chagas et al., 2017]. Finalmente, estos atributos fueron descartados ya que no mostraron mejoras significativas en los modelos predictivos construidos, lo que sugiere que la expectativa de una relación clara entre el grado del polinomio y estos factores no contó con suficiente sustento empírico.

En cuanto a la capacidad de los polinomios para modelar las trayectorias, previamente mencionamos que los extremos de las mismas no reflejaban adecuadamente el desplazamiento. Además, para algunos ejes con movimientos altamente oscilantes, un polinomio simple no lograba representar correctamente el comportamiento, lo cual se determinó a través de la observación manual de muchos ensayos. Esto nos llevó a considerar la implementación de técnicas que tengan en cuenta las va-

riaciones locales, como los cubic splines, los cuales permiten un ajuste más preciso en estas situaciones complejas.

La técnica de *cubic splines* se utiliza ampliamente para modelar trayectorias complejas debido a su capacidad para capturar tanto las características locales como globales del movimiento de manera precisa y suave [Eilers and Marx, 1996]. A diferencia de la regresión polinomial tradicional que tiende a sobreajustarse en presencia de fluctuaciones rápidas o ruidosas en los datos, los *cubic splines* dividen el intervalo en secciones más pequeñas con nudos elegidos estratégicamente. Cada *spline* cúbico es continuo y suave en las transiciones de estos nudos, asegurando que tanto las derivadas primera como segunda sean continuas, lo que proporciona un ajuste más natural a las trayectorias observadas [Faraway, 2016]. Este enfoque permite capturar comportamientos locales sin perder de vista la estructura general de la trayectoria. Esta flexibilidad hace que los cubic splines sean una herramienta ideal para modelar trayectorias en el espacio tridimensional. Para éste trabajo se implementó específicamente la técnica de natural cubic splines, ya que además proporciona una solución efectiva para los problemas en los extremos de los datos imponiendo restricciones adicionales en los límites, haciendo que las curvas se comporten de forma lineal en los extremos, lo que evita fluctuaciones erráticas [De Boor, 2001].

Al definir un valor lambda entre cero y uno, se asegura que las trayectorias estén adecuadamente regularizadas, proporcionando un ajuste suave que captura las características esenciales del movimiento sin sobrerrepresentar fluctuaciones o ruidos menores en los datos. Lambda actúa como un parámetro de ajuste que controla la penalización impuesta a los coeficientes del polinomio, lo que permite un control fino sobre la complejidad del modelo [Hastie et al., 2009]. Esto permite una regularización flexible, que es esencial para garantizar que los *cubic splines* no capturen ruidos espurios pero aún representen las trayectorias de manera precisa.

Para la implementación de ésta técnica se debía determinar qué cantidad y en qué lugar localizar los nodos. Para esto es importante recordar que mientras más nodos más coeficientes deberíamos guardar y que a su vez estábamos generando una regresión por eje y sensor por tanto limitar de forma inteligente la cantidad de nodos nos ayudaría a controlar el volumen del dataset que luego se utilizaría para procesar las diferentes técnicas de *machine learning*. En cuanto a la localización de los nodos se evaluaron tres técnicas que son el posicionamiento equidistante, aleatorio y por cuantiles. Por complejidad en la implementación del código

se avanzó con las dos primeras técnicas. El procedimiento consistió en iterar por cada ensayo en el lote de pruebas y por cada sensor y eje calcular las técnicas equidistante y aleatoria para polinomios de 3 hasta 8 nodos, guardando en un dataset los coeficientes de determinación de cada uno. El dataset resultante tenía un aspecto como el de la tabla 2.1. Para simplificar la evaluación se promediaron los coeficientes de determinación por eje entre los 13 sensores originales, así como también se probaron algunos tipos de visualización que permitieran entender el resultado según la cantidad de nodos y las dos técnicas evaluadas.

Id	Trial	Sensor	Nodos	Cant	R² x	R² y	R² z
7	149	9	Random	3	0.9996290001	0.9994600499	0.9967639468
7	149	9	Equidistant	3	0.9996450555	0.9989979362	0.9956086643
7	149	9	Random	4	0.9996313542	0.9996006536	0.9968217117
7	149	9	Equidistant	4	0.9994688904	0.9993380615	0.9988836778
7	149	9	Random	5	0.999644993	0.9996265685	0.9968241854
7	149	9	Equidistant	5	0.9999149611	0.999702734	0.999753024
7	149	9	Random	6	0.9996686606	0.9997253548	0.999361885
7	149	9	Equidistant	6	0.999808308	0.9997665026	0.9998970885
7	149	9	Random	7	0.9998227352	0.999732077	0.999366282
7	149	9	Equidistant	7	0.999957268	0.9998640815	0.999540092
7	149	9	Random	8	0.9998378409	0.9997324374	0.999438587
7	149	9	Equidistant	8	0.999655024	0.9999408998	0.999944231

Cuadro 2.1: Comparación de valores de R^2 en función de la cantidad de nodos y el tipo de ubicación para cubic splines.

La figura 2.5 muestra a la izquierda la distribución del R^2 en cada eje, evidenciando cómo varía en función de la cantidad de nodos y la técnica utilizada (aleatoria o equidistante). Se observa que, a medida que aumenta la cantidad de nodos, disminuye la presencia de valores atípicos con bajo R^2 , los cuales se presentan principalmente en la ubicación aleatoria de los nodos. Es importante señalar que esta visualización se realizó con un conjunto de ensayos seleccionado previamente a la eliminación de ensayos en los que se capturaron las observaciones incorrectamente, lo que provoca un bajo R^2 , especialmente cuando se utilizan menos de 5 nodos. Estos ensayos mayormente quedaron excluidos en el dataset final. La figura 2.6 ilustra un ejemplo de un ensayo con bajo R^2 , evidenciando los efectos de estos casos atípicos en los resultados. Al enfocar el análisis en los ensayos con R^2 entre 0.9999 y 1, la figura 2.5 a la derecha muestra una mayor acumulación de pruebas con mejor R^2 conforme aumenta el número de nodos, predominando además las pruebas con la técnica equidistante.

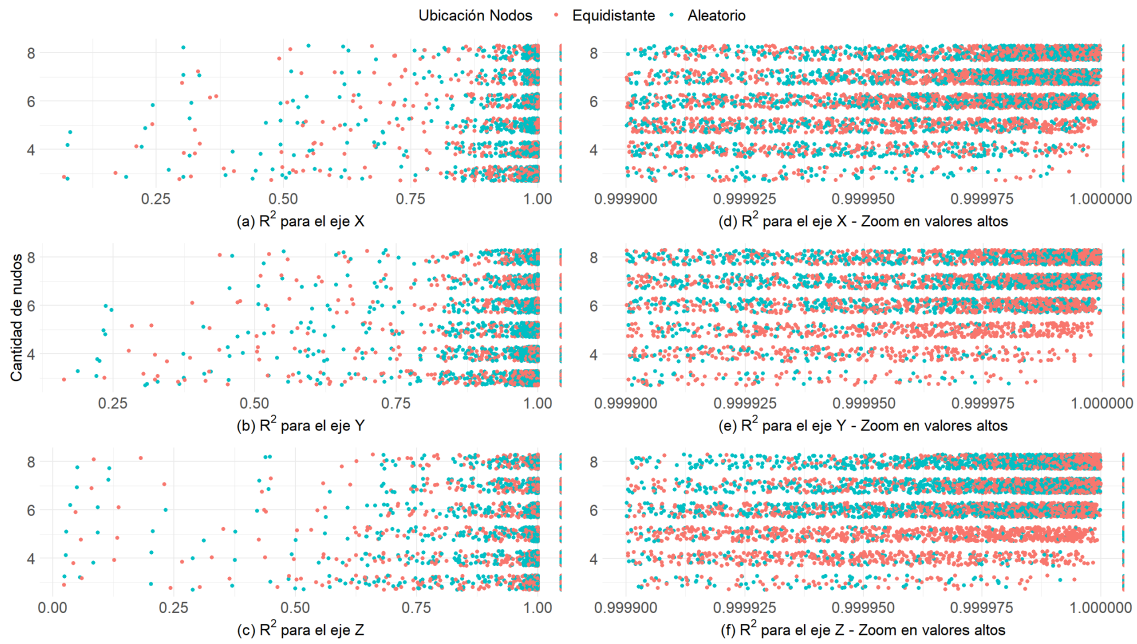


Figura 2.5: R^2 según la cantidad de nodos y ubicación de los mismos para los ejes X, Y, Z

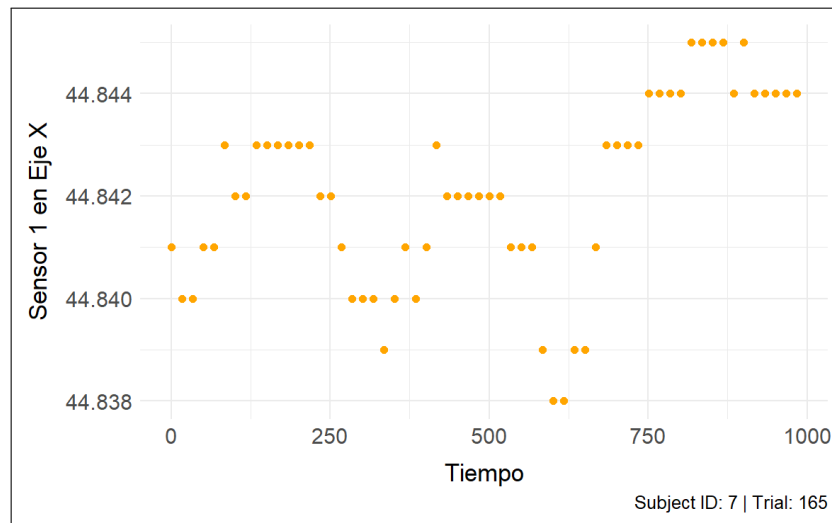




Figura 2.6: Ejemplo de ensayo con bajo R^2 , Es posible observar que una baja performance de cubic splines aquí está dado por las sinusoides y ruido de la trayectoria captada.

Claro está que al definir una técnica y cantidad de nodos para todos los participantes, ensayos, ejes y sensores puede dar lugar a no siempre haber definido la mejor configuración para cada trayectoria pero sí asegura cierta uniformidad a la hora de comparar coeficientes que luego pasarán a ser atributos de nuestros modelos predictivos. A continuación podemos ver algunos ejemplos de observaciones y el polinomio resultante. En la figura 2.7a podemos ver una curva perfectamente ajustada a los puntos de la trayectoria. En el caso de la figura 2.7b se observa un ensayo ruidoso donde el ajuste consigue suavizar el efecto y dibujar

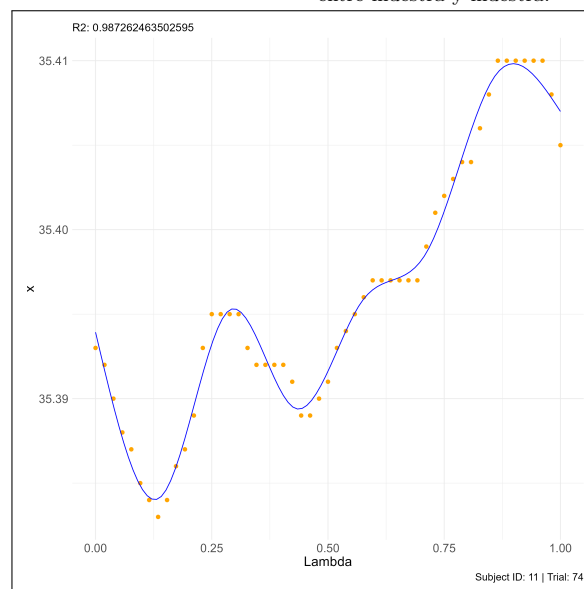
una trayectoria más natural. Finalmente la figura 2.7c nos muestra un ejemplo donde el ajuste no pareciera ser el mejor utilizando 3 nodos. Finalmente la configuración utilizada para todos los ensayos fue de 5 nodos equidistantes que resulta en 7 coeficientes a guardar en el dataset justo con 2 coeficientes adicionales comunes a todos los ejes dentro del mismo ensayo que representan el tiempo.



(a) Trayectoria Sideway congruente de Vividez 4 en el eje Z en función de lambda ajustada con cubic splines con tres nodos con un muy buen coeficiente de determinación.



(b) Trayectoria *Crimp* incongruente de Vividez 4 en el eje X en función de lambda ajustada con cubic splines con seis nodos que atenúa algunos movimientos poco suaves, seguramente por limitaciones de la captura de datos y la ventana entre muestra y muestra.



(c) Trayectoria *Crimp* incongruente de Vividez 3 en el eje Y en función de lambda ajustada con cubic splines con tres nodos donde no consigue una buena representación del movimiento.

Figura 2.7: Ejemplo de curvas ajustadas con cubic splines.




Figura 2.8: Comparativa de ajuste con y sin cubic splines. En naranja el ajuste con cubic splines atraviesa las observaciones mientras que un polinomio grado 5 si bien tiene un buen ajuste solo consigue acercarse a las observaciones en la mayoría de los casos.

En la figura 2.8 se muestran las observaciones de un sensor para un ensayo como puntos rojos, junto con el ajuste de un polinomio de grado 5 en naranja y un ajuste con cubic splines de 4 nodos en azul y verde. Es evidente cómo el ajuste con cubic splines ofrece una mayor precisión al modelar las observaciones, logrando un resultado más cercano a los datos reales. A su vez, en las figuras 2.9 y 2.10 se examina el ajuste en los extremos de las trayectorias, donde suele concentrarse la mayor dificultad en el modelado del movimiento. En estas figuras se presentan los finales de ensayos correspondientes a un movimiento *crimp* y otro *sideway*, ilustrando cómo el ajuste se comporta en esa etapa crítica del movimiento. Para una mejor visualización, se seleccionaron algunos de los sensores de la mano, específicamente aquellos ubicados en las puntas de los dedos pulgar, índice, medio y anular, ya que capturan con mayor precisión los detalles finos de la trayectoria en los extremos. De esta manera, se enfoca particularmente en los últimos momentos de cada trayectoria.




Figura 2.9: Final de un movimiento *Crimp* para los sensores de la punta de los dedos pulgar, índice, medio y anular.




Figura 2.10: Final de un movimiento *Sideway* para los sensores de la punta de los dedos pulgar, índice, medio y anular.

Antes de avanzar con el uso del dataset construido se decidió realizar un control para validar la efectividad de los coeficientes de las trayectorias como características que resumen las observaciones de los movimientos. Para ello, se ajustaron modelos de regresión logística con cross-validation y LASSO, utilizando como variable objetivo la acción realizada (con valores *crimp* o *sideway*) y como variables independientes los coeficientes obtenidos de las trayectorias de los sensores en los ejes “x”, “y”, “z”, junto con los coeficientes de la recta del tiempo para cada ensayo. Este análisis obedece a la idea de que, si el suavizado por splines de las trayectorias es efectivo, los parámetros que definen a estos splines deberían ser suficientes para diferenciar los dos movimientos básicos del experimento.

La decisión de utilizar LASSO (Least Absolute Shrinkage and Selection Operator) está motivada por su capacidad de realizar una selección automática de características, lo que es esencial en datasets con alta dimensionalidad, como el de las trayectorias de sensores. LASSO reduce algunos coeficientes a cero, eliminando aquellos irrelevantes o ruidosos, mejorando así la interpretabilidad del modelo y evitando el sobreajuste [Tibshirani, 1996]. La validación cruzada complementa este proceso, ya que asegura que los modelos generados sean robustos y generalizables, al evaluar el rendimiento en diferentes subconjuntos del dataset [Hastie et al., 2009]. Este enfoque asegura que los coeficientes de las trayectorias capturen información relevante para distinguir entre los tipos de movimientos (*crimp* o *sideway*) sin introducir ruido innecesario.

En la figura 2.11 podemos observar el gráfico resultante de la validación cruzada para el ajuste del modelo de regresión logística con penalización LASSO. En el eje horizontal se representa el logaritmo de lambda, que es el parámetro de regularización, mientras que en el eje vertical se muestra la desviación binomial, una medida de la falta de ajuste del modelo. Los números en la parte superior del gráfico corresponden a la cantidad de características utilizadas en el modelo para cada valor de lambda. Este tipo de gráfico se utiliza para seleccionar el valor óptimo de lambda en un modelo de regresión logística penalizado. Las líneas punteadas marcan los valores de lambda seleccionados como óptimos según distintos criterios, como el que minimiza la desviación (lambda mínimo) o un valor más grande que da lugar a un modelo más simple con una desviación similar (lambda SE). Estos valores permiten encontrar un balance adecuado entre la complejidad del modelo y su capacidad de generalización.




Figura 2.11: Gráfico de resultados del modelo de regresión logística penalizado con LASSO, ajustado mediante validación cruzada. El eje horizontal muestra el logaritmo del parámetro de regularización λ , mientras que el eje vertical presenta la desviación binomial, que sirve para evaluar el ajuste del modelo. Los números en la parte superior indican la cantidad de características seleccionadas para cada valor de λ . Las líneas punteadas representan los valores de λ óptimos según distintos criterios: el que minimiza la desviación (mayor ajuste) y otro que da lugar a un modelo más simple con una desviación similar. Este gráfico ayuda a seleccionar el valor adecuado de λ , equilibrando la complejidad del modelo con su capacidad de generalización.

Se utilizó el valor de regularización seleccionado previamente, λ mínimo, para ajustar un modelo de regresión logística con LASSO, sin emplear validación cruzada en esta ocasión. El modelo resultante mostró una precisión del 94.34 %, lo cual sugiere un desempeño eficaz para clasificar correctamente las observaciones en sus respectivas categorías. La métrica de precisión (*accuracy*) mide la proporción de predicciones correctas realizadas por el modelo en comparación con el total de observaciones, siendo un indicador fundamental del rendimiento global del modelo de clasificación. Sin embargo, es importante destacar que el *accuracy* tiene sus limitaciones, especialmente en conjuntos de datos desbalanceados, ya que un modelo podría obtener un alto valor de precisión simplemente prediciendo siempre la clase mayoritaria. Además, esta métrica no proporciona información detallada sobre el rendimiento del modelo en cada clase individual.

Para obtener una visión más completa, se analizó la matriz de confusión, la cual revela cuántas observaciones fueron correctamente clasificadas en cada categoría y cuántas fueron erróneamente asignadas a la clase incorrecta. En nuestro caso, el modelo identificó correctamente la mayoría de los ensayos de tipo *crimp* y *sideway*, con un número reducido de falsas

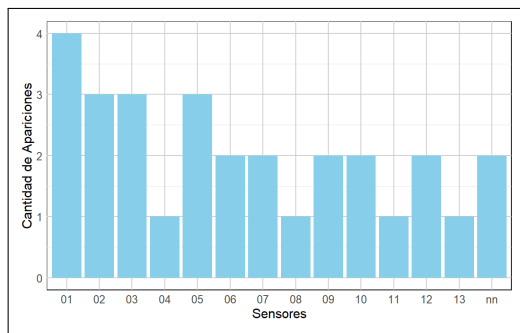
clasificaciones. La matriz de confusión nos permite desglosar las métricas de sensitivity y specificity. La sensitivity, también conocida como recall o sensibilidad, mide la capacidad del modelo para identificar correctamente las instancias positivas; en este caso, se obtuvo un valor de 98.66 %, lo cual indica que el modelo es eficaz para detectar correctamente los movimientos de tipo *crimp*. Por su parte, la specificity mide la capacidad del modelo para identificar correctamente las instancias negativas, es decir, la proporción de verdaderos negativos sobre el total de negativos reales; en este caso, la especificidad fue del 90.76 %, lo cual sugiere que el modelo también fue efectivo en la clasificación de movimientos de tipo *sideway*. Estas métricas proporcionan una visión más detallada del rendimiento del modelo al evaluar su capacidad para clasificar correctamente tanto las instancias positivas como las negativas.

Además, se utilizó el indicador kappa para evaluar de manera más robusta el grado de acuerdo entre la clasificación observada y la predicha. Esta métrica ajusta el acuerdo teniendo en cuenta el que podría esperarse por azar, lo cual es particularmente útil en modelos de clasificación. Los valores de kappa se interpretan de la siguiente manera: valores inferiores a 0 indican que no hay acuerdo, entre 0.01 y 0.20 reflejan un acuerdo leve, entre 0.21 y 0.40 un acuerdo justo, entre 0.41 y 0.60 un acuerdo moderado, entre 0.61 y 0.80 un acuerdo sustancial, y valores entre 0.81 y 1.00 reflejan un acuerdo casi perfecto. En nuestro caso, el valor de kappa fue de 0.8868, lo cual indica un acuerdo casi perfecto, confirmando la efectividad del modelo para predecir si el movimiento realizado fue *crimp* o *sideway*.

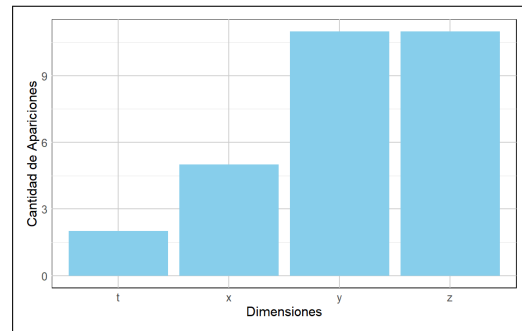
En este punto, se ha validado la efectividad de los coeficientes utilizados para representar las trayectorias de los movimientos, modelados a partir de un determinado coeficiente de determinación. Estos coeficientes permiten resumir la información de las observaciones y, por ejemplo, identificar el tipo de movimiento realizado en cada ensayo. Este enfoque resulta en una reducción significativa del volumen del dataset, ya que se pasa de contar con 13 datos de posición por 3 ejes por cada observación dentro de un ensayo, a disponer de 7 datos por 3 ejes, junto con dos datos que representan el tiempo. Con un promedio de 40 observaciones por ensayo, se estima que este proceso reduce la cantidad de datos a aproximadamente un 5.9 % del total inicial.

Adicionalmente, al seleccionar solo los atributos indicados por el valor óptimo de lambda mínimo, logramos una mayor reducción de la información necesaria, preservando en cierta medida la información relevante sobre las trayectorias realizadas. Sin embargo, es importante destacar

que los atributos seleccionados por el modelo responden a una lógica matemática más que conceptual, lo cual puede dificultar su interpretación directa. Por esta razón, se ha añadido una prueba complementaria. Se generaron gráficos adicionales que muestran la frecuencia de aparición de cada sensor y de cada eje, como se puede observar en la figura 2.12. El objetivo de estos gráficos es evaluar si la reducción de información desde la perspectiva de los sensores o ejes mantiene resultados sólidos, y explorar la posibilidad de simplificar la captura de movimientos en experimentos futuros.



(a) Frecuencia de atributos utilizados de cada sensor en el modelo de regresión logística para la variable objetivo acción realizada donde los sensores 1, 2, 3 y 5 son los más repetidos.



(b) Frecuencia de atributos utilizados de cada eje “x”, “y”, “z” o temporal en el modelo de regresión logística para la variable objetivo acción realizada donde los ejes “y” y “z” son los más repetidos.

Figura 2.12: Frecuencia de feautres en regresión logística para clasificar los movimientos por ensayo.

De la observación de estos gráficos y con la motivación antes mencionada de resumir la información del movimiento en menos sensores y/o ejes, se probó ajustar un modelo utilizando únicamente los coeficientes de los sensores 1, 2, 3 y 5, en los ejes “y” y “z”, que son los que presentaron más apariciones relevantes en el análisis previo. El modelo ajustado con esta selección de sensores y ejes alcanzó una precisión del 92.22 %, ligeramente inferior al 94 % obtenido anteriormente, lo cual sigue indicando un buen desempeño para clasificar correctamente las observaciones.

El indicador kappa se mantuvo en un nivel significativo con un valor de 0.8443, reflejando un acuerdo sustancial y una solidez del modelo similar a la del ajuste previo. Por otro lado, la métrica de sensitivity mostró que el modelo logró identificar correctamente el 99.76 % de las instancias positivas, mientras que la specificity fue del 86.71 %, lo que indica una ligera disminución en la capacidad del modelo para clasificar las instancias negativas.

Estos resultados sugieren que, de ser necesario, sería factible reducir el dataset utilizando únicamente los movimientos en los ejes “y” y “z” y los datos de los sensores 1, 2, 3 y 5. Es importante notar que estos sensores están ubicados sobre los huesos que incluyen el tercer y segundo meta-

carpiano, los cuales conforman la base ósea de la palma y son esenciales para la estabilidad y fuerza de la mano, así como sobre las falanges proximales del pulgar y del índice, responsables de la precisión y el control fino durante la ejecución de movimientos. Dado que el pulgar y el índice son los principales responsables de la manipulación de objetos y las tareas que requieren destreza, y que los metacarpianos proporcionan la estructura y soporte necesarios para ejecutar movimientos más amplios, resulta coherente que la información recolectada por los sensores ubicados en estas áreas sea suficiente para describir con precisión los dos tipos de movimientos realizados en los ensayos. No obstante, dado que el tiempo de procesamiento de los modelos no suponía limitaciones relevantes y que la reducción implicaba una ligera disminución en la precisión, se consideró conveniente conservar el conjunto completo de información en los análisis posteriores.

Ya finalizando este apartado, cabe mencionar que se han agregado al set de datos para algunas pruebas en la construcción de modelos de clasificación la posición de todos los sensores en la última observación para cada ensayo y la vividez reportada del ensayo anterior al actual.

2.3.1. Variables objetivo

En las siguientes secciones veremos en detalle los modelos que se han construido para analizar patrones y efectos de los ensayos en función de la vividez y congruencia. Para ello nuestras variables objetivo combinan éstos conceptos.

En la figura 2.13 podemos observar la frecuencia y distribución de la característica Vividez Reportada, con valores del uno al cuatro, Nivel de Vividez Reportada, que agrupa los valores uno y dos en Bajo (Low) y tres y cuatro en Alto (High), con la intención de polarizar efectos. Finalmente se creó la variable Priming Motor que combina la Vividez Reportada y la Congruencia en 8 categorías y por último una variante llamada Priming Motor Binario que combina el nivel de Vividez Reportada con Congruencia.

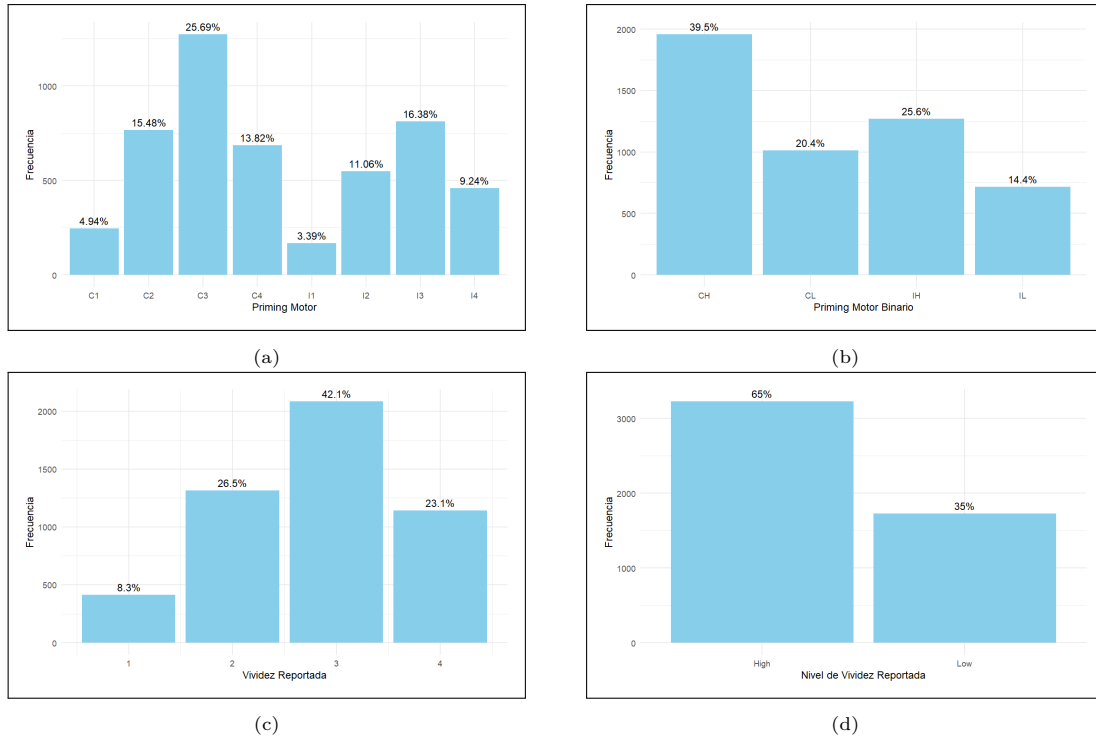


Figura 2.13: Frecuencia de atributos utilizados como variable objetivo.

En la tabla 1 de los Anexos se describe en detalle la totalidad del dataset que comprende los campos provistos por el laboratorio como los construídos para éste trabajo que han sido mencionados anteriormente.

2.4. Análisis exploratorio de los datos

En esta sección nos enfocaremos en la descripción de algunas de las características más relevantes del dataset. Dado que varios de nuestros análisis se centran en la relación entre vividez y congruencia, en las siguientes subsecciones se analizarán aspectos de la variable Priming Motor en relación con características centrales de los movimientos, como el tiempo de reacción y la duración del movimiento.

2.4.1. Expectativas en relación a Priming Motor

Basándonos en estudios previos, como el de Pearson sobre imaginaria visual, se espera que la variable Priming Motor, que combina vividez y congruencia, muestre un patrón característico en el tiempo de reacción y la duración del movimiento. En particular, anticipamos que la media del tiempo de reacción y de la duración del movimiento disminuye a medida que se avanza desde los niveles más bajos de priming (i4, i3, i2, i1) hacia los niveles de mayor priming (c1, c2, c3, c4). La hipótesis plantea que

un mayor nivel de vividez reducirá estos tiempos debido a una mayor claridad mental, mientras que la incongruencia, especialmente en los niveles de vividez altos, aumentará el tiempo de reacción debido a la interferencia entre la acción imaginada y la acción ejecutada.

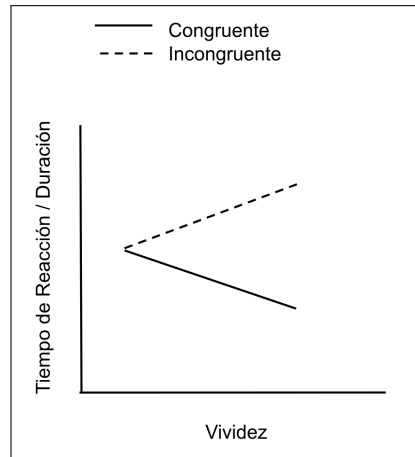


Figura 2.14: Gráfico que muestra la expectativa de conseguir mayores tiempos de reacción y movimiento para ensayos congruentes y en contraposición obtener tiempos de reacción y movimientos más largos conforme hay mayor vividez en ensayos incongruentes.

2.4.2. Análisis de Tiempo de Reacción y Duración del Movimiento

Para evaluar si el comportamiento del dataset está alineado con estas expectativas, se realizaron gráficos de violín y boxplot que muestran la distribución del tiempo de reacción y la duración del movimiento en función de los niveles de Priming Motor.

El gráfico 2.15a muestra para los tiempos de reacción una tendencia decreciente donde las medianas de los niveles incongruentes son mayores a los congruentes. Esperaríamos sin embargo cierta progresión decreciente de “i4” a “c4” que no se cumple y para el caso de los niveles congruentes se mantienen mayormente constantes. Si observamos la figura 2.15c los movimientos Crimp conservan un comportamiento similar al general en términos de tiempo de reacción, sin embargo en la figura 2.15e, movimiento *sideway*, sí es posible ver un comportamiento a la baja desde “i4” a “c4”. Al ser tan sutiles las variaciones entre las categorías, vale la pena revisar si las magnitudes entre categorías son estadísticamente significativas. Para este análisis, no fue posible realizar un ANOVA debido al incumplimiento de sus supuestos, por lo que se optó por el test de Kruskal-Wallis, que es adecuado para comparar más de dos grupos sin asumir una distribución normal de los datos. Este test es una alternativa no paramétrica al ANOVA cuando se cumplen pocas suposiciones sobre

los datos [Conover, 1999]. Posteriormente, se realizó una comparación de pares mediante el test de Dunn, un procedimiento post-hoc adecuado cuando se utilizan pruebas no paramétricas como Kruskal-Wallis [Dunn, 1961]. El test de Dunn reveló diferencias significativas solamente entre algunas categorías, lo que sugiere que las diferencias entre los niveles de vividez no son lo suficientemente robustas para generalizarse a lo largo de todos los niveles de Priming Motor. Las matrices de resultados del test de Dunn se incluyen en el anexo para proporcionar detalles adicionales sobre las comparaciones realizadas.

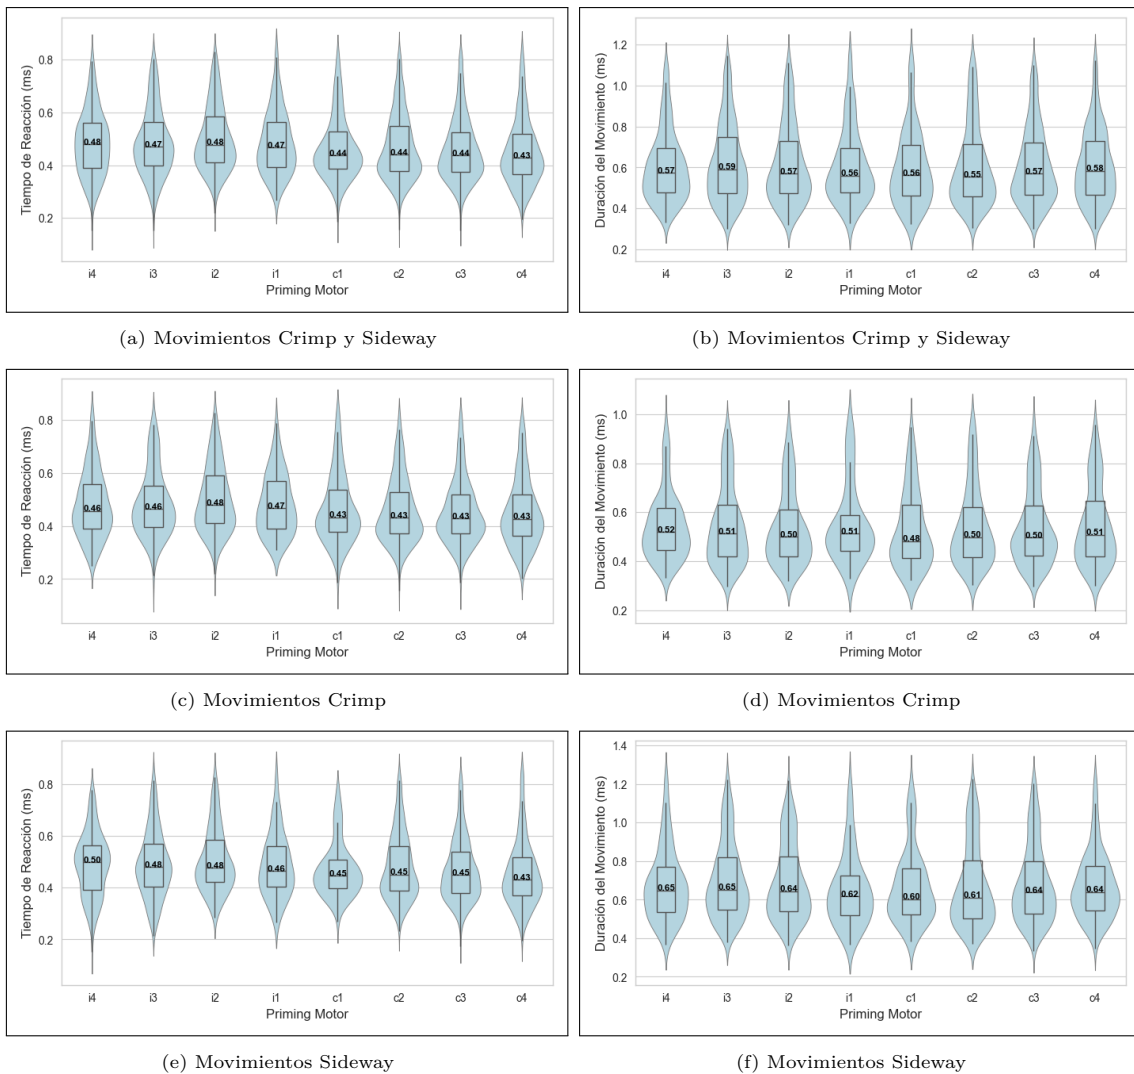


Figura 2.15: Boxplot y violín plot para el tiempo de reacción y duración del movimiento en función del Priming Motor con el ordenamiento teórico desde una mayor interferencia en la imagería motora (i4) a una menor interferencia (c4).

Para el análisis de la duración del movimiento, los resultados mostrados en el gráfico 2.15b no revelan una variación sólida entre categorías congruentes e incongruentes; las medianas se mantienen en valores similares a lo largo de la escala, incluso al pasar de incongruente a congruente

(de izquierda a derecha). En ese sentido, al revisar las figuras 2.15d y 2.15f, correspondientes a los movimientos por separado, es posible notar un descenso entre las categorías “i1” y “c1”, aunque este patrón se ve atenuado cuando se observa la mediana general. Para la duración del movimiento, también se utilizó el test de Kruskal-Wallis, pero este no detectó diferencias significativas entre las categorías, por lo que no se avanzó con la comparación de las categorías.

Tanto para el tiempo de reacción como para la duración del movimiento esta falta de progresión lineal robusta en las categorías intermedias y en algunos casos en los extremos podría estar relacionada con varias limitaciones inherentes a los datos. En primer lugar, la cantidad total de datos y el balanceo de clases pueden no ser suficientes para captar patrones consistentes en cada nivel de Priming Motor. Con 32 sujetos y 4956 ensayos en total, la variabilidad individual en cada sujeto podría estar modulando el comportamiento de los promedios en las categorías intermedias, especialmente si algunos sujetos responden de manera diferente a los niveles de vividez y congruencia.

Además, aunque el efecto de la vividez y la congruencia es observable en términos generales, las particularidades individuales de cada sujeto, como su capacidad para reportar vividez con precisión o su familiaridad con el tipo de movimiento, podrían estar introduciendo ruido en los resultados. Las categorías intermedias, al ser una combinación de niveles moderados de vividez y congruencia, podrían ser especialmente sensibles a estas diferencias individuales. Es por ello que a continuación detallaremos los elementos del priming motor, vividez y congruencia, en relación con el tiempo de reacción y la duración del movimiento para cada participante.

En las Figuras 2.16 y 2.17, se presenta la relación entre la vividez, la congruencia y dos medidas clave de desempeño motor: el tiempo de reacción y la duración del movimiento, respectivamente.

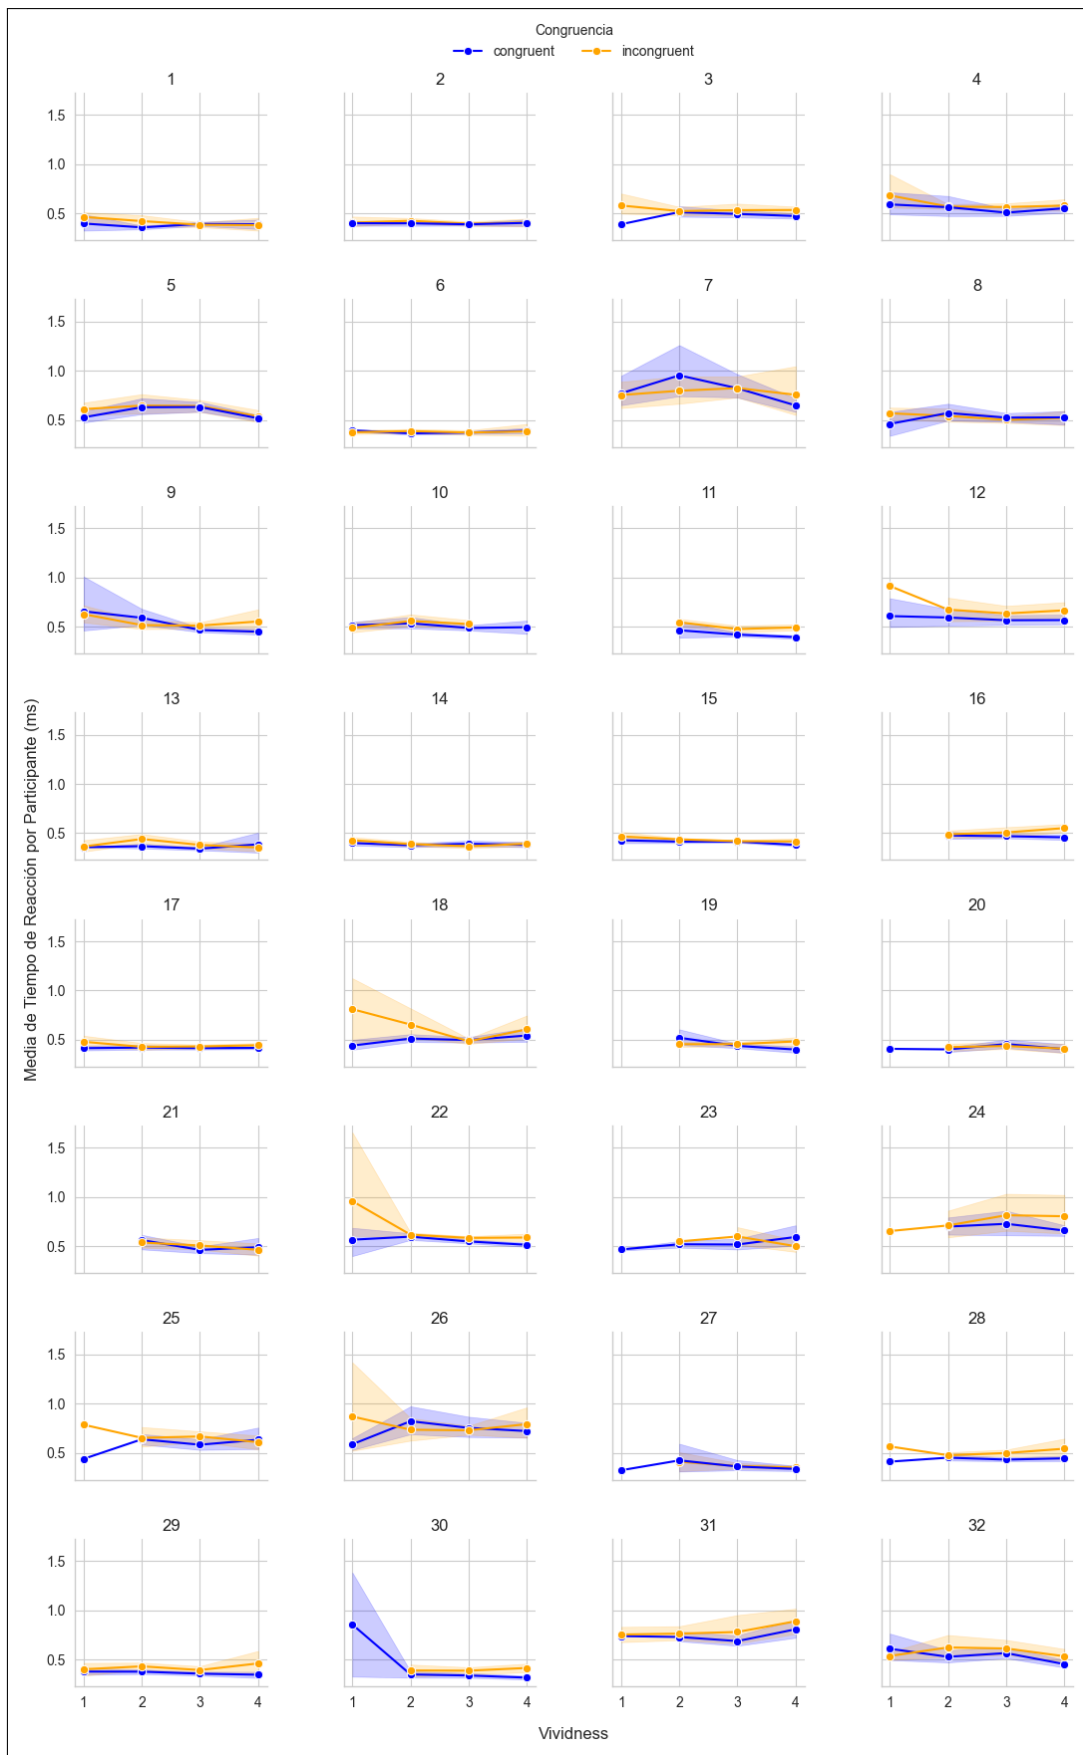


Figura 2.16: Representación de la media de los tiempos de reacción por participante distinguiendo la escala de de vivez tanto para ensayos congruentes como incongruentes que se identifican con azul y naranja respectivamente.

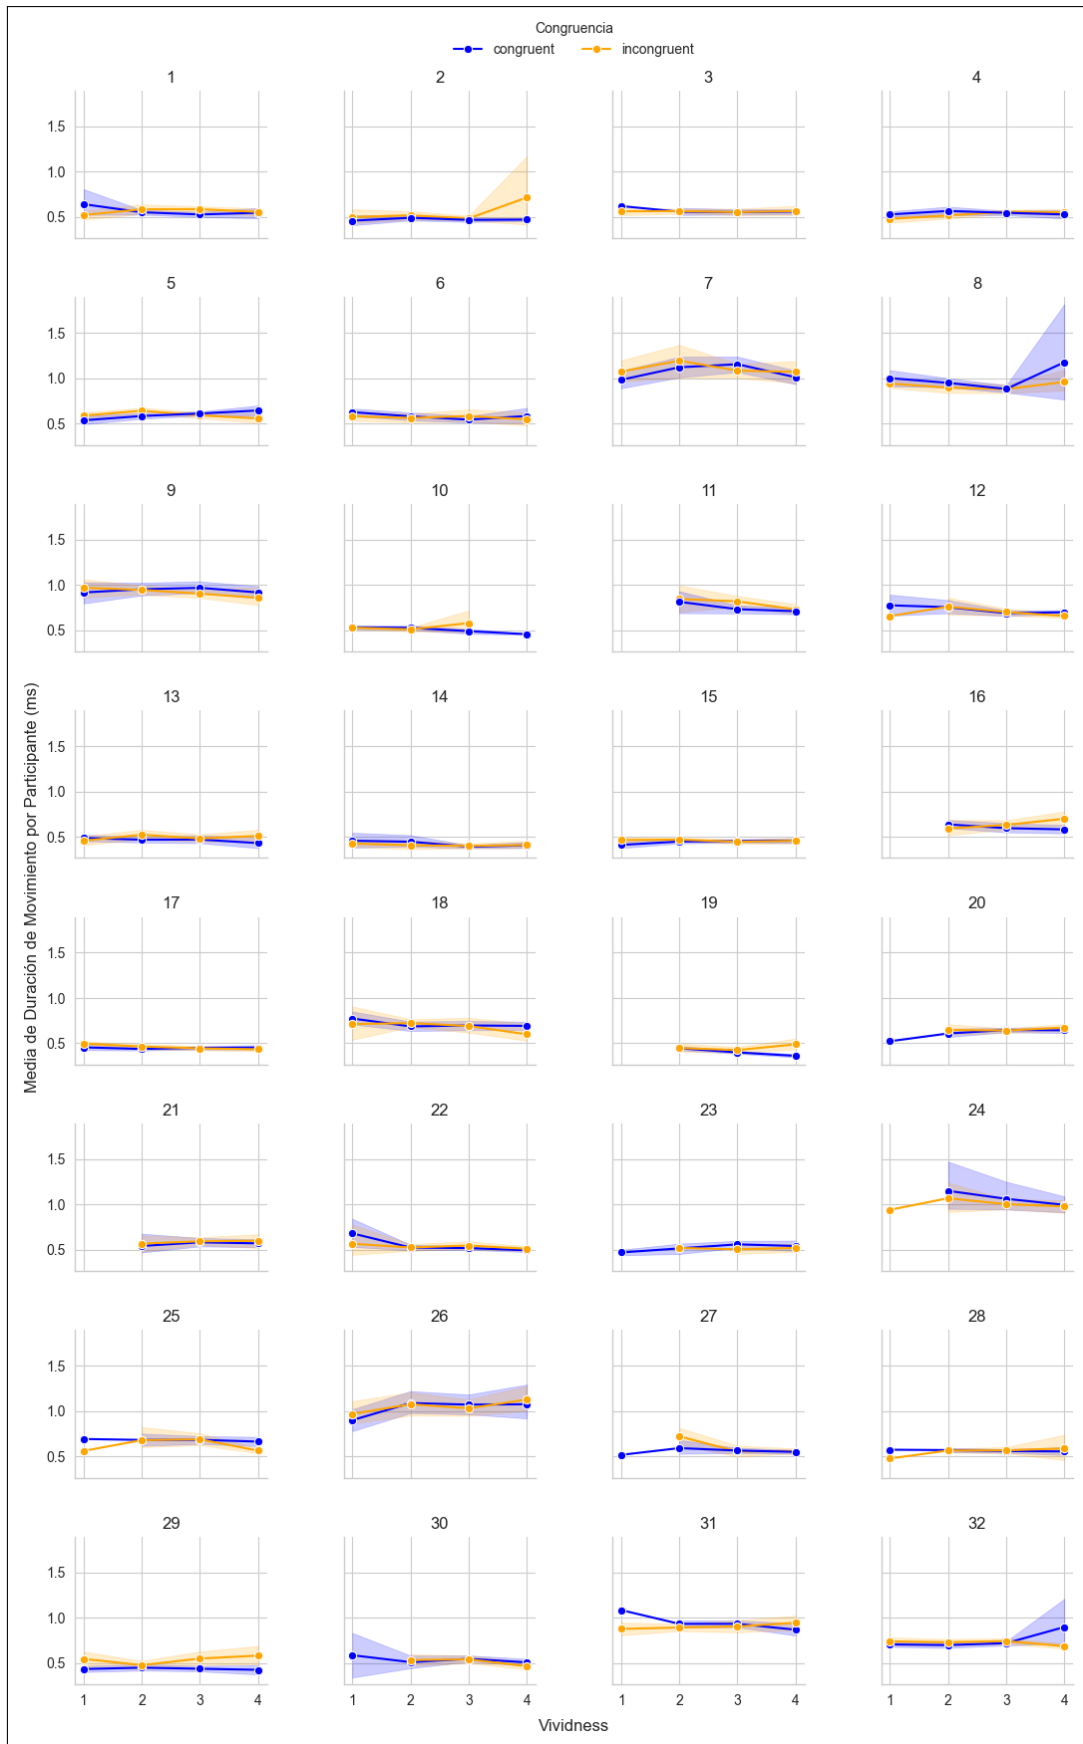


Figura 2.17: Representación de la media de los tiempos del movimiento por participante distinguiendo la escala de de vividez tanto para ensayos congruentes como incongruentes que se identifican con azul y naranja respectivamente.

La figura 2.16 muestra la media del tiempo de reacción dentro de cada nivel de vividez reportado, categorizado además por la congruencia (congruente o incongruente) del ensayo, con los diferentes sujetos representados en cada subgráfico individual. Cada línea de color representa un tipo de congruencia, lo que permite observar las diferencias en el tiempo de reacción entre condiciones congruentes e incongruentes en función de la vividez. En general, se observa que los tiempos de reacción son menores en los ensayos congruentes que en los incongruentes, particularmente en niveles altos de vividez (valores 3 y 4). Esta relación sugiere que una congruencia alta, junto con una vividez elevada, facilita una respuesta más rápida, lo cual podría indicar una preparación motora más eficaz cuando el sujeto percibe una vividez clara de la imagen mental.

Similar al análisis del tiempo de reacción, la figura 2.17 presenta la media de la duración del movimiento para cada sujeto, diferenciada por los niveles de vividez y congruencia. A diferencia del tiempo de reacción, la duración del movimiento muestra un patrón más variable en relación con la vividez y congruencia. Aunque los ensayos congruentes tienden a presentar una duración del movimiento algo menor en comparación con los incongruentes, esta diferencia no es tan marcada ni uniforme como en el tiempo de reacción. Esto sugiere que, mientras que la congruencia y vividez impactan significativamente en la fase inicial del movimiento (tiempo de reacción), su influencia es menos consistente durante la ejecución del movimiento, posiblemente debido a otros factores motores que se activan una vez iniciada la acción.

Para facilitar una visualización más detallada de la información individual, en los Anexos se incluyen versiones adicionales de las Figuras 2.16 y 2.17 en las que el eje Y está escalado de manera independiente para cada participante. Este ajuste permite apreciar con mayor precisión las variaciones relativas entre los niveles de vividez y congruencia dentro de cada sujeto, sin la restricción del rango fijo utilizado en las figuras principales del cuerpo del documento.

Estas observaciones respaldan la hipótesis de que la vividez y congruencia afectan principalmente la fase de preparación y planificación motora (reflejada en el tiempo de reacción), mientras que su impacto en la duración del movimiento es menos predecible.

2.4.3. Correlación de variables numéricas

Las matrices de correlación son herramientas fundamentales en el análisis de datos numéricos, ya que permiten observar la relación lineal entre

pares de variables. En una matriz de correlación, cada celda representa el coeficiente de correlación entre dos variables específicas, con valores que van de -1 a 1. Un valor cercano a 1 indica una fuerte correlación positiva, es decir, cuando una variable aumenta, la otra tiende a aumentar también. Por el contrario, un valor cercano a -1 indica una fuerte correlación negativa, lo que significa que cuando una variable aumenta, la otra tiende a disminuir. Valores cercanos a 0 sugieren que no existe una correlación lineal significativa. El análisis de estas matrices es clave para identificar patrones y posibles redundancias entre variables, lo que puede facilitar la interpretación de los datos y mejorar la construcción de modelos predictivos.

La figura 2.18 presenta la matriz de correlación de las principales variables numéricas del dataset. En esta matriz se observan algunas correlaciones relevantes. Por ejemplo, existe una correlación positiva de moderada a alta entre la Duración del Movimiento y el Tiempo de Reacción (0.38), lo que indica que los ensayos en los que los participantes tienen tiempos de reacción más largos también tienden a mostrar una mayor duración en la ejecución del movimiento. De igual modo, la Distancia Recorrida y la Velocidad Promedio están altamente correlacionadas (0.64), lo cual es consistente, ya que a mayor distancia recorrida es probable que se alcance una velocidad promedio mayor. En contraste, variables como la Vividez Reportada no muestran correlaciones significativas con la mayoría de las otras variables, lo que sugiere que la autopercepción de la vividez no está directamente asociada con los tiempos de reacción ni con la distancia recorrida, entre otros aspectos motores evaluados en el estudio.




Figura 2.18: Matrices de correlación para las características numéricas más relevantes del dataset.

A continuación, las siguientes tres imágenes en la figura 2.19 presentan las matrices de correlación de los coeficientes de las trayectorias calculados mediante cubic splines para los ejes x, y, y z respectivamente. Estos coeficientes representan los parámetros que caracterizan la forma de la trayectoria de los sensores en cada eje y reflejan la variabilidad en los movimientos de los participantes.

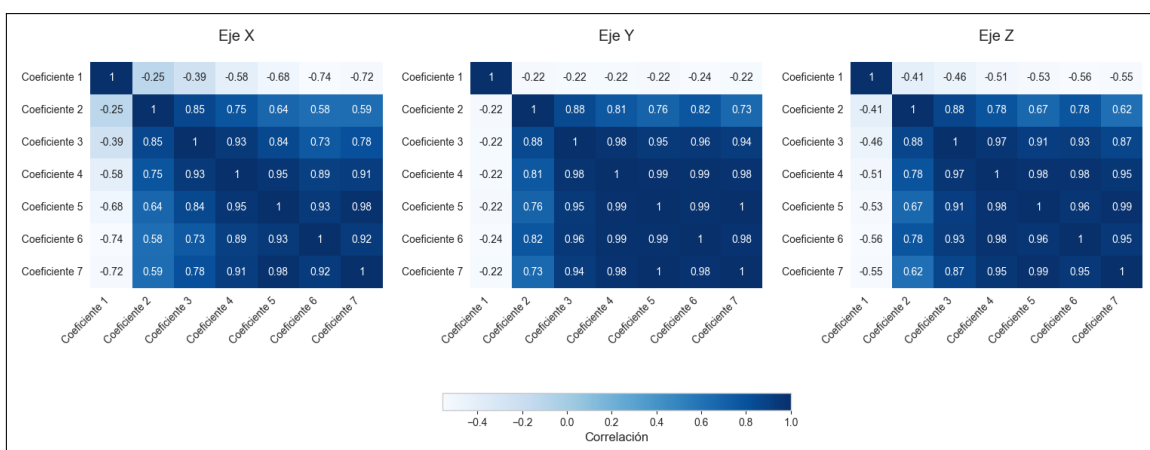


Figura 2.19: Matrices de correlación para los coeficientes de cubic splines del sensor 14 (centroide) en los ejes “x”, “y” y “z”.

En las matrices de correlación de los coeficientes para los ejes, se observa una tendencia clara: los coeficientes que siguen al primero muestran una

correlación positiva alta entre sí, indicando que comparten información similar sobre la forma de la trayectoria. Este patrón se mantiene en los tres ejes (x , y , y z), lo que sugiere que estos coeficientes capturan aspectos de curvatura que son consistentes en cada eje. En particular, la fuerte correlación entre los coeficientes 2 a 7 implica que estos parámetros representan características de mayor frecuencia en la trayectoria, probablemente describiendo oscilaciones o cambios locales en la dirección del movimiento.

Por otro lado, el coeficiente 1 tiene una correlación baja o negativa con los demás coeficientes, lo cual sugiere que este primer coeficiente está capturando una característica global o de baja frecuencia en la forma de la curva, como la tendencia general de la trayectoria en el eje correspondiente. Es probable que el coeficiente 1 esté relacionado con el "tono" general de la trayectoria, mientras que los otros coeficientes ajustan detalles específicos, permitiendo que el spline capture variaciones más sutiles en puntos específicos de la trayectoria.

Esta estructura de correlación indica que los coeficientes 2 a 7 contienen información redundante entre sí, debido a su alta correlación. Por lo tanto, en futuros modelos que busquen reducir la dimensionalidad del dataset sin sacrificar demasiada precisión, podría ser beneficioso considerar una selección de coeficientes representativos o aplicar técnicas de reducción de dimensionalidad, como el análisis de componentes principales (PCA). Esto simplificaría el modelo sin perder el valor explicativo de la trayectoria en términos de cubic splines. El coeficiente 1, al ser menos redundante, debería conservarse en cualquier esquema de simplificación, ya que aporta una perspectiva única sobre la forma general de la curva.

2.4.4. Balance de variables discretas

En las figuras 2.20c y 2.20d se observa que la distribución de las acciones ejecutadas y las imaginadas entre los movimientos *crimp* y *sideway* está bastante equilibrada, con porcentajes similares en ambos casos (49.82 % para *crimp* y 50.18 % para *sideway*). Este equilibrio sugiere que las tareas de imaginar y ejecutar movimientos fueron diseñadas para no favorecer ninguna de las dos acciones en particular. En cuanto a la congruencia de los ensayos, representada en la figura 2.20a, se destaca que un 60 % de los casos son congruentes y el 40 % incongruentes. Como se mencionó en secciones previas, esta proporción se estableció intencionalmente como parte del diseño experimental, permitiendo una adecuada cantidad de ensayos congruentes para el análisis sin excluir una muestra representa-

tiva de ensayos incongruentes.

La figura 2.20b muestra la distribución de la variable de vividez reportada, con valores en una escala de 1 a 4. Podemos observar que la mayor frecuencia de reportes se concentra en el valor 3, representando el 42.1 % de las observaciones, lo cual indica que este nivel de vividez es el más común entre los participantes. El segundo nivel más frecuente es 2, con un 26.5 % de las observaciones, seguido por el nivel 4, que representa el 23.1 %. El valor más bajo, 1, es el menos común, con solo un 8.3 % de las observaciones. Esta distribución sugiere una tendencia hacia niveles intermedios y altos de vividez en la percepción de los participantes.

La figura 2.20e muestra la distribución de la variable de esfuerzo reportado en una escala de 1 a 4. En este caso, el valor más frecuente es 3, con un 36.5 % de las observaciones, seguido por el nivel 2 con un 33.7 %. Esto sugiere que los participantes reportaron un esfuerzo moderado en la mayoría de los casos. Los niveles de esfuerzo más bajos (1) y más altos (4) representan el 15.7 % y el 14.0 % de las observaciones, respectivamente, lo que indica que los extremos de la escala fueron menos comunes. En conjunto, esta distribución sugiere una tendencia hacia niveles medios de esfuerzo en las tareas de imaginación realizadas.

La figura 2.20g muestra la distribución de la variable ^{Experiencia Escalando.}entre los participantes, categorizada en una escala de 0 a 5. La mayoría de los participantes, un 59.1 %, reportaron no tener experiencia en escalada (nivel 0), mientras que el 24.1 % reportaron tener un nivel 1. Los niveles de experiencia 2, 3, 4 y 5 presentan porcentajes mucho menores. Esto indica que la mayoría de los participantes carecen de experiencia en escalada, con solo un pequeño porcentaje de ellos reportando niveles de experiencia más altos. Esta distribución sugiere que el grupo estudiado está compuesto predominantemente por personas sin o con poca experiencia en esta actividad.

La figura 2.20f muestra la distribución de los ensayos según el "Tipo de Mesa utilizada". Al inicio del experimento, se empleó una mesa de metal, en la cual se realizaron el 15 % de los ensayos. Sin embargo, debido a que este tipo de mesa generaba interferencias en la captación de datos por parte de los sensores, se decidió cambiar a una tabla de madera. Este cambio es evidente en la distribución, ya que el 85 % de los ensayos fueron realizados en la mesa de madera, asegurando así una mejor calidad en la recolección de datos.

Este gráfico 2.20h ofrece una visión clara de la composición demográfica de los participantes del experimento en términos de edad y género. Se



Figura 2.20: Distribución de las variables categóricas del dataset.

observa que el rango de edades está comprendido entre los 20 y los 34 años, con una mayor concentración en las edades de 23, 25 y 27 años. Las

barras indican la frecuencia de participantes en cada edad, diferenciados por género. Se puede notar que en la mayoría de las edades predomina el género femenino, especialmente en las edades de 23 y 25 años, mientras que en algunas edades como 26 y 27 años la frecuencia de participantes masculinos es similar o ligeramente mayor.

2.5. Técnicas estadísticas y de aprendizaje automático utilizadas

En esta sección describiremos las diferentes técnicas que se implementaron a lo largo del trabajo para analizar los datos de los movimientos y su relación con la vividez reportada.

2.5.1. Modelos estadísticos

Dada la complejidad de las relaciones entre las variables de Vividez Reportada y Congruencia, era fundamental obtener una primera comprensión de cómo estas características se asociaban con variables continuas de rendimiento motor, como el tiempo de reacción, la duración del movimiento, la distancia recorrida y la velocidad promedio. Esta aproximación inicial, basada en Modelos Lineales Mixtos (LMM), fue crucial para identificar patrones relevantes antes de avanzar hacia técnicas de clasificación más complejas.

La elección de LMM responde a su capacidad para manejar datos con estructuras de correlación o dependencias entre las observaciones, lo cual es particularmente relevante en el contexto del dataset utilizado en este trabajo. Los LMM permiten capturar tanto los efectos fijos de las variables de interés como los efectos aleatorios asociados a posibles variaciones no controladas, como diferencias entre grupos o participantes, facilitando un análisis más robusto en situaciones donde las observaciones no son independientes [Fitzmaurice et al., 2012]. Al hacer esto, es posible obtener una comprensión más detallada de los efectos individuales y sus interacciones, lo que facilita la identificación de relaciones significativas entre los principales atributos del dataset antes de avanzar a la construcción de modelos de clasificación más complejos, como regresiones logísticas o LightGBM. Este enfoque inicial asegura que los patrones y efectos dentro de los datos se modelen de manera adecuada y justifica el uso de modelos de clasificación basados en un entendimiento más sólido de la estructura subyacente de los datos [West et al., 2014].

Para ajustar estos modelos, se evaluó el impacto de las variables Vividez

Reportada y Congruencia en variables representativas de los ensayos, como el tiempo de reacción, la duración del movimiento, la distancia, y la velocidad recorrida en promedio para los 13 sensores (lo que llamamos centroide). Se plantearon una serie de modelos para cada una de estas cuatro variables de respuesta. Los predictores fijos a testear incluyeron Vividez Reportada, Nivel de Vividez Reportada, Congruencia, Vividez en conjunto con Congruencia, Priming Motor y Priming Motor Binario.

Para todos los casos se planteó un efecto aleatorio por participante y que el efecto de los predictores fijos sea común a todos. Es decir que aleatoriamente cada participante tiene un efecto aditivo, donde cada uno será más o menos rápido, por ejemplo en el caso de la duración del movimiento, pero se asume que en promedio el efecto de los predictores fijos afectará de la misma forma a la respuesta.

Es importante destacar que, antes de analizar el efecto de las variables continuas en la vividez y la congruencia, se ajustaron modelos que incluían otras variables, como edad, género, experiencia, ensayo, entre otras. El objetivo fue validar que los efectos observados no fueran el resultado de algún factor confuso o enmascarado por estas características adicionales, garantizando así que los hallazgos fueran realmente atribuibles a las variables de interés.

2.5.2. Modelos de clasificación

Tras identificar patrones relevantes en el comportamiento de las variables continuas mediante los LMM, resultaba necesario invertir el enfoque y explorar si era posible predecir categorías concretas de Vividez Reportada y Congruencia utilizando la amplia gama de características disponibles en el *dataset*. Dado que el conjunto de datos incluía una gran cantidad de variables calculadas o derivadas de las observaciones de los movimientos, se optó por emplear modelos de clasificación, comenzando con regresiones logísticas multinomiales y binomiales, dependiendo de la naturaleza de la variable objetivo. Estas técnicas proporcionan una herramienta adecuada para modelar las probabilidades de pertenencia a cada categoría en función de múltiples predictores [Hosmer et al., 2013].

El objetivo de este enfoque era estudiar cómo las combinaciones de predictores podían explicar las probabilidades de pertenencia a diferentes niveles de vividez y congruencia, complementando las observaciones realizadas con los LMM y proporcionando una perspectiva más integral

sobre los datos. Este cambio de enfoque permitió aprovechar la mayor cantidad de variables disponibles en el dataset para obtener un entendimiento más detallado de las relaciones y patrones subyacentes. Posteriormente, se exploraron técnicas basadas en árboles de decisión con el fin de obtener una mejor intuición sobre la importancia relativa de los diferentes atributos y su influencia en la clasificación.

Se utilizó la librería LightGBM en Python, la cual es particularmente adecuada para el manejo de grandes volúmenes de datos y para la construcción de modelos de clasificación robustos con una eficiencia computacional superior a la de métodos tradicionales de árboles como los basados en *random forests*. LightGBM emplea un enfoque basado en el crecimiento de los árboles por hojas, lo que optimiza tanto la precisión como la velocidad de entrenamiento, permitiendo que se exploren de manera eficiente las interacciones no lineales entre las variables predictoras. Además, para mejorar el rendimiento de los modelos y asegurar que los hiperparámetros más adecuados fueran seleccionados, se empleó Optuna, una herramienta de optimización de hiperparámetros basada en búsqueda bayesiana. Junto a esta librería se utilizó el método de validación cruzada estratificada integrado en LightGBM, definiendo cinco *folds* con muestreo estratificado sobre la variable objetivo, de manera que se preservara la distribución de clases en cada partición. Esta técnica se aplicó en cada iteración de búsqueda para evaluar la configuración de hiperparámetros y reducir el sobreajuste. Los hiperparámetros finales optimizados, listados en el Anexo correspondiente, incluyen la tasa de aprendizaje, la profundidad de los árboles, el número de hojas y los coeficientes de regularización, entre otros..

Para estas técnicas de clasificación (regresión logística y LightGBM), se evaluaron tanto modelos únicos que consideraban todos los participantes, como modelos separados por cada participante, con el fin de estudiar si existían patrones individuales que no se capturaban en el modelo global. Además, se probó la separación de los modelos por tipo de movimiento (*sideway* y *crimp*) para determinar si los patrones diferían significativamente entre ellos. Al igual que en los LMM, se probaron diferentes variables objetivo como Vividez Reportada, Congruencia y combinaciones de éstas.

Este proceso permitió identificar las fortalezas y debilidades de cada método, asegurando que el enfoque más adecuado fuera seleccionado en función del comportamiento específico de los datos y el objetivo principal del trabajo: comprender los factores que determinan la vividez reportada por los participantes.

Capítulo 3

Resultados

3.1. Modelos Lineales Mixtos

3.1.1. Análisis de la Vividez

Para explorar el impacto de la vividez sobre los tiempos de reacción, se categorizó la variable de vividez en dos niveles: bajo (que combina los puntajes 1 y 2) y alto (que combina los puntajes 3 y 4). En la figura 3.1, se observa que los tiempos de reacción son más cortos para los ensayos donde los participantes reportaron una vividez alta en comparación con los ensayos donde la vividez reportada fue baja. Este patrón sugiere que un nivel mayor de vividez está asociado con una mayor eficiencia en la ejecución de los movimientos.




Figura 3.1: Gráfico de efectos del Modelo Lineal Mixto (LMM) mostrando la relación entre el nivel de vividez (Vividness Level) y el tiempo de reacción promedio. La línea azul representa el tiempo de reacción estimado para niveles bajos y altos de vividez, mientras que las barras de error en magenta indican el intervalo de confianza. Se observa una disminución en el tiempo de reacción a medida que aumenta la vividez, lo que sugiere que una mayor claridad de las imágenes mentales podría estar asociada con respuestas más rápidas.

Los resultados del modelo lineal mixto confirman esta observación. El modelo reveló un efecto significativo de la vividez en los tiempos de reacción ($\beta=0.0230$, $SE = 0.0050$, $t(4936) = 4.638$, $p < 0.001$), indicando que un aumento en la vividez de la imagen mental se traduce en una reducción significativa en los tiempos de reacción. En términos cuantitativos, los participantes con un nivel de vividez alto mostraron tiempos de reacción aproximadamente un 4.38 % menores en comparación con aquellos que reportaron un nivel de vividez bajo. Este hallazgo sugiere que la claridad de las imágenes mentales podría jugar un papel crucial en la preparación y ejecución de los movimientos. La reducción de los tiempos de reacción en condiciones de alta vividez podría explicarse por una mayor facilidad para anticipar y planificar los movimientos, gracias a una representación mental más clara y detallada. Además, el modelo incluyó un término aleatorio para cada sujeto, lo que permitió capturar la variabilidad individual, mostrando una desviación estándar de 0.122 entre los participantes. Esto indica que, aunque la vividez tiene un efecto consistente en los tiempos de reacción, existen diferencias individuales importantes en cómo cada sujeto procesa sus imágenes mentales.

3.1.2. Análisis de la Congruencia

En el contexto del diseño experimental, se introdujo el concepto de congruencia para evaluar cómo el tiempo de reacción se ve afectado cuando la acción imaginada difiere de la ejecutada. La figura 3.2 muestra la relación entre la congruencia y los tiempos de reacción. Se observa que los ensayos congruentes presentan tiempos de reacción más cortos en comparación con los ensayos incongruentes, donde se detecta un ligero retraso al iniciar el movimiento.

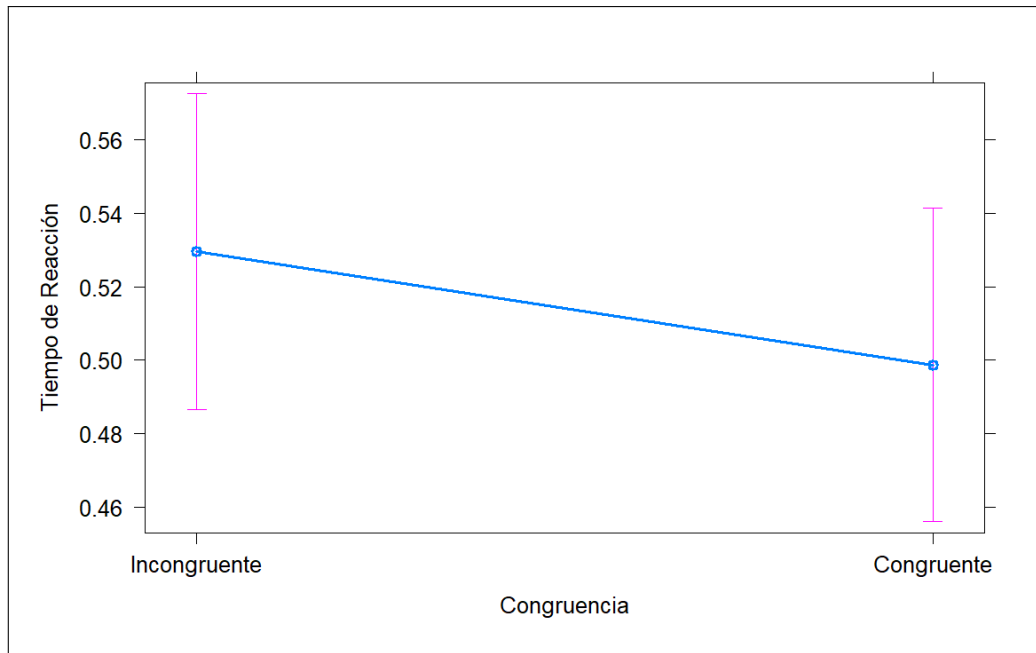


Figura 3.2: Gráfico de efectos del Modelo Lineal Mixto (LMM) mostrando la relación entre la congruencia (Congruencia) de la tarea de imaginaria motora y el tiempo de reacción promedio. La línea azul representa el tiempo de reacción estimado para condiciones incongruentes y congruentes, mientras que las barras de error en magenta indican el intervalo de confianza. Se observa una disminución en el tiempo de reacción en la condición congruente, lo cual sugiere que cuando la imagen mental del movimiento coincide con el movimiento ejecutado, los tiempos de reacción tienden a ser menores.

Los resultados del modelo lineal mixto respaldan esta observación. El análisis indicó un efecto significativo de la congruencia sobre los tiempos de reacción ($\beta = -0.0309$, $SE = 0.0045$, $t(4923) = -6.847$, $p < 0.001$). Esta disminución en el tiempo de reacción sugiere que, cuando el movimiento imaginado y el ejecutado son congruentes, los participantes pueden iniciar el movimiento de manera más rápida y eficiente. En términos cuantitativos, la incongruencia incrementa los tiempos de reacción aproximadamente un 5.8%, lo cual puede explicarse por el tiempo adicional necesario para ajustar y corregir mentalmente el plan de acción. Estos resultados refuerzan la hipótesis de que la congruencia entre la imaginaria motora y la ejecución real facilita la planificación y el control del movimiento, reduciendo los tiempos de reacción y optimizando la respuesta motora de los participantes. Además, el modelo consideró las diferencias individuales mediante el término aleatorio para cada sujeto, mostrando una variabilidad significativa entre los participantes, con una desviación estándar del intercepto de 0.122.

3.1.3. Interacción entre Vividez y Congruencia

Ahora que tenemos las primeras nociones del comportamiento de la vividez y la congruencia en términos de tiempo de reacción podemos ex-

pandir el análisis a la interacción de ambos factores. En la figura 3.3, se pueden observar los efectos obtenidos en el modelo. El panel izquierdo muestra que en los ensayos congruentes, los tiempos de reacción tienden a ser más cortos cuando la vividez reportada es alta, en comparación con los ensayos con baja vividez. Este comportamiento es esperable, dado que imaginar claramente una acción y luego ejecutarla facilita la eficiencia en la respuesta motora, como se ha discutido en la sección de antecedentes.




Figura 3.3: Gráfico de efectos del Modelo Lineal Mixto (LMM) mostrando la relación entre el nivel de vividez (Vividness Level) y la congruencia (Congruency) en el tiempo de reacción promedio. En el panel izquierdo se presentan los resultados para la condición congruente, y en el derecho para la condición incongruente. La línea azul representa el tiempo de reacción estimado para niveles bajos (Low) y altos (High) de vividez, mientras que las barras de error en magenta indican el intervalo de confianza. Se observa que el tiempo de reacción disminuye con un nivel de vividez más alto en ambas condiciones de congruencia, aunque la pendiente es más pronunciada en la condición congruente, lo cual sugiere una mayor influencia de la vividez en la eficiencia del tiempo de reacción cuando la imagen mental del movimiento coincide con el movimiento ejecutado.

En el panel izquierdo, que corresponde a los ensayos incongruentes, se puede observar un desplazamiento vertical hacia tiempos de reacción más largos, independientemente del nivel de vividez reportada. Esto sugiere que, en situaciones de incongruencia, la falta de correspondencia entre la acción imaginada y la ejecutada impide que una alta vividez mejore significativamente la velocidad de respuesta. Estos hallazgos son consistentes con la hipótesis planteada inicialmente sobre la interferencia de la incongruencia. Sin embargo, al examinar en detalle la tendencia dentro de los ensayos incongruentes, se observa que los tiempos de reacción también disminuyen ligeramente cuando la vividez es alta, en lugar de aumentar como se esperaría si la incongruencia atenuara comple-

tamente el efecto positivo de la vividez. Esta contradicción plantea un conflicto con la hipótesis, ya que se anticiparía una pendiente positiva en el caso de que la incongruencia moderara efectivamente los beneficios de una alta vividez. Los resultados del modelo lineal mixto respaldan estas observaciones y revelan efectos significativos tanto de la vividez como de la congruencia, así como una interacción significativa entre ambos factores. El análisis mostró que una alta vividez reduce los tiempos de reacción de manera significativa ($\beta=-0.0301$, $SE = 0.0063$, $t = -4.807$, $p < 0.001$), mientras que la incongruencia tiende a aumentar los tiempos de reacción ($\beta=0.0181$, $SE = 0.0076$, $t = 2.390$, $p = 0.017$). Además, la interacción entre vividez alta e incongruencia presentó un efecto significativo ($\beta=0.0190$, $SE = 0.0094$, $t = 2.015$, $p = 0.044$), lo que indica que la incongruencia modera parcialmente el efecto positivo de la alta vividez, pero no lo anula completamente. Para clarificar esta interacción, se analizaron los efectos simples de la vividez dentro de cada nivel de congruencia mediante estimaciones marginales. En ensayos congruentes, la vividez alta se asoció con una reducción significativa de los tiempos de reacción en comparación con la vividez baja (diferencia = 0.0302, $SE = 0.0063$, $z = 4.807$, $p < 0.001$). En cambio, en los ensayos incongruentes, esta diferencia no alcanzó significación estadística (diferencia = 0.0111, $SE = 0.0075$, $z = 1.495$, $p = 0.135$). Estos resultados sugieren que el efecto de la vividez sobre la reducción del tiempo de reacción es más pronunciado en contextos congruentes, y que en condiciones de incongruencia el beneficio asociado a la vividez elevada es limitado.

3.1.4. Análisis del Priming Motor Binario

En este análisis se construyó un modelo que toma como atributo principal el "Priming Motor Binario", el cual combina la congruencia y los niveles de vividez (alto y bajo). La categoría de referencia seleccionada fueron los ensayos congruentes con vividez alta (CH), ya que representan el extremo de la escala de priming que se asocia con un impacto positivo en la eficiencia del movimiento. Además, en los modelos anteriores, el comportamiento congruente es el que mostró resultados alineados con la hipótesis de mejora en los tiempos de reacción.

En la figura 3.4, se puede observar que el orden de las categorías de izquierda a derecha se alinea con un incremento progresivo en los tiempos de reacción. Este patrón sugiere que la incongruencia es un factor predominante que interfiere negativamente en los tiempos de reacción. Sin embargo, es importante notar que, dentro del contexto de incongruencia, una mayor vividez (IH) aún consigue un efecto de priming

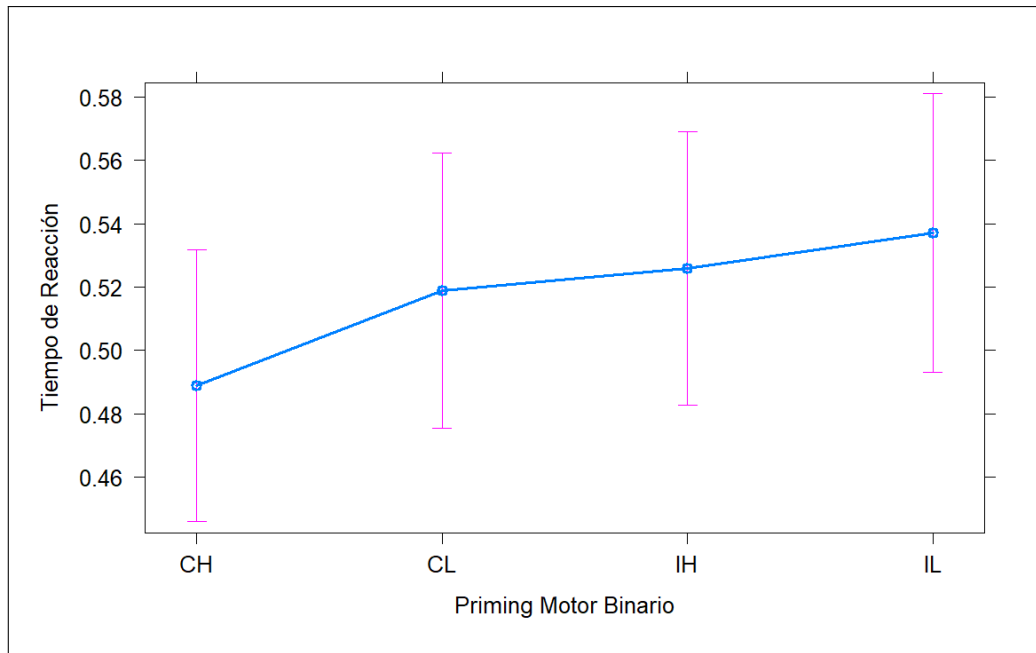


Figura 3.4: Gráfico de efectos del Modelo Lineal Mixto (LMM) que muestra el tiempo de reacción promedio en función del priming motor binario, clasificado en cuatro condiciones: CH (Congruente-Alta Vividez), CL (Congruente-Baja Vividez), IH (Incongruente-Alta Vividez) e IL (Incongruente-Baja Vividez). La línea azul representa el tiempo de reacción estimado en cada condición, y las barras de error en magenta indican el intervalo de confianza. Se observa un incremento en el tiempo de reacción en las condiciones incongruentes y de baja vividez, sugiriendo que el priming motor y la vividez pueden afectar la eficiencia en la ejecución del movimiento.

mejor que una baja vividez (IL), aunque la acción imaginada difiera de la realizada. Esto indica que, a pesar de la interferencia de la incongruencia, una vividez alta proporciona una ventaja relativa en términos de eficiencia motora. Los resultados del modelo lineal mixto corroboran estas observaciones, mostrando que todas las categorías presentan diferencias significativas con respecto a la categoría de referencia. Por ejemplo, los ensayos incongruentes con vividez baja (IL) presentan un incremento significativo en el tiempo de reacción en comparación con los ensayos congruentes con vividez alta ($\beta = 0.0483$, $SE = 0.0070$, $t(4928) = 6.908$, $p < 0.001$), seguidos de los ensayos incongruentes con vividez alta (IH) ($\beta = 0.0372$, $SE = 0.0056$, $t(4921) = 6.643$, $p < 0.001$). De igual forma, los ensayos congruentes con vividez baja (CL) también muestran un aumento significativo en el tiempo de reacción en comparación con los ensayos de referencia ($\beta = 0.0301$, $SE = 0.0063$, $t(4930) = 4.807$, $p < 0.001$).

Por otra parte, en la figura 3.5 se puede observar el orden de las etiquetas de Priming Motor Binario, que combina la vividez y la congruencia de los ensayos. Este ordenamiento sigue la expectativa de una relación lineal de pendiente negativa a lo largo de las diferentes categorías, alineándose con los antecedentes teóricos mencionados en trabajos como el de Pearson.

La interpretación de esta tendencia sugiere que los ensayos congruentes con alta vividez (CH) presentan los tiempos de reacción más cortos, y que los ensayos incongruentes con baja vividez (IL) tienden a mostrar tiempos de reacción más largos, lo cual es consistente con lo que se esperaba.




Figura 3.5: Gráfico de efectos del Modelo Lineal Mixto (LMM) que muestra el tiempo de reacción promedio en función del priming motor binario, con las clases ordenadas según la expectativa de interferencia en el movimiento, desde mayor (IH: Incongruente-Alta Vividez) hasta menor (CH: Congruente-Alta Vividez). Esta clasificación se basa en antecedentes de estudios de Pearson en imaginación visual, donde se ha observado que mayores niveles de vividez combinados con incongruencia producen tiempos de reacción más prolongados, mientras que mayores niveles de vividez y congruencia se asocian con tiempos de reacción más cortos. En este gráfico, la línea azul representa el tiempo de reacción estimado en cada condición, y las barras de error en magenta indican el intervalo de confianza.

Sin embargo, se observa una discrepancia en los ensayos incongruentes con alta vividez (IH), ya que muestran tiempos de reacción más cortos de lo anticipado. Esta disminución en los tiempos de reacción en la condición IH contradice parcialmente las expectativas iniciales, ya que, bajo la hipótesis de interferencia de la incongruencia, se esperaba que una alta vividez no lograra contrarrestar el impacto negativo de la incongruencia sobre la eficiencia del movimiento.

En los anexos, se pueden consultar los detalles completos de estos modelos, incluyendo una versión más desagregada que incorpora las cuatro categorías de vividez. Además, se visualizan por separado los ensayos de los dos tipos de movimientos realizados, *sideway* y *crimp*, para explorar posibles diferencias específicas entre ellos. Aunque los resultados con tiempo de reacción fueron los más robustos y, por ello, se analizaron en mayor profundidad, se identificaron también efectos significativos

en los modelos que utilizan como variable de respuesta la duración del movimiento. Por otro lado, en los modelos que emplean la velocidad promedio se observaron algunos efectos esperados, aunque con menor magnitud, mientras que en los modelos que analizan la distancia recorrida no se encontraron efectos significativos. Todos estos resultados y sus implicaciones están disponibles en los anexos, para una revisión más detallada.

3.2. Modelos de Regresión Logística

Tras una exploración exhaustiva del comportamiento de ciertas variables mediante los Modelos Lineales Mixtos (LMM), fue posible establecer relaciones significativas entre la vividez reportada, la congruencia y métricas clave de rendimiento motor, como el tiempo de reacción. Los LMM permitieron capturar tanto los efectos fijos de estas variables como las variaciones individuales entre los participantes, proporcionando una comprensión inicial de cómo estas características afectan el rendimiento motor. Sin embargo, para avanzar en el análisis y abordar problemas de clasificación más específicos, resultó necesario implementar un enfoque que permitiera predecir categorías concretas de vividez y congruencia. En este contexto, la técnica de regresión logística se presenta como una alternativa adecuada, ya que permite modelar las probabilidades de pertenencia a distintas categorías en función de múltiples predictores.

Con las nociones y patrones identificados a partir de los LMM, se procedió a construir una serie de modelos de regresión logística. El objetivo de estos modelos era evaluar la capacidad de los distintos atributos disponibles para clasificar combinaciones de vividez y congruencia. La construcción de estos modelos se realizó siguiendo una metodología similar a la descrita en secciones anteriores, donde se validó que los coeficientes obtenidos a partir de las trayectorias eran lo suficientemente robustos para clasificar los tipos de movimientos.

En particular, se implementó un modelo de regresión logística multinomial que define como variable objetivo a Priming Motor, una combinación de las etiquetas de congruencia y el puntaje de vividez, resultando en ocho categorías (I1, I2, I3, I4, C1, C2, C3, C4). Este modelo fue diseñado para capturar la complejidad de estas interacciones y evaluar la eficacia de los predictores en la clasificación de estas categorías.

En primer lugar, se ajustó un modelo utilizando LASSO con validación cruzada. A partir de este ajuste, se seleccionó el valor de lambda correspondiente al lambda mínimo, y luego se procedió a ajustar un nuevo

modelo con LASSO, pero sin validación cruzada, empleando el valor de lambda previamente seleccionado. El gráfico de la figura 3.6 ilustra el proceso de selección del parámetro lambda. Se destaca una línea punteada vertical que indica el valor de lambda donde se obtiene el menor error de clasificación promedio. Este punto marca el valor óptimo de lambda para el modelo, en el cual se logra un equilibrio entre la minimización del error y la simplificación del modelo mediante la reducción del número de predictores. Además, en la parte superior del gráfico se señala el número de predictores seleccionados para cada valor de lambda, lo que permite observar cómo aumenta la regularización al incrementar lambda, reduciendo gradualmente la cantidad de variables en el modelo.




Figura 3.6: Gráfico de validación cruzada para un modelo LASSO, utilizado para seleccionar el valor óptimo del parámetro λ . En el eje Y se observa el error de clasificación promedio, mientras que el eje X muestra el logaritmo de λ . Los puntos rojos representan el error de clasificación promedio para cada valor de λ , y las barras de error reflejan la variabilidad del error estimado en la validación cruzada.

El análisis de los resultados del modelo de regresión logística multinomial revela una baja precisión en la clasificación de las categorías de vividez y congruencia, con una exactitud global del 25.2%. Este valor es cercano al esperado por azar, lo que indica que el modelo tiene dificultades para identificar correctamente las clases específicas. Este desempeño limitado también se evidencia en el índice Kappa, que presenta un valor de 0.0406, señalando un nivel de acuerdo apenas superior al azar.

Al examinar el desempeño por cada clase, las métricas de sensibilidad y especificidad muestran un rendimiento desigual. Por ejemplo, una de las clases presenta una sensibilidad elevada (70.87%) pero con una es-

pecificidad baja, lo que sugiere que el modelo clasifica erróneamente observaciones de otras clases en esta categoría. En contraste, algunas clases alcanzan una especificidad muy alta, superior al 98 %, pero con sensibilidades muy bajas, lo que implica que el modelo rara vez identifica correctamente estas clases cuando están presentes en los datos.

En conjunto, estas métricas sugieren que el modelo tiene una capacidad limitada para diferenciar entre las distintas combinaciones de vividez y congruencia, lo cual puede deberse a la falta de discriminación de las características seleccionadas o a una posible complejidad en la estructura subyacente de estas categorías que no es capturada adecuadamente mediante este enfoque de regresión logística multinomial.




Figura 3.7: Matriz de confusión para el modelo global con Regresión Logística Multinomial y Priming Motor como variable objetivo. La clase mayoritaria, C3 tiene mayor tasa de aciertos.

A pesar de las limitaciones en la precisión, resulta relevante revisar las características que tuvieron mayor peso en el ajuste del modelo. En los anexos se presentan las principales características en orden de magnitud, tanto positivas como negativas. Las características positivas son aquellas que favorecen la clasificación en una categoría específica, mientras que las negativas contribuyen a su exclusión. En la figura 3.8 se muestra un resumen de las características a nivel global que más influyeron en el ajuste del modelo, independientemente de si favorecieron la clasificación o exclusión de las categorías evaluadas.




Figura 3.8: Primeras 15 características más importantes para el modelo global con Regresión Logística Multinomial y Priming Motor como variable objetivo. Se advierten las velocidades promedio de varios sensores como preponderantes.

Es interesante observar que, en estos modelos, la velocidad promedio de los sensores resulta especialmente relevante, a diferencia de otros análisis previos. Además, los sensores seleccionados corresponden principalmente a los ubicados en el dedo pulgar, el índice y los extremos de cada dedo, dejando fuera la palma y los sensores intermedios de los dedos medio, anular y meñique. Esta selección concuerda con resultados previos que sugieren una participación prominente del pulgar y el índice en el movimiento.

Se probaron variantes de modelos tanto binomiales como multinomiales, empleando diferentes variables de interés como objetivo. No obstante, los resultados obtenidos mostraron una solidez estadística similar al modelo multinomial aquí descrito, sin mejoras significativas en la precisión de clasificación. Podemos decir entonces que no se ha podido conseguir un modelo robusto que permita comprobar que la vividez reportada tenga una conexión con los datos que tenemos por ensayo y sin tener en cuenta patrones individuales por sujeto.

3.3. Árboles de Decisión

3.3.1. Modelo general

La última técnica abordada fue la utilización de árboles de decisión que nos permita detectar particularidades a nivel general o bien por participante. A continuación recorreremos los resultados de los modelos realizados con LightGBM con priming motor como variable objetivo.

En primer lugar se realizó un modelo general para todos los participantes. En la figura 3.9 se visualiza la matriz de confusión obtenida.




Figura 3.9: Matriz de confusión para el modelo global con LightGBM y Priming Motor como variable objetivo. Donde la clase mayoritaria, C3 y sus categorías adyacentes tienen mayor tasa de aciertos.

La matriz de confusión proporciona información sobre el desempeño del modelo en la clasificación de las etiquetas de priming motor en ocho categorías distintas (c1, c2, c3, c4, i1, i2, i3, i4). La clase con la mayor proporción de predicciones correctas es trivial, porque esta es la categoría que ocurría más frecuentemente en el dataset. Más allá de eso, vemos que las clases incongruente-1 e incongruente-4 tienen un rendimiento muy bajo en términos de predicciones correctas, con pocos casos identificados correctamente, lo que sugiere que el modelo tiene dificultades para diferenciar entre estas clases. En general, el modelo tiende

a confundir las clases cercanas en valor, como las clases c2 y c3, y las clases i2 e i3.

El informe de clasificación del modelo muestra un rendimiento general moderado, con una exactitud global del 30 %. La precisión es variable entre las clases, siendo relativamente más alta para la clase c1, aunque sigue siendo limitada para otras, particularmente en las clases i1 e i4, donde el modelo no logra un buen desempeño. La clase c3 destaca en términos de sensibilidad, ya que el modelo logra identificar la mayoría de sus instancias, pero en otras clases la sensibilidad es baja, lo que sugiere una dificultad para capturar correctamente una proporción significativa de observaciones en estas categorías.

El F1-score, que combina precisión y sensibilidad, refleja aún más esta dificultad, con un máximo de 0.41 en la clase c3, indicando que el modelo lucha por equilibrar estos dos aspectos en la mayoría de las clases. En general, el modelo tiene un rendimiento desigual, capturando mejor algunas clases y mostrando fallas notables en otras, especialmente en aquellas relacionadas con categorías extremas de incongruencia.

El modelo LightGBM, optimizado con Optuna, identificó variables como el tiempo de reacción, los ensayos y el esfuerzo como las más relevantes para predecir el priming motor. No obstante, estos hallazgos no se tradujeron en un rendimiento robusto en la clasificación de todas las categorías, destacando la necesidad de una mayor refinación del modelo o de la inclusión de variables adicionales que puedan mejorar la discriminación entre las diferentes clases de priming motor.

La figura 3.10 muestra las variables que tuvieron mayor influencia en la predicción del priming motor, destacándose especialmente tres características principales. En primer lugar, el tiempo de reacción se presenta como el predictor más relevante y con una magnitud elevada lo que indica una relación fuerte con la variable objetivo de priming motor. Esto sugiere que el tiempo de reacción es un factor clave para entender cómo se comportan los diferentes niveles de vividez y congruencia en el modelo.

La segunda variable más influyente es el ensayo (*trial*), lo que implica que las características relacionadas con los diferentes ensayos contribuyen de manera significativa en la predicción. Esto puede reflejar variaciones en la vividez y congruencia dependiendo de la condición experimental específica de cada ensayo.

En tercer lugar, el esfuerzo aparece con una importancia considerable, lo que subraya el papel del esfuerzo percibido en el proceso de predicción.




Figura 3.10: Primeras 20 características más importantes para el modelo global con LightGBM y Priming Motor como variable objetivo.

Esta variable añade valor en la clasificación, sugiriendo que niveles de esfuerzo pueden tener un efecto relevante en la vividez y congruencia del priming motor.

Además de estas variables, se observa la presencia de varios coeficientes asociados a los sensores, etiquetados como “coef_1_sensor_x_y_z”. Aunque su contribución es menor en comparación con las variables más globales como tiempo de reacción y esfuerzo, estos coeficientes aportan información significativa. Esto indica que las trayectorias captadas por los sensores también influyen en el modelo, proporcionando una capa adicional de detalle en la predicción de las combinaciones de vividez y congruencia.

3.3.2. Modelo por participante

Al desarrollar los modelos en este estudio, surgió un dilema metodológico: ¿es válido generalizar patrones de comportamiento motor entre diferentes participantes o cada individuo tiene particularidades que deben modelarse por separado? Los movimientos y la imaginación motora son procesos complejos, influenciados por características únicas de cada participante, como su experiencia previa, habilidades motrices y la per-

cepción subjetiva de los movimientos. De hecho, investigaciones previas han demostrado que las diferencias interindividuales en la imaginación y ejecución motora pueden ser significativas, sugiriendo que los patrones de comportamiento observados no necesariamente se replican de manera uniforme entre todos los individuos [Guillot and Collet, 2005]. Por lo tanto, se consideró plausible que cada participante responda de manera distinta a las mismas condiciones experimentales. Este enfoque justifica la necesidad de construir modelos específicos por participante, permitiendo capturar con mayor precisión las variaciones individuales y evitando una generalización que podría enmascarar la diversidad de respuestas.

A continuación, se construyeron, entonces, modelos individuales para cada participante, con el objetivo de evaluar la importancia relativa de las diferentes características en la predicción de la variable objetivo priming motor. En la figura 3.11, se representan los participantes en el eje x y la importancia de las características en el eje y, donde cada punto corresponde a una variable diferente. Dado que algunas características como los coeficientes de las trayectorias polinómicas generan una gran cantidad de variables, se decidió agruparlas y mostrar únicamente el coeficiente con mayor importancia en cada caso.

En términos generales, se observa que la importancia de las características varía considerablemente entre los participantes. En algunos casos, como los participantes 8 y 10, las características relacionadas con la distancia recorrida y la velocidad promedio parecen ser las más influyentes, lo que sugiere que para estos individuos, los aspectos cinemáticos de sus movimientos tienen un mayor impacto en la predicción de la vividez y la congruencia. En otros participantes, como los participantes 3 y 9, características como los coeficientes polinómicos asociados a las trayectorias espaciales destacan en importancia, lo que indica que las trayectorias de los movimientos son un factor determinante en la predicción de la variable objetivo.

Un aspecto importante a destacar es que, a diferencia de los modelos generales, donde características como la edad y la experiencia en escalada emergen como factores relevantes, en el contexto de los modelos por participante, estas características pierden validez como predictores. Esto se debe a que tanto la edad como la experiencia son constantes dentro de cada individuo, y por lo tanto, no aportan variabilidad que pueda ser utilizada para predecir las diferencias en el priming motor. Por otra parte, variables globales como el tiempo de reacción y el ensayo se destacan con una importancia moderada a alta en varios participantes,

mostrando su consistencia como predictores relevantes en los modelos personalizados.




Figura 3.11: Representación de la importancia de las características en modelos individuales por participante.

En conclusión, este análisis sugiere que no existe un conjunto único de características que sea igualmente importante para todos los participantes, lo que refuerza la idea de que los patrones individuales de movimiento y comportamiento influyen de manera diferenciada en la predicción de priming motor. Esta variabilidad entre participantes subraya la importancia de utilizar enfoques personalizados en los modelos de predicción, especialmente cuando se trata de variables complejas como la vividez y la congruencia en movimientos motores.

Discusión y Conclusiones

Este trabajo ha aportado nuevas evidencias en el estudio de la metacognición aplicada a la imaginería motora, explorando específicamente cómo la vividez percibida de las imágenes mentales influye en el desempeño motor. La estrategia empleada se centró en validar relaciones clave entre variables de los movimientos y la vividez reportada por los participantes, así como en desarrollar modelos predictivos capaces de generalizar estos niveles de vividez. Los análisis iniciales, basados en Modelos Lineales Mixtos, mostraron que una vividez elevada tiende a asociarse con tiempos de reacción más cortos, mientras que la incongruencia entre el movimiento imaginado y el ejecutado genera tiempos de reacción más prolongados. Sin embargo, en el contexto de incongruencia, se esperaba que la pendiente de la relación entre vividez y tiempo de reacción fuera positiva, es decir, que una vividez más alta se tradujera en tiempos de reacción más largos en comparación con una vividez baja. Sin embargo, los resultados indicaron lo contrario: a medida que la vividez aumenta, los tiempos de reacción disminuyen incluso en contextos incongruentes. Este hallazgo plantea la posibilidad de que el comportamiento de la vividez en la imaginería motora no siga los mismos patrones observados en la imaginería visual, donde se ha encontrado que una mayor claridad de la imaginería tiende a interferir progresivamente en situaciones de incongruencia. Este patrón de variabilidad individual también ha sido descrito en estudios previos de priming motor, como el trabajo de [Dijkstra et al., 2019], donde se observó que algunos participantes presentaron priming positivo mientras que otros mostraron inhibición. Estos hallazgos refuerzan la idea de que la respuesta al priming motor no es homogénea en la población. Además de explorar el efecto de la vividez en el desempeño del movimiento, otro objetivo fundamental del estudio era evaluar si los participantes podían reportar con precisión el grado de claridad de su imaginería motora. Sin embargo, los resultados obtenidos no permitieron validar de manera concluyente esta capacidad de autoinforme. De hecho, los patrones observados en los LMM podrían sugerir que los participantes confunden vividez con estado de alerta, lo que facilita un mejor rendimiento al ejecutar el movimiento independientemente de la claridad de la imagen mental. Esta limitación sugiere que futuros estudios podrían beneficiarse de la incorporación de mediciones directas de actividad cerebral, como electroencefalografía (EEG) o resonancia magnética funcional (fMRI), para contrastar de manera objetiva

los reportes subjetivos de vividez y complementar los datos actuales, proporcionando un control adicional sobre la precisión de los autoinformes de vividez. Posteriormente, se construyeron modelos de clasificación para intentar predecir los niveles de vividez, utilizando regresiones logísticas y métodos basados en árboles de decisión. Estos modelos enfrentaron limitaciones importantes debido al tamaño del conjunto de datos, compuesto por 4,956 ensayos de 32 sujetos (con un promedio de 154 ensayos por sujeto, tras eliminar algunos registros) luego de la limpieza de datos. La cantidad de datos, aunque adecuada para ciertos análisis globales, dificultó la obtención de una precisión elevada en los modelos de clasificación y limitó la generalización de los modelos específicos por individuo, lo que plantea restricciones al momento de interpretar los hallazgos. A pesar de estas limitaciones, el análisis de importancia de variables reveló ciertos atributos relevantes, como el esfuerzo percibido, el tiempo de reacción y la distancia recorrida por sensores clave. Estos resultados sugieren que, aunque existen patrones que ayudan a entender el impacto de la vividez en el movimiento, el fenómeno podría no ser totalmente generalizable debido a variaciones individuales significativas. En este sentido, los modelos específicos por participante indicaron que cada sujeto otorga diferente relevancia a los atributos en función de su perfil, lo cual apoya la idea de que la personalización de los modelos predictivos podría ser una vía prometedora para la investigación futura en metacognición motora, donde las diferencias individuales jueguen un papel crucial. Además, se introdujo una metodología innovadora para resumir las trayectorias de los movimientos utilizando cubic splines, permitiendo capturar las características clave del movimiento en un espacio tridimensional. Aunque efectiva en términos de compresión de datos, esta técnica no fue suficiente para capturar por completo las variaciones subjetivas asociadas a la vividez. En conclusión, esta tesis ha contribuido a la comprensión de la relación entre la imaginería motora, la vividez percibida y la congruencia en el comportamiento motor. A pesar de las limitaciones de los modelos predictivos y del tamaño del conjunto de datos, los hallazgos sugieren una conexión entre vividez y eficiencia en tiempos de reacción, lo cual abre la puerta a futuros estudios que incorporen técnicas avanzadas para explorar la metacognición motora. Además, la integración de nuevos tipos de señales, como EEG o fMRI, podría no solo enriquecer el análisis, sino también permitir evaluar de manera más objetiva la capacidad de los individuos para reportar la vividez de sus imágenes mentales, abordando uno de los aspectos clave que no pudo confirmarse en este estudio.

Capítulo 4

Anexos

4.1. Estructura de los datos

4.1.1. Por Ensayo

Nombre atributo	Unidad	Descripción
subjID	Alfanumérico	Identificación de sujeto experimental
id	Entero	Identificación numérica de cada sujeto experimental
trial	Entero	Identificación de 1 a 200 de cada trial por sujeto
time	Decimal	Timestamp de cada observación dentro del trial
sensors_x [1..13]	Decimal	Posición del sensor de 1 a 13 en el eje X
sensors_y [1..13]	Decimal	Posición del sensor de 1 a 13 en el eje Y
sensors_z [1..13]	Decimal	Posición del sensor de 1 a 13 en el eje Z
theta_x [1..13]	Decimal	Eje X de coordenadas homogéneas que representa el ángulo para cada sensor
theta_y [1..13]	Decimal	Eje Y de coordenadas homogéneas que representa el ángulo para cada sensor
theta_z [1..13]	Decimal	Eje Z de coordenadas homogéneas que representa el ángulo para cada sensor
theta_w [1..13]	Decimal	Factor de escala de coordenadas homogéneas que representa el ángulo para cada sensor

Continúa en la siguiente página

Nombre atributo	Unidad	Descripción
congruency	Alfabético	<i>Congruent</i> o <i>Incongruent</i> para indicar si la acción imaginada coincide con la ejecutada
imagined_action	Alfabético	<i>Crimp</i> o <i>Sideway</i> para indicar la acción imaginada
performed_action	Alfabético	<i>Crimp</i> o <i>Sideway</i> para indicar la acción ejecutada
obs_count	Entero	Cantidad de observaciones del trial
vividness	Entero	Escala de 1 a 4 de qué tan vívido fue imaginada la acción del trial
effort	Entero	Escala de 1 a 4 de con cuánto esfuerzo fue imaginada la acción del trial
reactionTime	Decimal	Timestamp que registra el momento cuando comenzó el movimiento
movementTime	Decimal	Duración total del movimiento
table_condition	Alfabético	<i>Metal</i> o <i>Wooden</i> indica el material de la mesa donde se realizó el trial

4.1.2. Por Sujeto

Nombre atributo	Unidad	Descripción
subjID	Alfanumérico	Identificación de sujeto experimental
gender	Binario	<i>F</i> o <i>M</i> indican género femenino o masculino
age	Entero	Edad del sujeto experimental que realiza el trial
boulder_experience	Entero	Escala de 1 a 5 de experiencia en escalamiento

Continúa en la siguiente página

Nombre atributo	Unidad	Descripción
score_visual	Entero	Escala de 1 a 25 de destreza visual
score_kinaesthetic	Entero	Escala de 1 a 25 de destreza cinestésica

4.1.3. Nuevos campos calculados

Nombre atributo	Unidad	Descripción
subjID	Alfanumérico	Identificación de sujeto experimental
movement_duration	Decimal	Diferencia en tiempo entre la última y primera observación del trial
sensors_x_14	Decimal	Posición de la media de los 13 sensores en el eje X
sensors_y_14	Decimal	Posición de la media de los 13 sensores en el eje Y
sensors_z_14	Decimal	Posición de la media de los 13 sensores en el eje Z
dist_sensor_[1..14]	Decimal	Distancia recorrida para cada uno de los sensores durante el trial
avg_speed_s_[1..14]	Decimal	Velocidad promedio para cada sensor durante el trial
coef_[1..7]_sensor_[1..14]_x	Decimal	Coefficientes del polinomio con 5 nodos que representa la trayectoria proyectada en el eje X del trial

Continúa en la siguiente página

Nombre atributo	Unidad	Descripción
coef_[1..7]_sensor_[1..14]_y	Decimal	Coeficientes del polinomio con 5 nodos que representa la trayectoria proyectada en el eje Y del trial
coef_[1..7]_sensor_[1..14]_z	Decimal	Coeficientes del polinomio con 5 nodos que representa la trayectoria proyectada en el eje Z del trial
coef_[1..2]_sensor_nn_t	Decimal	Coeficientes de la recta que representa el tiempo del trial
priming motor	Entero	Unión de la vividness y congruencia donde el primer carácter es C o I seguido del score de vividness. Ej: C1, ... C4, I1 ... I4
priming motor binario	Entero	Reducción de priming motor que unifica vividness 1 y 2 bajo el carácter L y 3 y 4 bajo H. Los posibles valores son IH, IL, CH, CL
vividness_level	Entero	Unificación de los valores de vividness donde los valores Low y High se asignan a trials con scores de vividness 1 o 2 y 3 o 4 respectivamente

4.2. Análisis preliminar de los datos

4.2.1. Boxplot y violín de Priming Motor Binarío

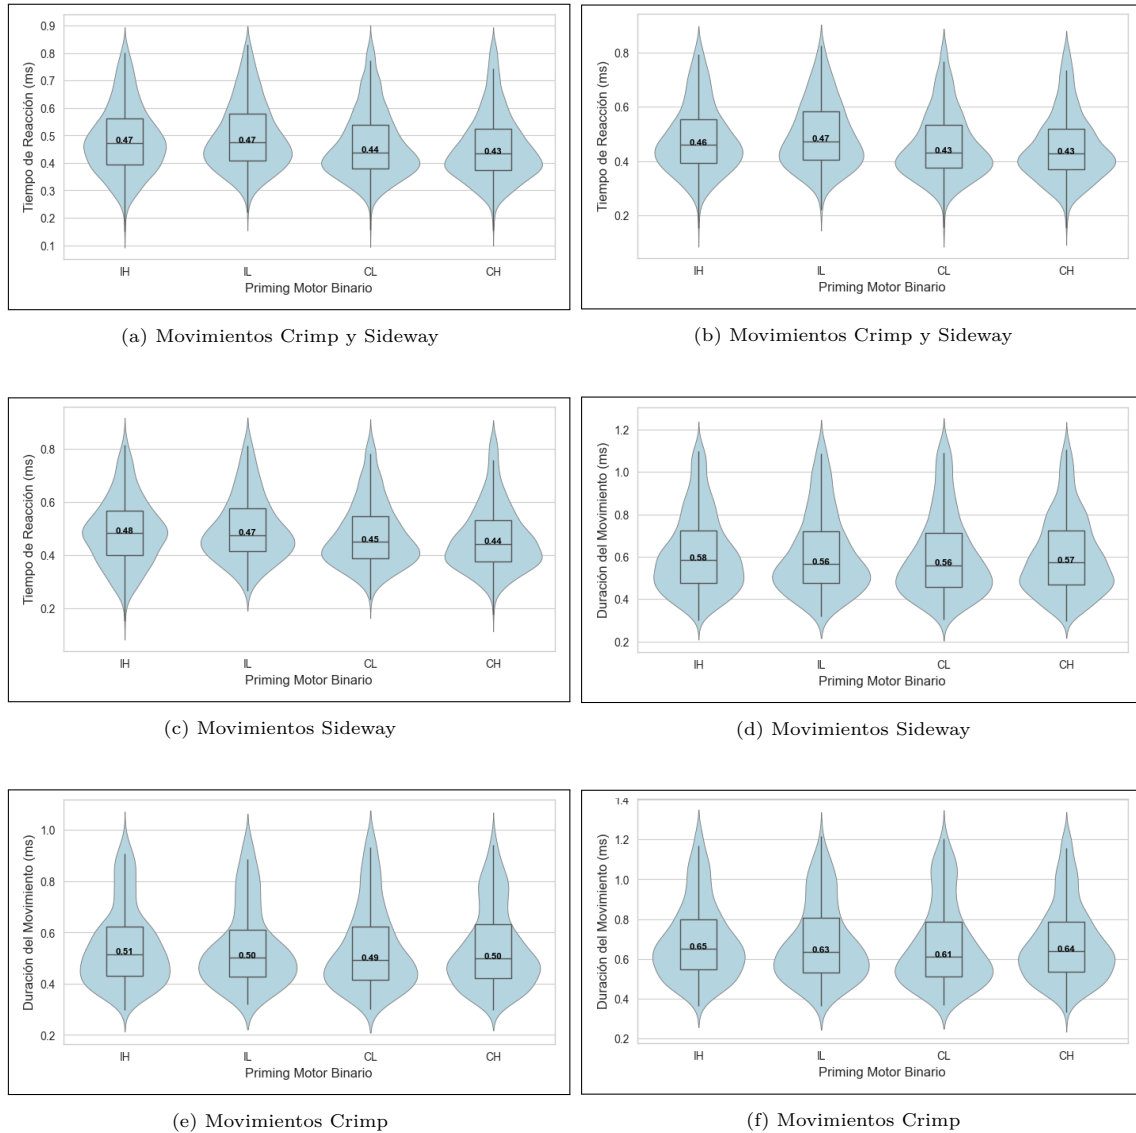


Figura 4.1: Boxplot y violín plot para el tiempo de reacción y duración del movimiento en función del Priming Motor Binario con el ordenamiento teórico desde una mayor interferencia en la imaginaria motora (i4) a una menor interferencia (c4)

4.2.2. Test de Dunn para Tiempo de reacción




Figura 4.2: Test de Dunn para Tiempo de reacción en Priming Motor

4.2.3. Análisis de Tiempo de Reacción y Duración del Movimiento

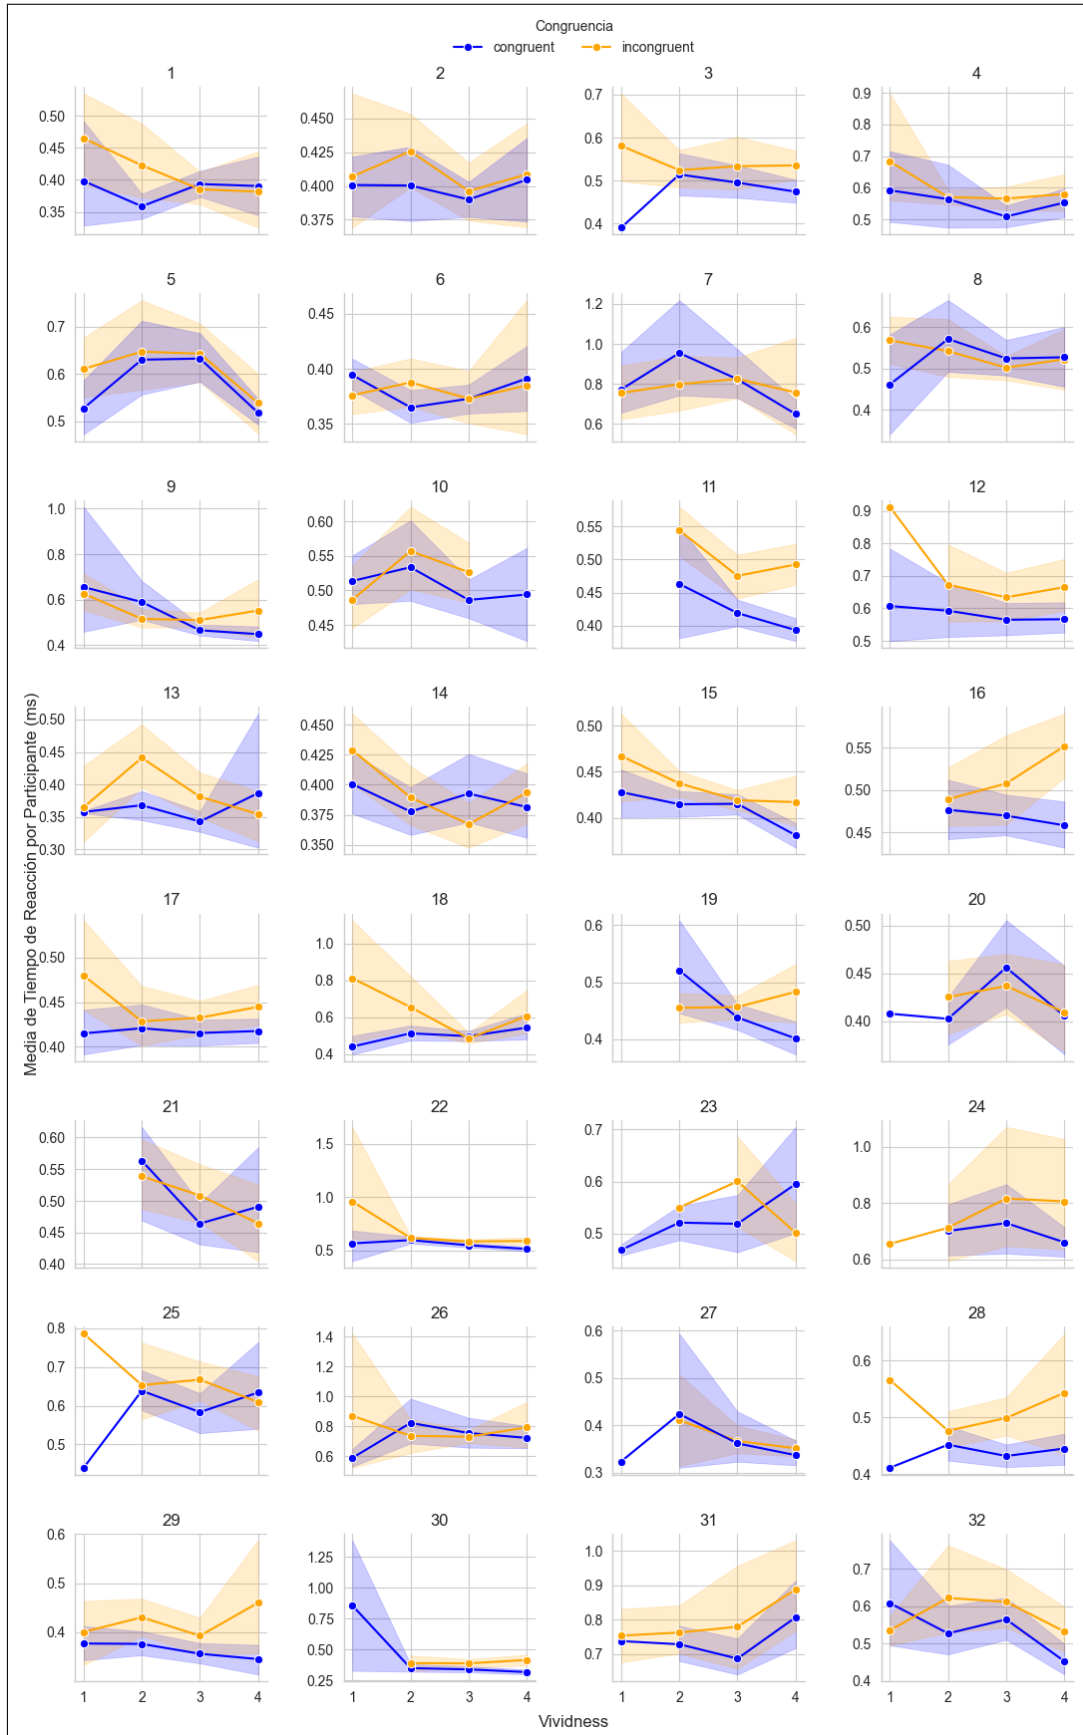


Figura 4.3: Representación de la media de los tiempos de reacción por participante con escala de eje Y ajustada individualmente para cada sujeto, diferenciada por nivel de vividez y congruencia.

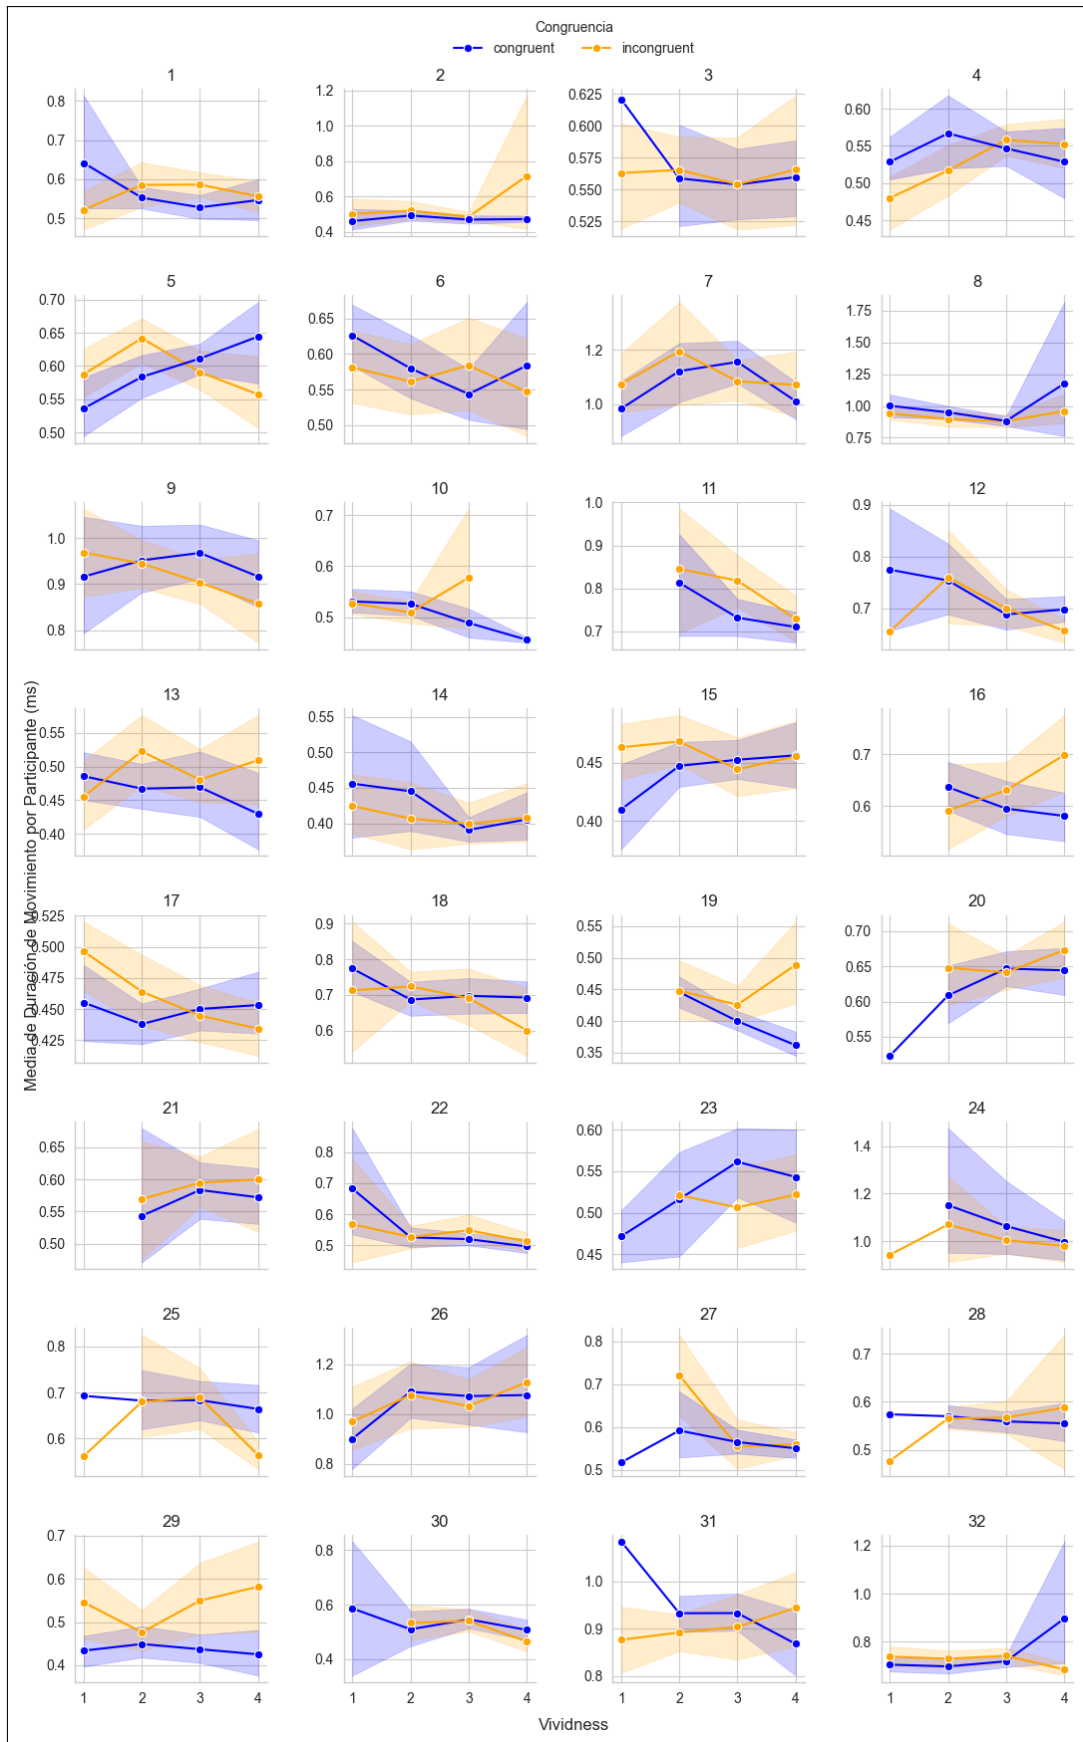


Figura 4.4: Representación de la media de la duración del movimiento por participante con escala de eje Y ajustada individualmente para cada sujeto, diferenciada por nivel de vividez y congruencia.

4.3. Modelos Lineales Mixtos

4.3.1. Estructura de los modelos LMM en R

```
modelo <- lmer( respuesta ~ predictores\_fijos +  
              (efectos\_aleatorios | agrupamiento), data = datos)
```

A continuación, se detalla cada parte de la fórmula: respuesta (y):

1. La variable dependiente o de respuesta que se modela. Es lo que se está tratando de predecir o explicar.
2. predictores_fijos (X):
3. Las variables independientes o explicativas (efectos fijos). Estas son las variables que se suponen tener efectos constantes a lo largo de todas las observaciones, como en un modelo lineal estándar. Ejemplo: X1 + X2 + X3.
4. (efectos_aleatorios | agrupamiento): Aquí se especifican los efectos aleatorios y el agrupamiento o factor por el cual se agrupan las observaciones.
 - efectos_aleatorios: Variables que se asumen tener efectos específicos para cada nivel de agrupamiento. Son aleatorios porque los efectos varían entre grupos o participantes.
 - agrupamiento: Factor que define cómo se agrupan los datos, como "individuos", "grupos" o "participantes". Por ejemplo, si las observaciones están agrupadas por "individuos", el agrupamiento sería el identificador de los individuos.
5. La notación efectos_aleatorios | agrupamiento indica que los efectos aleatorios están definidos a nivel del agrupamiento. Ejemplo: (1 | sujeto) indica un intercepto aleatorio para cada participante. Esto fue lo que nos dio mejores resultados.

4.3.2. Detalle de resultados de Modelos Lineales Mixtos

Cuadro 4.4: Resultados de los modelos lineales mixtos sobre tiempos de reacción

Modelo 1: Vividez como predictor					
Efecto	β	SE	gl	t	p
Intercepto	0.5264	0.0220	32.47	23.949	< ,001
Vividez alta (vs baja)	-0.0230	0.0050	4936	-4.638	< ,001

Modelo 2: Congruencia como predictor					
Efecto	β	SE	gl	t	p
Intercepto	0.5296	0.0219	32.00	24.194	< ,001
Congruente (vs incongruente)	-0.0309	0.0045	4923	-6.847	< ,001

Modelo 3: Interacción Vividez \times Congruencia					
Efecto	β	SE	gl	t	p
Intercepto	0.5189	0.0222	33.81	23.365	< ,001
Vividez alta	-0.0301	0.0063	4930	-4.807	< ,001
Incongruente	+0.0181	0.0076	4922	+2.390	.017
Vividez alta \times Incongruente	+0.0190	0.0094	4922	+2.015	.044

Modelo 4: Priming Motor Binario					
Efecto	β	SE	gl	t	p
Intercepto (CH)	0.4888	0.0219	32.02	22.309	< ,001
CL vs CH	+0.0301	0.0063	4930	+4.807	< ,001
IH vs CH	+0.0372	0.0056	4921	+6.643	< ,001
IL vs CH	+0.0483	0.0070	4928	+6.908	< ,001

4.3.3. Gráfica de Modelos Lineales Mixtos Desagregados

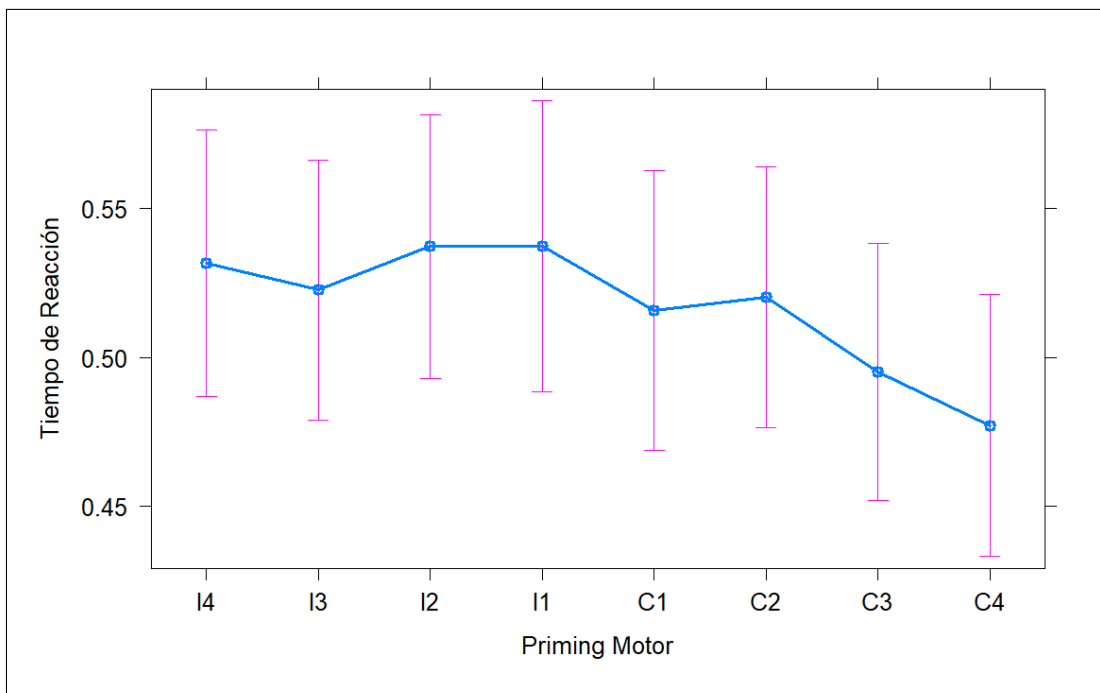


Figura 4.5: Priming motor en sus 8 categorías y ordenado según la interferencia esperada para la efectividad del movimiento de mayor a menor.




Figura 4.6: Priming motor en sus 8 categorías y ordenado según la interferencia esperada para la efectividad del movimiento *sideway* de mayor a menor.

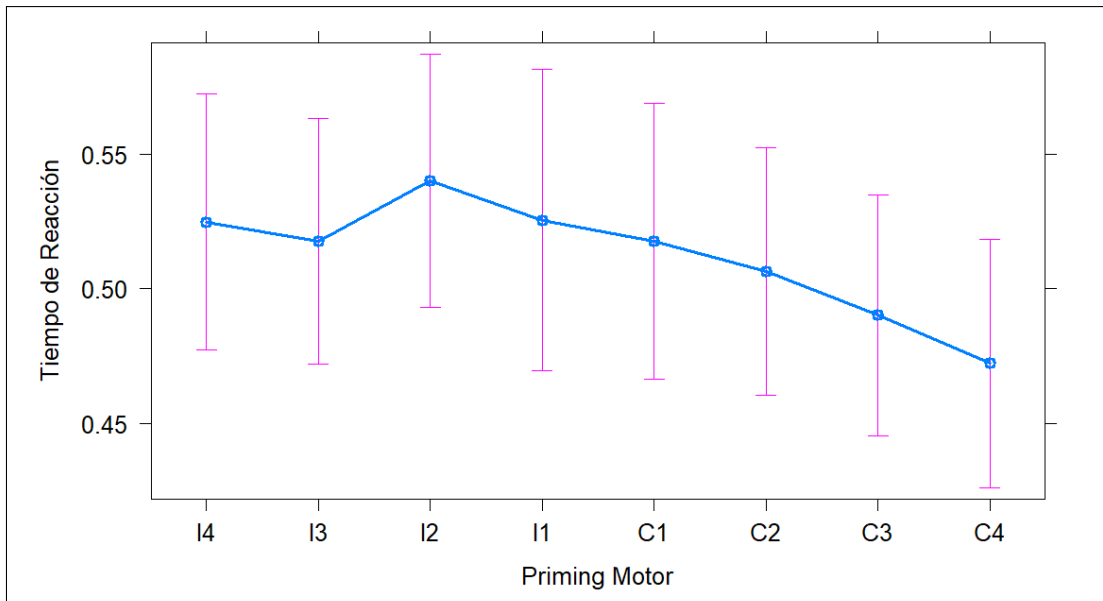




Figura 4.7: Priming motor en sus 8 categorías y ordenado según la interferencia esperada para la efectividad del movimiento *crimp* de mayor a menor.

4.4. Regresiones logísticas

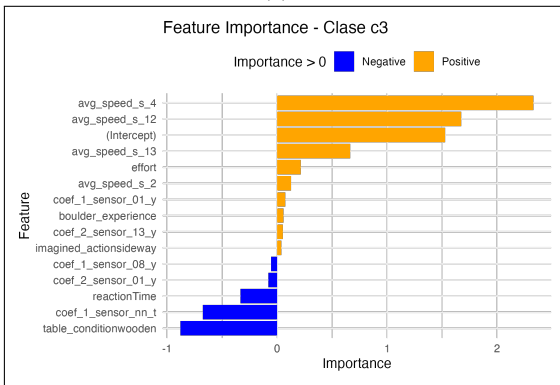
4.4.1. Importancia de características por Clase de Priming Motor




(a)




(b)



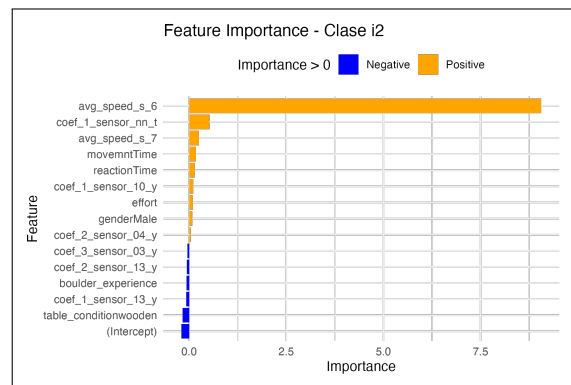
(c)



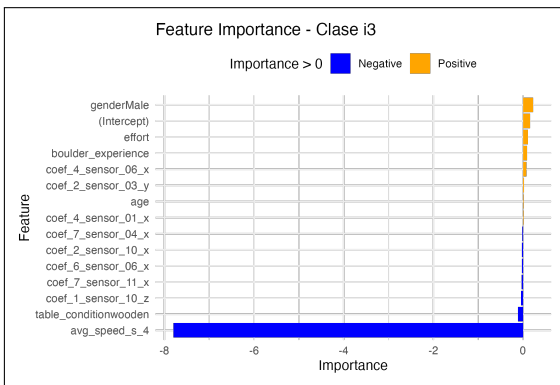
(d)



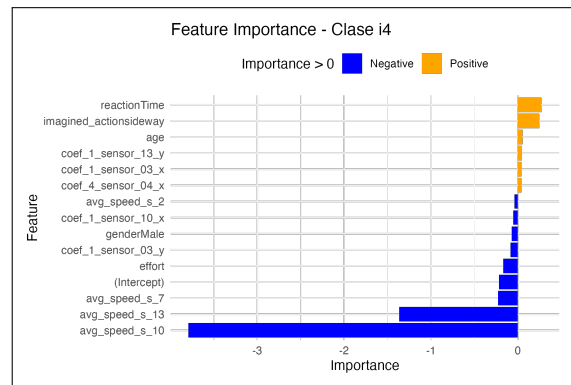
(e)



(f)



(g)



(h)

Figura 4.8: Importancia de características por Clase de Priming Motor.

4.5. Árboles de Decisión

4.5.1. Rango de búsqueda y valores finales de los hiperparámetros de LightGBM

El objetivo optimizado durante la búsqueda bayesiana fue un modelo de clasificación multiclase (`objective="multiclass"`), buscando minimizar la métrica de *multi logloss* en un esquema de validación cruzada estratificada. La tabla siguiente detalla los rangos definidos para cada hiperparámetro y el valor final seleccionado tras el proceso de optimización con Optuna.

Cuadro 4.5: Rangos de búsqueda y valores finales de los hiperparámetros optimizados

Hiperparámetro	Rango de búsqueda	Valor final seleccionado
<code>lambda_l1</code>	1×10^{-8} a 10 (log)	1.0768
<code>lambda_l2</code>	1×10^{-8} a 10 (log)	0.8733
<code>num_leaves</code>	2 a 256	52
<code>feature_fraction</code>	0.4 a 1.0	0.5733
<code>bagging_fraction</code>	0.4 a 1.0	0.8104
<code>bagging_freq</code>	1 a 7	6
<code>min_child_samples</code>	5 a 100	91
<code>learning_rate</code>	0.005 a 0.3 (log)	0.0233
<code>max_depth</code>	3 a 20	20

Bibliografía

- [Bengio et al., 2013] Bengio, Y., Courville, A., and Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8):1798–1828.
- [Bläsing et al., 2014] Bläsing, B., Tenenbaum, G., and Schack, T. (2014). The cognitive structure of movements in traditional climbing and its implications for action representation. *Cognitive Processing*, 15(3):329–342.
- [Cohen et al., 2017] Cohen, M. X., Elger, C. E., and Fell, J. (2017). Oscillatory brain activity and the mechanisms of working memory. *Trends in Cognitive Sciences*, 15(2):50–60.
- [Conover, 1999] Conover, W. J. (1999). *Practical Nonparametric Statistics*. Wiley-Interscience, 3rd edition.
- [De Boor, 2001] De Boor, C. (2001). *A Practical Guide to Splines*. Springer-Verlag, revised edition edition.
- [Decety, 1996] Decety, J. (1996). Do imagined and executed actions share the same neural substrate? *Cognitive Brain Research*, 3(2):87–93.
- [Decety and Grezes, 2006] Decety, J. and Grezes, J. (2006). The power of simulation: Imagining one’s own and other’s behavior. *Brain Research*, 1079(1):4–14.
- [Di Palma et al., 2022] Di Palma, M., Carioti, D., Arcangeli, E., Rosazza, C., Ambrogini, P., Cuppini, R., Minelli, A., and Berlinger, M. (2022). The biased hand. mouse-tracking metrics to examine the conflict processing in a race-implicit association test. *PLOS ONE*, 17(7):e0271748.
- [Dijkstra et al., 2019] Dijkstra, N., Hinne, M., Bosch, S. E., and van Gerven, M. A. J. (2019). Between-subject variability in the influence of mental imagery on conscious perception. *Scientific Reports*, 9:15658.
- [Domingos, 2012] Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10):78–87.
- [Draper and Smith, 1998] Draper, N. R. and Smith, H. (1998). *Applied Regression Analysis*. Wiley, 3rd edition.

- [Dunn, 1961] Dunn, O. J. (1961). Multiple comparisons among means. *Journal of the American Statistical Association*, 56(293):52–64.
- [Eilers and Marx, 1996] Eilers, P. H. C. and Marx, B. D. (1996). Flexible smoothing with b-splines and penalties. *Statistical Science*, 11(2):89–121.
- [Faivre et al., 2021] Faivre, N., Roger, M., Pereira, M., de Gardelle, V., Vergnaud, J.-C., Passerieux, C., and Roux, P. (2021). Confidence in visual motion discrimination is preserved in individuals with schizophrenia. *Journal of Psychiatry and Neuroscience*, 46(1):E65–E73.
- [Faraway, 2016] Faraway, J. J. (2016). *Extending the Linear Model with R: Generalized Linear, Mixed Effects and Nonparametric Regression Models*. Chapman and Hall/CRC, Boca Raton, FL, second edition.
- [Fitzmaurice et al., 2012] Fitzmaurice, G. M., Laird, N. M., and Ware, J. H. (2012). *Applied Longitudinal Analysis*. John Wiley & Sons.
- [Fleming and Dolan, 2012] Fleming, S. M. and Dolan, R. J. (2012). The neural basis of metacognitive ability. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 367(1594):1338–1349.
- [Gentsch et al., 2015] Gentsch, A., Schütz-Bosbach, S., and Synofzik, M. (2015). Mechanisms of motor action monitoring: Shared representations of motor prediction and sensory input. *Cerebral Cortex*, 25(9):3144–3153.
- [Grezes and Decety, 2001] Grezes, J. and Decety, J. (2001). Functional anatomy of execution, mental simulation, observation, and verb generation of actions: A meta-analysis. *Human Brain Mapping*, 12(1):1–19.
- [Guillot and Collet, 2005] Guillot, A. and Collet, C. (2005). Duration of mentally simulated movement: A review. *Journal of Motor Behavior*, 37(1):10–20.
- [Guyon and Elisseeff, 2003] Guyon, I. and Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3:1157–1182.
- [Hardwick et al., 2018] Hardwick, R. M., Caspers, S., Eickhoff, S. B., and Swinnen, S. P. (2018). Neural correlates of motor imagery, action observation, and movement execution: A comparison across quantitative meta-analyses. *Neuroscience & Biobehavioral Reviews*, 94:31–44.

- [Hastie et al., 2009] Hastie, T., Tibshirani, R., and Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, 2nd edition.
- [Hoffmann, 2022] Hoffmann, K. C. (2022). Metacognition of motor imagery. Master’s thesis, Maastricht University. Retrieved from MetaMotor Lab, Berlin, Germany.
- [Hosmer et al., 2013] Hosmer, D. W., Lemeshow, S., and Sturdivant, R. X. (2013). *Applied Logistic Regression*. Wiley, 3rd edition.
- [Hétu et al., 2013] Hétu, S., Gregoire, M., Saimpont, A., Coll, M. P., Eugene, F., Michon, P. E., and Jackson, P. L. (2013). The neural network of motor imagery: An ale meta-analysis. *Neuroscience & Biobehavioral Reviews*, 37(5):930–949.
- [Kilintari et al., 2016] Kilintari, M., Raos, V., and Savaki, H. E. (2016). Involvement of the superior parietal lobule in action execution and imagery: An fmri study. *Cerebral Cortex*, 25(9):3144–3153.
- [Koß and Filevich, 2020] Koß, C. and Filevich, E. (2020). Metacognition of movement imagination. Master Thesis, Technische Universität Berlin & Humboldt-Universität zu Berlin. Tesis no disponible en línea.
- [Lorey et al., 2013] Lorey, B., Bischoff, M., Pilgramm, S., Stark, R., Munzert, J., and Zentgraf, K. (2013). The embodied nature of motor imagery: The influence of posture and perspective. *Experimental Brain Research*, 229(3):301–311.
- [Lotze and Halsband, 2006] Lotze, M. and Halsband, U. (2006). Motor imagery. *Journal of Physiology-Paris*, 99(4–6):386–395.
- [Malouin et al., 2007] Malouin, F., Richards, C. L., Jackson, P. L., Lafleur, M. F., Durand, A., and Doyon, J. (2007). The kinesthetic and visual imagery questionnaire (kviq) for assessing motor imagery in persons with physical disabilities: A reliability and construct validity study. *Journal of Neurologic Physical Therapy*, 31(1):20–29.
- [Markey, 2022] Markey, D. (2022). Climbing moves, holds, & technique: The beginner’s guide. *Blog post*. Retrieved from <https://www.99boulders.com/climbing-moves-holds-and-technique>.
- [Metcalf and Shimamura, 1994] Metcalfe, J. and Shimamura, A. P. (1994). *Metacognition: Knowing about Knowing*. MIT Press.
- [Oldfield, 1971] Oldfield, R. C. (1971). The assessment and analysis of handedness: The edinburgh inventory. *Neuropsychologia*, 9(1):97–113.

- [Pearson and Logie, 2015] Pearson, D. G. and Logie, R. H. (2015). The impact of task on storage and processing: Evidence from the visual patterns test. *Quarterly Journal of Experimental Psychology*, 68(10):1945–1956.
- [Pearson et al., 2008] Pearson, J., Clifford, C. W., and Tong, F. (2008). The functional impact of mental imagery on conscious perception. *Current Biology*, 18(13):982–986.
- [Pearson et al., 2011] Pearson, J., Rademaker, R. L., and Tong, F. (2011). Evaluating the mind’s eye: The metacognition of visual imagery. *Psychological Science*, 22(12):1535–1542.
- [Pinheiro-Chagas et al., 2017] Pinheiro-Chagas, P., Dotan, D., Piazza, M., and Dehaene, S. (2017). Finger tracking reveals the covert stages of mental arithmetic. *Open Mind*, 1(1):30–41.
- [Solodkin et al., 2004] Solodkin, A., Hlustik, P., Chen, E. E., and Small, S. L. (2004). Fine modulation in network activation during motor execution and motor imagery. *Cerebral Cortex*, 14(11):1246–1255.
- [Tibshirani, 1996] Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1):267–288.
- [Voss et al., 2019] Voss, M., Chambon, V., Wenke, D., Kühn, S., and Haggard, P. (2019). In and out of control: Brain mechanisms linking self- and social-agency. *Trends in Cognitive Sciences*, 17(6):304–313.
- [Wang et al., 2014] Wang, S., Mellet, E., and Tzourio-Mazoyer, N. (2014). Neural bases of motor imagery of finger movements: An fmri study. *Human Brain Mapping*, 35(1):117–127.
- [West et al., 2014] West, B. T., Welch, K. B., and Galecki, A. T. (2014). *Linear Mixed Models: A Practical Guide Using Statistical Software*. CRC Press.