

Jornadas de Automática

Clasificación de señales EEG para aplicaciones BCI de imaginación motora

Omari, S.^{a,*}, Omari, A.^b, Abderrahim, M.^c, Abu-Dakka, F.^d

^aDepartamento de Ingeniería de Sistemas y Automática, Universidad Carlos III de Madrid, Avda de la Universidad 30, 28911 Leganés, Madrid, España.

^bDepartamento de Teoría de la Señal y Comunicaciones, Universidad Carlos III de Madrid, Avda de la Universidad 30, 28911 Leganés, Madrid, España.

^cDepartamento de Ingeniería de Sistemas y Automática, Universidad Carlos III de Madrid, Avda de la Universidad 30, 28911 Leganés, Madrid, España.

^dDepartamento de Electrónica e Informática, Facultad de Ingeniería, Mondragon Unibertsitatea, 20500 Arrasate, España;

To cite this article: Omari, S., Omari, A., Abderrahim, M., Abu-Dakka, F. 2024. EEG signal classification for BCI Motor Imagery applications. *Jornadas de Automática*, 45. <https://doi.org/10.17979/ja-cea.2024.45.10957>

Resumen

La decodificación de señales EEG constituye la base de la mayoría de los estudios de interfaces cerebro-computadora. Una técnica prominente de preprocesamiento para estas señales implica el uso de matrices de covarianza. Este método ha ganado una amplia aplicación en los últimos años, particularmente en el procesamiento de señales EEG y el filtrado espacial para BCI de imaginación motora. Dado que las matrices de covarianza residen dentro de la variedad Riemanniana de matrices SPD, la aplicación de la geometría Riemanniana ha demostrado ser un enfoque robusto y de alto rendimiento. Con el fin de interpretar las señales cerebrales para aplicaciones futuras en robótica médica y sistemas de control, este artículo presenta un método que proyecta estas matrices de covarianza desde su espacio Riemanniano nativo a múltiples espacios tangentes, lo que permite el uso de clasificadores convencionales como la regresión logística y las máquinas de vectores de soporte. Nuestros resultados demuestran que este enfoque supera significativamente el método de proyección única.

Palabras clave:

Interfaz cerebro-ordenador, Imaginación motora, Electroencefalografía, Matrices de covarianza, Espacio tangente, Aprendizaje automático, Análisis e interpretación de bioseñales, Tecnología de asistencia e ingeniería de rehabilitación, Interacción cerebro-máquina.

EEG signal classification for BCI Motor Imagery applications

Abstract

EEG signal decoding serves as the foundation for the majority of brain-computer interface studies. A prominent preprocessing technique for these signals involves the use of spatial covariance matrices. This method has gained extensive application in recent years, particularly in EEG signal processing and spatial filtering for BCI motor imagery. Since spatial covariance matrices reside within the Riemannian manifold of Symmetric Positive-Definite matrices, the application of Riemannian geometry has proven to be a robust and high-performing approach. In order to interpret brain signals for future applications in medical robotics and control systems, this paper presents a method that projects these covariance matrices from their native Riemannian space to multiple tangent spaces, thereby enabling the use of conventional classifiers such as logistic regression and support vector machines. Our results demonstrate that this approach significantly outperforms the single projection method.

Keywords: Brain-computer interface, Motor imagery, Electroencephalography, Covariance matrices, Tangent space, Machine Learning, Bio-signals analysis and interpretation, Assistive technology and rehabilitation engineering, Brain-machine interaction.

1. Introducción

La tecnología de las Interfaces Cerebro-Computadora (BCI) es uno de los campos de investigación más prometedores de las últimas décadas. Esta tecnología tiene como objetivo traducir las señales cerebrales, capturadas mediante electroencefalograma (EEG), en comandos electrónicos, permitiendo de esta forma controlar computadoras o otros dispositivos electrónicos mediante la actividad cerebral humana, sin la intervención de ningún nervio o músculo periférico.

Las BCI descifran patrones de actividad neural, facilitando la interacción con el entorno, el control de dispositivos de asistencia y la restauración de funciones sensoriales o motoras perdidas, dentro de planes específicos de rehabilitación. Entre los distintos enfoques de BCI, las interfaces basadas en Imaginación Motora (MI-BCI) se destacan por aprovechar la capacidad del cerebro para generar señales neurales al imaginar acciones motoras. Este enfoque es especialmente útil en la rehabilitación de pacientes con lesiones cerebrales o daño medular, mejorando la función motora y la recuperación funcional mediante el control de dispositivos externos como prótesis robóticas o interfaces de computadora. Esto no solo mejora la calidad de vida y la autonomía de las personas con discapacidades motoras, sino que también subraya el enorme potencial de las MI-BCI en el ámbito de la asistencia y la rehabilitación.

Por otro lado, las aplicaciones de BCI abarcan una variedad de campos, incluyendo el entretenimiento, como el control de videojuegos Liao et al. (2012), y el comportamiento deportivo Park et al. (2015). También se emplean en el control de teléfonos móviles Wang et al. (2011), entornos inteligentes Lin et al. (2010) y diversas otras aplicaciones Torres P et al. (2020).

Se han considerado diversos enfoques para clasificar señales EEG en MI-BCI, de los cuales se pueden destacar 3 categorías:

- Extracción de características a partir de las señales EEG mediante análisis avanzado de señales seguida de un algoritmo de clasificación Fazli et al. (2009).
- Utilización de modelos de aprendizaje profundo, en particular redes convolucionales (CNN) Zhang et al. (2021); Tang et al. (2017) o redes recurrentes (RNN) Wang et al. (2018); Tortora et al. (2020) que se pueden alimentar con señales EEG brutas o combinarlos con características resultantes de un procedimiento de extracción de características.
- Utilización de las matrices de covarianza como descriptores de las señales EEG y manipularlas en su espacio nativo, no euclídeo, utilizando la geometría de Riemann Barachant et al. (2010); Congedo et al. (2017); Omari et al. (2023).

Este trabajo se engloba en esta última categoría y propone utilizar geometría de Riemann para proyectar las matrices de covarianza de las señales EEG desde su espacio nativo no euclídeo a diferentes espacios euclídeos tangentes al espacio nativo y utilizar estas proyecciones para alimentar un clasificador lineal. El objetivo es interpretar las señales cerebrales para ser usadas en aplicaciones futuras en el campo de la

robótica médica y el control. En particular, la metodología está diseñada para mejorar el control de prótesis, exoesqueletos y brazos robóticos, con el fin de mejorar la calidad de vida de las personas con discapacidades motoras. Al interpretar con precisión los movimientos imaginados, esta investigación podría suponer un avance significativo en las tecnologías asistivas y la neurorehabilitación.

La estructura de este artículo se organiza de la siguiente manera: En la Sección 2 se presentan el método propuesto, proporcionando tanto el contexto como los detalles de nuestra metodología. La Sección 3 se centra en los experimentos realizados, incluyendo una presentación detallada de la base de datos utilizada, los resultados obtenidos y una discusión de estos hallazgos. Finalmente, en la Sección 4 se ofrece una conclusión que sintetiza el trabajo realizado y describe las posibles direcciones para investigaciones futuras.

2. Método propuesto

2.1. Antecedentes

La geometría Riemanniana ha emergido como una herramienta poderosa en el campo de las interfaces cerebro-computadora, particularmente en el análisis y clasificación de las señales de EEG. Uno de los conceptos centrales en este enfoque es el uso de matrices de covarianza espacial, que capturan las dependencias estadísticas entre diferentes canales de EEG. Estas matrices proporcionan una representación robusta de la actividad eléctrica del cerebro, haciéndolas invaluable para la fase de preprocesamiento y extracción de características en los sistemas BCI.

Las matrices de covarianza espacial no son puntos de datos convencionales que residen en el espacio euclidiano; en su lugar, pertenecen a la variedad Riemanniana de matrices Simétricas Definidas Positivas (SPD). Esta variedad tiene una estructura geométrica única que las herramientas estándar de álgebra lineal no pueden explotar completamente. La geometría Riemanniana ofrece una manera de navegar por este espacio complejo, proporcionando métodos para medir distancias, realizar interpolaciones y aplicar otras operaciones geométricas directamente en la variedad. Esto es crucial para mantener las propiedades intrínsecas de los datos, lo que puede llevar a una clasificación más precisa y confiable.

En los trabajos publicados en los últimos años, se ha demostrado que la aplicación de la geometría Riemanniana a las BCI puede ser altamente efectiva. Al proyectar las matrices de covarianza en espacios tangentes de la variedad Riemanniana, se pueden transformar estas matrices en una forma que sea adecuada para los algoritmos convencionales de aprendizaje automático, como la regresión logística (LR) y las máquinas de vectores de soporte (SVM). Este proceso de proyección preserva las relaciones geométricas entre los puntos de datos, permitiendo que los clasificadores aprovechen la rica estructura de la variedad SPD.

Existen dos formas de combinar el uso de las matrices de covarianza y de la geometría de Riemann para la clasificación de señales EEG:

- desarrollar clasificadores basados en la geometría riemanniana, que es un enfoque que podría aprovechar toda la información de las matrices de covarianza pero

necesita el desarrollo de nuevos algoritmos de clasificación, lo que representa un esfuerzo muy considerable Barachant et al. (2012).

- utilizar la geometría riemanniana para proyectar las matrices de covarianza de su espacio nativo a un espacio euclídeo minimizando la pérdida de información y conservando al máximo la distribución de los datos, para luego aplicar un método de clasificación convencional Barachant et al. (2010); Congedo et al. (2017).

La Clasificación en Espacio Tangente (TSC) Barachant (2012) se enmarca dentro de la segunda categoría, y consiste en:

1. Calcular las matrices de covarianza de cada muestra de las señales EEG del conjunto de datos de entrenamiento.
2. Definir el punto de referencia para el espacio tangente que se va a utilizar.
3. Proyectar las matrices de covarianza de su espacio nativo al espacio tangente.
4. Aplicar un clasificador estándar.

2.1.1. Proyección al espacio tangente

Consideremos el espacio $P(n)$ de matrices simétricas definidas positivas de dimensión $n \times n$, para cada punto $\mathbf{P} \in P(n)$ corresponde un espacio tangente $T(n)$ de matrices simétricas $n \times n$, dicho espacio es un espacio plano en el que podemos utilizar los instrumentos tradicionales de la geometría euclidiana Barachant et al. (2013).

Para operar en espacios tangentes, se requiere un mapeo de $P(n)$ a $T(n)$, que se logra mediante la proyección logarítmica $\log\text{-}p(\mathbf{P}_i)$:

$$\mathbf{S}_i = \log\text{-}p(\mathbf{P}_i) = \mathbf{P}^{1/2} \log(\mathbf{P}^{-1/2} \mathbf{P}_i \mathbf{P}^{-1/2}) \mathbf{P}^{1/2} \quad (1)$$

2.1.2. Clasificación en Espacio Tangente

La Clasificación en Espacio Tangente presentada por A. Barachant en Barachant et al. (2010), es un enfoque especialmente adecuado para el análisis de datos que al igual que las matrices de covarianza residen en una variedad riemanniana.

Consideremos un conjunto de datos de entrenamiento etiquetados $\{\mathbf{C}^{(n)}, t^{(n)}\}$ para $n = 1 \dots N$ donde N es el número de datos de entrenamiento, \mathbf{C}^n la matriz de covarianza de la muestra n de la señal EEG y $t^{(n)}$ es su etiqueta. El primer paso es calcular el punto de referencia \mathbf{C}_{ref} como la media riemanniana de todas las matrices de covarianza de entrenamiento según la ecuación 2. Posteriormente se calculan las proyecciones \mathbf{Z}^n de las muestras \mathbf{C}^n mediante (1).

$$\mathbf{C}_{ref} = \operatorname{argmin}_C \sum_n \delta(C, C_i) \quad (2)$$

donde $\delta(C, C_i)$ es la distancia riemanniana entre las C y C_i .

Dado que las proyecciones \mathbf{Z}^n son matrices simétricas solo se considera la parte triangular superior de la matriz y se reordena para formar un vector $\mathbf{z}^{(n)} = \operatorname{upper}(\mathbf{Z}^n)$ de longitud $d = e(e+1)/2$ (e número de canales del EEG). Finalmente, se usa el conjunto $\{\mathbf{z}^{(n)}, t^{(n)}\}$ para entrenar un Regresión Logística (LR).

2.2. Clasificación por proyección a múltiples espacios tangentes

En este artículo se presenta un nuevo clasificador para señales EEG inspirado en el TSC, en el que se sustituye la proyección a un único espacio tangente por múltiples proyecciones, una por cada clase, lo que permite generar características más discriminatorias, mejorando así el rendimiento del modelo. Mientras el TSC proyectaba los datos a un espacio tangente al espacio nativo de las matrices de covarianza en el punto que representa la media de los datos de entrenamiento, la nueva propuesta ilustrada en la figura 1, propone proyectar todos los datos de entrenamiento a varios espacios tangentes, uno por clase, usando como referencia la media de las muestras de cada clase, ofreciendo al clasificador diferentes perspectivas de los datos.

Consideremos un conjunto de datos de entrenamiento etiquetados $\{\mathbf{C}^{(n)}, t^{(n)}\}$, el clasificador por proyección a múltiples espacios tangentes (M-TSC) calcula la media riemanniana de las muestras de cada una de las M clases \mathbf{C}_{refm} para $m = 1, 2, \dots, M$. Posteriormente, se proyectan todas las muestras a los M espacios tangentes y se conserva únicamente el triángulo superior de cada una de las proyecciones $\mathbf{C}^{(n)} \rightarrow \{\mathbf{z}_0^{(n)}, \mathbf{z}_1^{(n)}, \dots, \mathbf{z}_M^{(n)}\}$ calculado de la forma siguiente:

$$\mathbf{z}_m^{(n)} = \operatorname{upper}\left(\mathbf{C}_{refm}^{1/2} \log\left(\mathbf{C}_{refm}^{-1/2} \mathbf{C}^{(n)} \mathbf{C}_{refm}^{-1/2}\right) \mathbf{C}_{refm}^{1/2}\right) \quad n = 1, \dots, N \quad (3)$$

A continuación, se concatenan los M vectores $\mathbf{z}_m^{(n)}$ para formar el vector de características $\mathbf{z}^{(n)}$ de longitud $d = Me(e+1)/2$. Finalmente, se usa el conjunto $\{\mathbf{z}^{(n)}, t^{(n)}\}$ para entrenar un clasificador lineal.

El uso de múltiples proyecciones dependientes de la clase, permite extraer características más discriminatorias lo que supone una clara ventaja a la hora de entrenar un clasificador, por otro lado, el mayor número de características supone un riesgo de sobreajuste lo que degrada las prestaciones de prácticamente todos los clasificadores, para limitar estos riesgos tendremos que recurrir a métodos de Regularización, o a clasificadores más resistentes a los problemas asociados con la alta dimensionalidad. como las Maquinas de Vectores de Soporte (SVM).

3. Experimentos

En esta sección, se lleva a cabo un experimento para demostrar la robustez y eficacia del Clasificador de Proyección en Múltiples Espacios Tangentes (MTS) utilizando el conjunto de datos que se introduce en la subsección 3.1. Los datos resultantes de todas las proyecciones se concatenan y normalizan a una media de cero y una desviación estándar de unidad antes de ser empleados como entrada para un clasificador lineal, como la regresión logística o el SVM. Posteriormente, los resultados obtenidos en términos de precisión se comparan con los del Clasificador TSC.

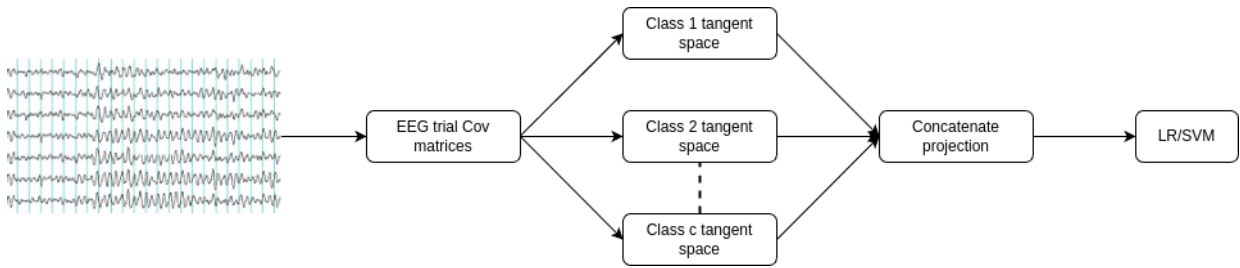


Figura 1: Clasificación por proyección a múltiples espacios tangentes.

3.1. Base de datos

Con el objetivo de evaluar el desempeño del modelo propuesto, se ha utilizado el conjunto de datos públicos 2a de la Competencia BCI de 2008 Brunner et al. (2008). Este conjunto de datos contiene información EEG etiquetada, recopilada con un casco de 22 electrodos de 9 sujetos. Cada sujeto participó en dos sesiones de captura de datos, durante las cuales realizaron la imaginación motora de movimientos de la mano izquierda (clase 1), mano derecha (clase 2), ambos pies (clase 3) y lengua (clase 4).

Hemos considerado solo dos clases de extremidades superiores, ya que son las más fáciles de detectar en los sistemas BCI de imaginación motora debido a la clara separación de las áreas somatosensoriales y motoras en el cerebro, lo que nos permite establecer una base sólida y comprensible, optimizar la precisión y robustez de nuestro método, y preparar adecuadamente futuras investigaciones con extremidades más complejas. Por ello, solo se han considerado los datos de las dos clases: mano izquierda y mano derecha. El conjunto de datos se divide en una sesión para entrenamiento y una sesión para prueba, con cada sesión consistiendo en 120 ensayos por sujeto.

3.2. Resultados y discusión

La tabla 1 presenta los porcentajes de precisión para tres experimentos diferentes (TSC, MTS SVM y MTS LR) en nueve sujetos. Comparando MTS SVM con TSC, la mayoría de los sujetos mostraron una mejora en la precisión.

Tabla 1: la tasa de aciertos (%) para los experimentos TCS, MTS SVM y MTS LR.

Sujetos	TSC	MTS SVM	MTS LR
Sujeto 1	86.80	88.89	88.19
Sujeto 2	57.64	56.94	57.64
Sujeto 3	93.75	97.92	98.61
Sujeto 4	72.22	81.25	77.78
Sujeto 5	63.89	65.97	65.97
Sujeto 6	72.22	75.00	76.39
Sujeto 7	57.64	59.03	62.50
Sujeto 8	97.22	96.53	97.22
Sujeto 9	87.50	88.19	91.67
Media	76.54	78.86	79.55

Notablemente, el Sujeto 3 experimentó un aumento significativo del 4.17 %, y el Sujeto 4 vio una mejora del 8.03 %. Sin embargo, hubo disminuciones menores para los Sujetos

2 y 8, con reducciones del 0.70 % y 0.69 %, respectivamente. En general, la precisión promedio aumentó del 76.54 % al 78.86 %, reflejando una mejora general del 2.32 %.

Comparando MTS LR con MTS SVM, la precisión mostró una mejora general modesta. Se observaron mejoras significativas en los Sujetos 7 y 9, con aumentos del 3.47 % y 3.48 %, respectivamente. El Sujeto 3 también mostró una mejora menor del 0.69 %. A pesar de estos avances, los Sujetos 1 y 4 experimentaron ligeras disminuciones en la precisión, con reducciones del 0.70 % y 3.47 %, respectivamente. La precisión promedio aumentó del 78.86 % al 79.55 %, reflejando una pequeña mejora del 0.69 %.

Al comparar MTS LR con TSC, las mejoras son más pronunciadas. Por ejemplo, la precisión del Sujeto 3 aumentó significativamente del 93.75 % en V1 al 98.61 % en MTS LR, y la precisión del Sujeto 9 mejoró del 87.50 % al 91.67 %. Además, el Sujeto 4, a pesar de una disminución al pasar de MTS SVM a MTS LR, aún muestra una mejora general del 72.22 % en TSC al 77.78 % en V3. La precisión promedio tuvo un aumento notable del 76.54 % en TSC al 79.55 % en MTS LR.




Figura 2: Representación gráfica de las tasas de acierto de los modelos TSC y MTS para nueve sujetos. MTS logró el mejor rendimiento.

Estos resultados resumidos gráficamente en la figura 2 muestran claramente que las dos versiones del método MTS proporcionan un rendimiento superior al TSC con un ligero aumento en los esfuerzos computacionales, debido al mayor número de características proporcionadas al clasificador. Esto demuestra la efectividad de las múltiples proyecciones, subrayando el progreso constante y las mejoras logradas a través

de las versiones sucesivas del clasificador presentadas.

4. Conclusiones

La geometría riemanniana ha introducido un nuevo marco de clasificación en las interfaces cerebro-computadora (BCI). Este estudio presenta un novedoso clasificador de EEG para aplicaciones de BCI, el cual proyecta datos desde la variedad riemanniana de matrices de covarianza de señales EEG hacia múltiples espacios tangentes. Cada proyección mejora la capacidad del clasificador para crear un modelo más discriminatorio. La evidencia experimental respalda la superioridad de este clasificador de proyección en múltiples espacios tangentes sobre la proyección única para problemas de MI-BCI.

El trabajo futuro tiene como objetivo adaptar este modelo a configuraciones de entrenamiento adaptativo en línea para mejorar su aplicabilidad en entornos del mundo real.

Referencias

- Barachant, A., 2012. *Commande robuste d'un effecteur par une interface cerveau machine eeg asynchrone*. Ph.D. thesis, Université de Grenoble.
- Barachant, A., Bonnet, S., Congedo, M., Jutten, C., 2010. Riemannian geometry applied to bci classification. In: *International conference on latent variable analysis and signal separation*. Springer, pp. 629–636. DOI: 10.1007/978-3-642-15995-4_78
- Barachant, A., Bonnet, S., Congedo, M., Jutten, C., 2012. Bci signal classification using a riemannian-based kernel. In: *ESANN 2012-20th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*. Michel Verleysen, pp. 97–102.
- Barachant, A., Bonnet, S., Congedo, M., Jutten, C., 2013. Classification of covariance matrices using a riemannian-based kernel for bci applications. *Neurocomputing* 112, 172–178. DOI: 10.1016/j.neucom.2012.12.039
- Brunner, C., Leeb, R., Müller-Putz, G., Schlögl, A., Pfurtscheller, G., 2008. Bci competition 2008–graz data set a. *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces)*, Graz University of Technology 16, 1–6. DOI: 10.21227/katb-zv89
- Congedo, M., Barachant, A., Bhatia, R., 2017. Riemannian geometry for eeg-based brain-computer interfaces; a primer and a review. *Brain-Computer Interfaces* 4 (3), 155–174. DOI: 10.1080/2326263X.2017.1297192
- Fazli, S., Grozea, C., Danóczy, M., Blankertz, B., Popescu, F., Müller, K.-R., 2009. Subject independent eeg-based bci decoding. *Advances in Neural Information Processing Systems* 22, 513–521.
- Liao, L.-D., Chen, C.-Y., Wang, I.-J., Chen, S.-F., Li, S.-Y., Chen, B.-W., Chang, J.-Y., Lin, C.-T., 2012. Gaming control using a wearable and wireless eeg-based brain-computer interface device with novel dry foam-based sensors. *Journal of neuroengineering and rehabilitation* 9 (1), 1–12. DOI: 10.1186/1743-0003-9-5
- Lin, C.-T., Lin, F.-C., Chen, S.-A., Lu, S.-W., Chen, T.-C., Ko, L.-W., 2010. Eeg-based brain-computer interface for smart living environmental auto-adjustment. *Journal of Medical and Biological Engineering* 30 (4), 237–245. DOI: 10.1109/JSYST.2012.2192756
- Omari, S., Omari, A., Abderrahim, M., 2023. Multiple tangent space projection for motor imagery eeg classification. *Applied Intelligence* 53 (18), 21192–21200. DOI: 10.1007/s10489-023-04551-2
- Park, J. L., Fairweather, M. M., Donaldson, D. I., 2015. Making the case for mobile cognition: Eeg and sports performance. *Neuroscience & Biobehavioral Reviews* 52, 117–130. DOI: 10.1016/j.neubiorev.2015.02.014
- Tang, Z., Li, C., Sun, S., 2017. Single-trial eeg classification of motor imagery using deep convolutional neural networks. *Optik* 130, 11–18. DOI: 10.1016/j.ijleo.2016.10.117
- Torres P, E. P., Torres, E. A., Hernández-Álvarez, M., Yoo, S. G., et al., 2020. Eeg-based bci emotion recognition: A survey. *Sensors* 20 (18), 5083. DOI: 10.3390/s20185083
- Tortora, S., Ghidoni, S., Chisari, C., Micera, S., Artoni, F., 2020. Deep learning-based bci for gait decoding from eeg with lstm recurrent neural network. *Journal of Neural Engineering* 17 (4), 046011. DOI: 10.1088/1741-2552/ab9842
- Wang, P., Jiang, A., Liu, X., Shang, J., Zhang, L., 2018. Lstm-based eeg classification in motor imagery tasks. *IEEE transactions on neural systems and rehabilitation engineering* 26 (11), 2086–2095. DOI: 10.1109/TNSRE.2018.2876129
- Wang, Y.-T., Wang, Y., Jung, T.-P., 2011. A cell-phone-based brain-computer interface for communication in daily life. *Journal of neural engineering* 8 (2), 025018. DOI: 10.1088/1741-2560/8/2/025018
- Zhang, K., Robinson, N., Lee, S.-W., Guan, C., 2021. Adaptive transfer learning for eeg motor imagery classification with deep convolutional neural network. *Neural Networks* 136, 1–10. DOI: 10.1016/j.neunet.2020.12.013