

Universidad de las Américas Puebla

FACULTAD DE INGENIERÍA

DEPARTAMENTO DE COMPUTACIÓN, ELECTRÓNICA Y MECATRÓNICA

DOCTORADO EN SISTEMAS INTELIGENTES

UDLAP®

Modelado no lineal de la actividad cerebral relacionada con tareas motrices

Disertación de Tesis para obtener el grado de Doctor en Sistemas Inteligentes

Autores:

M.C. Martín Durán Santos

Dra. Rocío Salazar Varas (Advisor)

Dr. Gibran Etcheverry D. (External Advisor)

Santa Catarina Mártir, San Andrés Cholula, Puebla

23 de junio de 2024

Resumen

A pesar de los numerosos estudios sobre la actividad cerebral en tareas de control mecánico, se ha investigado poco cuando fuerzas externas perturban las extremidades superiores, lo que indica un conocimiento limitado de las vías fisiológicas implicadas en el proceso. Para evaluar la alteración de la actividad cerebral en personas con deficiencias motoras, es crucial examinar y analizar primero la actividad cerebral de personas sanas.

Por lo tanto, el objetivo subyacente de esta tesis es modelar la actividad general de la respuesta cerebral provocada por la manipulación mecánica de la muñeca en personas sanas y jóvenes. Para ello, se utiliza una base de datos pública de la Universidad Tecnológica de Delft (Países Bajos). En el experimento, un sistema robótico provoca un movimiento mecánico de la muñeca, y la respuesta cerebral correspondiente se registra mediante electroencefalograma.

Además, en esta tesis se desarrolla un manipulador robótico de bajo coste para provocar los mismos perfiles específicos de movimiento de la muñeca a partir de la base de datos de la TU DELFT. Para ambas configuraciones experimentales, la respuesta cortical (es decir, la fuente de movimiento) se identifica mediante el Análisis de Componentes Independientes y se estima basándose en un modelo embebido diferencial de retardo no lineal. Para validar el modelo propuesto, se realiza un análisis de validación cruzada y se compara con el conjunto de datos público de la Universidad Tecnológica DELFT, alcanzando un 90.55% de varianza contabilizada y una correlación del 95.01%.

Las contribuciones de esta tesis pueden dividirse en tres grupos: La primera contribución tiene en cuenta el marco matemático, que puede separarse en tres subgrupos principales: (1) el modelo matemático propuesto basado en el embebido diferencial de retardo no lineal puede estimar la respuesta cerebral causada por la manipulación específica de la muñeca, (2) el enfoque propuesto basado en los perfiles de correlación (entre la respuesta cerebral registrada y modelada) explica visualmente la base algebraica de la respuesta cortical causada por la manipulación de la muñeca, (3) y finalmente el modo de operación predominante general refleja la respuesta generalizada del cerebro.

La segunda contribución se refiere a la interpretación fisiológica, es decir, los resultados experimentales muestran que la aceleración del movimiento afecta a la respuesta cortical, y los retardos temporales del modelo propuesto reflejan vías específicas de la respuesta cerebral. Por tanto, existe una actividad retardada común en el tiempo a todos los sujetos.

Por último, la tercera contribución trata del equipo necesario para esta tesis. Para provocar la manipulación de la muñeca, se construyó un sistema robótico utilizando tecnologías de diseño asistido por ordenador e impresión en 3D. Para medir la actividad cerebral, un montaje reducido de 8 canales de EEG ayuda a construir un sistema menos complejo y, por tanto, más rápido en el procesamiento de datos que metodologías anteriores. Este enfoque permite la construcción de un nuevo conjunto de datos de señales cerebrales de participantes mexicanos, permitiendo así la validación de nuevos modelos.

Agradecimientos

A Dios por darme la vida para poder llevar a cabo este proyecto de investigación.

A mi familia por todo el apoyo brindado.

A CONACYT por el apoyo económico brindado durante mi formación profesional.

A la Universidad de las Américas Puebla (UDLAP) por aceptarme y por permitirme aprovechar las ventajas de formar parte de la comunidad universitaria.

Quiero agradecer a mis asesores de tesis por su tiempo, experiencia y apoyo.

A los miembros del jurado de revisión por sus ideas y por hacer posible la redacción de una tesis más sólida.

Índice general

1. Introducción	10
1.1. Motivación	11
1.2. Trabajo relacionado	12
1.3. Objetivo de la Tesis	13
1.4. Hipótesis	14
1.5. Contribuciones	14
1.6. Publicaciones	15
1.7. Esquema general de la tesis	16
2. Marco teórico	17
2.1. Sistema motor-sensorial	17
2.2. Efectos de retardo en el sistema sensoriomotor	19
2.3. Model embebido diferencial con retardos temporales	20
2.4. Análisis de Componentes Independientes (ICA)	20
3. Modelado de la respuesta cortical causada por perturbaciones de la articulación de la muñeca a través de un embebido no lineal diferencial con retardo temporal	22
3.1. Materiales y métodos	22
3.1.1. Base de datos pública	22
3.1.2. Replicación del protocolo de adquisición	23
3.1.3. Implementación de un sistema robótico	24
3.1.4. Canales EEG	26
3.1.5. Descripción del software	27
3.1.6. Métodos	27
3.1.7. Marco matemático	32
3.2. Resultados	33
3.2.1. Topología de la respuesta cortical	34
3.2.2. Establecer el grado de modelo	34
3.2.3. Mejores retrasos temporales del modelo	35
3.2.4. Validación del modelo	36
3.3. Discusión	36
3.3.1. Análisis de la respuesta cortical modelada	37
3.3.2. Modo de funcionamiento predominante general y base algebraica	37
3.3.3. Contribución de los poderes par e impar de la realización a la respuesta cortical	40
3.3.4. Interpretación fisiológica	41

4. Estimación proporcional de la fatiga muscular durante la flexión isométrica de la muñeca mediante electromiografía de superficie	43
4.1. Introducción	43
4.2. Materiales	44
4.2.1. Experimental Setup	44
4.2.2. Protocolo Experimental	44
4.3. Métodos	46
4.3.1. Inicio (Paso A)	46
4.3.2. Segmentación de la señal (Paso B)	46
4.3.3. Remuestreo (Paso C)	46
4.3.4. Extracción de características (Paso D)	47
4.3.5. Optimización (Paso E)	50
4.3.6. Modelo de Fatiga	51
4.3.7. Nivel de fatiga	51
4.3.8. Validación (Paso F)	52
4.4. Resultados	52
4.4.1. Optimización de ventanas	53
4.4.2. Selección de características	53
4.4.3. Validación del modelo	55
4.5. Discusión	57
4.5.1. Tiempo al fallo muscular	57
4.5.2. Rendimiento del modelo propuesto	57
4.5.3. Exploración individual de potenciales biomarcadores	57
4.6. Observaciones finales	60

Índice de figuras

1.0.1 Campos de conocimiento relacionados en el estudio de la actividad cerebral.	10
2.1.1 Fibras del huso muscular (modificadas de Knierim (2020)).	18
2.1.2 Esquema del sistema motor-sensorial. Imagen extraída de Vlaar (2017).	18
2.2.1 Consideración de los retrasos temporales en el sistema motor-sensorial.	19
2.4.1 Etapa de respuesta cortical mediante análisis de componentes independientes. Imagen tomada de Vliet et al. (2016)	21
3.1.1 Imagen tomada de la referencia "Cortical responses evoked by wrist joint manipulation" (Vlaar et al., 2018) and (Vlaar et al., 2017).	23
3.1.2A: Posición inicial del montaje experimental. B: Electrodo para medir la actividad cerebral. C: Mano derecha sujetando la articulación robótica para provocar perfiles específicos de movimiento de la muñeca. D: Interfaz EEG utilizando el software OPENBCI GUIv5.1.0.	24
3.1.3 Un experimento consta de 49 pruebas, lo que lleva a 1470s, o 210s por realización.	25
3.1.4 Diagrama de bloques del sistema de control en lazo cerrado.	25
3.1.5A: Diseño asistido por computadora. B: Montaje mecánico del sistema robótico.	26
3.1.6 Siete movimientos específicos para provocar la perturbación de la muñeca a partir de nuestro sistema robótico (negro) y del conjunto de datos NL_TU_DELFT_DB (azul).	26
3.1.7 Distribución de electrodos en el dispositivo OpenBCI.	27
3.1.8A: Esquema general de la metodología para identificar la respuesta cortical causada por perturbaciones externas. B: Estimación de los mejores tiempos de retardo. C: Secuencia del modelo matemático desde la perturbación (entrada) hasta la respuesta cortical (salida) y descomposición de la matriz base a través del análisis de componentes principales (PCA).	28
3.1.9 Impacto de la variación de las frecuencias de muestreo en el rendimiento de un modelo de 10° grado.	29
3.2.1 Topología de la respuesta cortical para diez sujetos y primera realización M0, para (A) Base de datos NL_TU_DELFT_DB, y (B) Base de datos MX_UDLAP_DB.	34
3.2.2 Izquierda: VAF Vs Grado del modelo. Derecha: Número de parámetros en función del grado del modelo, realización M=1.	35
3.2.3 Exploración (izquierda) y explotación (derecha) para encontrar los mejores retardos del modelo propuesto.	35
3.3.1 La respuesta cortical esperada (azul) y estimada (naranja) corresponden a la primera prueba de validación cruzada sin el filtro SavGol (gráfico superior) y después del filtro (gráfico inferior) cuando se aplica la realización M1.	37
3.3.2 Modo de funcionamiento predominante o respuesta al impulso (izquierda), y perfil de correlación (derecha) para la realización M0.	38

3.3.3	Dominio en frecuencia de los biomarcadores potenciales.	39
3.3.4	Comparación del rendimiento de los modelos al incluir (<i>_Acc</i>) o no (<i>_Not_Acc</i>) la aceleración angular: Correlación (izquierda) y VAF (derecha).	40
3.3.5	Promedio de V^T para potencias pares de entrada (izquierda). Promedio de V^T para potencias impares de entrada (derecha).	40
4.2.1	Esquema del montaje experimental para realizar la contracción isométrica y registrar la actividad muscular.	45
4.3.1	Metodología principal dividida en seis pasos: (A) Inicio; (B) Segmentación de la señal; (C) Remuestreo; (D) Extracción de características; (E) Entrenamiento del modelo, y (F) Validación del modelo.	46
4.4.1	Proceso de selección de características.	54
4.4.2	Nivel de fatiga estimado para diez participantes involucrados en el experimento.	55
4.5.1	Características individuales extraídas del extensor (ex) y el flexor (fl) al principio (0%) y al final (100%) de la tarea de contracción muscular. Estas características se normalizaron de cero a uno. Se seleccionan los sujetos P1 y P9, ya que su modelo de fatiga correspondiente tiene el peor y el mejor rendimiento, respectivamente. Las características para (CONE 1) son 4:22, (CONE 2) son 4:13, y (CONE 3) son 1:13.	59

Índice de tablas

3.2.1	Resultados de la validación del modelo	36
3.3.1	Contribución acumulativa de los términos con más energía del movimiento inducido (bases unitarias) a la respuesta cerebral generalizada	38
3.3.2	Valores medios de las 70 matrices (todos los sujetos y todas las realizaciones) de las bases unitarias pares e impares más relevantes que contribuyen relativamente a la respuesta cortical.	41
4.3.1	Características extraídas de la señal sEMG.	48
4.3.2	Características extraídas de la señal sEMG (cont).	49
4.3.3	Características extraídas de la señal sEMG (cont).	50
4.3.4	Parámetros de ventana para encontrar los valores óptimos.	50
4.3.5	Métricas de rendimiento.	52
4.4.1	Tiempo hasta el fallo de la tarea.	53
4.4.2	Las mejores características se encontraron en la configuración 2 (a partir de la señal de fuerza y el canal EMG1 <i>FL</i>), y en la configuración 3 (a partir del canal EMG2 <i>EX</i>).	54
4.4.3	Desempeño del modelo: Partición 1: Rep2-entrenar, Rep3-validar. Partición 2: Rep3-entrenar, Rep2-validar.	56
4.5.1	Trabajos relacionados con la estimación de la fatiga en miembros superiores durante contracciones isométricas mediante sEMG.	58
4.6.1	Sistema de identificación de sistemas neuronales a partir de señales neurofisiológicas	62
4.6.2	Trabajo Relacionado	62

Abreviaturas y acrónimos

AR	Autoregresivo
ARX	Autoregresivo con Entrada Exógena
EEG	Electroencefalograma
FRF	Función de Respuesta en Frecuencia
GFRF	Función de Respuesta en Frecuencia Generalizada
ICA	Análisis de Componentes Independientes
LLNF	Neuro-Difuso Localmente Lineal
NARX	Autoregresivo no lineal con entrada exógena.
NARMAX	Media Móvil Autoregresiva No Lineal con Entrada Exógena
NSR	Relación Ruido a Señal
OE	Error de Salida
OFRF	Función de Respuesta en Frecuencia de Salida
PCA	Análisis de Componentes Principales
SNR	Relación Señal a Ruido
SVD	Descomposición en Valores Singulares
TV-GFRF	Función de la Respuesta en Frecuencia Generalizada Variable en el Tiempo
TV-NARX	Autoregresivo No Lineal con Entrada Exógena Variable en el Tiempo
TV-NARMAX	Media Móvil Autoregresiva No Lineal con Entrada Exógena Variable en el Tiempo
TV-OFRF	Función de Respuesta en Frecuencia de Salida Variable en el Tiempo

Notación

∂	Derivada parcial
$\frac{d}{dn}$	Primera derivada
$\frac{d^2}{dn^2}$	Segunda derivada
$\mathbf{u}(n)$	Entrada (perfil de movimiento)
$\hat{\mathbf{y}}(n)$	Salida estimada (respuesta cortical modelada)
$\mathbf{y}(n)$	Salida real (respuesta cortical registrada)
$\tilde{\mathbf{y}}$	Señal de error
\mathbf{X}	Matriz
\mathbf{X}^T	Matriz transpuesta
Σ	Matriz de valores propios

Capítulo 1

Introducción

Las funciones del cerebro humano y cómo se comunican las neuronas entre sí son las principales preguntas sobre este órgano. Responderlas ayudará a comprender mejor su organización para mejorar el diagnóstico y el tratamiento de las enfermedades cerebrales. En este sentido, los nuevos métodos para el diagnóstico de enfermedades cerebrales que utilizan Machine Learning son prometedores. Sin embargo, aplicar únicamente métodos de Machine Learning podría no ser suficiente. Por ello, diferentes campos del conocimiento, como el procesamiento de señales, la fisiología o la modelización matemática, podrían contribuir a resolver los retos actuales en el diagnóstico de enfermedades cerebrales. A continuación se mencionan algunos ejemplos.

- Un modelo matemático es un enfoque más estricto para representar el sistema nervioso,
- Un subcampo de la fisiología estudia las funciones y mecanismos del cerebro humano,
- El procesamiento digital de señales mejora la calidad de la señal,
- Una red neuronal artificial se puede establecer en la etapa de identificación del sistema.

Este punto de vista multidisciplinar es necesario para comprender sistemas complejos como el cerebro humano. Por ejemplo, la Fig. 1.0.1 muestra los campos de conocimiento relacionados con la respuesta de la actividad cerebral debida a la entrada sensorial, teniendo en cuenta los modelos matemáticos, el procesamiento de señales, el aprendizaje automático y la fisiología del cerebro humano.

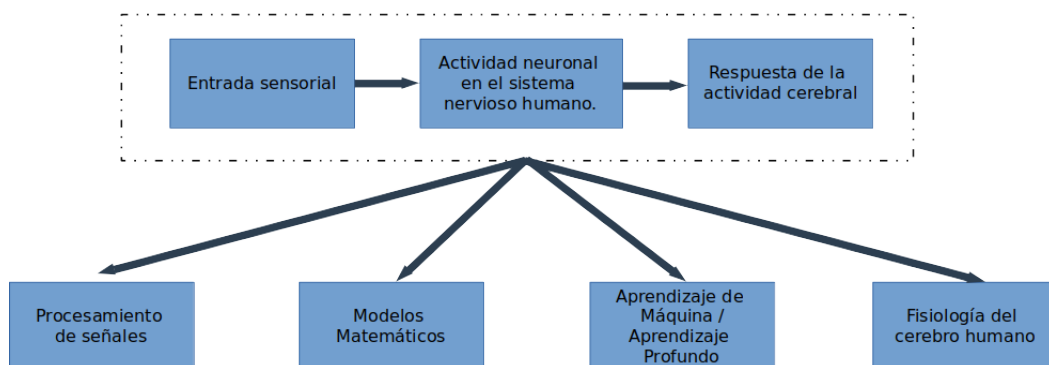


Figura 1.0.1: Campos de conocimiento relacionados en el estudio de la actividad cerebral.

1.1. Motivación

El modelado de la respuesta cerebral a tareas motoras ha sido ampliamente estudiado para diferentes condiciones como el control del movimiento (Bullock, 2001), (Úbeda et al., 2015), (Yoshimura et al., 2017), (Zhu et al., 2022), clasificación de tareas motoras (Kulkarni et al., 2022), (Wang et al., 2023), y movimientos secuenciales (Hervault et al., 2021), (Ohbayashi, 2021), (Li et al., 2023). Estos trabajos se centran en el movimiento voluntario del sujeto, sin embargo, la actividad cerebral puede ser modificada involuntariamente por algunas perturbaciones procedentes del entorno. En consecuencia, aunque existen varios estudios sobre la actividad cerebral relacionada con las tareas de control motor, el análisis cuando las extremidades son manipuladas externamente no ha sido explorado en profundidad.

Considerando las actividades motoras, en el cerebro intervienen procesos eferentes y aferentes. El eferente es un proceso de control, en el que la señal de acción del movimiento se origina en el cerebro y desciende a las extremidades a través de la médula espinal. El proceso aferente tiene un camino ascendente, donde los movimientos externos perturban las extremidades, entonces, esta información asciende al cerebro para ser procesada.

Desafortunadamente, las personas con deficiencias motoras tienen dificultades para realizar estos procesos, por lo que experimentan desde sutiles problemas y debilidades en los movimientos musculares hasta la pérdida total de las funciones motoras (van den Bos et al., 2019), disminuyendo su autonomía y bienestar. Apoyarlos ayudaría a frenar el deterioro, mejorar algunas funciones motoras y aumentar su calidad de vida.

Esta tesis pretende modelar la respuesta general de la actividad cerebral causada a la manipulación externa en las extremidades superiores, concretamente en la muñeca. Los métodos actuales que modelan la respuesta cortical debida a la manipulación de la muñeca no explican completamente la variabilidad de la señal (Gu et al., 2021). Aspectos como la memoria, los periodos de sincronía o las áreas cerebrales implicadas en las tareas motoras aún no se conocen bien. Identificar un modelo más preciso contribuirá a tener un conocimiento más preciso sobre el fenómeno en cuestión.

Para mejorar la precisión del modelado de la respuesta cortical debida a las manipulaciones de la muñeca, y la mejor comprensión de los fenómenos fisiológicos implicados, la solución propuesta se basa en un modelo embebido diferencial de retardo no lineal. Los modelos basados en ecuaciones diferenciales de retardo se han utilizado para distinguir a los pacientes con enfermedad de Parkinson de los individuos sanos y sugiere que los retardos temporales son importantes para detectar alteraciones motoras (Lainscsek et al., 2013).

1.2. Trabajo relacionado

Un trabajo que pretende encontrar una correlación entre la actividad de la región cortical y las tareas motoras es el de Yang et al. (2016). Provocaron la flexión de la muñeca de sujetos diestros que modificaron la longitud de estos músculos (contracciones isotónicas). Cuando midieron la actividad cortical, encontraron que se activaban 4 áreas del cerebro: áreas moto-sensoriales primarias, áreas prefrontales, áreas motoras suplementarias y corteza parietal posterior.

En 2016, Yang et al. (2016) no utilizó un modelo específico para explicar la actividad cortical. En su lugar, propusieron un método de coherencia N:M, que explica la correlación lineal y no lineal de la perturbación de la muñeca y los componentes independientes de las cuatro regiones antes mencionadas. Descubrieron que el acoplamiento lineal aparece en la banda beta de 15 a 35 Hz. Además, explican que existe un acoplamiento no lineal tanto para armónicos enteros como no enteros. Sin embargo, la respuesta cerebral tiene más armónicos que aún no se explican y su fuente de generación no se conoce bien.

Se han publicado cinco trabajos principales relacionados con el modelado no lineal de la actividad cerebral debida a la manipulación de la muñeca (Gu et al., 2021), (Tian et al., 2018), (Vlaar et al., 2018), (Pont, 2020), y (Nozari et al., 2020). Tian et al. (2018) y Vlaar et al. (2018) presentaron un modelo de series NARMAX y un modelo de series Volterra truncado, respectivamente. Los modelos pueden explicar sólo el 69% y el 46% de la varianza de la actividad cerebral, respectivamente. Una comparación de estos dos métodos fue realizada por Pont (2020). Su trabajo consistió en la identificación de un sistema no lineal de respuestas corticales utilizando la serie de Volterra. Argumentó que los métodos convencionales aplicados por Tian et al. (2018) y Vlaar et al. (2018), no incluían un nivel de incertidumbre de los parámetros involucrados, lo que podría mejorar el método de evaluación del modelo. A pesar del uso de la Inferencia Bayesiana y de las series de Volterra, los resultados de este trabajo fueron inestables debido a que la matriz de Volterra de segundo grado estaba cerca de ser singular.

Otros dos trabajos relacionados aparecen en (Nozari et al., 2020) y (Gu et al., 2021). En el primer trabajo, Nozari et al. (2020) utiliza una estrategia basada en redes Localmente Lineales Neuro-Difusas (LLNF), donde los modelos se calculan utilizando AutoRegresivo local con entradas eXógenas (ARX), Media Móvil AutoRegresiva con entradas eXógenas (ARMAX), Error de Salida (OE), y estructuras de Volterra. En este modelo, se crea una base que tiene una entrada y una salida retardadas con límites de desfase temporal (ν_u y ν_y), respectivamente. En este trabajo, el número de parámetros no es consistente a lo largo de todas las entradas o salidas, ya que depende de la estructura del modelo y de los valores de desfase ν_u y ν_y , lo que es opuesto a nuestro trabajo en el que el número de parámetros es fijo, de acuerdo con el grado del modelo.

Otro enfoque es el uso del modelo de red neuronal de retardo temporal (TDNN) (Trivedi and Rawat, 2022). Se observa que, en comparación con el sistema Volterra con optimización de enjambre de partículas (PSO), el modelo matemático TDNN tiene más parámetros ajustables y requiere menos tiempo de cálculo. Como este enfoque es un modelo basado en redes neuronales, tiene las limitaciones de la caja negra, por lo tanto, información fisiológica limitada se puede extraer de este modelo.

El trabajo más reciente fue publicado por Gu et al. (2021), donde identificaron una estructura de modelo común para personas sanas y jóvenes mediante el método NARMAX. Descu-

brieron que 13 términos del modelo son similares entre todos los participantes: cinco términos lineales de salida, seis términos cuadráticos de entrada, un término cuadrático de salida y una constante. Sin embargo, falta información sobre la aceleración angular, y los distintos desfases temporales no proporcionan una explicación fisiológica buena ni específica de los procesos implicados.

La ventaja del trabajo de Nozari et al. (2020) con el de Gu et al. (2021) se encuentra en la parte de predicción, es decir, cuando se utiliza un predictor 'One Step Ahead' (OSA) con modelos NARX, el rendimiento del sistema alcanzó una varianza contabilizada (VAF) media del 94,27%, mientras que para un modelo LLNF-NARMAX alcanzó el VAF 94,52%. Sin embargo, cuando el horizonte de predicción k es igual a 3, el modelo OSA-NARX tiene un bajo rendimiento del 54,84% (VAF), mientras que el modelo basado en LLNF-NARMAX alcanzó un VAF 91,54% en promedio. La razón de este fenómeno puede deberse a un tipo de descodificación mediante la reducción de la dimensión del espacio de entrada no lineal a través de subespacios lineales locales, en los que se identifican las características importantes y se puede predecir un horizonte de 43 ms ($k=11$) con un rendimiento superior al 80% (VAF).

Los trabajos más relevantes mencionados anteriormente relacionados con esta investigación pueden observarse tras las referencias en la Tabla 4.6.2.

1.3. Objetivo de la Tesis

La alta variabilidad inter e intrasujeto de las señales cerebrales se debe a muchas razones como la historia clínica, la alimentación, el estado de ánimo o factores externos (sonido, luz, etc.). Estos factores provocan que estas señales cerebrales sean no estacionarias y altamente no lineales. Por lo tanto, modelarlas durante la ejecución de una tarea específica es un problema desafiante. Además, hay que tener en cuenta que las señales no deseadas (como la línea eléctrica, o los artefactos internos) también pueden alterar los parámetros del modelo.

Por lo tanto, el objetivo principal de esta tesis es *modelar la respuesta cerebral general provocada por la manipulación de la muñeca de sujetos jóvenes y sanos*. Para alcanzar este objetivo se llevan a cabo las acciones que se enumeran a continuación:

1. Estudiar los modelos actuales de actividad cerebral relacionados con las tareas motoras,
2. Estudiar de forma general los principios fisiológicos y anatómicos del sistema nervioso, y en concreto del sistema motorsensorial,
3. Proponer, implementar y validar un modelo no lineal de actividad cerebral relacionada con tareas motoras,
4. Desarrollar un sistema robótico para provocar movimientos específicos en la muñeca derecha de los participantes,
5. Comparar el modelo propuesto (punto 3) con el modelo obtenido utilizando el sistema robótico desarrollado (punto 4),
6. Construir un nuevo conjunto de datos con voluntarios de México,
7. Publicar resultados.

1.4. Hipótesis

Un modelo embebido diferencial no lineal con retardo puede estimar la respuesta cortical causada por una manipulación específica de la muñeca alcanzando una correlación (entre las señales de salida reales y estimadas) superior al 90 % como rendimiento del modelo.

1.5. Contribuciones

Es crucial modelar la respuesta cerebral provocada por la manipulación de la muñeca para comprender el funcionamiento del cerebro sano inicialmente y, eventualmente, las alteraciones que surgen tras el daño cerebral. Para lograr este objetivo, se pueden mencionar las contribuciones de esta tesis en los campos del modelado no lineal, la fisiología del cerebro humano y la robótica.

En primer lugar, la contribución relacionada con el marco matemático es el modelo no lineal propuesto basado en la incrustación diferencial de retardo no lineal, es decir, el modelo tiene en cuenta las señales retardadas de los parámetros del movimiento inducido (la rotación angular de la muñeca provocada por el sistema robótico, la tasa de cambio y la aceleración del movimiento).

Además, la síntesis de resultados ayuda a calcular tanto la base algebraica como la respuesta al impulso de cada sujeto. Para ilustrar esta información pueden utilizarse los vectores de pesos y los perfiles de correlación, respectivamente. El primer término (vector de peso) representa la contribución cuantitativa de cada regresor del modelo, mientras que el segundo término (perfil de correlación) representa la correlación entre la señal de respuesta cortical real y la señal modelada cuando los regresores se añaden de uno en uno.

En segundo lugar, desde un punto de vista fisiológico, el modelo propuesto contempla la contribución de la aceleración angular, que no ha sido reportada previamente. Este parámetro está asociado a comportamientos explosivos causados por la fuerza inducida en la muñeca. Además, los productos de puntos de los parámetros de movimiento generados (posición angular de la muñeca, velocidad y aceleración), envuelven los armónicos no lineales de la respuesta cerebral en los mismos retardos temporales, sugiriendo vías fisiológicas particulares de la respuesta cerebral.

En cuanto a la primera y segunda contribuciones, los resultados experimentales revelan respuestas comunes entre los sujetos en términos de respuesta al impulso, base algebraica y retardos temporales de los parámetros de movimiento inducidos, lo que refleja una reacción generalizada de la actividad cerebral provocada por movimientos específicos de la muñeca.

Por último, las contribuciones a la instrumentación necesaria para el desarrollo de esta tesis incluyen (1) el sistema robótico para inducir siete movimientos específicos de la muñeca, que alcanzó una correlación media del 94,42% cuando se comparó con los perfiles de movimiento generados a partir de la base de datos TU DELE, y (2) la validación de la configuración EEG con ocho electrodos para medir la actividad cerebral, lo que permite reducir la complejidad y, por tanto, mejorar la velocidad de procesamiento de los datos.

Este método permite la creación de un nuevo conjunto de datos de las señales cerebrales de los participantes mexicanos, lo que constituye una valiosa contribución a la eventual validación de nuevos modelos.

1.6. Publicaciones

Durán-Santos, M., Salazar-Varas, R. and Etcheverry, G. (2024). Modeling the cortical response elicited by wrist manipulation via a nonlinear delay differential embedding. *Physical and Engineering Sciences in Medicine*. <https://doi.org/10.1007/s13246-024-01427-8>

Durán-Santos, M., Romero, C., Salazar-Varas, R., and Ubeda, A. (2024). Proportional estimation of muscle fatigue during isometric wrist flexion using surface electromyography. Manuscript submitted to *Journal of Electromyography and Kinesiology*.

Durán-Santos, M., Romero, C., Salazar-Varas, R., and Ubeda, A. (2024). EMG biomarkers for fatigue prediction during isometric wrist flexion. *International Society of Electrophysiology and Kinesiology (ISEK) Conference*, Japon, June 2024.

Romero, C., **Durán-Santos, M.**, Bernat, L., Jara, C., Úbeda, A. (2024) Estimación de fatiga muscular usando regresión lineal y HD-EMG. *Simposio de Robótica, Bioingeniería y Visión por Computador 2024*, Badajoz, España.

1.7. Esquema general de la tesis

En este trabajo se presentan cuatro capítulos y un apéndice:

El capítulo uno acerca al lector a la idea general de esta tesis. En este capítulo, se presenta una amplia introducción para explicar el punto de vista multidisciplinario de esta tesis, destacando la sinergia de los marcos matemáticos, la fisiología del cerebro humano y los métodos de procesamiento de señal. A continuación, se presentan la motivación, la bibliografía relacionada, el objetivo de la tesis, las hipótesis, las contribuciones y las publicaciones. El esquema de esta tesis se presenta al final de este capítulo.

El capítulo dos presenta el marco teórico que describe los temas más relevantes necesarios para comprender plenamente los capítulos siguientes. En este capítulo se incluye la descripción del sistema motorsensorial, parte esencial para comprender los caminos fisiológicos implicados en la manipulación de la muñeca. A continuación, se explican los fundamentos del modelo propuesto en esta tesis. Por último, al final de este capítulo se presenta la metodología para extraer la fuente de la actividad cerebral.

El capítulo tres presenta el desarrollo de esta tesis. Al principio de esta sección se describen el software y el hardware, que abarcan los recursos informáticos y la implementación del sistema robótico para provocar la manipulación de la muñeca. A continuación, se describe la metodología propuesta, que incluye el montaje experimental, los procedimientos de preprocesado, la estimación y validación del modelo propuesto y la teoría del marco matemático. Por último, al final de este capítulo, se describen los resultados y la discusión relacionada.

El capítulo cuatro describe el trabajo realizado durante la visita de investigación a HUMAN Robotics (HURO) en la Universidad de Alicante, España. El objetivo principal de este trabajo es estimar la fatiga muscular proporcional en tareas de contracción, lo que puede tener aplicaciones futuras en el campo de la rehabilitación motora. Dado que este proyecto examina el movimiento de control más que el efecto de perturbación, es un complemento de la tesis principal. Por último, este capítulo incluye una descripción del protocolo experimental, la metodología propuesta, los resultados y la discusión.

Por último, las conclusiones y el trabajo futuro se presentan en una sección aparte. Al final de la tesis se incluyen también los Apéndices y la Bibliografía.

Capítulo 2

Marco teórico

La base teórica incluye una descripción de la fisiología de las fibras que responden a la manipulación de la muñeca, así como de los retardos temporales implicados. También se discuten los principios del modelo propuesto, así como el fundamento matemático para determinar el origen del movimiento.

2.1. Sistema motor-sensorial

El ser humano puede ser consciente de su entorno gracias a los sentidos, que en cierto modo están relacionados con los sensores de un sistema, ya que ambos son elementos esenciales que reciben información del exterior y luego la transmiten a una parte central para ser procesada. En esta tesis, los sensores son las fibras aferentes (fibras que envían información desde las extremidades hasta el cerebro) que convierten el movimiento angular mecánico a nivel de la articulación de la muñeca en señales eléctricas enviadas a través de las fibras $A\alpha$ y $A\beta$ (Vlaar, 2017).

La Fig. 2.1.1 muestra las fibras del huso muscular que miden la información del exterior cuando se estiran. Dado que la aferente del grupo II inerva la fibra estática del saco nuclear, la aferente del grupo II aumenta su frecuencia de disparo cuando se estiran los husos musculares. Del mismo modo, la aferente del grupo Ia inerva las tres fibras (incluida la fibra de la bolsa nuclear dinámica), por lo tanto, tanto el cambio como la tasa de cambio del músculo son decodificados por la aferente del grupo Ia.

Un sistema implicado en el proceso de detección es el sistema propioceptivo, que consta de husos musculares, órganos tendinosos de Golgi, cápsulas articulares y terminaciones libres sensibles al estiramiento. Los mecanorreceptores pueden enviar información a través del sistema nervioso central (Vlaar, 2017). En otras palabras, los mecanorreceptores son receptores para convertir eventos mecánicos en señales neuronales (Riemann and Lephart, 2002).

La figura 2.1.2 muestra un esquema del sistema motor-sensorial. Como se menciona en el último párrafo, los mecanorreceptores y los músculos reciben la perturbación mecánica externa, luego se envía a través de la médula espinal y, por último, la información captada se transmite al cerebro, donde se mide la información a través de señales electroencefalográficas (EEG). Este proceso se denomina *aferente*, y está representado por las flechas rojas en la Figura 2.1.2. Las flechas azules representan el proceso *eferente*, que está relacionado con las tareas de control y tiene una dirección opuesta al proceso aferente.

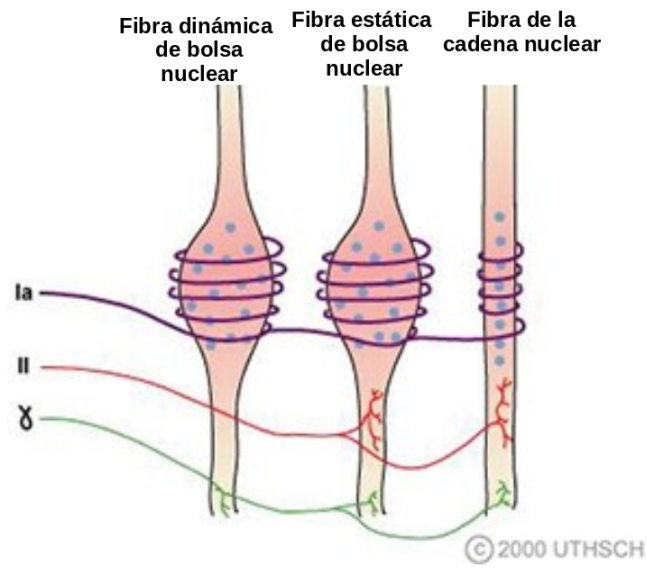


Figura 2.1.1: **Fibras del huso muscular (modificadas de Knierim (2020)).**

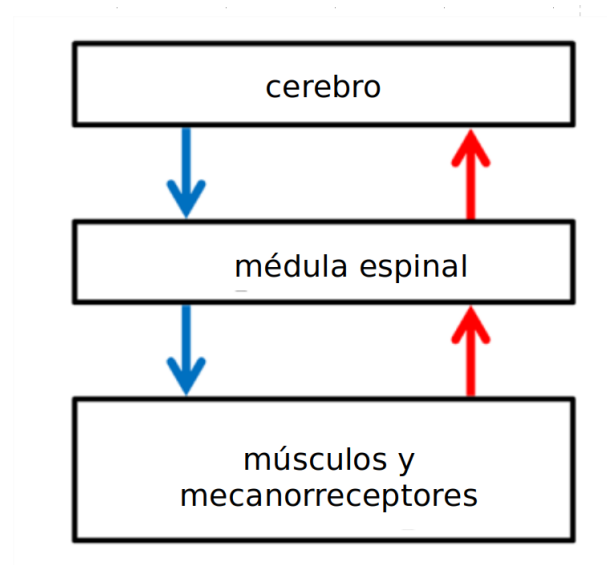


Figura 2.1.2: **Esquema del sistema motor-sensorial. Imagen extraída de Vlaar (2017).**

2.2. Efectos de retardo en el sistema sensoriomotor

Los efectos de retardo se observan en el sistema sensoriomotor humano debido a la fisiología y, más concretamente, a la naturaleza de los grupos aferentes-Ia y aferentes-II. Cuando se estiran los músculos, los cambios tanto en la longitud muscular como en la velocidad de cambio de la longitud muscular se perciben a través de los husos musculares. Los grupos aferente-Ia y aferente-II corresponden a las fibras $A\alpha$ y $A\beta$, respectivamente. La aferente del grupo Ia transmite la información de la longitud o el cambio en la longitud muscular y la aferente del grupo II sólo envía la información de la longitud muscular (Vlaar, 2017).

Se establece el menor tiempo de retardo (16 ms) en el grupo aferente-Ia para enviar las señales de posición y velocidad, y el menor retardo (32 ms) en el grupo aferente-II para enviar la señal de posición (Tian et al., 2018). La figura 2.2.1 muestra estos dos retardos de información en el sistema sensoriomotor. Aquí, la posición y la velocidad de rotación están representadas por q y $q\dot{p}$, respectivamente.

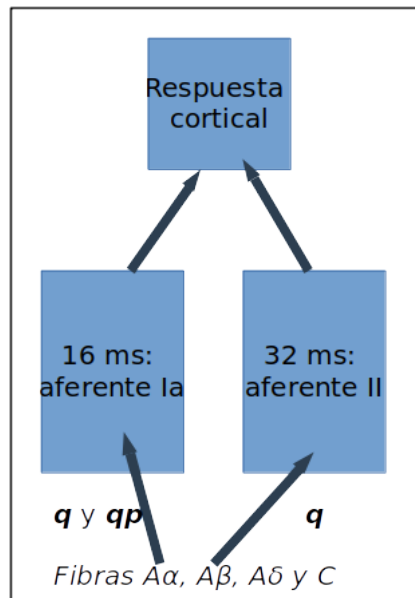


Figura 2.2.1: Consideración de los retrasos temporales en el sistema motor-sensorial.

El órgano tendinoso de Golgi, situado entre el músculo y el tendón, es un receptor que percibe información sobre la cantidad de fuerza aplicada a un músculo y la transmite al cerebro a través de la aferente del grupo 1b. Las membranas de las terminaciones sensoriales aferentes primarias son comprimidas y deformadas por las fibras de colágeno cuando se aplica una fuerza mecánica a un músculo, lo que estira el órgano tendinoso de Golgi. Entonces, la aferente se despolariza y libera potenciales de acción para comunicar la fuerza (Knierim, 2020).

Varias áreas corticales son moduladas por la perturbación durante el período de tiempo de 100 a 350 ms (Yang et al., 2017). Existe una ruta de conectividad menos compleja para diferentes períodos de tiempo de 20 a 100 ms. Los retardos temporales más largos (100-350 ms) y los más cortos (20-100 ms) están relacionados con lo que se denominan latencias largas y cortas, respectivamente.

2.3. Model embebido diferencial con retardos temporales

Un embebido convierte una serie temporal en un objeto geométrico multidimensional. El embebido derivativo es una estructura formada por derivadas sucesivas de la señal, mientras que el embebido diferencial se genera mediante versiones retardadas de la señal. En consecuencia, un embebido de retardo-diferencial transforma una serie temporal en una estructura geométrica compuesta por derivadas sucesivas y versiones retardadas de la señal (Lainscsek and Sejnowski, 2015).

Un ejemplo claro de la aplicación del modelo embebido diferencial retardado en el análisis de señales cerebrales es el de Lainscsek et al. (2013). En este trabajo, el análisis dinámico no lineal de las señales de EEG se basa en ecuaciones diferenciales de retardo (modelo de 3er grado con dos retardos temporales), que se utilizan para distinguir a los pacientes con enfermedad de Parkinson de los individuos sanos, (véase la ecuación 2.3.1).

$$\begin{aligned} \dot{x} = & a_1 x_{\tau_1} + a_2 x_{\tau_2} + a_3 x_{\tau_1}^2 + a_4 x_{\tau_1} x_{\tau_2} + a_5 x_{\tau_2}^2 \\ & + a_6 x_{\tau_1}^3 + a_7 x_{\tau_1}^2 x_{\tau_2} + a_8 x_{\tau_1} x_{\tau_2}^2 + a_9 x_{\tau_2}^3, \end{aligned} \quad (2.3.1)$$

donde:

x : Señal de entrada $x(n)$, en el instante de muestreo n ,

τ_1, τ_2 : Retrasos temporales,

x_{τ_i} : Señal retrasada en τ_i , o $x(n - \tau_i)$,

a_k : Parámetros del modelo.

2.4. Análisis de Componentes Independientes (ICA)

En lo que respecta a las señales biomédicas, un artefacto es una señal espuria que puede ser causada por eventos internos o externos, como el parpadeo de los ojos, movimientos musculares, actividad cardíaca, entre otros. Se han propuesto diversas metodologías para preprocesar la señal y eliminar los artefactos. En este sentido, el análisis de componentes independientes (ICA) es un método muy utilizado, a pesar de que es un proceso que requiere mucho tiempo y utiliza grandes recursos computacionales, ya que se necesita un gran conjunto de datos para procesar la información y obtener esos componentes independientes.

Dado que la actividad eléctrica del cerebro puede captarse del cuero cabelludo de los sujetos mediante grabaciones de EEG, es posible procesar las señales, analizarlas y extraer información importante. En particular, el método ICA permite conocer las fuentes de actividad cerebral, como se muestra en la Fig. 2.4.1.




Figura 2.4.1: Etapa de respuesta cortical mediante análisis de componentes independientes. Imagen tomada de Vliet et al. (2016)

La ecuación 2.4.1 muestra la relación entre los componentes independientes y las señales EEG.

$$X = AS, \quad (2.4.1)$$

donde: X : Señales observadas a través del EEG. Es una matriz de dimensiones $r \times c$, donde r representa el número de canales de EEG, y c es el número de muestras en cada canal, A : Matriz de mezcla. Se utiliza para trazar los mapas topológicos de componentes independientes en el cuero cabelludo. S : Señales de componentes independientes.

Cabe mencionar que antes de encontrar los componentes independientes, Vlaar et al. (2018) aplicó un filtro paso alto a una frecuencia de corte de 1Hz para atenuar las frecuencias bajas debidas a la presión sanguínea o la respiración. Yang et al. (2016) y Tian et al. (2018), aplicaron un filtro paso banda con desplazamiento de fase cero para atenuar las señales de ruido procedentes de interferencias electromagnéticas con alta frecuencia y las señales internas con bajas frecuencias. También utilizaron un filtro de muesca, o un filtro ideal como Vlaar et al. (2018) a una frecuencia de 50 Hz para atenuar la señal de línea (frecuencia de línea europea). Por último, se aplicó un submuestreo a las señales filtradas con una frecuencia remuestreada de 256 Hz como Vlaar et al. (2018) o 512 Hz como Yang et al. (2016) y Tian et al. (2018) para reducir la complejidad computacional. Tian et al. (2018).

Capítulo 3

Modelado de la respuesta cortical causada por perturbaciones de la articulación de la muñeca a través de un embebido no lineal diferencial con retardo temporal

En este capítulo se describe el experimento, el conjunto de datos públicos, el hardware y el software utilizados para desarrollar este proyecto. Se explica la metodología aplicada para identificar la respuesta cortical, proponer el modelo, encontrar los mejores retardos temporales, aproximar los parámetros del modelo y finalmente validar el modelo propuesto. Al final de esta sección se desarrolla un marco matemático que describe la base teórica del modelo propuesto. Los resultados se discuten al final de este capítulo.

3.1. Materiales y métodos

3.1.1. Base de datos pública

La Universidad Tecnológica de Delft (TU Delft) hizo público un conjunto de datos de la actividad cerebral de 10 sujetos diestros, jóvenes y sanos (seis hombres y cuatro mujeres) cuando se manipula mecánicamente su muñeca (Schouten et al., 2019). El procedimiento experimental fue aprobado por el Comité Ético de Investigación Humana de la TU Delft. Todos los participantes dieron su consentimiento informado por escrito antes de la realización de los experimentos.

En el experimento, el brazo derecho de cada persona, que está sentada en una silla, está relajado y fijado a una articulación robótica (véase la parte izquierda de la Fig. 3.1.1). Siete movimientos de rotación (realizaciones) perturban la muñeca derecha. Cada realización es una señal multisenso con frecuencias 1, 3, 5, 7, 9, 11, 13, 15, 19 y 23Hz y fase aleatoria; dos realizaciones se muestran en la parte superior derecha de la Fig 3.1.1. Las tres primeras frecuencias tienen la amplitud más alta, luego descende 20dB en cada frecuencia (parte inferior derecha de la Fig. 3.1.1). Cada realización se segmenta en 210 periodos de 1s. En la parte superior izquierda de la Fig. 3.1.1 se muestran tres grupos de realizaciones diferentes, donde las regiones sombreadas se eliminan para disminuir los efectos de transición. Estos ajustes se establecen

para permitir la similitud entre las realizaciones, pero con una ligera diferencia para evitar un proceso de aprendizaje.

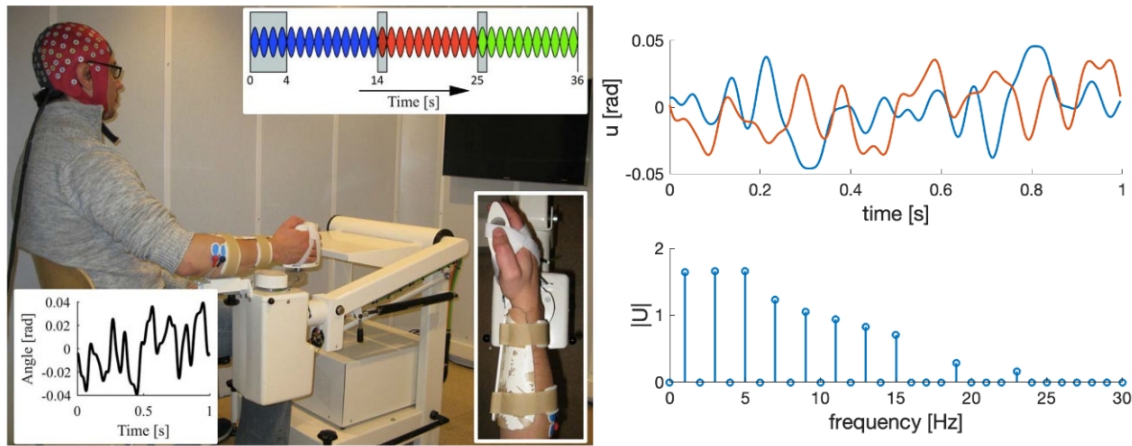


Figura 3.1.1: Imagen tomada de la referencia "Cortical responses evoked by wrist joint manipulation" (Vlaar et al., 2018) and (Vlaar et al., 2017).

La actividad cerebral se registra mediante EEG, con 126 canales y una frecuencia de muestreo de 2048 Hz. Se aplica un filtro pasabanda de cuarto orden con desplazamiento de fase cero (frecuencias de corte a 1 Hz y 100 Hz) para atenuar las señales sin interés. Para atenuar la señal de la línea eléctrica se utiliza un filtro Notch de 50 Hz.

3.1.2. Replicación del protocolo de adquisición

Para replicar el experimento, se siguió un protocolo similar al de la Universidad Tecnológica TU Delft, que se puede dividir en cinco secciones: (a) Preparación, (b) Sujetos y materiales, (c) Fuente de perturbación, (d) Ensayos, y (e) Segmentación de la señal.

(a) Preparación: El sujeto se sienta en una silla, colocando el brazo derecho en posición fija y relajada y la muñeca recostada sobre la articulación robótica, y la mirada se fija en un punto del ordenador que se encuentra separado 1 metro del sujeto (ver Figs. 3.1.2A, 3.1.2B), and 3.1.2C).

(b) Sujetos y materiales: En el experimento, 10 voluntarios (cinco hombres y cinco mujeres, de edades comprendidas entre 22 y 30 años) fueron considerados para registrar su actividad cerebral a través de EEG utilizando la interfaz OpenBCI. GUIv5.1.0 con 8 canales, y una frecuencia de muestreo de 256 Hz (un ejemplo de esta interfaz se puede ver en la Fig. 3.1.2D).

(c) Fuente de perturbación: El sistema robótico descrito en la sección 3.1.3 provocó siete diferentes perfiles específicos de movimiento de la muñeca (entradas). Cada perfil es una señal multisenal, con 10 componentes de frecuencia (1, 3, 5, 7, 9, 11, 13, 15, 19 y 23 Hz) y fase aleatoria. Estos ajustes se establecen para permitir la similitud entre las realizaciones, pero con una ligera diferencia para evitar un proceso de aprendizaje. Estos perfiles tienen una correlación media del 94 % con las señales de entrada presentadas en el conjunto de datos NL_TU_DELFDT_DB.

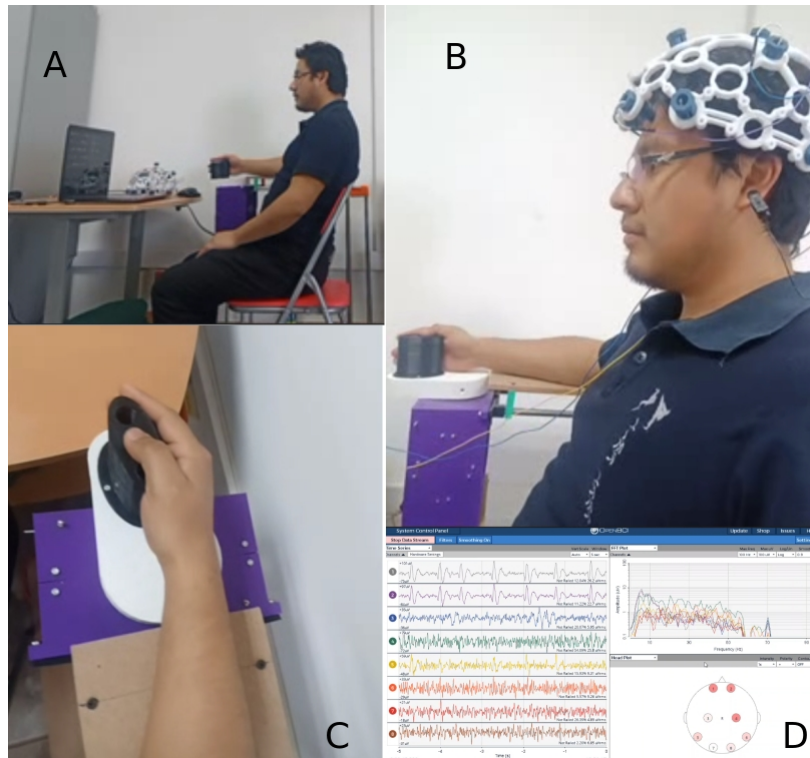



Figura 3.1.2: **A: Posición inicial del montaje experimental. B: Electrodo para medir la actividad cerebral. C: Mano derecha sujetando la articulación robótica para provocar perfiles específicos de movimiento de la muñeca. D: Interfaz EEG utilizando el software OPENBCI GUIv5.1.0.**

(d) Pruebas: Un experimento consta de 49 pruebas. Cada prueba dura 36 segundos y registra 3 grupos diferentes elegidos al azar. Para cada prueba, los primeros cuatro segundos, y un segundo entre grupos se eliminan para disminuir los efectos transitorios, lo que lleva a 1470s, o 210s por realización (ver Fig. 3.1.3). Se realizó una pausa de 10 a 20 segundos entre los ensayos grabados, y cada sujeto escuchó un pitido al principio y al final de cada prueba para ser consciente de la manipulación de la muñeca. Para evitar la fatiga, el experimento se dividió de tres a cinco sesiones, dependiendo del sujeto, con una pausa de dos a cuatro minutos entre sesiones.

(e) Segmentación de la señal: Tras registrar la actividad cerebral, las señales de las series temporales se segmentan por periodos y por perfiles de movimiento (es decir, se eliminan las pequeñas interrupciones), y se organizan en un tensor $X[M, P, n, Ch]$, donde M es el perfil de entrada actual ($M = 1, 2, \dots, 7$), P es el periodo ($P = 1, 2, \dots, 210$), n es la señal muestreada ($n = 1, 2, \dots, 256$), y Ch es el canal EEG actual ($Ch = 1, 2, \dots, 8$).

3.1.3. Implementación de un sistema robótico

El sistema robótico está formado esencialmente por dos subsistemas: el sistema electrónico y el conjunto mecánico. El sistema electrónico está constituido por un motorreductor metálico Pololu, un driver de motor de alta potencia y una tarjeta electrónica. Respecto a la Fig. 3.1.4, la posición deseada es el punto actual de la trayectoria dada por uno de los siete movimientos específicos que se provocarán a la muñeca. Una vez medida la posición real mediante el contador de impulsos y la detección del sentido de giro, se estima la velocidad angular. La ley



1 Periodo = 1s
 1 Grupo = 10 Periodos = 10s
 1 Prueba = 3 Grupos = 30s (sin pausas)

1 experimento = 147 Grupos (o 49 Pruebas) = 1470s / 7 Realizaciones

Figura 3.1.3: **Un experimento consta de 49 pruebas, lo que lleva a 1470s, o 210s por realización.**

de control considera tanto la posición angular como la velocidad del error. Por último, la señal de salida se envía a los terminales del motor a través del controlador del motor de alta potencia.

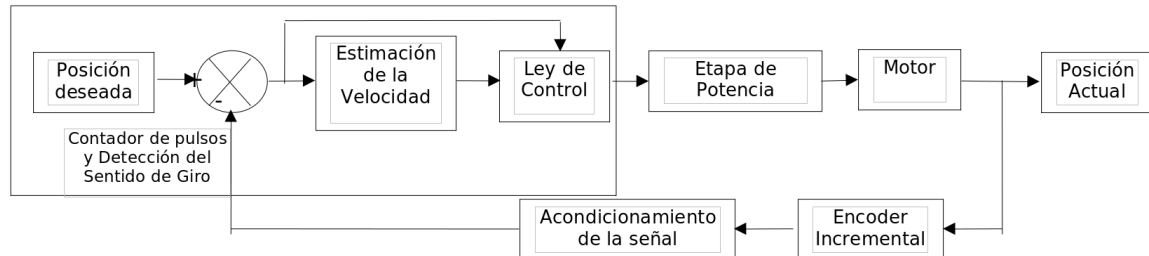


Figura 3.1.4: **Diagrama de bloques del sistema de control en lazo cerrado.**

El montaje mecánico se muestra en la Fig. 3.1.5. En primer lugar, se realizó un diseño asistido por computadora para obtener una primera impresión del ensamblaje y, posteriormente, se utilizaron los archivos generados para la impresión 3D (A). Una vez impresas las piezas en 3D, se realizó el ensamblaje y las adaptaciones mecánicas necesarias (B).

Este sistema robótico se utilizó para provocar siete movimientos diferentes (los mismos que en el NL_TU_DELFDT_DB Dataset (Schouten et al., 2019)), consiguiendo una correlación promedio de 94.42% (ver Fig. 3.1.6).




Figura 3.1.5: **A: Diseño asistido por computadora. B: Montaje mecánico del sistema robótico.**

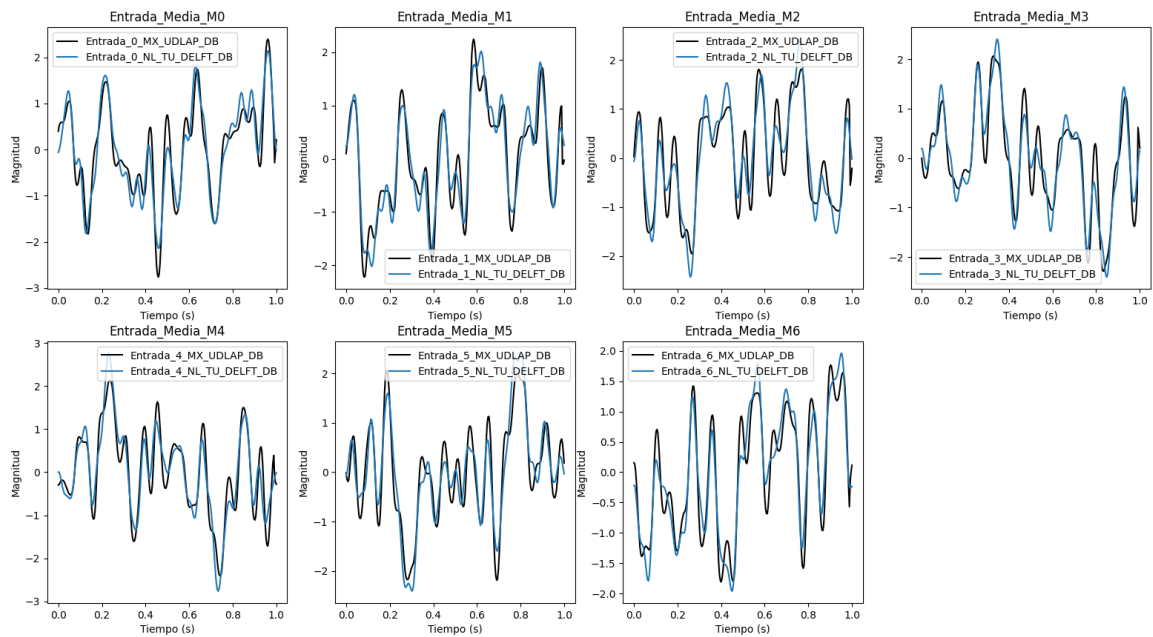


Figura 3.1.6: **Siete movimientos específicos para provocar la perturbación de la muñeca a partir de nuestro sistema robótico (negro) y del conjunto de datos NL_TU_DELF_T_DB (azul).**

3.1.4. Canales EEG

La herramienta OpenBCI es una plataforma de hardware y software de código abierto que permite registrar la actividad cerebral a partir de 8 canales con una frecuencia de muestreo de 256 Hz (la ubicación de los electrodos se muestra en la Fig. 3.1.7 que cubre las áreas cerebrales importantes para este trabajo, y aún queda una distribución general, que es suficiente para este

trabajo).




Figura 3.1.7: Distribución de electrodos en el dispositivo OpenBCI.

3.1.5. Descripción del software

Para la realización de todas las etapas de este trabajo se realizó un convenio con el Laboratorio Nacional de Supercómputo del Sureste de México (LNS¹). El hardware utilizado en este proyecto tiene una capacidad máxima de hasta 50GB para almacenamiento y 240 núcleos de cálculo simultáneos, hasta 128GB en RAM. Se utilizaron librerías de Python 3.8. Usando Matlab 2022, se utilizó la función *topoplot* de *EEGLAB* para el trazado de la topología de la respuesta cortical.

3.1.6. Métodos

En esta subsección se describe la metodología propuesta, incluida la técnica para validar el modelo. La metodología propuesta consta de tres pasos principales (Fig. 3.1.8): (A) la identificación de la respuesta cortical, (B) la estimación de los retardos temporales y (C) la aproximación de los parámetros del modelo.

Preprocesamiento

En cuanto al conjunto de datos público publicado por Schouten et al. (2019) de la Universidad Tecnológica de Delft (denominado NL_TU_DELFT_DB, y descrito en la subsección 3.1.1), las señales se reducen de 2048 Hz a 256 Hz para reducir la complejidad computacional, lo que permite una configuración similar a efectos de comparación. Además, el número de electrodos se reduce de 126 canales a 8 canales, con respecto a la distribución de electrodos mostrada anteriormente en la Fig. 3.1.7. Por otra parte, la actividad cerebral obtenida del sistema de adquisición diseñado (denominado MX_UDLAP_DB, y descrito en la subsección 3.1.2), se registra a través del dispositivo OpenBCI, con 8 canales y frecuencia de muestreo de 256 Hz.

¹LNS: Laboratorio Nacional de Supercómputo del Sureste de México, <https://lms.buap.mx/>

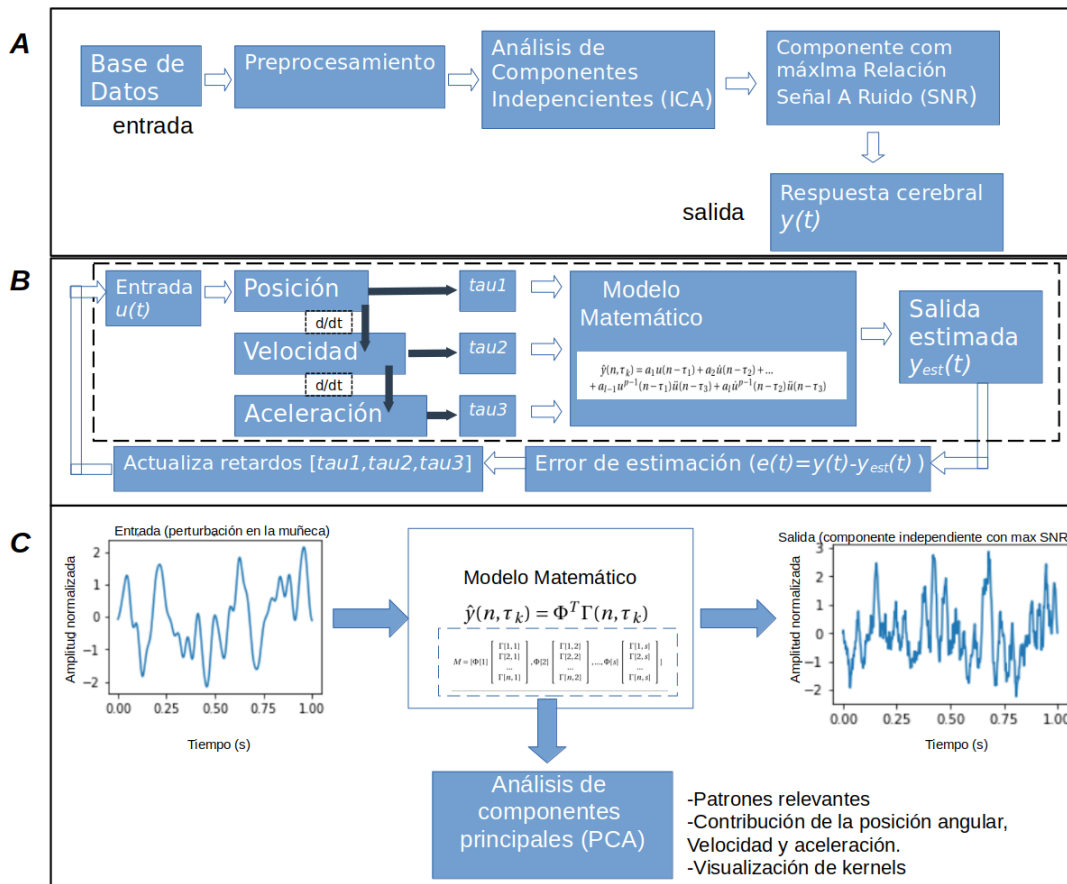


Figura 3.1.8: **A: Esquema general de la metodología para identificar la respuesta cortical causada por perturbaciones externas. B: Estimación de los mejores tiempos de retardo. C: Secuencia del modelo matemático desde la perturbación (entrada) hasta la respuesta cortical (salida) y descomposición de la matriz base a través del análisis de componentes principales (PCA).**

Es importante mencionar que la frecuencia de muestreo de 256 Hz se seleccionó utilizando un enfoque cuantitativo, es decir, para los diez sujetos del conjunto de datos NL_TU_DELEFT_DB, se consideraron cuatro frecuencias de muestreo diferentes, midiendo la varianza residual entre la respuesta cerebral registrada provocada por la manipulación de la muñeca y su modelo correspondiente. La Fig. 3.1.9 muestra el impacto de la variación de cuatro frecuencias de muestreo diferentes en el rendimiento del modelo considerando un modelo de 10° grado.

La Fig. 3.1.9 muestra que, para todos los participantes, la frecuencia de muestreo de 256 Hz produce los mejores resultados, mientras que 2048 Hz produce los peores resultados para el modelo de 10° grado. Una frecuencia de muestreo de 128 Hz es inviable debido a los posibles efectos de aliasing resultantes del incumplimiento del teorema de Nyquist-Shannon. En consecuencia, se elige 256 Hz como frecuencia de muestreo para el modelado.

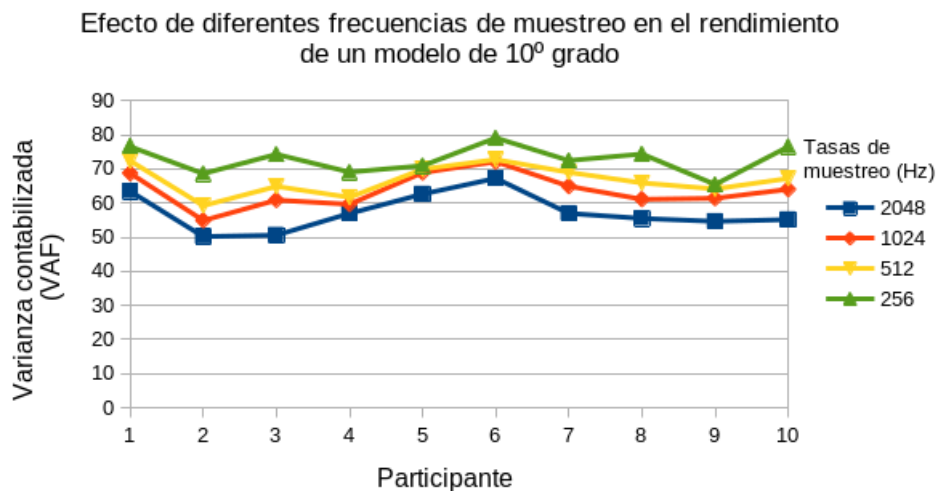


Figura 3.1.9: **Impacto de la variación de las frecuencias de muestreo en el rendimiento de un modelo de 10º grado.**

Parece contradictorio que una frecuencia de muestreo más baja (lo que significa menos puntos de datos) dé lugar a un modelo con mejor rendimiento VAF. Esto podría ser provocado por el hecho de que las frecuencias de muestreo más altas generan más puntos de datos, capturando más ruido debido al alto grado del modelo. Por lo tanto, con respecto a un menor número de muestras (frecuencia de muestreo más baja), los datos podrían contener menos incertidumbre, lo que facilitaría al modelo el aprendizaje de la actividad cerebral registrada.

En cuanto al preprocesado de la señal, se aplica un filtro pasabanda de cuarto orden con desplazamiento de fase cero (frecuencias de corte a 1 Hz y 100 Hz) a ambas fuentes de datos (NL_TU_DELFIT_DB y MX_UDLAP_DB) para atenuar las señales sin interés. En los conjuntos de datos NL_TU_DELFIT_DB y MX_UDLAP_DB se aplica un filtro Notch de 50 Hz y 60 Hz, respectivamente, para atenuar la señal de la línea eléctrica de acuerdo con la frecuencia de línea de cada país.

Identificación de la respuesta cortical

Para cada realización, se construye una matriz X a partir de los registros EEG, y se aplica el Análisis de Componentes Independientes (ICA) como $X = AS$, donde A es la matriz de pesos, y S la matriz de componentes independientes.

La relación señal/ruido (SNR^2) se calcula para todos los componentes independientes como en el algoritmo 1. La respuesta cortical se identifica seleccionando el componente con la máxima SNR y que su topología muestre una respuesta contralateral. El componente resultante se promedia por periodos para obtener la señal esperada que será modelada.

Se aplicó un método similar al de Vlaar et al. (2018) para calcular la SNR de cada componente (véase el algoritmo 1). La principal diferencia con el método descrito en este trabajo es que ICA se realiza para cada realización, es decir, para cada sujeto hay siete procesos ICA, en

²SNR: Relación Señal/Ruido por sus siglas en inglés: Signal-to-Noise Ratio

lugar de solo uno como en el método de Vlaar. Este nuevo enfoque acelera el proceso de identificación de la respuesta cortical y reduce el coste computacional.

Algorithm 1: Algoritmo de Relación Señal/Ruido (SNR)

Inicio

$T = 210$

for $M=1:7$ **do**

$$\bar{I}C_{M,i}(n) = \frac{1}{T} \sum_{p=1}^{210} IC[M, P, n, i]$$

$$E_{M,i}(n) = \bar{I}C_{M,i}^2(n)$$

$$\Sigma_{M,i}(n) = \frac{1}{T-1} \sum_{p=1}^{210} (IC[M, P, n, i] - \bar{I}C_{M,i}(n))^2$$

$$SNR_M(i) = \frac{\sum_{n=1}^{2048} E_{M,i}(n)}{\sum_{n=1}^{2048} \Sigma_{M,i}(n)}$$

$$r = \max(SNR_M(i))$$

$$y_M(n) = \bar{I}C_{M,r}$$

end

En el Algoritmo 1, T es el número total de periodos, $\bar{I}C_i(n)$ es la media del i -ésimo componente independiente con $i \in [1, 7]$, y r es el índice del componente independiente con máxima SNR en cada realización. La respuesta cortical se representa como $y_M(n)$, que es provocada por la correspondiente señal multiseno $u_M(n)$. A partir de aquí, las realizaciones M estarán implícitas, por lo que la respuesta cortical se representa entonces como $y(n)$, y la realización M^{th} que provoca esta respuesta se muestra como $u(n)$.

Modelo Propuesto

La expresión general para estimar la respuesta cortical causada por la manipulación de la muñeca viene dada por la Ec. 3.1.1

$$\begin{aligned} \hat{y}(n) &= \Phi^T \Gamma \\ \Phi &= [a_1, a_2, a_3, \dots, a_s] \\ \Gamma &= [u(n - \tau_1), \dot{u}(n - \tau_2), \ddot{u}(n - \tau_3), \dots, \dot{u}^{p-1}(n - \tau_2) \ddot{u}(n - \tau_3)] \end{aligned} \quad (3.1.1)$$

donde $\hat{y}(n)$ es la señal modelada de la respuesta cortical, Φ es el vector de pesos que incluye la contribución de cada base unitaria (regresor) en la matriz Γ , y $u(n)$ es la realización correspondiente (entrada) que provoca la respuesta cerebral $y(n)$. Como Φ es un filtro para obtener la respuesta cortical a partir de la entrada, representa la respuesta al impulso del sistema. Una descripción completa del modelo se encuentra en la sección 3.1.7.

Hallar los mejores retardos del modelo propuesto

El modelo propuesto considera señales retardadas comunes de las realizaciones y sus derivadas, es decir, se consideran términos de retardo para la posición angular, la velocidad y la aceleración (τ_1 , τ_2 y τ_3 , respectivamente). Para encontrar los mejores retardos del modelo propuesto, esos términos de retardo se reúnen en $Q = [\tau_1, \tau_2, \tau_3]$ como una partícula 3D, seguida de procesos de exploración y explotación.

Por lo tanto, los mejores retardos se encuentran de la siguiente manera: la exploración de todo el espacio con un cierto *step* da la primera aproximación de la mejor solución. A continuación, la explotación de esta partícula (con un *step* menor) da la mejor partícula final. Un valor alto de *step* significa una baja resolución. Para evitar mínimos locales, se obtuvieron 10

posibles soluciones (debido a 10 sujetos), y la solución final considera la partícula Q que dio la máxima correlación entre todas las respuestas al impulso de los sujetos.

Ambos procesos, exploración y explotación, siguen el mismo enfoque del Algoritmo 2. Este enfoque inicializa primero las variables necesarias, luego itera a través de los retardos temporales y las realizaciones, calculando la matriz de base unitaria Γ , el vector de pesos Φ , y estimando el error. Por último, los mejores valores de los retrasos se guardan cuando el error es mínimo.

Algorithm 2: Algoritmo para encontrar los mejores retardos del modelo

Inicio

Calcula, filtra y normaliza $\dot{u}(n)$ y $\ddot{u}(n)$ como en en la Ec. 3.1.6

$\Phi_0 = \mathbf{0}$

$Error_{old} = 100000$

for $\tau_1 = \tau_{b1} : \text{step} : \tau_{e1}$ **do**

for $\tau_2 = \tau_{b2} : \text{step} : \tau_{e2}$ **do**

for $\tau_3 = \tau_{b3} : \text{step} : \tau_{e3}$ **do**

for $M=1:7$ **do**

 Calcula $u(n - \tau_1)$, $\dot{u}(n - \tau_2)$ and $\ddot{u}(n - \tau_3)$

 Calcula Γ como en la Ec. 3.1.8

 Calcula Γ^{-1}

 Calcula Φ_M como en la Ec. 3.1.17

 Normaliza Φ_M

$Error_{new} = \frac{1}{N} \sum_{n=1}^N (\Phi_{M-1} - \Phi_M)^2$

end

if $Error_{new} < Error_{old}$ **then**

$Error_{old} = Error_{new}$

$\tau_1^{best} = \tau_1$

$\tau_2^{best} = \tau_2$

$\tau_3^{best} = \tau_3$

else

end

end

end

end

Aproximación de los parámetros del modelo

A partir de Φ (vector de pesos) y Γ (matriz de bases unitarias) de la Ec. 3.1.10, se construye una nueva matriz Z como en la Ec. 3.1.2, que reúne los elementos algebraicos que reflejan la respuesta cortical al sumarlos. A cada entrada y a cada sujeto le corresponde una matriz Z , por lo que se construyen un total de 70 matrices a partir de los 10 sujetos y las siete realizaciones.

$$Z = [\Phi[1] \begin{bmatrix} \Gamma[1,1] \\ \Gamma[2,1] \\ \dots \\ \Gamma[n,1] \end{bmatrix}, \Phi[2] \begin{bmatrix} \Gamma[1,2] \\ \Gamma[2,2] \\ \dots \\ \Gamma[n,2] \end{bmatrix}, \dots, \Phi[s] \begin{bmatrix} \Gamma[1,s] \\ \Gamma[2,s] \\ \dots \\ \Gamma[n,s] \end{bmatrix}] \quad (3.1.2)$$

Después de construir 70 matrices a partir de Φ (vector de pesos) y Γ (matriz de bases unitarias) y aplicar SVD ($Z = U\Sigma V^T$) para adquirir sus componentes principales, se pueden encontrar diferentes patrones inspeccionando visualmente la matriz V , que dan información sobre la contribución de cada base unitaria.

Validación del modelo

Para validar el modelo propuesto, se consideran dos configuraciones. En la primera (denominada **10sub**), se consideran 10 sujetos para aplicar el método de validación cruzada de exclusión única. En la segunda configuración (etiquetada como **11sub**), se promedian todas las señales EEG procedentes de 10 sujetos y las señales resultantes se establecen como pertenecientes a un undécimo sujeto imaginario. Esta acción pretende resaltar la actividad común entre los sujetos causada por el movimiento inducido en la muñeca. También se aplica el método de validación cruzada leave-one-out. Las métricas de rendimiento para este proyecto son el **VAF** que calcula una relación de varianza residual, el Coeficiente de Correlación de Pearson (**Corr**) para ver cómo de similares son las señales, y el **RMSE** que calcula cuantitativamente el error de estimación (ver Ecs. 3.1.3, 3.1.4, y 3.1.5, respectivamente).

$$VAF = [1 - \frac{var(y(t) - \hat{y}(t))}{var(y(t))}] * 100 \quad (3.1.3)$$

$$Corr = \frac{\sigma_{y(t), \hat{y}(t)}}{\sigma_{y(t)} \sigma_{\hat{y}(t)}} \quad (3.1.4)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_1^N [y(t) - \hat{y}(t)]^2} \quad (3.1.5)$$

Se consideró un filtro polinómico porque existe ruido intrínseco al promediar las señales de salida estimadas. Por lo tanto, se elige el filtro Savitski-Golay (ampliamente utilizado para suavizar señales biomédicas (Savitzky and Golay, 1964)), considerando un equilibrio entre suavidad y distorsión de la señal, y efectos de sesgo (exceso de suavidad) también, al elegir los parámetros del filtro (Dai et al., 2017), (van Breugel et al., 2020).

3.1.7. Marco matemático

Considere $u(n)$ como la señal de entrada (realización), $y(n)$ como la señal de salida (componente con SNR máxima y respuesta cortical contralateral), y $N = 256$ como el número de muestras dada la frecuencia de muestreo seleccionada.

A partir de la Ec. 3.1.6, calcular la derivada numérica de la entrada y la aceleración, filtrar y normalizarlos.

$$\begin{aligned} \dot{u}_D(n) &= \frac{d}{dn} u(n), & \ddot{u}_D(n) &= \frac{d^2}{dn^2} u(n) \\ \dot{u}_{SG}(n) &= SavGol(\dot{u}_D(n)), & \ddot{u}_{SG}(n) &= SavGol(\ddot{u}_D(n)) \\ \dot{u}(n) &= \frac{\dot{u}_{SG}(n)}{std[\dot{u}_{SG}(n)]}, & \ddot{u}(n) &= \frac{\ddot{u}_{SG}(n)}{std[\ddot{u}_{SG}(n)]}, \end{aligned} \quad (3.1.6)$$

donde *SavGol* es el filtro Savitzky-Golay utilizado para reducir el ruido intrínseco causado por procesos numéricos (Savitzky and Golay, 1964), (Dai et al., 2017), y $std[x(n)]$ se calcula como en la Ec. 3.1.7.

$$std[x(n)] = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x(n) - \frac{1}{N} \sum_{n=1}^N x(n))^2}. \quad (3.1.7)$$

Al dividir entre la desviación estándar, los términos de velocidad y aceleración se normalizan. Por lo tanto, la interacción entre los parámetros de movimiento inducido son la base unitaria para la construcción de la matriz Gamma, como se muestra en la Ec. 3.1.8.

$$\begin{aligned}
\Gamma(n, \tau_k) = & [u(n - \tau_1), \dot{u}(n - \tau_2), \ddot{u}(n - \tau_3), \\
& u^2(n - \tau_1), u^3(n - \tau_1), \dots, u^p(n - \tau_1), \dot{u}^3(n - \tau_2), \ddot{u}^3(n - \tau_3), \\
& u(n - \tau_1) \dot{u}(n - \tau_2), u(n - \tau_1) \ddot{u}(n - \tau_3), \dot{u}(n - \tau_2) \ddot{u}(n - \tau_3), \\
& u^2(n - \tau_1) \dot{u}(n - \tau_2), u^2(n - \tau_1) \ddot{u}(n - \tau_3), \dot{u}^2(n - \tau_2) \ddot{u}(n - \tau_3), \\
& u(n - \tau_1) \dot{u}^2(n - \tau_2), u(n - \tau_1) \ddot{u}^2(n - \tau_3), \dot{u}(n - \tau_2) \ddot{u}^2(n - \tau_3), \\
& \dots \\
& u^{p-1}(n - \tau_1) \dot{u}(n - \tau_2), u^{p-1}(n - \tau_1) \ddot{u}(n - \tau_3), \dot{u}^{p-1}(n - \tau_2) \ddot{u}(n - \tau_3)],
\end{aligned} \tag{3.1.8}$$

donde τ_1 , τ_2 y τ_3 son los retardos temporales de la posición angular, la velocidad y la aceleración, respectivamente, y p es el grado del modelo, que se establece mediante un compromiso entre el rendimiento del grado de 15 modelos diferentes y su coste computacional (número de parámetros a calcular).

La señal de salida estimada se calcula como en las Ecs. 3.1.9 y 3.1.10.

$$\begin{aligned}
\hat{y}(n, \tau_k) = & a_1 u(n - \tau_1) + a_2 \dot{u}(n - \tau_2) + \dots \\
& + a_{s-1} u^{p-1}(n - \tau_1) \ddot{u}(n - \tau_3) + a_s \dot{u}^{p-1}(n - \tau_2) \ddot{u}(n - \tau_3)
\end{aligned} \tag{3.1.9}$$

$$\hat{y}(n, \tau_k) = \Phi^T \Gamma(n, \tau_k) \tag{3.1.10}$$

donde $\Phi = [a_1, a_2, \dots, a_{s-1}, a_s]$ es el vector de pesos que contiene la contribución de cada base unitaria situada en el espacio de columnas de la matriz $\Gamma(n, \tau_k)$. Por último, calcular Φ como en la Ec. 3.1.17.

$$\tilde{y}(n, \tau_k) = y(n) - \hat{y}(n, \tau_k) \tag{3.1.11}$$

$$f(n, \tau_k, \Phi) = \frac{1}{2N} \sum_{n=1}^N \tilde{y}^2(n, \tau_k) \tag{3.1.12}$$

$$f(n, \tau_k, \Phi) = \frac{1}{2N} \sum_{n=1}^N (y(n) - \Phi^T \Gamma(n, \tau_k))^2 \tag{3.1.13}$$

$$\frac{\partial f(n, \tau_k, \Phi)}{\partial \Phi} = \frac{1}{N} [\sum_{n=1}^N (y(n) - \Phi^T \Gamma(n, \tau_k)) [-\Gamma^T(n, \tau_k)] \tag{3.1.14}$$

$$-\frac{1}{N} \sum_{n=1}^N y(n) \Gamma^T(n, \tau_k) + \Phi^T \frac{1}{N} \sum_{n=1}^N \Gamma(n, \tau_k) \Gamma^T(n, \tau_k) = 0 \tag{3.1.15}$$

$$\frac{1}{N} \sum_{n=1}^N \Gamma(n, \tau_k) \Gamma^T(n, \tau_k) \Phi = \frac{1}{N} \sum_{n=1}^N \Gamma(n, \tau_k) y^T(n) \tag{3.1.16}$$

$$\Phi = (\sum_{n=1}^N \Gamma(n, \tau_k) \Gamma^T(n, \tau_k))^{-1} \sum_{n=1}^N \Gamma(n, \tau_k) y^T(n) \tag{3.1.17}$$

3.2. Resultados

En esta sección, la localización de la actividad cerebral resultante, el grado final del modelo, los mejores retrasos temporales del modelo propuesto y la tabla de validación del modelo se describen en las subsecciones 3.2.1, 3.2.2, 3.2.3, y 3.2.4, respectivamente.

3.2.1. Topología de la respuesta cortical

Después de aplicar ICA, se identificaron las respuestas corticales causadas por las siete realizaciones eligiendo el componente con SNR máxima y trazando su topología mostrando una actividad contralateral. La Fig. 3.2.1 muestra las respuestas corticales de diez sujetos cuando se aplicó la primera realización M0.

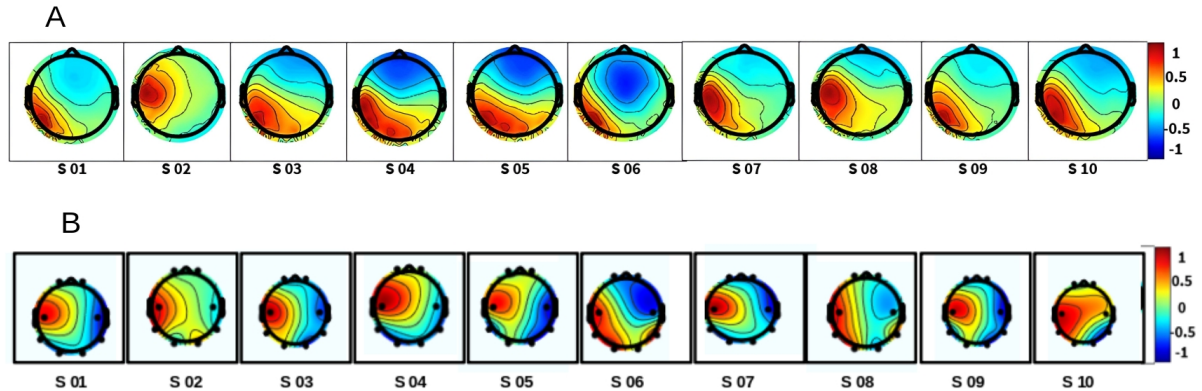


Figura 3.2.1: Topología de la respuesta cortical para diez sujetos y primera realización M0, para (A) Base de datos NL_TU_DELFIT_DB, y (B) Base de datos MX_UDLAP_DB.

A partir de la Fig. 3.2.1, la actividad cerebral es similar para la mayoría de los sujetos y se localiza en la corteza motora contralateral (área central izquierda), teniendo en cuenta que el movimiento se induce en la mano derecha. Estos resultados son similares a los obtenidos por Vlaar et al. (2018), con la ventaja de una menor complejidad computacional y, por tanto, un método más rápido para obtener la respuesta cortical.

3.2.2. Establecer el grado de modelo

En términos de rendimiento (véase la parte izquierda de la Fig. 3.2.2), cuando el grado del modelo es 10, el VAF se sitúa entre el 70 % y el 80 % con 165 parámetros que hallar. Considerando un modelo de grado 12, hay 234 parámetros que calcular, alcanzando un VAF en torno al 90 %. Cuando el grado del modelo es 13, hay que calcular 273 parámetros, y el VAF aumenta hasta casi el 100 %, sin embargo, como se ha indicado anteriormente, se pierde algo de información sobre las bases algebraicas.

Además, en cuanto al número de parámetros, si se elige el modelo de grado 13 (considerando 273 parámetros), podría perderse alguna información de las bases algebraicas causada por el truncamiento de la matriz de valores propios Σ (cuya dimensión es 256, la misma que la frecuencia de muestreo). Por lo tanto, se selecciona el modelo más cercano, es decir, el modelo de 12º grado con 234 parámetros para calcular (véase la parte derecha de la Fig. 3.2.2).

En este sentido, en relación con el modelo de grado 12, un modelo de grado más bajo tendrá un rendimiento más bajo, y uno más alto, llegando a VAF 100 %, posiblemente podría tener efectos de sobreajuste, que no es deseable cuando se computa un modelo general, ya que limita la adición de más sujetos al experimento.

Por lo tanto, para fines de modelado matemático en el presente trabajo, el modelo de grado




Figura 3.2.2: Izquierda: VAF Vs Grado del modelo. Derecha: Número de parámetros en función del grado del modelo, realización M=1.

12 permite construir una base algebraica para explicar la respuesta cortical provocada por la manipulación de la muñeca.

3.2.3. Mejores retrasos temporales del modelo

Exploración: La parte izquierda de la Fig. 3.2.3 muestra la exploración de la partícula $Q = [\tau_1, \tau_2, \tau_3]$ para encontrar los mejores retardos del modelo. Este proceso comienza con una resolución baja ($step = 6$ unidades, equivalente a 23.4ms, considerando una frecuencia de muestreo de 256Hz) a través de todo el espacio delimitado de 1 a 128 ($\tau_{b1} = \tau_{b2} = \tau_{b3} = 1$, y $\tau_{e1} = \tau_{e2} = \tau_{e3} = 128$), donde 128 muestras representan un retardo de 500ms. La mejor solución es $Q = [72, 12, 18]$ muestras.

Explotación: Después de la exploración, la explotación de la partícula se realiza considerando la resolución más alta ($step = 1$) alrededor de la última mejor partícula (véase la parte derecha de la Fig. 3.2.3). Los nuevos límites de cada eje se determinan sumando/restando el valor $step$ anterior ($step = 6$) a los valores anteriores de la mejor partícula de retardo.

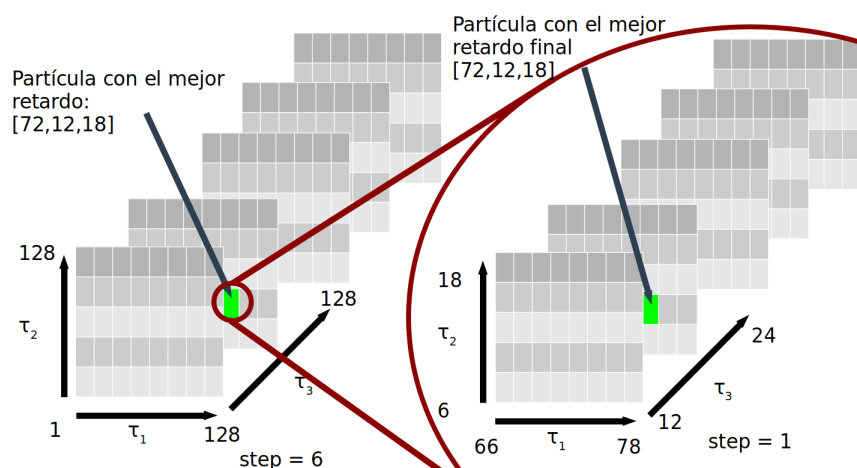


Figura 3.2.3: Exploración (izquierda) y explotación (derecha) para encontrar los mejores retardos del modelo propuesto.

Los mejores retardos del modelo para la posición angular, la velocidad y la aceleración fue-

ron de 281ms, 47ms y 70ms, respectivamente, correspondientes a $\tau_1 = 72$, $\tau_2 = 12$ y $\tau_3 = 18$ muestras, respectivamente, con una frecuencia de muestreo de 256Hz.

3.2.4. Validación del modelo

Las métricas VAF y Correlación son importantes para esta investigación porque reflejan el rendimiento del modelo centrándose en aspectos diferentes. Mientras que la métrica VAF resalta la relación de varianza entre la señal de error y la respuesta cortical (100% VAF indica señales idénticas, por lo tanto, los valores altos de VAF reflejan un mejor rendimiento del modelo), la Correlación de Pearson muestra la similitud entre la respuesta cortical identificada y su estimación. Los resultados del proceso de validación cruzada para ambas configuraciones (bases de datos NL_TU_DELFDT_DB y MX_UDLAP_DB) se muestran en la Tabla 3.2.1.

Tabla 3.2.1: Resultados de la validación del modelo

Entrada Externa	Base de datos NL_TU_DELFDT_DB			Base de datos MX_UDLAP_DB		
	Corr	VAF(%)	RMSE	Corr	VAF(%)	RMSE
M0	0.9505	90.3292	0.1302	0.8937	78.3436	0.1607
M1	0.9583	91.6559	0.0960	0.8490	68.5446	0.1984
M2	0.9766	95.3048	0.0731	0.9021	77.8938	0.2658
M3	0.9541	90.9029	0.1177	0.8576	73.0310	0.2478
M4	0.9434	88.2549	0.1159	0.8686	75.0271	0.2668
M5	0.9396	87.9265	0.1138	0.8873	77.7760	0.1503
M6	0.9498	90.0318	0.0970	0.9019	80.5294	0.2199
media	0.9531	90.6294	0.1062	0.8800	75.8779	0.2156
std	0.0111	2.2796	0.0175	0.0200	3.7414	0.0443

La métrica RMSE mostró resultados diferentes al comparar los procesos de validación cruzada en M5 y M0 con respecto a la base de datos NL_TU_DELFDT_DB (véase la Tabla 3.2.1). Mientras que las métricas VAF y Correlación indican que el peor rendimiento del modelo se da en M5 (87.9265% VAF y 0.9396 Correlación), la métrica RMSE indica que el peor rendimiento se da en M0 (0,1302). En cuanto a la base de datos MX_UDLAP_DB, ocurre lo mismo en M1 y M4. Esto puede explicarse por el hecho de que incluso pequeños cambios en la señal tienen un gran impacto en el rendimiento del modelo cuando se utiliza la métrica RMSE. Por lo tanto, se aconseja el uso de VAF y la correlación para evaluar el rendimiento del modelo de trabajos relacionados.

Por último, de la Tabla 3.2.1, el mejor rendimiento promedio del modelo es $90.63\% \pm 2.28\%$ VAF, y $95.31\% \pm 1.11\%$ Correlación, lo que indica que, al resaltar el comportamiento promedio de la respuesta cortical provocada por la manipulación de la muñeca, se enfatizan las relaciones intrínsecas entre los sujetos y se mejora el rendimiento del modelo.

3.3. Discusión

En esta sección se explican la respuesta cortical modelada, el modo de funcionamiento generalizado y predominante, y la base algebraica correspondiente. Al final de esta sección se ofrece una interpretación fisiológica de los mejores retardos del modelo basada en trabajos anteriores.

3.3.1. Análisis de la respuesta cortical modelada

El gráfico superior de la Fig. 3.3.1 muestra en azul la respuesta cortical registrada para el sujeto **S_01** cuando se aplica la perturbación **M1**, y la señal naranja representa la respuesta cortical estimada calculada a partir de la primera configuración de validación cruzada **10sub**. Algo de ruido intrínseco está representado por algunos picos centrados en las muestras 10, 50 y 120, aproximadamente (sombreados en círculos rojos). Después del filtro SavGol (mejores parámetros en $windowlength = 7$ y $polyorder = 3$), estos picos se atenúan y disminuyen suavemente, por lo tanto, el rendimiento del modelo mejoró al aumentar la correlación en porcentaje (de 93.74% a 94.81%), los valores VAF (de 87.8336% a 89.7890%) y disminuir el RMSE (de 0.1259 a 0.1153).

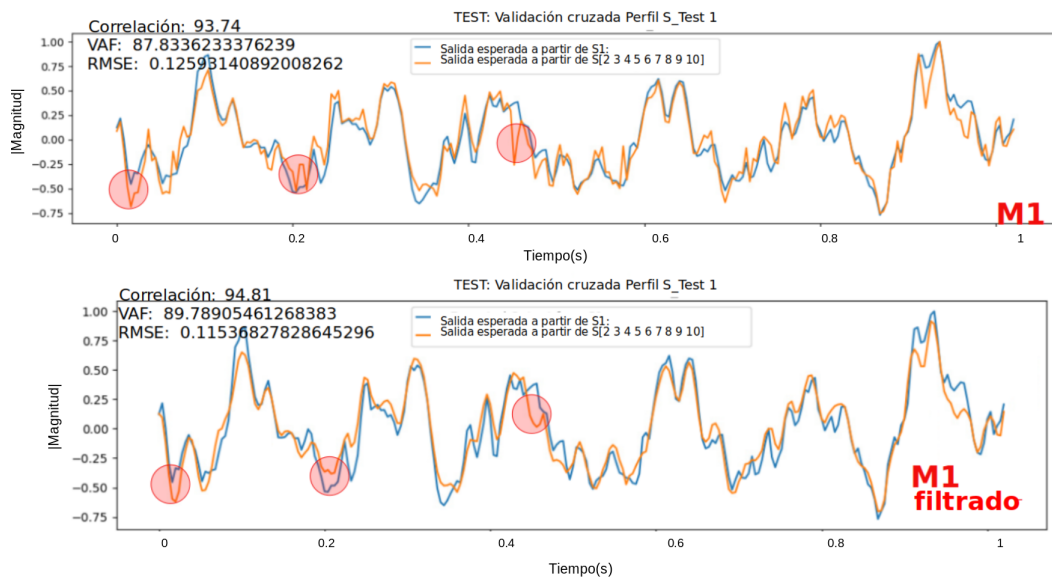


Figura 3.3.1: La respuesta cortical esperada (azul) y estimada (naranja) corresponden a la primera prueba de validación cruzada sin el filtro SavGol (gráfico superior) y después del filtro (gráfico inferior) cuando se aplica la realización **M1**.

Es importante mencionar que estos resultados se obtienen a partir de un modelo de grado 12 para todos los sujetos y todas las realizaciones, incluyendo 234 parámetros a calcular, lo que es contrario al trabajo de Nozari et al. (2020), donde el número de parámetros cambia según cada sujeto y cada realización, lo que no permite tener un modelo general de la respuesta cortical que es el objetivo principal de este trabajo.

3.3.2. Modo de funcionamiento predominante general y base algebraica

La parte izquierda de la Fig. 3.3.2 muestra el promedio de las señales de respuesta al impulso Φ (vector de pesos) para todos los sujetos en la configuración de validación cruzada **10sub** para la realización **M0**. Comparando visualmente los gráficos, se puede observar que todos los sujetos presentan una respuesta al impulso similar para cada realización, lo que significa que el comportamiento intrínseco es el mismo entre todos ellos, pero ligeramente diferente entre realizaciones.

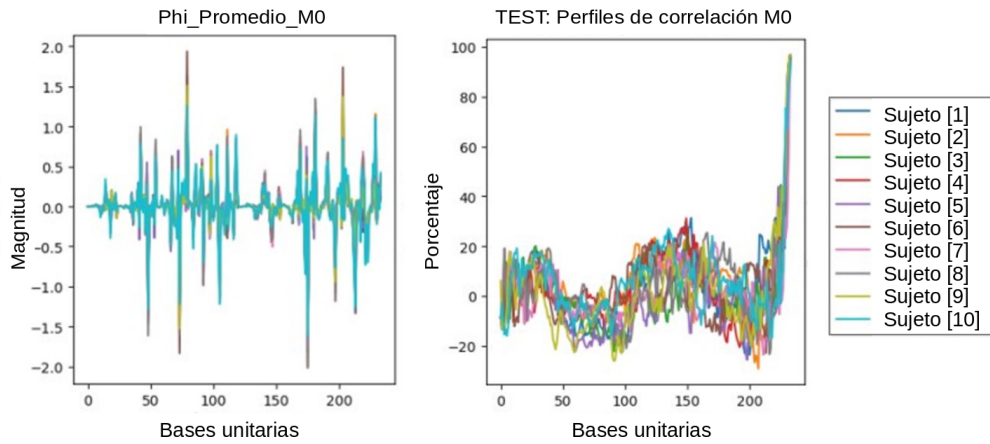


Figura 3.3.2: **Modo de funcionamiento predominante o respuesta al impulso (izquierda), y perfil de correlación (derecha) para la realización M0.**

La tabla 3.3.1 muestra que, de los 234 parámetros del modelo propuesto de grado 12 , 10 de ellos incluyen potencias pares y contribuyen a una cuarta parte de la respuesta general del cerebro. Además, nueve de esos términos del modelo (resultado del producto punto entre varias potencias de la velocidad angular de entrada, \mathbf{u}_{τ_2} , y la aceleración, \mathbf{u}_{τ_3}) tienen su valor pico en 10Hz y 12Hz, y luego descienden en amplitud a 22Hz, 24Hz, 32Hz, y 34Hz (ver Fig. 3.3.3). Esto sugiere que esos términos del modelo están fisiológicamente relacionados con la intermodulación de las frecuencias excitadas en la entrada, ya que solo las frecuencias impares están contenidas en la perturbación, resaltando el carácter dominante de las potencias pares de la perturbación (lo que concuerda con hallazgos anteriores de Vlaar (2017)) y el impacto de la aceleración del movimiento en la respuesta cortical común debida a \mathbf{u}_{τ_3} .

Tabla 3.3.1: Contribución acumulativa de los términos M0 con más energía del movimiento inducido (bases unitarias) a la respuesta cerebral generalizada

Parámetro	(%)	Parámetro	(%)
$\mathbf{u}_{\tau_2}^4 \mathbf{u}_{\tau_3}^6$	3.2686	$\mathbf{u}_{\tau_2}^3 \mathbf{u}_{\tau_3}^5$	16.654
$\mathbf{u}_{\tau_2}^2 \mathbf{u}_{\tau_3}^8$	6.18	$\mathbf{u}_{\tau_1}^{10}$	19.0871
$\mathbf{u}_{\tau_2}^5 \mathbf{u}_{\tau_3}^5$	8.994	$\mathbf{u}_{\tau_2} \mathbf{u}_{\tau_3}^9$	21.4445
$\mathbf{u}_{\tau_2}^2 \mathbf{u}_{\tau_3}^6$	11.5781	$\mathbf{u}_{\tau_2}^4 \mathbf{u}_{\tau_3}^4$	23.7298
$\mathbf{u}_{\tau_2}^3 \mathbf{u}_{\tau_3}^7$	14.1478	$\mathbf{u}_{\tau_2} \mathbf{u}_{\tau_3}^7$	25.9509

En términos de perfiles de correlación, estos ilustran el rendimiento del modelo a medida que los términos del modelo se añaden uno en uno, alcanzando su punto máximo después de que se hayan incluido todos los términos. Los perfiles de correlación para la configuración de validación cruzada **10sub** para la realización M0 (véase la parte derecha de la Fig. 3.3.2) reflejan las bases algebraicas que producen la respuesta cerebral de cada sujeto, indicando una tendencia común del rendimiento del modelo entre los individuos, y, por lo tanto, destacando un comportamiento común de las respuestas cerebrales entre los participantes.




Figura 3.3.3: **Dominio en frecuencia de los biomarcadores potenciales.**

La correlación entre la salida esperada y la estimada tiene un signo positivo y el valor más alto al final, pero ocasionalmente el signo se invierte (se puede encontrar una situación similar en Gu et al. (2021)). Dado que los datos son discretos, es de esperar que se produzcan cambios de signo al calcular los coeficientes de correlación. Nuestros hallazgos sugieren que las potencias pares e impares de la realización pueden ser la causa de este cambio de signo, es decir, ya que la entrada sólo tiene frecuencias impares, el signo de la señal estimada puede cambiar cuando se suman los componentes pares o impares.

A partir de estas observaciones, para ilustrar la contribución específica de la aceleración angular, se calcularon dos modelos: El primer modelo considera únicamente los términos de posición angular y velocidad, y el segundo incluye la aceleración. La Fig. 3.3.4 muestra esos resultados para los participantes incluidos en el conjunto de datos NL_TU_DELFIT_DB.

A partir de la Fig. 3.3.4, los resultados experimentales sugieren que es importante incluir la aceleración angular a la hora de estimar la respuesta cerebral causada por la manipulación de la muñeca, ya que el rendimiento del modelo mejoró con respecto a ambas métricas, Correlación y VAF, destacando el impacto de la aceleración angular en el modelo propuesto.

Por último, en esta tesis se presenta un enfoque más amplio, que considera no solo la posición angular (Vlaar et al., 2018) y la velocidad (Tian et al., 2018), sino también la aceleración, lo que permite un marco más amplio en el que los respectivos retardos temporales reflejan vías fisiológicas específicas.

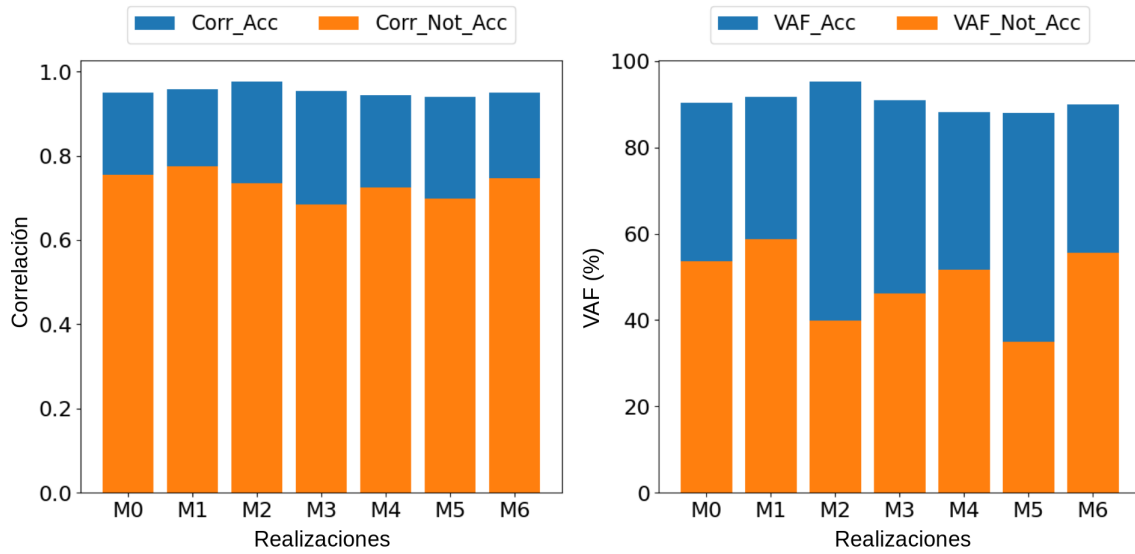


Figura 3.3.4: Comparación del rendimiento de los modelos al incluir (_Acc) o no (_Not_Acc) la aceleración angular: Correlación (izquierda) y VAF (derecha).

3.3.3. Contribución de los poderes par e impar de la realización a la respuesta cortical

Tras construir 70 matrices a partir de Φ (vector de pesos) y Γ (matriz de bases unitarias) (véase la subsección 3.1.6) y aplicar SVD ($Z = U\Sigma V^T$) para adquirir sus componentes principales, aparecieron dos patrones correspondientes a las potencias pares e impares de la realización. Se calcularon los valores medios de estos componentes en las 70 matrices (considerando todos los sujetos y todas las realizaciones), con lo que apareció el mismo comportamiento que se muestra en la Fig. 3.3.5.

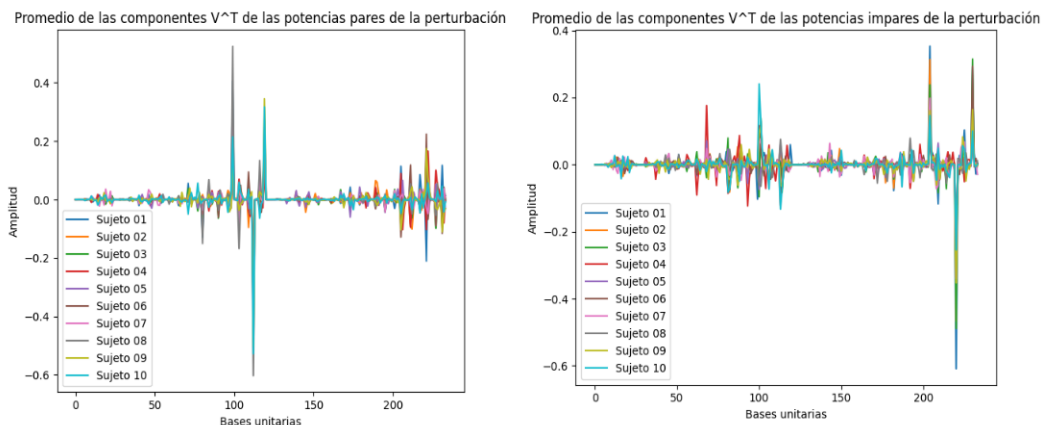


Figura 3.3.5: Promedio de V^T para potencias pares de entrada (izquierda). Promedio de V^T para potencias impares de entrada (derecha).

A partir del proceso SVD, la matriz V^T proporcionó información sobre las bases unitarias más relevantes que contribuyeron relativamente a la respuesta cortical (ver Tabla 3.3.2), ya que dicha información se encuentra en diferentes componentes principales.

Tabla 3.3.2: Valores medios de las 70 matrices (todos los sujetos y todas las realizaciones) de las bases unitarias pares e impares más relevantes que contribuyen relativamente a la respuesta cortical.

Potencias pares (%)	Potencias impares (%)		
$\mathbf{u}_{\tau_1}^{12}$	6.2381	$\mathbf{u}_{\tau_1}^{11}$	5.6994
$\mathbf{u}_{\tau_1}^{10}$	11.3819	$\mathbf{u}_{\tau_1}^9$	10.1282
$\mathbf{u}_{\tau_1}^8$	7.7666	$\mathbf{u}_{\tau_1}^7$	6.1263
$\mathbf{u}_{\tau_1}^6$	2.7260	$\mathbf{u}_{\tau_1}^5$	2.0961
$\mathbf{u}_{\tau_1}^4$	0.9150		

Haciendo una comparación entre la tabla 3.3.1 y la tabla 3.3.2, la contribución relativa del 11.3819% de $\mathbf{u}_{\tau_1}^{10}$ puede interpretarse como 19.0871 menos 16.654 (véase la tabla 3.3.1), lo que da como resultado una contribución del 2.4331% a la respuesta cortical general. En este sentido, la contribución de las potencias pares e impares de la entrada (\mathbf{u}_{τ_1}) a la respuesta cortical son 6.2052% y 5.1411%, respectivamente. Estos resultados muestran que el comportamiento par es dominante, lo que concuerda con el trabajo anterior de Vlaar et al. (2018).

Yang et al. (2016) descubrieron que existe un acoplamiento cortico-muscular no lineal mediante el método de acoplamiento de frecuencias cruzadas (coherencia n:m). Detectaron acoplamiento no lineal tanto para armónicos enteros (proporciones 1:2, 1:3 y 1:4) como para armónicos no enteros, es decir, acoplamiento neural con una proporción 2:3 entre la actividad cerebral y muscular.

Además, las conexiones de bucle cerrado como el modelo NARX pueden estimar más información sobre la dinámica de la muñeca (Gu et al., 2021) que las conexiones de bucle abierto como el modelo de Volterra (Vlaar et al., 2018). Sin embargo, la respuesta del cerebro tiene más armónicos que no se explican y su fuente de generación no se comprende bien. Nuestros resultados indican que las potencias pares e impares de la entrada producen dichos armónicos, es decir, que las diferentes potencias reproducen el efecto de retroalimentación de la conexión de bucle cerrado.

Estos resultados sugieren que el orden de los patrones en términos de porcentaje de contribución general a la respuesta cortical tanto en los términos pares ($\mathbf{u}_{\tau_1}^{10}$, $\mathbf{u}_{\tau_1}^8$, y $\mathbf{u}_{\tau_1}^{12}$) como en los impares ($\mathbf{u}_{\tau_1}^9$, $\mathbf{u}_{\tau_1}^7$, y $\mathbf{u}_{\tau_1}^{11}$) podrían utilizarse como huella potencial para caracterizar el comportamiento común de la respuesta del cerebro sano y joven provocada por una manipulación específica de la muñeca. Por lo tanto, la disposición de cada patrón descubierto en las potencias pares e impares también se puede sugerir como un biomarcador potencial adicional.

3.3.4. Interpretación fisiológica

El sistema propioceptivo es un elemento clave para convertir eventos mecánicos (percibidos a través de mecanorreceptores, como husos musculares u órganos tendinosos de Golgi (Vlaar, 2017)) en señales neurales (Riemann and Lephart, 2002), donde los registros EEG de la actividad cerebral reflejan la contribución de muchas neuronas a nivel macroscópico. Tras aplicar ICA a las grabaciones de EEG filtradas, el componente con máxima SNR (encontrado en el lado contralateral de la perturbación) representa la fuente de activación de la respuesta cerebral causada por la manipulación externa de la muñeca.

Además, con respecto a los parámetros de retardo temporal τ_2 y τ_3 del modelo propuesto (47ms y 70ms, respectivamente), la información de la velocidad angular y la aceleración de la perturbación se envía al cerebro a través de los grupos Ia-aférente y Ib-aférente, respectivamente, y procesada por un modelo lateral izquierdo parcialmente modulado (Yang et al., 2017), que refleja la tasa de cambio de los comportamientos de estiramiento muscular y explosivo provocados por la fuerza aplicada a la muñeca (Yang et al., 2016), respectivamente. Onishi et al. (2013) informó de periodos de tiempo similares (36.2 ± 8.2 ms, y 86.1 ± 12.1 ms) para los movimientos pasivos de los dedos.

La posición angular de la muñeca es la señal más lenta enviada al cerebro (281 ms de retardo temporal) a través del grupo II-aférente, lo que sugiere una respuesta de latencia larga que implica a más áreas cerebrales y que es procesada por un modelo lateral izquierdo totalmente modulado (Yang et al., 2017).

En resumen, los resultados obtenidos sugieren que los productos de intermodulación derivados de las señales retardadas de la velocidad y la aceleración de la perturbación de la muñeca (y controlados por los grupos Ia-aférente y Ib-aférente, respectivamente) desempeñan un papel significativo en el comportamiento no lineal de la respuesta cortical general, destacando el dominio de las frecuencias pares no excitadas asociadas a las potencias pares de los términos del modelo.

Por lo tanto, aquellos términos del modelo que exhiben las mayores amplitudes de la respuesta general al impulso cuando se consideran todos los sujetos y todas las realizaciones se sugieren como posibles biomarcadores a utilizar en futuras investigaciones sobre la actividad cerebral de individuos con deficiencias motoras de los miembros superiores.

Capítulo 4

Estimación proporcional de la fatiga muscular durante la flexión isométrica de la muñeca mediante electromiografía de superficie

En el capítulo anterior, se consideró el modelado de la actividad cerebral cuando fuerzas externas perturban las extremidades superiores. Para tener un enfoque más amplio, en este capítulo se describe el modelado de la fatiga del antebrazo a partir de la actividad muscular exclusivamente, incluyendo la descripción del protocolo experimental propuesto, la metodología y la discusión de los resultados.

4.1. Introducción

La fatiga muscular es un síntoma físico experimentado con frecuencia por las personas. Principalmente, se entiende como una disminución gradual de la capacidad para mantener tareas físicas, y depende de la actividad específica que se esté realizando. En esencia, la fatiga denota una reducción de la capacidad de los músculos para generar fuerza o potencia durante un determinado ejercicio. Esta perspectiva hace hincapié en el hecho de que la fatiga se caracteriza por una aparición gradual que se produce tras iniciar un esfuerzo físico prolongado, y no por el momento en el que la tarea fracasa.

Los métodos clásicos para medir la fatiga muscular consideran escalas de nivel de percepción como la Escala de Fatiga de Chalder (Jackson, 2015), el Inventario Multidimensional de Fatiga (IMF) (Smets et al., 1995) o la Escala CR-10 de Borg (Williams, 2017), y estimadores de fatiga como el Índice de Mapeo Generalizado (GMI) (Rogers and MacIsaac, 2010), o la Puntuación de Fatiga Multimuscular (MMFS) (McDonald et al., 2019). Todas estas escalas convencionales se basan en la percepción subjetiva del encuestado y tienen un número limitado de niveles y un comportamiento no lineal. Además, a pesar de que los enfoques de los índices GMI y MMFS muestran métodos útiles para el seguimiento y la estimación de los niveles de fatiga, son incapaces de señalar un estado exacto de fatiga, como un valor porcentual. Esta laguna en la literatura es especialmente relevante para las personas con deficiencias motoras, ya que una comprensión exhaustiva de la fatiga muscular es crucial para el seguimiento de las mejoras en las sesiones de rehabilitación.

La instrumentación médica es otra forma útil de abordar esta cuestión. Algunos trabajos incluyen sensores de fibra óptica (OFS) y unidades de medición inercial (IMU) (Otálora et al., 2023) o incluso imágenes de ultrasonido (Li et al., 2020). Otro método bien conocido para estimar la fatiga muscular es la electromiografía de superficie (sEMG). Dentro de este enfoque, los primeros esfuerzos analizaron la fatiga como una tarea de clasificación binaria (Subasi and Kiyimik, 2010; Venugopal et al., 2014), identificando los estados fatigado y no fatigado. A continuación, se consideró un tercer estado, denominado transición a la fatiga (Al-Mulla et al., 2011a,b), estado de semifatiga (Dang et al., 2023), o fase amarilla 2 (González-Zamora et al., 2023), alcanzando rendimientos del modelo superiores al 90 % de precisión. A pesar de su utilidad, los trabajos citados no proporcionan una estimación proporcional de la fatiga.

Esta estimación proporcional de la fatiga muscular podría ser especialmente útil en el ámbito de la rehabilitación, donde el entrenamiento isométrico se ha utilizado durante las sesiones de terapia, mostrando mejoras sustanciales en la producción de fuerza máxima, la morfología muscular, y la estructura y función del tendón (Oranchuk et al., 2019). Por lo tanto, en este trabajo se considera una tarea de contracción isométrica para realizar un seguimiento de la fatiga muscular de los participantes. Sabiendo esto, proponemos estimar cuantitativamente el nivel de fatiga sobre el flexor carpi radialis (escasamente analizado debido a que los trabajos anteriormente mencionados se centran mayoritariamente en músculos bíceps o tríceps) mediante un enfoque basado en el análisis de las características de la señal EMG del músculo fatigado y aplicando posteriormente una regresión multidimensional para decodificar niveles de fatiga proporcionales establecidos entre 0% y 100%. Esto proporciona una forma mucho más precisa de determinar la fatiga muscular, y supera los enfoques EMG anteriores que sólo proporcionan una estimación de un número limitado de niveles de fatiga.

4.2. Materiales

4.2.1. Experimental Setup

Para medir la actividad muscular y la fuerza, se ha utilizado un sistema sEMG bipolar Noraxon miniDTS para adquirir la actividad de los músculos flexores y extensores con una frecuencia de muestreo de 1500 Hz, y un sensor Optoforce de 6 ejes para medir la fuerza ejercida en flexión de la muñeca con una frecuencia de muestreo de 1000 Hz. Para adquirir y procesar todos los datos se ha utilizado un ordenador portátil con sistema operativo Windows 10, Intel Core i7 de 11ª generación, 735 GB de almacenamiento interno, 16 GB de RAM y GPU NVIDIA GeForce RTX 3050 de 12 GB. Se desarrolló una interfaz para mostrar información visual de la fuerza ejercida por el participante sobre la articulación acoplada al sensor de fuerza. Para sincronizar la fuerza y la información muscular se ha programado un Arduino UNO para enviar un trigger analógico entre dispositivos (ver Fig. 4.2.1).

4.2.2. Protocolo Experimental

Diez sujetos (cinco mujeres) sin lesión muscular en el antebrazo (28.5 ± 8.3 de edad media, nueve de los cuales presentan lateralidad derecha) participaron en este estudio. Todos los registros se realizaron siguiendo el consenso sobre Normas de Instrumentación EMG (Tankisi et al., 2020). Todos los usuarios firmaron un consentimiento informado antes de realizar cada experimento de acuerdo con la declaración de Helsinki (protocolo UA-2023-10-04).




Figura 4.2.1: Esquema del montaje experimental para realizar la contracción isométrica y registrar la actividad muscular.

Al comienzo del experimento (véase la Fig. 4.2.1), cada participante está sentado cómodamente en una silla y apoya la muñeca dominante en un soporte. Se utiliza una correa de velcro para bloquear la muñeca.

El acto de doblar la mano hacia abajo por la muñeca de forma que la palma quede orientada hacia el brazo se conoce como flexión de muñeca (Hersh, 2019). Este tipo de movimiento de la mano dominante es ejercido por cada participante siguiendo dos pasos:

1. El participante realiza una fuerza máxima (en la articulación vinculada al sensor de fuerza) durante el movimiento de flexión de la mano dominante para registrar la fuerza de contracción voluntaria máxima (MVC) que refleja la fuerza máxima del participante.
2. El participante realiza una fuerza MVC continua del 40% (en la articulación vinculada al sensor de fuerza) durante el movimiento de flexión de la muñeca dominante para registrar la actividad muscular hasta la fatiga. Se realiza una pausa para que la muñeca y el antebrazo descansen de su agotamiento. Se realizan dos iteraciones más de esta etapa con una pausa entre repeticiones para la recuperación muscular.

4.3. Métodos

En esta sección se describe la metodología propuesta para estimar la fatiga durante la contracción isométrica, que consta de seis pasos principales: (A) Inicio, que implica el preprocesamiento de las señales en bruto; (B) Segmentación de la señal; (C) Remuestreo; (D) Extracción de características; (E) Entrenamiento del modelo, y (F) Validación del modelo (Fig. 4.3.1).

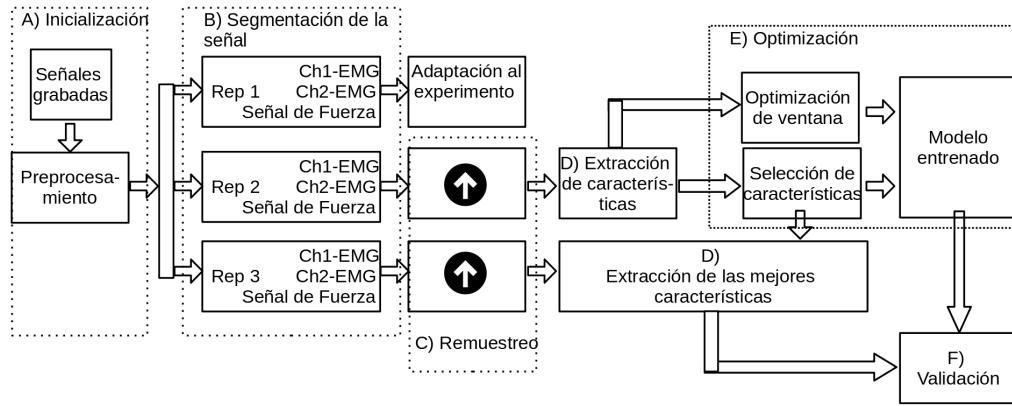


Figura 4.3.1: Metodología principal dividida en seis pasos: (A) Inicio; (B) Segmentación de la señal; (C) Remuestreo; (D) Extracción de características; (E) Entrenamiento del modelo, y (F) Validación del modelo.

4.3.1. Inicio (Paso A)

Antes de extraer las características, se detecta una señal de ruido de 83,5 Hz y sus armónicos en las señales EMG, que pueden ser el resultado de factores externos como los componentes eléctricos utilizados en el experimento. Por lo tanto, en el paso (A), se realiza una etapa de preprocesamiento de las señales grabadas, en la que se utiliza un filtro de muesca de 50 Hz para disminuir el ruido de la línea eléctrica. También se aplica a los canales de sEMG un filtro de paso de banda de cuarto orden con desplazamiento de fase cero y frecuencias de corte de 1 Hz y 400 Hz. A continuación, se añadieron filtros de corte adicionales para disminuir el ruido de 83,5 Hz y sus armónicos. Por último, se restó la media de la señal para eliminar el componente de CC. Estos filtros se aplican a los canales EMG. Se utiliza un filtro de media móvil en las señales de fuerza para eliminar los movimientos musculares involuntarios del participante.

4.3.2. Segmentación de la señal (Paso B)

En este paso, las señales preprocesadas se segmentan para cada repetición, utilizando los datos de disparo (activados a través del Arduino UNO) al principio y al final de cada repetición, donde Rep k indica la k -ésima repetición de la tarea de contracción muscular isométrica ($k = 1, 2, 3$), y Ch1-EMG y Ch2-EMG corresponden a las señales flexora y extensora del carpo radialis, respectivamente (ver Fig. 4.3.1).

4.3.3. Remuestreo (Paso C)

Tras el proceso de segmentación, la señal de fuerza se amplía a 1500 Hz, ya que las señales de fuerza y EMG se registraron con frecuencias de muestreo diferentes. Durante la primera repetición, el participante se está adaptando al movimiento específico de la muñeca que requiere

el experimento para realizar la tarea de contracción isométrica, a la que el participante no está acostumbrado.

4.3.4. Extracción de características (Paso D)

En este paso, se extrae un conjunto de características de las señales sEMG, es decir, se considera para el modelado la señal de fuerza más 18 características extraídas de los canales flexor y extensor. Las tablas 4.3.1:4.3.3 las describen, mostrando las ecuaciones correspondientes implementadas en este trabajo, donde:

N es el número total de muestras,

x_i es la i -ésima muestra,

μ representa el valor medio,

$sgn(x)$ es 1 cuando $x \geq umbral$ o 0 en caso contrario,

$f(x)$ es 1 cuando $x \geq umbral$ o 0 en caso contrario,

P_j es el valor del espectro de potencia en el j -ésimo bin,

$[f1, f2]$ & $[f3, f4]$ son intervalos para frecuencias bajas y altas, respectivamente,

M es la longitud total del vector del espectro de potencia,

$x(max(P))$ es el índice del valor máximo del espectro de potencia,

p_i representa la probabilidad asignada a los distintos niveles de energía por la transformada wavelet,

f_j es el valor de la frecuencia en el j -ésimo bin.

Tabla 4.3.1: Características extraídas de la señal sEMG.

Ecuación	Característica
$VAR = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2 \quad (4.3.1)$	<p>La varianza (VAR) evalúa la diferencia entre cada valor y el valor medio y se utiliza ampliamente para describir la dispersión (Spiewak, 2018).</p>
$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4.3.2)$	<p>La raíz cuadrática media (RMS) proporciona información sobre la fuerza que puede producir un músculo (Spiewak, 2018).</p>
$IEMG = \sum_{i=1}^N x_i \quad (4.3.3)$	<p>La EMG integrada (IEMG) se utiliza con frecuencia como medida previa a la activación de la actividad muscular (Spiewak, 2018).</p>
$MAV = \frac{1}{N} \sum_{i=1}^N x_i . \quad (4.3.4)$	<p>El valor absoluto medio (MAV) es un método para determinar y cuantificar la contracción muscular (Spiewak, 2018).</p>
$LOG = e^{\frac{1}{N} \sum_{i=1}^N \log(x_i)}. \quad (4.3.5)$	<p>El Detector Logarítmico (LOG) proporciona una estimación de la fuerza muscular (Tkach et al., 2010).</p>
$WL = \sum_{i=1}^N x_{i+1} - x_i \quad (4.3.6)$	<p>La longitud de la forma de onda (WL) refleja una medida de la amplitud, frecuencia y duración de la forma de onda (Spiewak, 2018).</p>
$AAC = \frac{1}{N} \sum_{i=1}^N x_{i+1} - x_i \quad (4.3.7)$	<p>El cambio de amplitud media (AAC) indica el grado de activación muscular (Jayaweera, 2021).</p>

Tabla 4.3.2: Características extraídas de la señal sEMG (cont).

$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_{i+1} - x_i)^2} \quad (4.3.8)$	<p>El valor de la desviación estándar absoluta de la diferencia (DASDV) es una medida media de la dispersión de dos valores adyacentes a lo largo de la señal (Jie et al., 2021).</p>
$ZC = \sum_{i=1}^{N-1} [\text{sgn}(x_i x_{i+1}) \cap x_i - x_{i+1} \geq 0] \quad (4.3.9)$	<p>El cruce por cero (ZC) mide el número de veces que las muestras de segmentos de una señal cambian de signo, lo que proporciona un indicador del grado de fluctuación de los datos puntuales (Jie et al., 2021).</p>
$WAMP = \sum_{i=1}^N [f(x_{i+1} - x_i)] \quad (4.3.10)$	<p>La amplitud de Willison (WAMP) está relacionada con el nivel de contracción muscular y con el disparo del potencial de acción de las unidades motoras (Tkach et al., 2010).</p>
$MYOP = \frac{1}{N} \sum_{i=1}^N [f(x_i)] \quad (4.3.11)$	<p>La tasa de porcentaje de impulsos musculares (MYOP) puede utilizarse para expresar el número de impulsos musculares (Ramírez-Martínez et al., 2019).</p>
$FR = \sum_{j=f_1}^{f_2} P_j / \sum_{k=f_3}^{f_4} P_k \quad (4.3.12)$	<p>La relación de frecuencias (FR) puede diferenciar entre contracción y relajación muscular, midiendo la relación entre el espectro de potencia a frecuencias bajas y altas (Zecca et al., 2002).</p>
$MNP = \frac{1}{M} \sum_{j=1}^M P_j, \quad (4.3.13)$	<p>La potencia media (MNP) refleja el valor medio del espectro de potencia (Jie et al., 2021).</p>
$TOT = \sum_{j=1}^M P_j. \quad (4.3.14)$	<p>La potencia total (TOT) describe la suma acumulativa del espectro de potencia (Jie et al., 2021).</p>

Tabla 4.3.3: Características extraídas de la señal sEMG (cont).

$PKF = f_{x(\max(P))}, \quad (4.3.15)$	<p>La frecuencia máxima (PKF) indica el valor de frecuencia en el que el espectro de potencia alcanza su valor máximo (Jie et al., 2021).</p>
$WESE = - \sum_{i=1}^n p_i \log_2(p_i), \quad (4.3.16)$	<p>La Entropía de Shannon de la Energía Wavelet (WESE) se utiliza para calcular la entropía de la energía wavelet de la señal (Chen et al., 2016).</p>
$MNF = \sum_{j=1}^M f_j P_j / \sum_{j=1}^M P_j \quad (4.3.17)$	<p>La frecuencia media (MNF) y la frecuencia mediana (MDF) se utilizan generalmente para describir el desplazamiento hacia las frecuencias más bajas en tareas de fatiga isométrica, y la disminución de la velocidad de conducción de las fibras musculares (Thongpanja et al., 2013).</p>
$\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j \quad (4.3.18)$	

4.3.5. Optimización (Paso E)

En este paso, se seleccionan los mejores valores de longitud de ventana y solapamiento de entre un total de 37 opciones posibles que van desde 125ms a 1500ms, como se ve en la Tabla 4.3.4.

Tabla 4.3.4: Parámetros de ventana para encontrar los valores óptimos.

Longitud (ms)	125	250	500	1000	1250	1500
Solapamiento (ms)	25,50, 100,125	25,50, 100,250	25,50, 100,250, 500	25,50, 100,250, 500,750, 1000	25,50, 100,250, 500,750, 1000,1250	25,50, 100,250, 500,750, 1000,1250, 1500

Se consideran tres configuraciones de selección para encontrar las mejores características mediante el análisis de los valores óptimos de ventana (longitud y superposición).

CONE 1: Se crea una matriz de entrenamiento \mathbf{X}_{tr1} (descrita en la Ec. 4.3.19) a partir de la media móvil de la señal de fuerza y todas las características de la señal de flexión (véanse las Tablas 4.3.1:4.3.3).

$$\mathbf{X}_{tr1} = [\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_k], \quad (4.3.19)$$

donde \mathbf{x}_k es el k -ésimo vector de características.

CONF. 2: Se calcula un conjunto reducido de características \mathbf{X}_{tr1}^* a partir de la matriz \mathbf{X}_{tr1} de la Ec. 4.3.19, mediante un algoritmo de Optimización por Enjambre de Partículas (PSO), que proporciona un mejor rendimiento del modelo. Se considera un total de 100 iteraciones, y la función objetivo es el valor de correlación promediado entre los sujetos entre las señales esperadas y las modeladas (ver Ec. 4.3.20).

$$\mathbf{X}_{tr1}^* = [\mathbf{x}_1^*, \mathbf{x}_2^*, \mathbf{x}_3^*, \dots, \mathbf{x}_l^*]. \quad (4.3.20)$$

CONF. 3: Considerando la matriz \mathbf{X}_{tr1}^* de la Ec. 4.3.20, se construye un nuevo conjunto de características como en la Ec. 4.3.21.

$$\mathbf{X}_{tr2} = [\mathbf{x}_1^*, \mathbf{x}_2^*, \dots, \mathbf{x}_l^*, \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m], \quad (4.3.21)$$

donde $\mathbf{x}_1^*, \dots, \mathbf{x}_l^*$ son las características óptimas descritas en la Ec. 4.3.20, y $\mathbf{y}_1, \dots, \mathbf{y}_m$ son las mismas características pero en este caso extraídas del canal 2 de EMG. Esta configuración se propone para analizar el impacto del músculo extensor radial del carpo en la estimación de la fatiga. A continuación, de forma similar al SETUP 2, se aplica el algoritmo PSO a \mathbf{X}_{tr2} para encontrar un nuevo conjunto de características \mathbf{X}_{tr2}^* que ofrezca un mejor rendimiento del modelo (véase la Ec. 4.3.22).

$$\mathbf{X}_{tr2}^* = [\mathbf{x}_1^*, \mathbf{x}_2^*, \mathbf{x}_3^*, \dots, \mathbf{x}_{13}^*], \quad (4.3.22)$$

4.3.6. Modelo de Fatiga

La solución propuesta se muestra en la Ec. 4.3.23, consistente en un modelo de Regresión Lineal Múltiple, donde la suma ponderada de un conjunto seleccionado de vectores de características explica el comportamiento lineal de la fatiga muscular, asumiendo un 0% de fatiga al inicio de las tareas de contracción, y un 100% al final.

$$F = a_0 + a_1 \mathbf{x}_1 + a_2 \mathbf{x}_2 + a_3 \mathbf{x}_3 + \dots + a_p \mathbf{x}_p, \quad (4.3.23)$$

donde F es la fatiga muscular proporcional, el intercepto a_0 y el vector de pesos $\mathbf{A} = [a_1, a_2, a_3, \dots, a_p]$ son los parámetros del modelo aprendidos en el paso de entrenamiento, $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_p]$ es la matriz de características correspondiente, y p es el número de vectores de características seleccionados.

Por último, este modelo puede presentarse como una estructura matricial, considerada para el s -ésimo participante como se muestra en la Ec. 4.3.24.

$$\mathbf{F}_s = a_{s0} + \mathbf{A}_s \mathbf{X}_s. \quad (4.3.24)$$

4.3.7. Nivel de fatiga

Para explorar la posible aplicación de cada característica \mathbf{x}_k como biomarcador para caracterizar proporcionalmente la fatiga muscular, las características se normalizaron a una escala entre cero y uno (véase la Ec. 4.3.25). Posteriormente, cada característica se remuestrea en relación con los intervalos de tiempo de la tarea de contracción, donde 0% denota la condición inicial no fatigada de la tarea y 100% denota el final de la tarea de contracción muscular,

$$\bar{\mathbf{x}}_k = \frac{(\mathbf{x}_k - \min(\mathbf{x}_k))}{\max(\mathbf{x}_k) - \min(\mathbf{x}_k)}, \quad (4.3.25)$$

donde \bar{x}_k es la k -ésima característica normalizada, y $max(\mathbf{x}_k)$ y $min(\mathbf{x}_k)$ corresponden a los valores máximo y mínimo de \mathbf{x}_k , respectivamente.

4.3.8. Validación (Paso F)

Por último, se realiza una validación cruzada doble para validar el modelo propuesto. Las características extraídas de las señales de Rep-2 y Rep-3 se utilizan para entrenar y probar el modelo, respectivamente, y luego se intercambian las repeticiones. El modelo propuesto se valida utilizando las mejores características descubiertas durante el proceso de optimización, teniendo en cuenta dos métricas de rendimiento: Coeficiente de determinación (R^2) y Correlación ($Corr$) entre la fatiga esperada y la señal modelada (véase la Tabla 4.3.5).

Tabla 4.3.5: Métricas de rendimiento.

Ecuación	Métrica
$Corr = \frac{\sigma_{y(t),\hat{y}(t)}}{\sigma_{y(t)}\sigma_{\hat{y}(t)}} \quad (4.3.26)$	La Correlación de Pearson $Corr$ se utiliza para ver lo similares que son las señales.
$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i^2)}{\sum_{i=1}^m (\bar{Y} - Y_i^2)} \quad (4.3.27)$	El coeficiente de determinación R^2 indica la cantidad de la variación de la variable dependiente que puede predecirse a partir de la variable independiente.

La correlación es la métrica de rendimiento que refleja lo similares que son la fatiga esperada y la señal modelada F_s (Ec. 4.3.24). Un valor alto de esta métrica indica un mejor rendimiento.

Además, una medida más adecuada para validar un modelo lineal es a través de la métrica R^2 , que indica el porcentaje de la variación de la variable dependiente que se puede predecir utilizando las variables independientes. Se demostró por Chicco et al. (2021) que la métrica R^2 es más instructiva y fiable que otras métricas de rendimiento como SMAPE, MSE, RMSE, MAE y MAPE. En este sentido, un valor de 0 de R^2 muestra que las características extraídas no pueden explicar ninguna varianza del modelo de fatiga, mientras que un valor de 1 indica que toda la varianza del modelo propuesto puede ser explicada por las características extraídas.

4.4. Resultados

La tabla 4, que agrupa a los individuos por sexo, muestra el tiempo hasta el fallo muscular del flexor radial del carpo para cada una de las tres tareas de contracción isométrica (la tarea de adaptación más dos repeticiones adicionales que corresponden a las señales de entrenamiento y prueba). La media global y la desviación estándar son $163.066s \pm 89.646s$ para las mujeres y $171.198s \pm 80.011s$ para los hombres.

Tabla 4.4.1: Tiempo hasta el fallo de la tarea.

Participante	Sexo	Adaptación (s)	Rep2 (s)	Rep3 (s)	Media (s)
P5	F	163.881	67.236	159.426	130.181
P6	F	326.216	156.626	137.319	206.720
P7	F	431.656	300.253	203.661	311.856
P8	F	96.806	122.535	132.87	117.403
P9	F	57.169	49.636	40.71	49.171
			Total mujeres:	Media	163.066
				Std	89.646
P1	M	171.632	177.442	180.628	176.567
P2	M	151.006	89.855	77.52	106.127
P3	M	364.917	354.616	237.932	319.155
P4	M	181.995	122.823	170.32	158.379
P10	M	90.554	87.153	109.58	95.762
			Total hombres:	Media	171.198
				Std	80.011

4.4.1. Optimización de ventanas

A partir de la Tabla 4.3.4, se consideran 37 combinaciones posibles de valores de solapamiento y longitud que oscilan entre 125ms y 1500ms para determinar los parámetros óptimos de ventana. La media móvil de la señal de fuerza más todas las características enumeradas en las tablas 4.3.1:4.3.3 extraídas del músculo flexor se utilizan para modelar el nivel proporcional de fatiga de cada participante. Posteriormente, se calculan los correspondientes coeficientes de correlación entre los niveles de fatiga modelados y esperados, que muestran un patrón lineal que oscila entre el 0% y el 100% con respecto al tiempo hasta el fallo muscular de cada sujeto. Por último, los mejores valores de longitud de ventana y solapamiento son los que producen la máxima correlación promediada entre los sujetos, que son 1 y 0,83 segundos, respectivamente.

4.4.2. Selección de características

Después de encontrar la longitud óptima de la ventana y los valores de solapamiento, se consideran tres configuraciones para entrenar el modelo propuesto. La configuración 1 considera el conjunto completo de características extraídas de la señal de fuerza y el canal 1 EMG descrito en las tablas 4.3.1:4.3.3, dando un total de 19 características para extraer. La configuración 2 encuentra el mejor subconjunto de características a partir de las 19 características de la configuración 1, donde el algoritmo PSO se aproxima a la mejor solución. En este caso, 10 características se encontraron como las características más predominantes (véase la configuración 2 en la Tabla 4.4.2).

Tabla 4.4.2: Las mejores características se encontraron en la configuración 2 (a partir de la señal de fuerza y el canal EMG1 FL), y en la configuración 3 (a partir del canal EMG2 EX).

Conf. 2	Conf. 3
Vectores de características óptimas de X_{tr1}^*	Vectores de características óptimas de X_{tr2}^*
$(x_1^*) FORCE$	$(x_1^*) FORCE$
$(x_2^*) MNF_{FL}$	$(x_2^*) MNF_{FL}$
$(x_3^*) MDF_{FL}$	$(x_3^*) MDF_{FL}$
$(x_4^*) RMS_{FL}$	$(x_4^*) RMS_{FL}$
$(x_5^*) IEMG_{FL}$	$(x_5^*) IEMG_{FL}$
$(x_6^*) WL_{FL}$	$(x_6^*) WL_{FL}$
$(x_7^*) DASDV_{FL}$	$(x_7^*) DASDV_{FL}$
$(x_8^*) ZC_{FL}$	$(x_8^*) ZC_{FL}$
$(x_9^*) FR_{FL}$	$(x_9^*) FR_{FL}$
$(x_{10}^*) WESE_{FL}$	$(x_{10}^*) WESE_{FL}$
	$(x_{11}^*) MNF_{EX}$
	$(x_{12}^*) MDF_{EX}$
	$(x_{13}^*) WESE_{EX}$

Finalmente, como se ve en la Fig. 4.4.1, se forma una nueva matriz con el mejor subconjunto encontrado en la Configuración 2 y las mismas características extraídas del Canal 2 de EMG. Esta configuración se considera para averiguar la relevancia del músculo antagonista (extensor radial del carpo) en el modelo de fatiga. Por lo tanto, la configuración 3 encuentra el mejor subconjunto de características al aplicar el algoritmo PSO a este nuevo conjunto. En este sentido, 13 características extraídas de la señal de fuerza y de los canales EMG 1 y 2 reflejaron el mejor rendimiento del modelo (véase la configuración 3 en la Table 4.4.2).

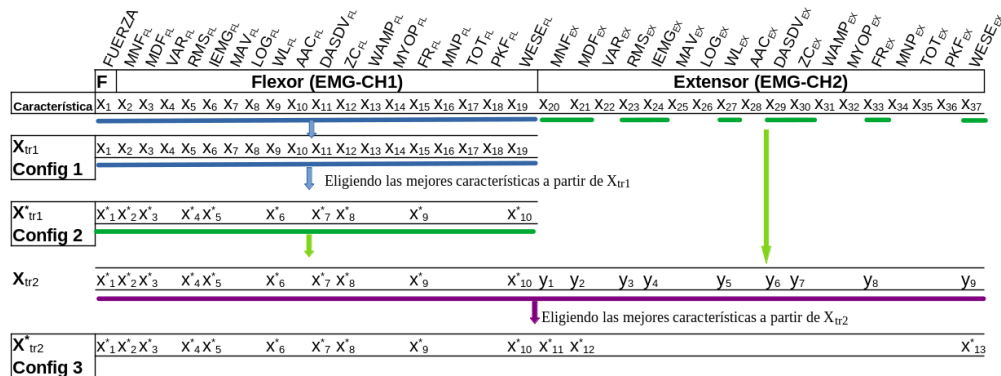


Figura 4.4.1: Proceso de selección de características.

4.4.3. Validación del modelo

Una comparación entre el nivel de fatiga estimado por el modelo propuesto y el nivel de fatiga real se presenta en la Fig. 4.4.2, donde 0% representa el nivel de no-fatiga y 100% es el tiempo hasta el fallo muscular. Los participantes 1 y 9 están resaltados, ya que reflejan el peor y el mejor rendimiento del modelo, respectivamente, es decir, el modelo resultante del sujeto 9 es el más cercano a la línea recta negra, lo que refleja la mejor estimación del nivel de fatiga real.

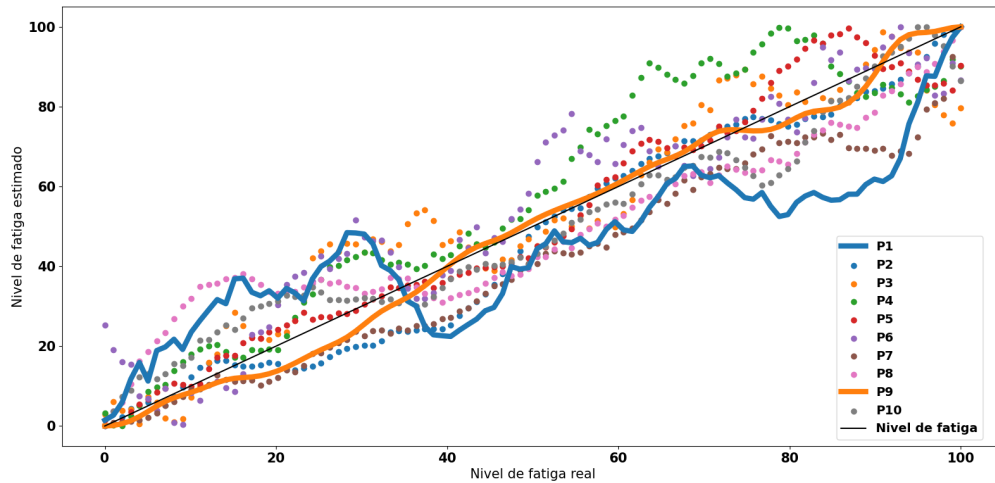


Figura 4.4.2: Nivel de fatiga estimado para diez participantes involucrados en el experimento.

El rendimiento de cada modelo con respecto a las tres configuraciones diferentes se puede ver en la tabla 4.4.3. El rendimiento medio de los resultados experimentales con respecto a la configuración 1 (Partición-1) es de $0.7915 \pm 0.2065 R^2$, que tiene en cuenta todas las características extraídas del flexor. Al elegir un conjunto seleccionado de características de esa configuración, el rendimiento medio de la Configuración 2 aumenta considerablemente a $0.8851 \pm 0.0935 R^2$ ($p=0.00003$, datos convertidos a distribución normal, seguidos de una prueba t de Welch), lo que significa que las características seleccionadas podrían explicar mejor la fatiga muscular de los participantes.

Por último, el rendimiento medio de la Configuración 3 considera un conjunto de características seleccionadas extraídas de los canales flexor y extensor radial del carpo, y es de 0.8880 ± 0.0782 , pero no existe una diferencia estadística con respecto a la configuración anterior ($p=0.80587$, datos convertidos a distribución normal, seguidos de una prueba t de Welch).

Tabla 4.4.3: Desempeño del modelo: Partición 1: Rep2-entrenar, Rep3-validar. Partición 2: Rep3-entrenar, Rep2-validar.

Partición	Sujeto	Conf. 1		Conf. 2		Conf. 3	
		Corr(%)	R^2	Corr(%)	R^2	Corr(%)	R^2
1	P1	84.1159	0.3773	85.1899	0.6556	88.2676	0.7028
	P2	98.1065	0.9577	98.5737	0.9565	98.4476	0.9534
	P3	95.8456	0.9112	95.0749	0.8760	95.3203	0.8995
	P4	96.2921	0.9238	96.3291	0.9108	95.1368	0.8336
	P5	99.1675	0.9484	99.1577	0.9651	98.0807	0.9591
	P6	86.8415	0.7432	91.3099	0.8260	95.3179	0.8878
	P7	99.3450	0.8669	99.0959	0.8505	98.9107	0.8601
	P8	94.9827	0.7879	94.3624	0.8575	94.8529	0.8561
	P9	99.2377	0.9694	99.7102	0.9917	99.6146	0.9887
	P10	88.6536	0.4294	98.6864	0.9617	97.5749	0.9388
	media	94.2588	0.7915	95.7490	0.8851	96.1524	0.8880
std	5.3483	0.2065	4.3478	0.0935	3.1126	0.0782	
2	P1	74.6001	0.3139	90.5972	0.5476	79.8948	0.4517
	P2	95.0921	0.8441	91.2576	0.6738	84.6153	0.3196
	P3	96.5837	0.8689	91.8861	0.8171	88.1077	0.7330
	P4	94.7920	0.8488	97.7099	0.8586	86.5214	0.2462
	P5	97.9467	0.8681	97.0521	0.7649	97.7655	0.8622
	P6	84.6810	0.2348	88.4666	0.3614	93.6712	0.6342
	P7	98.5055	0.9039	98.9833	0.9547	98.7856	0.9439
	P8	93.6113	0.8539	92.5770	0.8220	88.3864	0.7436
	P9	99.0488	0.9348	99.7269	0.9893	99.6604	0.9866
	P10	74.6881	0.2265	69.6847	0.3394	83.7921	0.6612
	media	90.9549	0.6898	91.7941	0.7129	90.1200	0.6582
std	9.0190	0.2843	8.2431	0.2176	6.5732	0.2390	
media	promedio	92.6068	0.7406	93.7715	0.7990	93.1362	0.7731
std	promedio	7.1836	0.2454	6.2954	0.1555	4.8429	0.1586

4.5. Discusión

4.5.1. Tiempo al fallo muscular

En cuanto al tiempo hasta el fallo muscular en tareas de contracción isométrica, se han encontrado diferencias de sexo en algunos grupos musculares como flexores del codo, flexores de los dedos, aductor del pulgar, extensores de la espalda, dorsiflexores, extensores de la rodilla y músculos respiratorios Hunter (2014). En este trabajo, el tiempo hasta el fallo en la tarea del músculo flexor radial del carpo se estima y se presenta en la Tabla 4.4.1, mostrando que el tiempo medio es de $163.066s \pm 89.646s$ para las mujeres y $171.198s \pm 80.011s$ para los hombres, lo que refleja una diferencia no estadísticamente significativa con respecto al sexo ($p=0.63414$, datos convertidos a distribución normal, seguidos de una prueba t de Welch). Una razón de este comportamiento puede explicarse por la colocación de los electrodos, ya que la actividad muscular depende de la tarea (Mehta and Rhee, 2021).

4.5.2. Rendimiento del modelo propuesto

Según la tabla 4.4.3, el rendimiento general en Partición-1 es mayor que en Partición-2, lo que podría deberse al desbalanceo de datos, ya que el tiempo hasta el fallo muscular en la repetición 3 es en su mayoría más corto que el tiempo hasta el fallo en la repetición 2, por lo tanto, hay menos datos para el entrenamiento del modelo.

Para disminuir este efecto, el resultado final del análisis del rendimiento del modelo de este trabajo se elige a partir de las filas de la media y la desviación estándar de la configuración dos, dando valores promediados de 93.7715% Correlación y $0.7990 R^2$. En esta configuración, se identificaron las mejores características extraídas de los músculos flexores, dando una alta correlación entre el comportamiento de fatiga continua modelado y el esperado, y R^2 cercano a uno, lo que indica un alto rendimiento del modelo.

Al optimizar el modelo propuesto, los mejores parámetros de ventana (longitud y solapamiento) y el uso del algoritmo PSO mejoraron sustancialmente el rendimiento del modelo. Además, debido al diseño experimental, la adición de un músculo antagonista, como el extensor radial del carpo, mejoró ligeramente el rendimiento, muy probablemente como resultado del cansancio de este músculo.

La ventaja del trabajo propuesto es la estimación continua de la fatiga muscular, lo que permite una inspección más detallada del estado actual de agotamiento del paciente en vez de utilizar sólo estados discretos (Subasi and Kiymik, 2010), (Venugopal et al., 2014), (Terracina et al., 2019), (Dang et al., 2023) (ver Tabla 4.5.1).

4.5.3. Exploración individual de potenciales biomarcadores

A partir de los resultados experimentales vistos en la Tabla 4.4.3, se puede hacer una comparación entre el peor y el mejor rendimiento. Por este motivo, se eligieron los participantes P1 y P9 para representar las características correspondientes en la Fig. 4.5.1, ya que reflejaban el peor ($0.3773 R^2$ para P1 en SETUP 1, Partición 1) y el mejor ($0.9917 R^2$ para P9 en SETUP 2, Partición 1) rendimiento del modelo propuesto, respectivamente.

Tabla 4.5.1: Trabajos relacionados con la estimación de la fatiga en miembros superiores durante contracciones isométricas mediante sEMG.

Autor (Year)	Músculos	Características	Optimización	Estados de fatiga	Desempeño
Subasi (2010) ^a	Bíceps braquiales	STFT, WVD y CWT	NA	Fresco y F	91 % Precisión
Al-Mulla (2010) ^b	Bíceps braquiales	1D spectro_std	NA	NE, TE, y F	74 %:NE,TF 73 %:TE,F Precisión
Al-Mulla (2011) ^c	Bíceps braquiales	Pseudo-wavelet	GA	NF y F	88.41 % Precisión
Venugopal (2014) ^d	Bíceps braquiales	MAVS	GA y IGR	NF y F	93 % Precisión
Terracina (2019) ^e	Músculos del tronco	MNF, MDE, iEMG, RMS, ZC	NLMS filter	NE, TE, y F	99 % Precisión
Dang (2023) ^f	Biceps, Triceps braquiales	LSMT	NA	NE, Semi-Fatiga, y F	93.5 % Precisión
Proposed model	Flexor	Multi- Características	WO y PSO	Estimación proporcional	95.75 % Correlación

^aSubasi and Kiyimik (2010). ^bAl-Mulla and Sepulveda (2010). ^cAl-Mulla et al. (2011a). ^dVenugopal et al. (2014).

^eTerracina et al. (2019). ^fDang et al. (2023).

STFT: Transformada de Fourier de corta duración. WVD: Distribución de Wigner-Ville. CWT: Transformada Wavelet Continua. NF: Sin fatiga. TE: Transición a la fatiga. F: fatigado. GA: Algoritmos genéticos. IGR: Puntuación basada en la ganancia de información. NLMS: Mínimos cuadrados medios normalizados. LSTM: Memoria a corto y largo plazo. WO: Optimización de ventanas. PSO: Optimización por enjambre de partículas.

A partir de la Fig. 4.5.1, de acuerdo con las características extraídas del participante P1, se puede ver todas esas características no tienen un comportamiento lineal, que es opuesta a nuestra suposición de que la fatiga muscular es lineal. Esta podría ser la razón principal del bajo rendimiento del modelo propuesto, donde un modelo exponencial podría ajustarse mejor a los datos extraídos del participante P1 (Ma et al., 2013).

Por otro lado, al extraer las características del participante P9 en las Configuraciones 2 y 3, se presenta un comportamiento lineal en la mayoría de ellas. Otra razón del bajo rendimiento en el participante P1 es que el sujeto está alcanzando la fatiga muy rápido, y además está activando de otros músculos diferentes a los flexores o extensores para sostener 40 % de la fuerza máxima de contracción voluntaria MVC.

Esto puede explicarse en la Fig. 4.5.1, cuando todas las características (excepto los números 2, 7, 18, 19 y 22) encuentra un mínimo en aproximadamente la mitad de la señal (sólo un máximo para la característica diez), lo que probablemente refleja que la fatiga muscular se ha alcanzado.

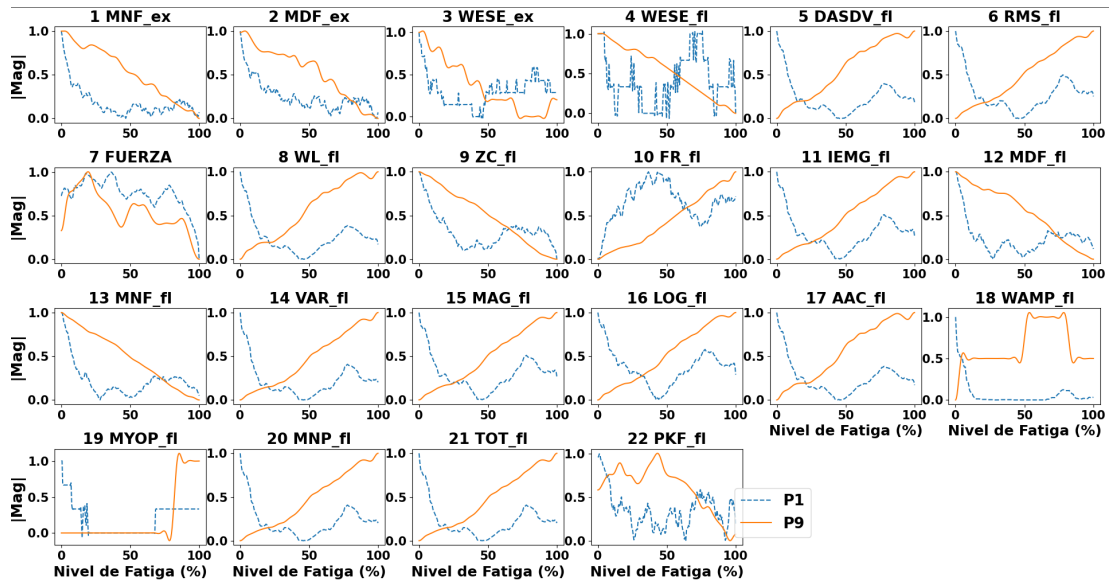


Figura 4.5.1: Características individuales extraídas del extensor (ex) y el flexor (fl) al principio (0%) y al final (100%) de la tarea de contracción muscular. Estas características se normalizaron de cero a uno. Se seleccionan los sujetos P1 y P9, ya que su modelo de fatiga correspondiente tiene el peor y el mejor rendimiento, respectivamente. Las características para (CONF. 1) son 4:22, (CONF. 2) son 4:13, y (CONF. 3) son 1:13.

A partir del número 10 de la Fig. 4.5.1, la característica Relación de Frecuencias (RT) aumenta para ambos participantes, donde las frecuencias bajas sobre las altas fueron consideradas para calcular esta característica. Resultados similares para tareas de contracción dinámica fueron reportados en Kim et al. (2013), donde el índice de fatiga sigue un comportamiento descendente principalmente porque este índice se calcula considerando frecuencias altas sobre frecuencias bajas.

La entropía de Shannon se calcula para la energía del nivel de descomposición wavelet seleccionado. En este trabajo, se utiliza la descomposición wavelet de cuarto nivel porque es óptima para la extracción de características EMG, evitando el ruido y las partes EMG no deseadas (Phinyomark et al., 2011). Por otra parte, de acuerdo con las características tres y cuatro de la Fig. 4.5.1, un indicador potencial de fatiga se refleja cuando la complejidad del músculo flexor del carpo radial disminuye en la banda de frecuencia 0,5Hz-400Hz, que se explica por Chen et al. (2016), quien afirma que la característica WESE ayuda a disminuir la dimensión para analizar la complejidad variable en el tiempo de las señales EMG.

Este resultado es congruente con trabajos anteriores publicados por Xie et al. (2010), donde se encontró que las características de entropía y frecuencia mediana disminuyen durante las tareas de contracciones isométricas fatigantes. Esto puede explicarse por el hecho de que la entropía, la media y la mediana de la frecuencia de potencia podrían verse afectadas por mecanismos fisiológicos similares, como se indica en González-Izal et al. (2012), lo que refleja la pérdida de fuerza y el aumento de la fatiga muscular.

Además, según nuestros resultados experimentales, cuanto más fatigado está el sujeto, menor es el número de veces que la señal EMG cruza por cero. Esto podría estar directamente re-

lacionado con la disminución de la MNF, lo que significa que a medida que disminuye la media de frecuencia, también disminuye el número de veces que la señal cruza por cero en un segundo. Resultados similares se encontraron en tareas de contracción dinámica, mostrando que las características MNF y ZC disminuyen con la fatiga, siguiendo una tendencia global entre todos los sujetos (Bueno et al., 2015).

4.6. Observaciones finales

El modelo propuesto de regresión de múltiples características puede decodificar niveles proporcionales de fatiga muscular de 0% a 100%. A partir de los resultados experimentales, se descubrió que algunos posibles indicadores de fatiga muscular podrían ser la disminución de los cruces por cero y de la entropía de los niveles de energía en la descomposición wavelet, y un aumento de la relación de frecuencias altas y bajas.

Además, el modelo propuesto valida resultados anteriores que indican una disminución de la frecuencia media y mediana, y un aumento de la raíz cuadrática media con la fatiga muscular. Por lo tanto, se encontró una tendencia global entre todos los sujetos, indicando fatiga muscular continua para tareas de contracción isométrica.

Según el tiempo estimado hasta el fallo, no hubo diferencias significativas de sexo en la fatigabilidad en tareas de contracciones isométricas, lo que puede explicarse por la naturaleza del experimento, concretamente por la colocación de los electrodos. Se necesita más investigación para determinar las diferencias de sexo al analizar la fatiga del músculo flexor.

Como trabajo futuro, el modelo propuesto puede implementarse para investigar la fatigabilidad en tiempo real, ampliando el conocimiento en las áreas de evaluación continua de la fatiga e identificación de biomarcadores musculares basados en electromiografía de superficie, elementos clave en el campo de la rehabilitación motora.

Conclusiones y trabajo futuro

La respuesta cortical provocada por la manipulación de la muñeca se identificó mediante ICA, mostrando una respuesta contralateral en el lado izquierdo de la corteza motora ya que la muñeca manipulada era la derecha. A continuación, se propuso una estructura embebida diferencial de retardo no lineal para modelar dicha respuesta. Este modelo puede utilizarse para identificar y analizar el modo de funcionamiento predominante general de la respuesta cortical provocada por la manipulación de la muñeca en personas diestras, jóvenes y sanas.

Se eligió el modelo de grado 12 como el mejor, teniendo en cuenta un balance entre rendimiento (VAF) y coste computacional (número de parámetros). Aumentar el grado del modelo podría mejorar el rendimiento, pero está expuesto al sobreajuste y limita la generalización. Reducir la complejidad implicaría utilizar un modelo más simple (es decir, considerar un modelo de grado inferior, en el que los detalles específicos no son cruciales, sino la respuesta general del cerebro). Además, la reconstrucción de la respuesta cortical a partir de frecuencias pares ayudaría a reducir el número total de términos del modelo que hay que calcular.

En la definición de los retardos no se hace ninguna suposición previa sobre el conocimiento fisiológico, sino que el enfoque de exploración y explotación de las partículas encuentra los mejores parámetros que reflejan la relación característica entre la parte fisiológica y el comportamiento de la señal. Cabe destacar que, utilizando este enfoque, los retardos obtenidos concuerdan con valores publicados anteriormente y fue posible darles una justificación fisiológica. Por otra parte, en lo que se refiere al cálculo de los retardos, otro tema de investigación puede ser la reducción del tiempo de cálculo mediante métodos de optimización, por ejemplo, metaheurísticos.

La diferencia de rendimiento entre el conjunto de datos mexicano y el de los Países Bajos puede deberse a la diferencia de los parámetros de retardo, que se consideraron iguales para esta tesis. Por lo tanto, los parámetros de retardo de tiempo para el conjunto de datos mexicano deben calcularse para tener un modelo más fiable y un mayor rendimiento.

En un futuro, con nuevos registros de EEG de pacientes con deficiencias motoras, la metodología propuesta en esta tesis puede ser replicada para evaluar el comportamiento de esos potenciales biomarcadores para personas con algunas limitaciones motoras. Por lo tanto, considerar esos elementos podría ayudar a desarrollar interfaces útiles como aplicaciones médicas para identificar biomarcadores potenciales que reflejen el estado actual del paciente en tiempo real. Esto facilitaría a los expertos terapeutas la evaluación y comparación de la eficacia de las sesiones de rehabilitación para personas con deficiencias motoras en las extremidades superiores.

Apéndices

Tabla 4.6.1: Sistema de identificación de sistemas neuronales a partir de señales neurofisiológicas

	Lineal	No lineal	No lineal Variante en el Tiempo
Modelado e Identificación del Sistema	<p><i>Tiempo:</i> AR/ARX</p> <p><i>Frecuencia:</i> Función de Transferencia FRF</p>	<p><i>Tiempo:</i> Series de Volterra NARX, NARMAX</p> <p><i>Frecuencia:</i> GFRFs OFRFs</p>	<p><i>Tiempo:</i> TV-NARX / TV-NARMAX Series de Volterra Variantes en el Tiempo Método de ventana deslizante</p> <p><i>Frecuencia:</i> TV-GFRFs TV-OFRFs</p>

Tabla 4.6.2: Trabajo Relacionado

Autor (Año)	Model	Methods	Variance Accounted For (VAF)
Yuanlin Gu et. al.(2020)	NARMAX	Infomax ICA CUDAICA. Signal-to-noise ratio (SNR)	93.91 % ± 1.54
Hazan A. Nozari (2020)	Locally Linear Neuro-Fuzzy (LLNF) networks: ARMAX (ARX, OE, Volterra structures)	Infomax ICA, NSR	94.52 % ± 1.45
Tian R, Yang Y, van der Helm FCT and Dewald JPA (2018)	NARMAX. Hierarchical Neural Network	Infomax ICA. Dipole fitting algorithm. Noise-to-signal ratio (NSR)	69.35 % ± 11.90
Vlaar MP, Birpoutsoukis G, Lataire J, Schoukens M, Schouten AC, Schoukens J, van der Helm FCT (2017)	Frequency Domain Representation (linear). Truncated Volterra Series Expansión (nonlinear contribution)	Infomax ICA – CUDAICA. noise-to-signal ratio (NSR)	42.84 % ± 13.78

Bibliografía

- Al-Mulla, M. R. and Sepulveda, F. (2010). Novel feature modelling the prediction and detection of semg muscle fatigue towards an automated wearable system. *Sensors*, 10(5):4838–4854.
- Al-Mulla, M. R., Sepulveda, F., and Colley, M. (2011a). Evolved pseudo-wavelet function to optimally decompose semg for automated classification of localized muscle fatigue. *Medical Engineering and Physics*, 33(4):411–417.
- Al-Mulla, M. R., Sepulveda, F., and Colley, M. (2011b). A review of non-invasive techniques to detect and predict localised muscle fatigue. *Sensors*, 11(4):3545–3594.
- Bueno, D. R., Lizano, J. M., and Montano, L. (2015). Muscular fatigue detection using semg in dynamic contractions. In *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 494–497. IEEE.
- Bullock, D. (2001). *Cortical models for movement control*. Springer.
- Chen, X., Xie, P., Liu, H., Song, Y., and Du, Y. (2016). Local band spectral entropy based on wavelet packet applied to surface emg signals analysis. *Entropy*, 18(2).
- Chicco, D., Warrens, M. J., and Jurman, G. (2021). The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. *PeerJ Computer Science*, 7:1–24.
- Dai, W., Selesnick, I., Rizzo, J. R., Rucker, J., and Hudson, T. (2017). A nonlinear generalization of the savitzky-golay filter and the quantitative analysis of saccades. *Journal of Vision*, 17(9):10.
- Dang, Y., Liu, Z., Yang, X., Ge, L., and Miao, S. (2023). A fatigue assessment method based on attention mechanism and surface electromyography. *Internet of Things and Cyber-Physical Systems*, 3:112–120.
- González-Izal, M., Malanda, A., Gorostiaga, E., and Izquierdo, M. (2012). Electromyographic models to assess muscle fatigue. *Journal of Electromyography and Kinesiology*, 22(4):501–512.
- González-Zamora, P., Benitez, V. H., and Pacheco, J. (2023). A feature-based processing framework for real-time implementation of muscle fatigue measurement. *Cluster Computing*, 26(1):385–394.
- Gu, Y., Yang, J. P. D., Helm, F. C. V. D., Schouten, A. C., and Wei, H. L. (March, 2021). Nonlinear modeling of cortical responses to mechanical wrist perturbations using the narmax method. *IEEE Transactions on Biomedical Engineering*, 68(3):948–958.
- Hersh, E. (2019). Wrist flexion: What's normal, what's not and exercises to improve it.

- Hervault, M., Zanone, P.-G., Buisson, J.-C., and Huys, R. (2021). Cortical sensorimotor activity in the execution and suppression of discrete and rhythmic movements. Scientific Reports, 11(1):22364.
- Hunter, S. K. (2014). Sex differences in human fatigability: Mechanisms and insight to physiological responses. Acta Physiologica, 210(4):768–789.
- Jackson, C. (2015). The chalde fatigue scale (cfq 11). Occupational Medicine, 65(1):86.
- Jayaweera, P. Y. (2021). Design and implementation of electromyography (emg) based real-time pattern recognition model for prosthetic hand control.
- Jie, J., Liu, K., Zheng, H., Wang, B., and Dai, R. (2021). High dimensional feature data reduction of multichannel semg for gesture recognition based on double phases pso. Complex and Intelligent Systems, 7(4):1877–1893.
- Kim, J., Kim, S., Park, S., Ahn, S., Lee, Y., and Kim, Y. (2013). Bandwidth optimization of the fatigue index to estimate muscle fatigue during dynamic contractions. International Journal of Precision Engineering and Manufacturing, 14(7):1185–1191.
- Knierim, J. (October 30, 2020). Neuroscience online, an open-access neuroscience electronic textbook. section 3: Motor systems. chapter 1: Motor units and muscle receptors. <https://nba.uth.tmc.edu/neuroscience/>.
- Kulkarni, V., Joshi, Y., Manthalkar, R., and Elamvazuthi, I. (2022). Band decomposition of asynchronous electroencephalogram signal for upper limb movement classification. Physical and Engineering Sciences in Medicine, 45(2):643–656.
- Lainscsek, C., Hernandez, M. E., Weyhenmeyer, J., Sejnowski, T. J., and Poizner, H. (2013). Non-linear dynamical analysis of eeg time series distinguishes patients with parkinson's disease from healthy individuals. Frontiers in Neurology, 4 DEC:200.
- Lainscsek, C. and Sejnowski, T. J. (2015). Delay differential analysis of time series. Neural Computation, 27:594–614.
- Li, H., Ji, H., Yu, J., Li, J., Jin, L., Liu, L., Bai, Z., and Ye, C. (2023). A sequential learning model with gnn for eeg-emg-based stroke rehabilitation bci. Frontiers in Neuroscience, 17:1125230.
- Li, P., Yang, X., Yin, G., and Guo, J. (2020). Skeletal muscle fatigue state evaluation with ultrasound image entropy. Ultrasonic Imaging, 42(6):235–244.
- Ma, L., Zhang, W., Hu, B., Chablat, D., Bennis, F., and Guillaume, F. (2013). Determination of subject-specific muscle fatigue rates under static fatiguing operations. Ergonomics, 56(12):1889–1900.
- McDonald, A. C., Mulla, D. M., and Keir, P. J. (2019). Using emg amplitude and frequency to calculate a multimuscle fatigue score and evaluate global shoulder fatigue. Human Factors, 61(4):526–536.
- Mehta, R. K. and Rhee, J. (2021). Revealing sex differences during upper and lower extremity neuromuscular fatigue in older adults through a neuroergonomics approach. Frontiers in Neuroergonomics, 2.
- Nozari, H. A., Rahmani, Z., Castaldi, P., Simani, S., and Sadati, S. J. (2020). Data-driven modeling of the nonlinear cortical responses generated by continuous mechanical perturbations. IFAC-PapersOnLine, 53(2):322–327.

- Ohbayashi, M. (2021). The roles of the cortical motor areas in sequential movements. Frontiers in Behavioral Neuroscience, 15:640659.
- Onishi, H., Sugawara, K., Yamashiro, K., Sato, D., Suzuki, M., Kirimoto, H., Tamaki, H., Murakami, H., and Kameyama, S. (2013). Neuromagnetic activation following active and passive finger movements. Brain and Behavior, 3(2):178–192.
- Oranchuk, D. J., Storey, A. G., Nelson, A. R., and Cronin, J. B. (2019). Isometric training and long-term adaptations: Effects of muscle length, intensity, and intent: A systematic review. Scandinavian Journal of Medicine and Science in Sports, 29(4):484–503.
- Otálora, S., Segatto, M. E., Monteiro, M. E., Múnera, M., Díaz, C. A., and Cifuentes, C. A. (2023). Data-driven approach for upper limb fatigue estimation based on wearable sensors. Sensors, 23(22):9291.
- Phinyomark, A., Limsakul, C., and Phukpattaranont, P. (2011). Application of wavelet analysis in emg feature extraction for pattern classification. Measurement Science Review, 11(2):45–52.
- Pont, M. D. (2020). Non-linear bayesian system identification of cortical responses using volterra series. Master's thesis, Delft University of Technology.
- Ramírez-Martínez, D., Alfaro-Ponce, M., Pogrebnyak, O., Aldape-Pérez, M., and Argüelles-Cruz, A. J. (2019). Hand movement classification using burg reflection coefficients. Sensors (Switzerland), 19(3).
- Riemann, B. L. and Lephart, S. M. (2002). The sensorimotor system, part i: The physiologic basis of functional joint stability. Journal of Athletic Training 71 Journal of Athletic Training, 37(1):71–79.
- Rogers, D. R. and MacIsaac, D. T. (2010). Training a multivariable myoelectric mapping function to estimate fatigue. Journal of Electromyography and Kinesiology, 20(5):953–960.
- Savitzky, A. and Golay, M. J. (1964). Smoothing and differentiation of data by simplified least squares procedures. Analytical chemistry, 36(8):1627–1639.
- Schouten, A., Vlaar, M. M., Vardy, A. A., Solis-Escalante, T. T., and van der Helm, F. F. (2019). Data underlying the research of cortical responses evoked by wrist joint manipulation.
- Smets, E., Garssen, B., Bonke, B. d., and De Haes, J. (1995). The multidimensional fatigue inventory (mfi) psychometric qualities of an instrument to assess fatigue. Journal of psychosomatic research, 39(3):315–325.
- Spiewak, C. (2018). A comprehensive study on emg feature extraction and classifiers. Open Access Journal of Biomedical Engineering and Biosciences, 1(1).
- Subasi, A. and Kiyimik, M. K. (2010). Muscle fatigue detection in emg using time-frequency methods, ica and neural networks. Journal of Medical Systems, 34(4):777–785.
- Tankisi, H., Burke, D., Cui, L., de Carvalho, M., Kuwabara, S., Nandedkar, S. D., Rutkove, S., Stålbjerg, E., van Putten, M. J., and Fuglsang-Frederiksen, A. (2020). Standards of instrumentation of emg. Clinical Neurophysiology, 131:243–258.
- Terracina, D., Moniri, A., Rodriguez-Manzano, J., Strutton, P. H., and Georgiou, P. (2019). Real-time forecasting and classification of trunk muscle fatigue using surface electromyography. In 2019 IEEE Biomedical Circuits and Systems Conference (BioCAS), pages 1–4. IEEE.

- Thongpanja, S., Phinyomark, A., Phukpattaranont, P., and Limsakul, C. (2013). Mean and median frequency of emg signal to determine muscle force based on time dependent power spectrum. Elektronika ir Elektrotechnika, 19(3):51–56.
- Tian, R., Yang, Y., van der Helm, F. C., and Dewald, J. P. (December, 2018). A novel approach for modeling neural responses to joint perturbations using the narmax method and a hierarchical neural network. Frontiers in Computational Neuroscience, 12:96.
- Tkach, D., Huang, H., and Kuiken, T. A. (2010). Study of stability of time-domain features for electromyographic pattern recognition.
- Trivedi, G. and Rawat, T. K. (2022). Volterra series based nonlinear system identification methods and modelling capabilities. International Journal of Modelling, Identification and Control, 41(3):222–230.
- Úbeda, A., Hortal, E., Iáñez, E., Perez-Vidal, C., and Azorín, J. M. (2015). Assessing movement factors in upper limb kinematics decoding from eeg signals. PLoS One, 10(5):e0128456.
- van Breugel, F., Kutz, J. N., and Brunton, B. W. (2020). Numerical differentiation of noisy data: A unifying multi-objective optimization framework. IEEE Access, 8:196865–196877.
- van den Bos, M. A., Geevasinga, N., Higashihara, M., Menon, P., , and Vucic, S. (June, 2019). Pathophysiology and diagnosis of ALS: Insights from advances in neurophysiological techniques. International Journal of Molecular Sciences, 20(11):2818.
- Venugopal, G., Navaneethakrishna, M., and Ramakrishnan, S. (2014). Extraction and analysis of multiple time window features associated with muscle fatigue conditions using semg signals. Expert Systems with Applications, 41(6):2652–2659.
- Vlaar, M. (September 28, 2017). Characterizing Cortical Responses Evoked by Robotic Joint Manipulation after Stroke. PhD thesis, Delft University of Technology.
- Vlaar, M. P., Birpoutsoukis, G., Lataire, J., Schoukens, M., Schouten, A. C., Schoukens, J., and Helm, F. C. V. D. (January, 2018). Modeling the nonlinear cortical response in eeg evoked by wrist joint manipulation. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 26(1):205–215.
- Vlaar, M. P., Solis-Escalante, T., Vardy, A. N., Helm, F. C. V. D., and Schouten, A. C. (May, 2017). Quantifying nonlinear contributions to cortical responses evoked by continuous wrist manipulation. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 25(5):481–491.
- Vliet, M. V., Chumerin, N., Deyne, S. D., Wiersema, J. R., Fias, W., Storms, G., and Hulle, M. M. V. (2016). Single-trial erp component analysis using a spatiotemporal lcmv beamformer. IEEE Transactions on Biomedical Engineering, 63(1):55–66.
- Wang, X., Dai, X., Liu, Y., Chen, X., Hu, Q., Hu, R., and Li, M. (2023). Motor imagery electroencephalogram classification algorithm based on joint features in the spatial and frequency domains and instance transfer. Frontiers in Human Neuroscience, 17:1175399.
- Williams, N. (2017). The Borg Rating of Perceived Exertion (RPE) scale. Occupational Medicine, 67(5):404–405.

- Xie, H. B., Guo, J. Y., and Zheng, Y. P. (2010). Fuzzy approximate entropy analysis of chaotic and natural complex systems: Detecting muscle fatigue using electromyography signals. Annals of Biomedical Engineering, 38(4):1483–1496.
- Yang, Y., Guliyev, B., and Schouten, A. C. (September, 2017). Dynamic causal modeling of the cortical responses to wrist perturbations. Frontiers in Neuroscience, 11:518.
- Yang, Y., Solis-Escalante, T., van de Ruit, M., van der Helm, F. C., and Schouten, A. C. (2016). Nonlinear coupling between cortical oscillations and muscle activity during isotonic wrist flexion. Frontiers in Computational Neuroscience, 10(126).
- Yoshimura, N., Tsuda, H., Kawase, T., Kambara, H., and Koike, Y. (2017). Decoding finger movement in humans using synergy of eeg cortical current signals. Scientific Reports, 7.
- Zecca, M., Micera, S., Carrozza, M. C., and Dario, P. (2002). Control of multifunctional prosthetic hands by processing the electromyographic signal. Critical Reviews in Biomedical Engineering, 30(4-6):459–485.
- Zhu, F., Li, Y., Shi, Z., and Lin, H. (2022). Nonlinear identification and time-frequency domain analysis of corticomuscular responses during card-grabbing using the narmax method. In 2022 8th International Conference on Control, Automation and Robotics (ICCAR), pages 1–6. IEEE, Institute of Electrical and Electronics Engineers Inc.