

INTERFAZ CEREBRO-COMPUTADORA HÍBRIDA BASADA EN LA FUSIÓN DE EEG Y EMG PARA DETECCIÓN DE LA INTENCIÓN MOTORA

Ramón Osmany Ramírez Tasé, Universidad de Granma, Cuba, rtase1984@gmail.com

Denis Delisle-Rodríguez, Universidad Federal Espírito Santo, Brasil, delisle05@gmail.com

Oluwarotimi Williams Samuel, Instituto de Tecnologías Avanzadas, China,

timitex92@gmail.com

Tiago H. Falk, Instituto Nacional de Investigación Científica, Canadá, tiago.falk@inrs.ca

Alberto López-Delis, Centro de Biofísica Médica, Cuba, lopez.delis69@gmail.com

Resumen

El presente trabajo propone el desarrollo de una interfaz cerebro-computador híbrida ICCH que permite la fusión de señales de electroencefalografía (EEG) y electromiografía de superficie (EMGs) para la decodificación de la intención de movimiento. Se implementan y prueban dos técnicas de fusión de señales: 1) fusión bayesiana y 2) voto mayoritario ponderado (VMP). El desempeño del esquema híbrido se evaluó a partir de las métricas de exactitud (*accuracy*) de la clasificación, la sensibilidad (*recall*), el coeficiente kappa de Cohen y la tasa de falsos positivos (TFP). El desempeño obtenido por la propuesta basada en fusión bayesiana fue; exactitud media del 93,38%, sensibilidad de 88,97, coeficiente kappa de 0,51 y TFP=16,68%. El esquema basado en VMP, por su parte, obtuvo una precisión media del 93,36%, sensibilidad del 86,90, coeficiente kappa del 0,45 y TFP del 22,53%. Ambos sistemas híbridos superaron a los modelos basados en EEG o EMGs, lo que sugiere la utilidad potencial de los métodos propuestos en aplicaciones de neurorrehabilitación.

Abstract

The present work proposes the development of a hybrid brain computer interface (HBCI) that allows the fusion of electroencephalography (EEG) and surface electromyography (sEMG) signals for a robust movement intent decoding. In this work, two signal fusion techniques based on Bayesian fusion and weighted-majority-vote (WMV) are proposed, and tested. The performance of the hybrid scheme was evaluated by using the classification accuracy (ACC), recall, Cohen's kappa coefficient, and false positive ratio (FPR). Our proposed HBCI based on Bayesian fusion obtained average ACC of 93.38%, recall of 88.97, kappa of 0.51 and FPR=16.68%. As other result, the scheme based on WMV achieved mean accuracy of 93.16%, recall of 86.90, kappa of 0.45 and FPR of 22.53%. Both hybrid systems outperformed solutions based on EEG or EMG alone, thus suggesting their potential for neuro-rehabilitation applications.

Palabras clave: fusión bayesiana, intención motora, interfaz cerebro-computadora, voto mayoritario ponderado

Key words: Bayesian fusion, weighted majority vote, Hybrid Brain-Computer Interface, Motor intention detection.

1. Introducción

La Organización Mundial de Salud (OMS) estima que más de mil millones de personas presentan alguna forma de discapacidad motora, los cuales constituyen 15% de la población mundial (OMS,

2020). Entre los tipos de discapacidad más frecuentes a nivel mundial se encuentran las que involucran las manos, que pueden estar asociadas a amputaciones o daños en el sistema motor. Esto ha motivado, el desarrollo de tecnologías para la rehabilitación de los miembros superiores, constituyendo actualmente una área de investigación en desarrollo (Anam & Al-Jumaily, 2017).

Las interfaces cerebro-computador (ICCs) son sistemas que proveen una vía de comunicación entre un usuario y una aplicación final; que puede ser un dispositivo robótico, juego serio, software, entre otros; para facilitar su interrelación (Drishti Yadav et al., 2020; Kögel et al., 2020). Estas tecnologías emergentes han demostrado un alto potencial en terapias de neurorehabilitación de pacientes con daño motor para la recuperación de la función motora perdida (Birbaumer et al., 2014; Bouton et al., 2016), mediante el control de exoesqueletos (Gui et al., 2019; Yun et al., 2017), induciendo plasticidad cerebral (Rupp et al., 2015). Es por ello que la comunidad científica en las últimas décadas ha mostrado especial interés en el desarrollo de este tipo de aplicaciones basadas en ICCs.

2. Desarrollo

2.1 Marco teórico

Varias tecnologías de ICCs han sido desarrolladas, a partir de diversos tipos de bioseñales (Hong & Khan, 2017; Naufel & Klein, 2020; Rashid et al., 2020). Entre las más utilizadas, se encuentran las que se soportan en las señales de electromiografía de superficie, que proveen una interacción más natural entre el humano y el dispositivo final. Estas señales, son ampliamente usadas en aplicaciones de control ya que reflejan directamente la intención motora de los músculos (Samuel et al., 2019). Otra tecnología, que se muestra promisoría en este sentido es la basada en EEG, ya que no es invasiva, no requiere de equipos costosos para su captura y presenta pequeños tiempos constantes que pueden funcionar en la práctica para muchas situaciones.

Para fortalecer las ICCs basadas en señales de EEG, varios estudios exploraron la combinación de esta señal con otras de menos variabilidad intrasujetos, tales como EMGs (Leeb et al., 2011). Las ICCs híbridas combinan o fusionan la información de dos o más subsistemas o señales con el objetivo de optimizar su desempeño (Aly et al., 2018; Guragain et al., 2018). Investigaciones similares (Ben Said et al., 2017; Chowdhury et al., 2019, 2017; Cisotto et al., 2017; Kawase et al., 2017; Leeb et al., 2011; Li et al., 2017; Mudiyansele, 2014; Samuel et al., 2015; Sarasola et al., 2017), combinaron las señales de EEG y EMGs con resultados promisorios. Estas estrategias simplifican las desventajas del uso de cada clasificador de patrones basados en EEG ó EMGs independiente. Pero aun es necesario continuar investigando nuevos esquemas híbridos más efectivos para su uso en aplicaciones biomédicas.

2.2 Planteamiento del problema

A pesar de su amplio uso en aplicaciones no clínicas, la exactitud alcanzada en la clasificación de la intención motora, mediante el uso de ICCs, sigue siendo baja. Esto limita su uso clínico para la terapia de neurorehabilitación (Li et al., 2017). Por ejemplo, en el caso de los modelos híbridos, basados en EEG, factores como la baja tasa de transferencia de información (TTI), la eficacia limitada en la identificación de la intención de movimiento del usuario, la baja usabilidad, la fiabilidad limitada en el funcionamiento en el mundo real y el aumento de los requisitos de carga cognitiva (Padfield et al., 2019). Los modelos basados en EMGs, presentan algunas limitaciones relacionadas

con la fatiga muscular, que puede afectar a la amplitud y al espectro de frecuencias de las señales mioeléctricas, además de los niveles normales de las contracciones musculares. El temblor involuntario es otro problema conocido para los métodos basados en esta señal (Rocon et al., 2006). Por otro lado, en el caso de individuos con paraplejia o hemiplejia, las señales EMGs no son suficientes para controlar un exoesqueleto, por ejemplo, cuando se tiene como objetivo mejorar el desempeño de las actividades de la vida diaria (Chowdhury et al., 2017). Mediante la combinación de ambas tecnologías en una ICC híbrida, se podría mejorar la clasificación de los movimientos en pacientes amputados (Li et al., 2017), así como su proceso de rehabilitación. Por lo anterior, se hace necesario desarrollar tecnologías para la rehabilitación de estos individuos en función de reparar el daño neurológico o motor, para facilitarle su autonomía y movilidad.

2.3 Método

Bases de datos: se adquirió una base de datos de 4 pacientes amputados (41.50 ± 7.05 años de edad promedio) con cinco clases de movimiento (Li et al., 2017; Samuel et al., 2019). Los sujetos ejecutaron cada tarea de movimiento durante 5 s incluyendo 5 s de reposo entre cada una, evitando fatiga mental y muscular. Cada movimiento fue repetido varias veces obteniéndose de 10 repeticiones en un tiempo total de 50 s de EEG y EMGs por sesión. La frecuencia de muestreo fue de 1024 Hz y 1000 Hz para EMGs y EEG, respectivamente.

Propuesta de ICC: la **Error! Reference source not found.** muestra la ICC propuesta basada en la fusión de señales de EEG y EMGs. El método está conformado por 4 etapas: preprocesamiento, extracción de características, clasificación y fusión de la clasificación. Los detalles de cada etapa se describen en las secciones siguientes.

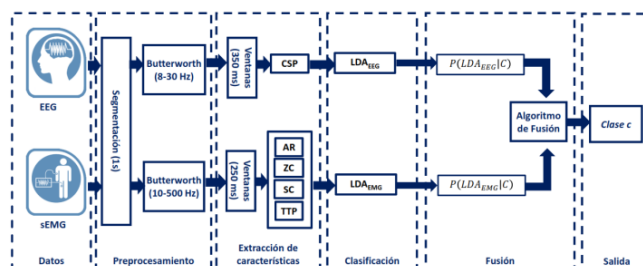


Figura 1. Diagrama en bloques de la ICC propuesta para la detección de la intención motora.

- a) **Preprocesamiento:** Para cada clase de movimiento se extrajeron segmentos desde -0,12 hasta 1s (siendo el inicio del movimiento en 0s). Se realizó el filtrado con filtros de Butterworth de segundo orden, para el caso de las señales de EEG en el rango de frecuencia de 8 a 30 Hz , y de 10 hasta 500 Hz para las señales de EMGs. Se implementó una estrategia de segmentación, analizando cada 100 ms ventanas de 250 ms para el procesamiento de la señal de EMGs y cada 100 ms ventanas de 350 ms para el caso de EEG.
- b) **Extracción de características:** para la señal EEG se usó el método conocido como CSP (del inglés Common Spatial Patterns) (Fu et al., 2020; Park & Chung, 2019). Teniendo en cuenta que en el presente estudio se trabaja con 5 clases de movimiento, para extender el método CSP de solo dos clases a multiclase, se diseñó un esquema de uno contra el resto. En este esquema cada filtro está diseñado para maximizar la varianza de una clase de

movimiento y minimizar el promedio de las varianzas del resto de las clases. Las características de los componentes seleccionados de cada filtro son concatenadas en un vector de características.

Sobre las épocas de 250 ms extraídas de la señal EMGs, se extrajeron de cada canal cuatro vectores característicos en el dominio temporal y frecuencial: modelos autorregresivos, cruces por cero, cambios de pendiente de la señal y potencia total.

- c) Classification:** en esta fase se empleó el clasificador basado en Análisis de Discriminante Lineal conocido como LDA (del inglés *Linear Discriminant Analysis*). Este método ha sido ampliamente usado en problemas de clasificación para la detección de la intención motora (Li et al., 2017; Lotte et al., 2018). En LDA, el hiperplano de separación se encuentra buscando una proyección de los datos que maximice la distancia entre las medias de dos o más clases y minimice las varianzas entre clases. El LDA asume una distribución de datos normal junto con matrices de covarianza iguales para ambas clases.
- d) Fusión:** para la fusión de las predicciones se estudiaron dos variantes: fusión bayesiana (Kuncheva et al., 2001) y el método voto mayoritario ponderado (Goyal, 2018) conocido como WMV (del inglés *Weighted Majority Vote*). La fusión bayesiana es considerada como un modelo condicional $P(C|O1,O2)$ que combina las decisiones de dos o más fuentes de entrada de datos (en este caso las señales EEG y EMGs), donde C denota el conjunto de clases y $O1$ y $O2$ son los resultados de los clasificadores LDA correspondientes a los modelos EEG y EMGs respectivamente. A diferencia del tradicional método bayesiano (Kuncheva et al., 2001), en este trabajo se inicializa P en cada caso, con la matriz de confusión obtenida del LDA correspondiente. Por otro lado, en el caso del WMV, se asigna un peso w a la predicción de cada clasificador para cada clase. A diferencia del original WMV (Goyal, 2018), en este caso, el peso es estático para cada clasificador ($w_{LDA_EEG}=0.5$ and $w_{LDA_EMG}=0.5$) aunque en la configuración puede modificarse este parámetro.

Evaluación de la propuesta: Con el fin de garantizar un rendimiento adecuado del clasificador, se utilizó un esquema de validación cruzada de 5 particiones para dividir la matriz de características extraídas en conjuntos de entrenamiento, prueba y validación antes de introducirlos en el clasificador. Los dos primeros conjuntos se utilizaron para obtener el modelo LDA, que posteriormente se evaluó con el tercer conjunto. Las métricas utilizadas para la evaluación fueron la exactitud de la clasificación (ACC, *Accuracy*), la sensibilidad (*recall*), el coeficiente kappa de Cohen (k) y la tasa de falsos positivos (FPR, *False Positive Rate*) (Japkowicz & Mohak, 2011). Se realizaron varias ejecuciones con cada sujeto, seleccionando en cada caso el promedio de las métricas. Inicialmente, se evaluó, la clasificación con LDA de los modelos EEG y EMGs de forma independiente con cada sujeto, y luego los dos métodos de fusión,

2.4 Resultados

La Tabla 1 muestra el rendimiento del clasificador LDA para cada sujeto utilizando las señales EEG y EMGs de forma independiente. Como se puede observar, para el modelo EEG, el desempeño obtenido fue ACC=67,38%, Recall=76,69, $k= 0,38$ y FPR=25,10%. Para el modelo EMGs, el

desempeño fue $ACC=92,24\%$, $Recall=88,02$, $\kappa=0,53$ y $FPR=16,43\%$, por lo tanto, mejor que el EEG solo. En ambos casos, el mejor rendimiento se obtuvo para el sujeto S2.

Tabla 1. Desempeño del clasificador LDA usando los modelos basados en señales EEG y EMGs de forma independiente.

Sujetos	EEG				EMG			
	ACC (%)	Recall	κ	FPR (%)	ACC (%)	Recall	κ	FPR (%)
S1	62,09	77,36	0,11	38,12	90,13	88,41	0,23	21,09
S2	72,26	78,23	0,68	15,56	94,65	89,09	0,74	-
S3	68,33	76,19	0,44	19,71	91,77	87,99	0,58	11,84
S4	66,85	74,96	0,28	27,01	92,39	86,57	0,39	16,35
Media	67,38	76,69	0,38	25,10	92,24	88,02	0,53	16,43
Desv. Est.	4,20	1,42	0,24	10,29	1,87	1,06	0,22	6,20

La tabla 2, a su vez, muestra los resultados de los ICCH a la izquierda con esquemas bayesiano y a la derecha con WMV. Como se puede observar, ambos métodos obtuvieron un mejor desempeño en relación con los modelos independientes. En el caso de la fusión bayesiana, se observó un aumento de la exactitud del 26% en relación con el modelo EEG, y del 1,14% en relación con el modelo EMGs. El incremento en la métrica de la sensibilidad usando esta estrategia de fusión fue del 12,28% y del 5,36% con respecto a EEG y EMGs respectivamente. El FPR promedio alcanzado, fue de un 16,68%, superior en solo 0,25% al alcanzado por el clasificador LDA para el modelo basado en EMGs, pero es inferior en un 8,42% con respecto al modelo basado en EEG, lo que demuestra su superioridad para la rehabilitación motora.

Tabla 2. Desempeño de la ICC híbridas con cada estrategia de fusión.

Sujetos	Fusión Bayesiana				Fusión por WMV			
	ACC (%)	Recall	κ	FPR (%)	ACC (%)	Recall	κ	FPR (%)
S1	92,02	86,43	0,18	29,05	91,87	85,1	0,26	32,01
S2	94,98	90,91	0,75	7,12	94,75	89,17	0,65	10,96
S3	93,63	89,08	0,68	12,07	92,99	87,99	0,52	25,03
S4	92,87	89,45	0,41	18,46	93,02	85,32	0,35	22,10
Media	93,38	88,97	0,51	16,68	93,16	86,90	0,45	22,53
Desv. Est.	1,26	1,87	0,26	9,47	1,19	2,01	0,17	8,76

En el caso de la fusión por WMV, la exactitud media obtenida fue del 93,16%, por tanto, inferior a la fusión bayesiana. Esta estrategia es superior en un 25,78% y un 0,92% en relación con los modelos EEG y sEMG, respectivamente. Se observaron mejoras similares en todas las restantes métricas. Otro aspecto importante es la estabilidad del rendimiento de los sistemas híbridos entre los sujetos. La variabilidad intra-sujeto es una de las principales limitaciones de los sistemas ICCs (Ruhunage et al., 2019). Como se puede observar en la Tabla 1, es el caso de los modelos basados en EEG y EMGs.

2.5 Discusión

Los resultados presentados, son comparables a los obtenidos en (Ruhunage et al., 2019; Samuel et al., 2017, 2015), coincidiendo en que la fusión de señales con EEG y EMGs constituyen una vía para mejorar la exactitud de las ICCs tradicionales basadas en una única señal. Ruhunage et al. (2019) obtienen una exactitud de 86,98% en la clasificación mediante una ICCH basada EEG y

EMGs para mover un exoesqueleto, resultados que mejoran en la propuesta aquí presentada. Se muestra además similar comportamiento respecto a Larraz et al. (2018), donde se evidencia el incremento de la exactitud de la clasificación de las ICC tradicionales basadas en una sola señal mediante la fusión de las señales antes mencionadas en una ICCH. Los resultados aquí obtenidos son también comparables con la exactitud obtenida por Samuel et al.(2015) con una base de datos similar a la utilizada en este trabajo, pero utilizando otra estrategia de fusión. Nuestros resultados, igual que otros estudios, han demostrado claramente que la fusión de las señales EEG y sEMG puede mejorar significativamente el rendimiento de la clasificación para la detección de los movimientos de la mano y la muñeca en comparación con los métodos basados en una sola señal.

3. Conclusiones

En este estudio se han propuesto dos métodos de clasificación híbridos basados en la fusión de señales EEG y EMGs para la clasificación de los movimientos de la mano y la muñeca. Los resultados experimentales muestran que los métodos híbridos presentan un mejor desempeño en comparación con los métodos individuales basados únicamente en EMGs o EEG, además de reducir la variabilidad entre sujetos que se observa habitualmente en los sistemas BCI.

Referencias

- Aly, H. I., Youssef, S., & Fathy, C. (2018). *Hybrid Brain Computer Interface for Movement Control of Upper Limb Prostheses*. 1-6. <https://doi.org/10.1109/ICBEA.2018.8471729>
- Anam, K., & Al-Jumaily, A. (2017). Evaluation of extreme learning machine for classification of individual and combined finger movements using electromyography on amputees and non-amputees. *Neural Networks*, 85, 51-68. <http://dx.doi.org/10.1016/j.neunet.2016.09.004>
- Ben Said, A., Mohamed, A., Elfouly, T., Harras, K., & Wang, Z. J. (2017). Multimodal Deep Learning Approach for Joint EEG-EMG Data Compression and Classification. *2017 IEEE Wireless Communications and Networking Conference (WCNC)*, 1-6. <https://doi.org/10.1109/WCNC.2017.7925709>
- Birbaumer, N., Gallegos, G., Wildgruber, M., Silvoni, S., & Soekadar, S. R. (2014). Direct brain control and communication in paralysis. *Brain topography*, 27, 4-11.
- Bouton, C. E., Shaikhouni, A., Annetta, N. V., Bockbrader, M. A., Friedenber, D. A., Nielson, D. M., Sharma, G., Sederberg, P. B., Glenn, B. C., & Mysiw, W. J. (2016). Restoring cortical control of functional movement in a human with quadriplegia. *Nature*, 533, 247-250.
- Chowdhury, A., Raza, H., Dutta, A., & Prasad, G. (2017). EEG-EMG based Hybrid Brain Computer Interface for Triggering Hand Exoskeleton for Neuro-Rehabilitation. *Proceedings of the Advances in Robotics on - AIR '17*, 1-6. <https://doi.org/10.1145/3132446.3134909>
- Chowdhury, A., Raza, H., Meena, Y. K., Dutta, A., & Prasad, G. (2019). An EEG-EMG correlation-based brain-computer interface for hand orthosis supported neuro-rehabilitation. *Journal of neuroscience methods*, 312, 1-11.
- Cisotto, G., Michieli, U., & Badia, L. (2017). A coherence study on EEG and EMG signals. *arXiv preprint arXiv:1712.01277*.

- Drishti Yadav, Shilpee Yadav, & Karan Veer. (2020). A comprehensive assessment of Brain Computer Interfaces: Recent trends and challenges. *Journal of Neuroscience Methods*, 346, 20. <https://doi.org/10.1016/j.jneumeth.2020.108918>
- Fu, R., Han, M., Tian, Y., & Shi, P. (2020). Improvement motor imagery EEG classification based on sparse common spatial pattern and regularized discriminant analysis. *Journal of Neuroscience Methods*, 343, 108833.
- Goyal, A. (2018). *Learning a Multiview Weighted Majority Vote Classifier: Using PAC-Bayesian Theory and Boosting* [PhD Thesis]. Université de Lyon.
- Gui, K., Liu, H., & Zhang, D. (2019). A practical and adaptive method to achieve EMG-based torque estimation for a robotic exoskeleton. *IEEE/ASME Transactions on Mechatronics*, 24, 483-494.
- Guragain, B., Haider, A., & Fazel-Rezai, R. (2018). Hybrid Brain-Computer Interface Systems: Approaches, Features, and Trends. En D. Larrivee (Ed.), *Evolving BCI Therapy—Engaging Brain State Dynamics*. InTech. <https://doi.org/10.5772/intechopen.75132>
- Hong, K.-S., & Khan, M. J. (2017). Hybrid Brain–Computer Interface Techniques for Improved Classification Accuracy and Increased Number of Commands: A Review. *Frontiers in Neurorobotics*, 11. <https://doi.org/10.3389/fnbot.2017.00035>
- Japkowicz, N., & Mohak, S. (2011). *Evaluating learning algorithms: A classification perspective*. Cambridge University Press.
- Kawase, T., Sakurada, T., Koike, Y., & Kansaku, K. (2017). A hybrid BMI-based exoskeleton for paresis: EMG control for assisting arm movements. *Journal of Neural Engineering*, 14, 016015. <https://doi.org/10.1088/1741-2552/aa525f>
- Kögel, J., Jox, R. J., & Friedrich, O. (2020). What is it like to use a BCI? - Insights from an interview study with brain-computer interface users. *BMC Medical Ethics*, 21(1), 2.
- Kuncheva, L. I., Bezdek, J. C., & Duin, R. P. W. (2001). Decision Templates for Multiple Classifier Fusion: An Experimental Comparison. *Pattern Recognition*, 34(2), 299-314.
- Larraz, E. L., Birbaumer, N., & Murguialday, A. R. (2018). *A hybrid EEG-EMG BMI improves the detection of movement intention in cortical stroke patients with complete hand paralysis*. 2000-2003. <https://doi.org/10.1109/EMBC.2018.8512711>
- Leeb, R., Sagha, H., Chavarriaga, R., & Millán, J. del R. (2011). A hybrid brain–computer interface based on the fusion of electroencephalographic and electromyographic activities. *Journal of Neural Engineering*, 8, 025011. <https://doi.org/10.1088/1741-2560/8/2/025011>
- Li, X., Samuel, O. W., Zhang, X., Wang, H., Fang, P., & Li, G. (2017). A motion-classification strategy based on sEMG-EEG signal combination for upper-limb amputees. *Journal of NeuroEngineering and Rehabilitation*, 14, 1-13. <https://doi.org/10.1186/s12984-016-0212-z>
- Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018). A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update. *Journal of Neural Engineering*, 15, 031005. <https://doi.org/10.1088/1741-2552/aab2f2>

- Mudiyanselage, S. (2014). *A Study of Controlling Upper-Limb Exoskeletons Using EMG and EEG signals*. 144.
- Naufel, S., & Klein, E. (2020). Brain–Computer Interface (BCI) researcher perspectives on neural data ownership and privacy. *Journal of Neural Engineering*. <https://iopscience.iop.org/article/10.1088/1741-2552/ab5b7f/meta>.
- OMS. (2020). *Discapacidad y Salud* [Corporativa]. Organización Mundial de la Salud. <http://www.who.int/es/news-room/fact-sheets/detail/disability-and-health/>
- Padfield, N., Zabalza, J., Zhao, H., Masero, V., & Ren, J. (2019). EEG-based brain-computer interfaces using motor-imagery: Techniques and challenges. *Sensors*, *19*, 1423.
- Park, Y., & Chung, W. (2019). Frequency-optimized local region common spatial pattern approach for motor imagery classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *27*(7), 1378-1388.
- Rashid, M., Sulaiman, N., Mustafa, M., Khatun, S., Bari, B. S., & Hasan, M. J. (2020). Recent Trends and Open Challenges in EEG Based Brain-Computer Interface Systems. *Springer, Singapore*, 367-378.
- Rocon, E., Miranda, J., & Pons, J. L. (2006). TechFilter: Filtering undesired tremorous movements from PC mouse cursor. *Technology and Disability*, *18*, 3-8.
- Ruhunage, I., Mallikarachchi, S., Chinthaka, D., Sandaruwan, J., & Lalitharatne, T. D. (2019). Hybrid EEG-EMG Signals Based Approach for Control of Hand Motions of a Transhumeral Prosthesis. *2019 IEEE 1st Global Conference on Life Sciences and Technologies (LifeTech)*, 50-53. <files/257/8883865.html>
- Rupp, R., Rohm, M., Schneiders, M., Kreiling, A., & Müller, G. (2015). Functional Rehabilitation of the Paralyzed Upper Extremity After Spinal Cord Injury by Noninvasive Hybrid Neuroprostheses. *IEEE*, *103*(6), 954-968.
- Samuel, O. W., Asogbon, M. G., Geng, Y., Al-Timemy, A. H., Pirbhulal, S., Ji, N., Chen, S., Fang, P., & Li, G. (2019). Intelligent EMG pattern recognition control method for upper-limb multifunctional prostheses: Advances, current challenges, and future prospects. *IEEE Access*, *7*, 10150-10165.
- Samuel, O. W., Li, X., Geng, Y., Feng, P., Chen, S., & Li, G. (2017). Motor Imagery Classification of Upper Limb Movements Based on Spectral Domain Features of EEG Patterns. *39th Annual International Conference of the IEEE EMBS*, 4.
- Samuel, O. W., Li, X., Zhang, X., & Wang, H. (2015). *A Hybrid Non-Invasive Method for the Classification of Amputees' Hand and Wrist Movements*. 5.
- Sarasola, A., Irastorza, N., Lopez, E., Bibian, C., Helmhold, F., Broetz, D., Birbaumer, N., & Ramos, A. (2017). A hybrid brain-machine interface based on EEG and EMG activity for the motor rehabilitation of stroke patients. *2017 International Conference on Rehabilitation Robotics (ICORR)*, 895-900. <https://doi.org/10.1109/ICORR.2017.8009362>
- Yun, Y., Dancausse, S., Esmatloo, P., Serrato, A., Merring, C. A., Agarwal, P., & Deshpande, A. D. (2017). *Maestro: An EMG-driven assistive hand exoskeleton for spinal cord injury patients*. 2904-2910.