

OPTIMIZACIÓN DEL MODELO DE REGRESIÓN LINEAL PARA LA DECODIFICACIÓN DE LAS TRAYECTORIAS CINEMÁTICAS DEL MIEMBRO INFERIOR A PARTIR DE SEÑALES EEG

Miguel Á. Ferre¹, Javier V. Juan¹, Eduardo Iáñez^{1,2}, Mario Ortiz^{1,2}, José M. Azorín^{1,2}

¹Brain-Machine Interface Systems Lab, Miguel Hernández University of Elche

Avda. de la Universidad s/n, Ed. Innova, 03202, Elche, España

²Instituto de Investigación en Ingeniería de Elche-I3E,

Avda. de la Universidad s/n, Ed. Innova, 03202, Elche, España

migferba@gmail.com, javier.juan@umh.es, eianez@umh.es, mortiz@umh.es, jm.azorin@umh.es

Resumen

Los exoesqueletos activos se han convertido en una herramienta clave en la rehabilitación de pacientes con problemas de movilidad, especialmente, afectados con enfermedades relacionadas con el sistema nervioso durante la última década. Varios son los estudios que han demostrado que el movimiento consciente efectuado por pacientes con dificultades de movilidad, asistido por este tipo de dispositivos, contribuye positivamente a la recuperación de su movilidad, acortando los tiempos de rehabilitación y mejorando sus resultados. Además, otros estudios han planteado la teoría de que el córtex motor se encuentra activo durante fases específicas del ciclo de la marcha. En este estudio se ha hecho una búsqueda de nuevos parámetros para la mejora de un modelo de regresión multilíneal que decodifica la cinemática de los miembros inferiores a partir de las señales de EEG. Además, se ha estudiado la generalización de estos nuevos parámetros para crear un modelo unificado que facilite su uso. Las nuevas configuraciones alcanzan valores medios (Coeficiente de correlación de Pearson) similares entre las trayectorias reales y las decodificadas $0,49 \pm 0,20$. Esto nos lleva a pensar que los nuevos parámetros se podrían generalizar sin ningún problema.

Palabras clave: Decodificación, EEG, cinemática, miembro inferior, exoesqueleto.

1 INTRODUCCIÓN

El uso de la robótica en el campo de la medicina sigue el auge precedido desde hace ya varios años [1]. Entre todos sus usos, uno de los más frecuentes es la asistencia para recuperación de la movilidad en pacientes que han sufrido una pérdida total o parcial en sus funciones articulares. Los sistemas robóticos de asistencia a la marcha son una herramienta cada vez más recurrente entre las terapias recetadas por profesionales de la sanidad y ya son muchos los

centros de rehabilitación que emplean exoesqueletos activos en su día a día.

Estos sistemas son útiles debido las ventajas que aportan frente a un tratamiento convencional: dotan a los pacientes de motivación y compromiso durante las distintas fases de la terapia, manteniendo su adherencia durante largos periodos de tiempo [7,17]. Además, la evidencia científica relaciona su uso con el aumento de la densidad ósea, la disminución del porcentaje de grasa corporal y la mejora de la postura al sentarse. Pero también mejoran las funciones internas, como por ejemplo la salud cardiovascular, la vejiga y las funciones intestinales [9]. En el caso de los pacientes que requieren rehabilitación neuronal motora (en su mayoría lesionados medulares y pacientes con ictus), este beneficio es aún mayor dado que uno de los primeros objetivos es la recuperación de la marcha. Esto se debe a la gran mejora en su calidad de vida diaria [10].

Estos dispositivos suelen estar formados por un armazón que envuelve el cuerpo del usuario y varios motores o transmisiones distribuidos en las articulaciones que proporcionan el torque necesario para el giro de las articulaciones artificiales. En cuanto al control de su activación, existen una gran variedad de métodos de control. En el campo de la rehabilitación se pretende que este control lo genere el paciente en mayor parte, por ello, se emplean señales generadas por el propio paciente, entre dichas señales biomédicas encontramos: la electromiografía (EMG), el electrooculograma (EOG) o la electroencefalografía (EEG). Esta última técnica registra los impulsos eléctricos generados por el cerebro del usuario mediante electrodos invasivos o no invasivos en la cabeza, creando un interfaz entre cerebro – máquina (BMI, Brain-Machine Interface), en este caso, el exoesqueleto.

Según varios estudios [3, 6], el uso de EEG para controlar los exoesqueletos provocan una implicación neuronal que conlleva a su vez en resultados de las terapias de rehabilitación más satisfactorios. La mayoría de estos modelos de control se basan en los

paradigmas de imaginación motora, es decir, tan sólo pueden reconocer cuando el usuario tiene intención de caminar, por tanto, el exoesqueleto se activa o desactiva en función de las señales. Además, tan solo es posible realizar una única función, bien sea caminar o subir escaleras [11]. Tratando de superar este problema y basándose en algunos estudios que confirman que el córtex motor está especialmente activo durante fases concretas del ciclo de la marcha humana [2], algunos estudios se han dispuesto a decodificar directamente los parámetros cinemáticos de las articulaciones [13,4], generando así un control más preciso del exoesqueleto.

Actualmente, varios son los algoritmos empleados para llevar a cabo dicha decodificación, mayoritariamente se emplean redes neuronales [14] o la regresión lineal multidimensional (MLR). Algunos estudios empleando este último enfoque han generado resultados muy prometedores [12,15,16]. Sin embargo, la amplia variedad de parámetros que ofrecen este tipo de modelos de regresión hace que sea muy complicado obtener algoritmos de decodificación perfectos.

Por todo ello, en este trabajo se seguirá profundizando en los modelos de decodificación cinemática de las extremidades inferiores a partir de señales de EEG, en este caso, se buscará optimizar la regresión multilínea probada previamente en estudios de A. et al [16]. La finalidad es obtener un modelo general y útil de dicha regresión lineal mediante la búsqueda en distintos parámetros, tanto del preprocesamiento de las señales EEG como de los parámetros variables del algoritmo.

2 MATERIAL Y MÉTODOS

En esta sección se detallan todos los pasos del proceso experimental, así como las características de los usuarios que lo han completado. Además, se especifican los sensores e instrumentación necesaria para las pruebas y el software de adquisición de los datos con los que posteriormente se realiza el análisis. Por último, se comenta brevemente el modelo de regresión lineal multidimensional empleado.

2.1 SUJETOS

En el estudio han participado ocho sujetos sanos, formados por seis varones y dos mujeres, con edades comprendidas entre 21 y 27 años ($24,1 \pm 1,9$). Todos ellos recibieron información sobre el estudio y firmaron el consentimiento informado siguiendo las bases de la declaración de Helsinki junto con la aprobación del comité ético de la Universidad Miguel Hernández de Elche.

2.2 PROTOCOLO

Previamente a las pruebas, los sujetos fueron instrumentados con un sistema de unidades de medición inercial (IMUs) en los miembros inferiores, el exoesqueleto H3 de Technaid S.L y un sistema de electrodos en la cabeza para la grabación de señales EEG (Figura 1). Una vez instrumentados, los sujetos debían completar 16 repeticiones con los siguientes pasos: 15 segundos relajado con el exoesqueleto, 20 segundos caminando, parada, 20 segundos caminando, parada, 20 segundos caminando y parada; completando un total de 1 minuto caminando por cada repetición. Cabe resaltar que tan solo los instantes en movimiento son de interés para la extracción de las características cinemáticas del sujeto. Todos los usuarios completaron las 16 repeticiones a excepción de los usuarios U3 y U5 que realizaron 7 repeticiones y el usuario U1 que realizó 13 repeticiones.

2.2.1 Registro EEG

Para los experimentos se utilizó un sistema de registro de EEG no invasivo, compuesto por el amplificador actiChamp de BrainProducts y el actiCap 32 de BrainProducts (Figura 1). La adquisición de las señales de EEG se realizó con una configuración de 32 electrodos activos, según el sistema internacional 10/20 (Figura 2), con una frecuencia de muestreo de 500Hz. El electrodo de tierra se colocó en el lóbulo de la oreja derecha; además, se colocó un electrodo de referencia también en el lóbulo de la oreja izquierda con la intención de minimizar las interferencias y mejorar la calidad de la señal. Además, se utilizaron dos filtros hardware, uno de paso alto a 0.1Hz para rechazar los artefactos de la marcha y otro filtro de Notch de 50Hz para borrar la componente de la red eléctrica.

2.2.2 Unidad de medición inercial

Se han empleado 7 IMUs de la marca Technaid S.L (Tech-MCS) para la medición de las trayectorias reales de las extremidades inferiores. Las siete IMUs están colocadas en la zona lumbar, una en cada muslo, una en cada espinilla, y una en cada tobillo (Figura 3); todas ellas están conectadas al transmisor Tech-HUB (Technaid S.L.) y por puerto USB al portátil de grabación. Esta configuración nos permite obtener las trayectorias de las articulaciones de las caderas, rodillas y tobillos, tanto a la derecha como a la izquierda. Por último, la frecuencia de muestreo de la señal es de 30Hz.

2.2.3 Exoesqueleto

Los usuarios han sido asistidos durante marcha por el exoesqueleto Exo-H3 de Technaid S.L como se observa en la Figura 1. Dicho exoesqueleto cuenta con



Figura 1: Instrumentación y equipos empleados durante los experimentos para el registro de señales EEG e IMUs.

seis motores en las principales articulaciones de las piernas, caderas, rodillas y tobillos. El control de los motores ha sido programado para realizar un ciclo de la marcha estandarizado, esto quiere decir que los usuarios tan solo deben acompañar el movimiento de este, sin ejercer fuerza en sentido contrario. El torque de asistencia a las articulaciones es el mismo en todos los usuarios.

2.3 PREPROCESAMIENTO DE DATOS

Los datos registrados que se emplean para el análisis son las diferentes características procedentes de las

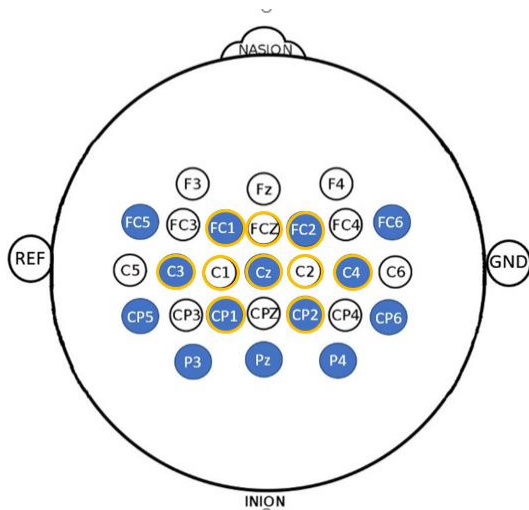


Figura 2: Configuración de electrodos siguiendo el sistema de referencia 10/20 empleada para decodificación; en azul, la configuración original, en amarillo, la configuración final estudiada.

IMUs mediante las que se obtendrán las trayectorias reales de las articulaciones y las señales EEG, a partir de las cuales se obtendrán las trayectorias decodificadas.

En primer lugar, las IMUs proporcionan las matrices de dirección y coseno (DCM) a las cuales se les aplica una rotación mediante otras matrices DCM con el objetivo de hacer coincidir las originales con los sistemas de referencia empleados por el fabricante. Una vez ya se encuentran en el sistema de referencia adecuado, se transforman en cuaterniones y se calcula la cinemática de las articulaciones a través del software proporcionado por el fabricante.

En segundo lugar, las señales EEG son preprocesadas antes de aplicar la decodificación. Según estudios previos de G. Garipelli et al., la información relacionada con los potenciales corticales lentos se




Figura 3: Distribución de las IMUs en las extremidades inferiores.

encuentra por encima de 0.1Hz, es por ello que se ha aplicado un filtro Butterworth de 4º orden y fase cero entre 0.1- 2Hz [5]. En cuanto a los electrodos empleados, la configuración base en la que se fundamentan los futuros resultados proviene del estudio previo realizado por A. Úbeda et. al (2013), donde asegura que la reducción del número de electrodos a los catorce situados en la corteza motora parietal central (FC5, FC1, FC2, FC6, C3, Cz, C4, CP5, CP1, CP2, CP6, P3, Pz y P4) como indica la Figura 2, apenas cambia el rendimiento de la decodificación, a su vez disminuyendo considerablemente los tiempos de cálculo [16]. Además, las señales EEG se estandarizan de acuerdo con la siguiente expresión:

$$EV[t] = \frac{V[t]-\bar{V}}{SD_V} \quad (1)$$

En esta estandarización, a cada señal $EV[t]$ se le resta, para cada muestra de tiempo $V[t]$, la media de toda la señal V y el resultado se divide por la desviación estándar SD_V . Este método de preprocesamiento se ha aplicado a todos los ensayos de todos los sujetos.

Por último, cabe resaltar que, para hacer coincidir ambas señales, tanto las trayectorias reales calculadas como las señales EEG han sido remuestreadas desde su frecuencia de adquisición (500-Hz EEG y 30-Hz IMUs) a 60 Hz. Además, a las trayectorias reales se les aplica el mismo filtro Butterworth de 4º orden y fase cero entre 0.1- 2Hz.

2.4 MÉTODO DE DECODIFICACIÓN

El método de decodificación seleccionado es una regresión lineal multidimensional. El modelo de regresión se crea relacionando los datos cinemáticos reales obtenidos con las IMUs y se relacionan con las señales de EEG seleccionadas, para ello, se emplea la siguiente ecuación:

$$x[t] = a + \sum_{n=1}^N \sum_{k=0}^L b_{nk} \cdot S_n[t - G \cdot k] \quad (2)$$

En esta regresión, $x[t]$ es el estado cinemático (los ángulos de las articulaciones de los miembros inferiores) en la muestra de tiempo t , a y b son los pesos de la regresión lineal, N es el número de canales (14 como se explica en 2.3), S_n es el voltaje estandarizado medido en el electrodo n y por último los parámetros LAG (L) y el GAP (G). El L está referido a cuántas muestras previas se toman para el cálculo de cada estado cinemático, mientras que el G indica la separación entre estas muestras, por ello, ambos parámetros vienen a indicar cuánto es el tiempo previo que se empleará para el cálculo de la trayectoria en el instante t , para más detalles consultar en [16].

El modelo de regresión se ha creado individualmente por usuario con los datos de trayectorias reales y las señales EEG de todas las repeticiones del experimento exceptuando los datos de EEG de la última repetición, que será la empleada para validar el modelo. Dicha comparación se ha llevado a cabo mediante los Coeficientes de Correlación de Pearson (PCC) entre las trayectorias reales de cada una de las articulaciones inferiores (obtenidas con las IMUs en el último ensayo de cada usuario) y las trayectorias decodificadas (generadas al aplicar el modelo de regresión a esa última prueba), por lo tanto, se obtendrán seis gráficas por usuario y un valor de PCC por cada una de estas gráficas.

Los análisis previos realizados por Javier et al. mostraban resultados esperanzadores en la búsqueda de la optimización de este modelo con el cambio de parámetros como el G , pero manteniendo la configuración inicial de $L = 10$ [17]. En este estudio se sigue profundizando todavía más en esta mejora a través de un barrido tanto en los valores de G como de L . Cabe resaltar que dichos valores han sido condicionados con la limitación de no exceder los tres segundos de señal previa para el cálculo de la trayectoria decodificada, esto quiere decir que si el valor de L es 10, el valor máximo de G es 19 ($L \cdot (G - 1)$) ya que en este caso, las señales con las que se trabajan están remuestreadas a 60 Hz. Además, otras configuraciones de electrodos distintas al empleado en [16] han sido analizadas.

3 RESULTADOS Y DISCUSIÓN

Primeramente, los resultados se han obtenido para todos los usuarios con la configuración de parámetros originales ($L=10$ y la configuración de electrodos mencionados en 2.3) y se ha variado el valor de G de 1 hasta 19 en todas las articulaciones de cada usuario; tan solo el valor de G que genera los mejores resultados por articulación se han indicado en la tabla 1. Los resultados muestran una alta variabilidad entre los sujetos ($0,53 \pm 0,21$). En cuanto a los valores de G , tienden a ser valores altos ($15,7 \pm 2,1$), evidenciando que cuanto mayor es la ventana temporal previa, mejor es el modelo obtenido. La alta variabilidad entre sujetos da pie a la discriminación de sujetos ya que se observan dos claras tendencias en los resultados. Para algunos usuarios como U1, U4, U7 y U8 el modelo presenta una menor efectividad ($0,36 \pm 0,08$) mientras que para U2, U3, U5 y U6 los resultados alcanzan valores más altos ($0,69 \pm 0,15$), llegando a valores de PCC de 0,83 para algunas articulaciones en algunos usuarios como el U6 (Figura 4).

A continuación, se ha realizado un estudio del parámetro L . Se han encontrado valores de L como 30 y 57 que podrían mejorar ligeramente los resultados

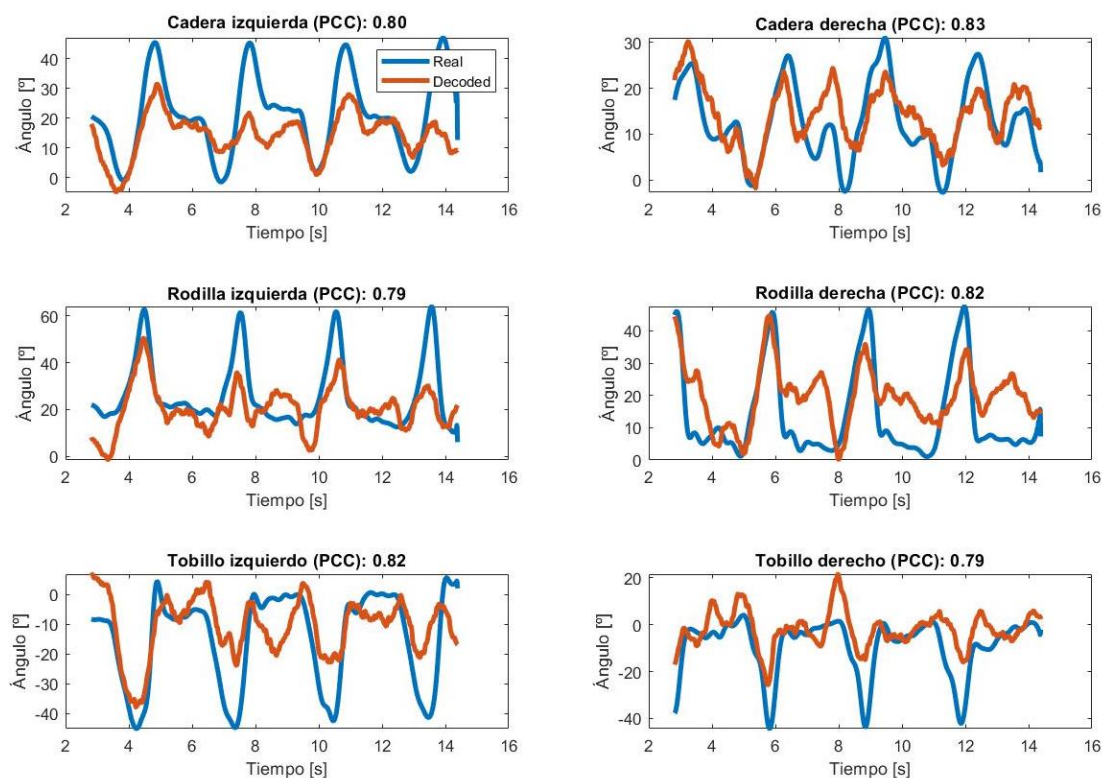


Figura 4: Comparación de trayectorias reales frente a las trayectorias decodificadas con EEG para cada una de las articulaciones de ambas extremidades inferiores del usuario 6. Se indica el índice del PCC en cada caso.

de la decodificación. El mismo estudio previo con $L = 10$ se ha llevado a cabo con el $L = 57$ y los resultados son similares ($0,52 \pm 0,21$) e incluso mejoran en algunos usuarios como el 2, 4 y 6. Cabe resaltar que se debe cumplir la condición comentada en 2.4, por ello, la variación de G en este caso admite como máximo un valor de $G = 3$, ya que valores mayores supondrían rebasar los tres segundos previos de la señal. Para seguir con los análisis, se ha fijado este nuevo valor de L .

Recordando el objetivo del estudio, obtener el valor óptimo de todos los parámetros del modelo, es necesario que los resultados puedan generalizarse para reducir la complejidad y el coste temporal derivado de su búsqueda. Tras haber fijado el mejor valor de L , se pretende encontrar un valor de G que se pueda consolidar como el mejor ya que hasta el momento, los resultados se han obtenido con el mejor valor de G personalizado por usuario y articulación (Tabla 1). Dicha generalización se ha llevado a cabo buscando el mejor G por usuario, por articulación y global. La generalización por usuario ha resultado ser la más exitosa ya que el PCC medio sigue siendo notablemente bueno ($0,51 \pm 0,22$), por tanto, como indican los valores de la tabla 2, emplear el mismo G para todas las articulaciones en cada uno de los sujetos sería una buena alternativa.

Por último, se han evaluado diferentes rangos de frecuencia de las señales de EEG sin mejorar los resultados anteriores. En cuanto a los electrodos implicados, se han probado varias configuraciones. Una de ellas, es la reducción de catorce a nueve electrodos más centrados en la corteza motora FC1, C1, CZ, CP1, C3, FC2, C2, C4 y CP2. La distribución de los datos se encuentra más centrada que empleando la primera de las configuraciones mencionadas, ya que

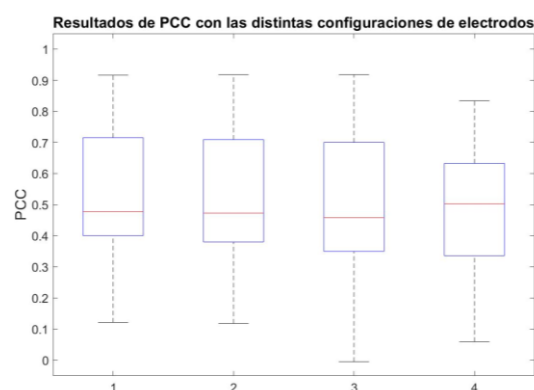


Figura 5: Boxplot con los valores PCC de las distintas configuraciones analizadas en el estudio. ($L=10$ y $G [1-19]$ específico por articulación/ $L=57$ y $G [1-3]$ específico por articulación / $L=57$ y G generalizado por usuario / $L=57$, G generalizado por usuario y 9 electrodos).

Tabla 1: Valores de PCC con la configuración inicial (L=10) y el mejor G específico por articulación de 1 a 19, dicho valor se indica entre paréntesis al lado de cada uno de los valores de PCC.

Usuario	Tobillo		Rodilla		Cadera		Media ±Desviación
	Derecho	Izquierdo	Derecha	Izquierda	Derecha	Izquierda	
U1	0,40 (19)	0,38 (14)	0,33 (19)	0,43 (6)	0,23 (16)	0,20 (3)	0,33±0,10 (12,8±6,8)
U2	0,53 (18)	0,59 (8)	0,58 (16)	0,40 (18)	0,47 (19)	0,51 (12)	0,51±0,07 (15,2±4,3)
U3	0,43 (1)	0,70 (19)	0,64 (3)	0,71 (18)	0,76 (19)	0,40 (19)	0,61±0,15 (13,2±8,7)
U4	0,37 (12)	0,41 (17)	0,12 (7)	0,16 (19)	0,40 (19)	0,23 (18)	0,28±0,13 (15,3±4,8)
U5	0,76 (18)	0,78 (13)	0,72 (14)	0,80 (19)	0,72 (16)	0,82 (19)	0,77±0,04 (16,5±2,6)
U6	0,89 (17)	0,88 (19)	0,92 (18)	0,84 (19)	0,85 (19)	0,84 (18)	0,87±0,03 (18,3±0,8)
U7	0,53 (19)	0,46 (19)	0,50 (9)	0,43 (12)	0,54 (13)	0,44 (17)	0,48±0,05 (14,8±4,1)
U8	0,46 (3)	0,33 (8)	0,49 (5)	0,47 (10)	0,16 (1)	0,26 (7)	0,36±0,13 (5,7±3,3)

el valor de la mediana es mayor (Figura 5). Además, como se observa en la tabla 2, los niveles de PCC (0,49 ± 0,20) se reducen muy poco respecto a la primera configuración de parámetros.

4 CONCLUSIÓN

Tras un estudio exhaustivo de todos los parámetros, los mejores resultados se han obtenido al utilizar nueve electrodos sobre la corteza motora, un rango de frecuencia de 0,1 a 2 Hz y un valor de L de 57. En cuanto al valor de G, se ha conseguido una generalización del modelo por usuario que provoca una variación mínima de los resultados finales respecto a la configuración original previamente comentada. Respecto a la reducción de electrodos, en algunos usuarios, como el 7, incluso se mejoran los resultados de la decodificación con los nuevos parámetros (media PCC = 0,52), llegando incluso a generar una mejora porcentual de 48,57 % respecto a

resultados obtenidos en estudios previos similares de Juan et al. [9].

El deterioro de los resultados finales debido a la generalización y la supresión de 5 electrodos de la configuración inicial ha sido mucho menor de la esperada, esto supone una gran liberación de procesamiento de datos y una mejora en el tiempo de creación del modelo. Sin embargo, cabe resaltar que no se ha encontrado ninguna configuración de parámetros que genere una mejora significativa respecto de los parámetros originales, por lo que concluye que los elegidos en el estudio [16] eran precisos.

A pesar de los resultados, todavía queda mucho trabajo por hacer para utilizar la decodificación de ángulos a partir del EEG como un enfoque potencial para el mando de exoesqueletos. En este sentido, serían prometedores otros estudios relacionados, como la identificación de las fases de la marcha a partir del EEG.

Tabla 2: Valores de PCC con la configuración final (L=10), mejor G generalizado por usuario de 1 a 3 y nueve electrodos en la corteza motora.

Usuario	GAP	Tobillo		Rodilla		Cadera		Media ±Desviación
		Derecho	Izquierdo	Derecha	Izquierda	Derecha	Izquierda	
U1	2	0,32	0,32	0,26	0,41	0,24	0,14	0,28±0,09
U2	3	0,53	0,57	0,60	0,39	0,44	0,45	0,50±0,08
U3	3	0,42	0,64	0,63	0,65	0,71	0,52	0,59±0,10
U4	3	0,36	0,30	0,10	0,06	0,37	0,16	0,22±0,14
U5	3	0,62	0,63	0,60	0,71	0,64	0,76	0,66±0,06
U6	3	0,79	0,82	0,82	0,79	0,84	0,80	0,81±0,02
U7	3	0,58	0,56	0,51	0,50	0,52	0,47	0,52±0,04
U8	1	0,41	0,27	0,47	0,39	0,24	0,19	0,33±0,11

Agradecimientos

Esta investigación ha recibido financiación del Programa de Investigación e Innovación Horizon 2020 de la Unión Europea, mediante una Open Call realizada y ejecutada bajo el proyecto EUROBENCH (grant agreement No 779963).

English summary

OPTIMISATION OF LINEAR REGRESSION MODEL FOR DECODING LOWER LIMB KINEMATIC TRAJECTORIES FROM EEG SIGNALS

Abstract

During the last decade, active exoskeletons have become a key tool in the rehabilitation of patients with mobility problems, especially those affected by diseases related to the nervous system. Several studies have shown that conscious movement by patients with mobility difficulties, assisted by these devices, contributes positively to the recovery of their mobility, shortening rehabilitation times and improving outcomes. In addition, other studies have hypothesized that the motor cortex is active during specific phases of the gait cycle. In this study, new multi-linear regression model parameters have been analyzed for enhancing the decoding of lower limb kinematics from EEG signals. Besides, the generalization of these new parameters has been studied in order to create a unified model that facilitates its use. The new configurations achieve similar mean values (Pearson's correlation coefficient) between the real and decoded trajectories 0.49 ± 0.20 . This leads to the conclusion that the new parameters could be generalized.

Keywords: Decoding, EEG, kinematics, lower limbs, exoskeleton

Referencias

- [1] Avila-Tomás, J., Mayer-Pujadas, M., Quesada-Varela, V., (2020) “La inteligencia artificial y sus aplicaciones en medicina I: introducción antecedentes a la IA y robótica”. *Atención Primaria*, 52(10), pp.778-784.
- [2] Castermans, T., Duvinage, M., (2013) Corticomuscular coherence revealed during treadmill walking: further evidence of supraspinal control in human locomotion, *Journal of Physiology*, vol. 591, pp. 1407-1408.
- [3] Cramer, S., (2008) “Repairing the human brain after stroke. II. Restorative therapies”, *Annals of Neurology*, 63(5), pp. 549-560.
- [4] Ferrero, L., Quiles, V., Ortiz, M., Iáñez, E., Azorín, J. M., (2021) “A BMI Based on Motor Imagery and Attention for Commanding a Lower-Limb Robotic Exoskeleton: A Case Study,” *Appl. Sci.*, Vol. 11, Page 4106.
- [5] Garipelli, G., Chavarriaga, R., Millán, J. del R., (2013) “Single trial analysis of slow cortical potentials: a study on anticipation related potentials”, *J. Neural Eng.*, vol. 10(3): 036014.
- [6] Gharabaghi, A., (2016) “What Turns Assistive into Restorative Brain-Machine Interfaces” *Front. Neurosci.*, vol. 0, no. OCT, p. 456.
- [7] Hidler, J., Nichols, D., Pelliccio, M., Brady, K., (2005) “Advances in the understanding and treatment of stroke impairment using robotic devices”. *Top. Stroke Rehabil.* 12:22–35.
- [8] Juan J.V., de la Ossa, L., Iáñez, E., Ortiz, M., Ferrero, L. Azorín, J.M., (2022) “Decoding Lower-Limbs Kinematics from EEG Signals while Walking with an Exoskeleton”. *In International Work-Conference on the Interplay Between Natural and Artificial Computation*. pp. 615-624.
- [9] Karelis A.D., Carvalho L.P., Castillo M.J., Gagnon DH, Aubertin-Leheudre M., (2017) “Effect on body composition and bone mineral density of walking with a robotic exoskeleton in adults with chronic spinal cord injury”. *J Rehabil Med.* ;49(1):84-87.
- [10] Leduc B.E., Lepage Y., (2002) “Health-related quality of life after spinal cord injury”, *Disabil Rehabil.* ;24(4):196-202.
- [11] Li, Y. D., Hsiao-Wecksler, E. T., (2013). “Gait mode recognition and control for a portable-powered ankle-foot orthosis”. *In 2013 IEEE 13th International Conference on Rehabilitation Robotics (ICORR)*, pp. 1-8.
- [12] Mercado, L., Azorín, J. M., Platas, M., Úbeda, A., Quiroz, G., (2013) “Offline LowerLimb Kinematic Decodification by Segments of EEG Signals. *In 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 2398-2401.

- [13] Ortiz, M., Ferrero, L., Iáñez, E., Azorín, J. M., Contreras-Vidal, J. L., (2020) "Sensory Integration in Human Movement: A New Brain-Machine Interface Based on Gamma Band and Attention Level for Controlling a Lower-Limb Exoskeleton". *Frontiers in Bioengineering and Biotechnology*, 8, 735.
- [14] Shakibae, F., Mottaghi, E., Kobravi, H. R., Ghoshuni, M., (2019) "Decoding knee angle trajectory from electroencephalogram signal using NARX neural network and a new channel selection algorithm". *Biomedical Physics & Engineering Express*, 5(2), 025024.
- [15] Úbeda, A., Costa, Á., Iáñez, E., Piñuela-Martín, E., Márquez-Sánchez, E., del-Ama, A. J., Gil-Agudo, Á., Azorín, J. M., (2015) "Single joint movement decoding from EEG in healthy and incomplete spinal cord injured subjects". In *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 6179-6183.
- [16] Úbeda, A., Planelles, D., Costa, A., Hortal, E., Iáñez, E., Azorín, J. M., (2014) "Decoding knee angles from EEG signals for different walking speeds". In *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 1475-1478 .
- [17] Volpe B.T., Huerta P.T., Zipse J.L., Rykman A., Edwards D., Dipietro L., Hogan N., Krebs H.I., (2009) "Robotic devices as therapeutic and diagnostic tools for stroke recovery". *Arch. Neurol.* 66:1086–1090.



© 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC-SA 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).