Interfaces Cerebro-Computadora como herramientas de rehabilitación: un enfoque desde el aprendizaje maquinal

CIITI ROSARIO 2019

Dra. Victoria Peterson

I M A L

UNL CONICET

UNER Facultad de Ingeniería

Accidente Cerebro Vascular (ACV)

Incidencia mundial de personas que sufren ACV cada año

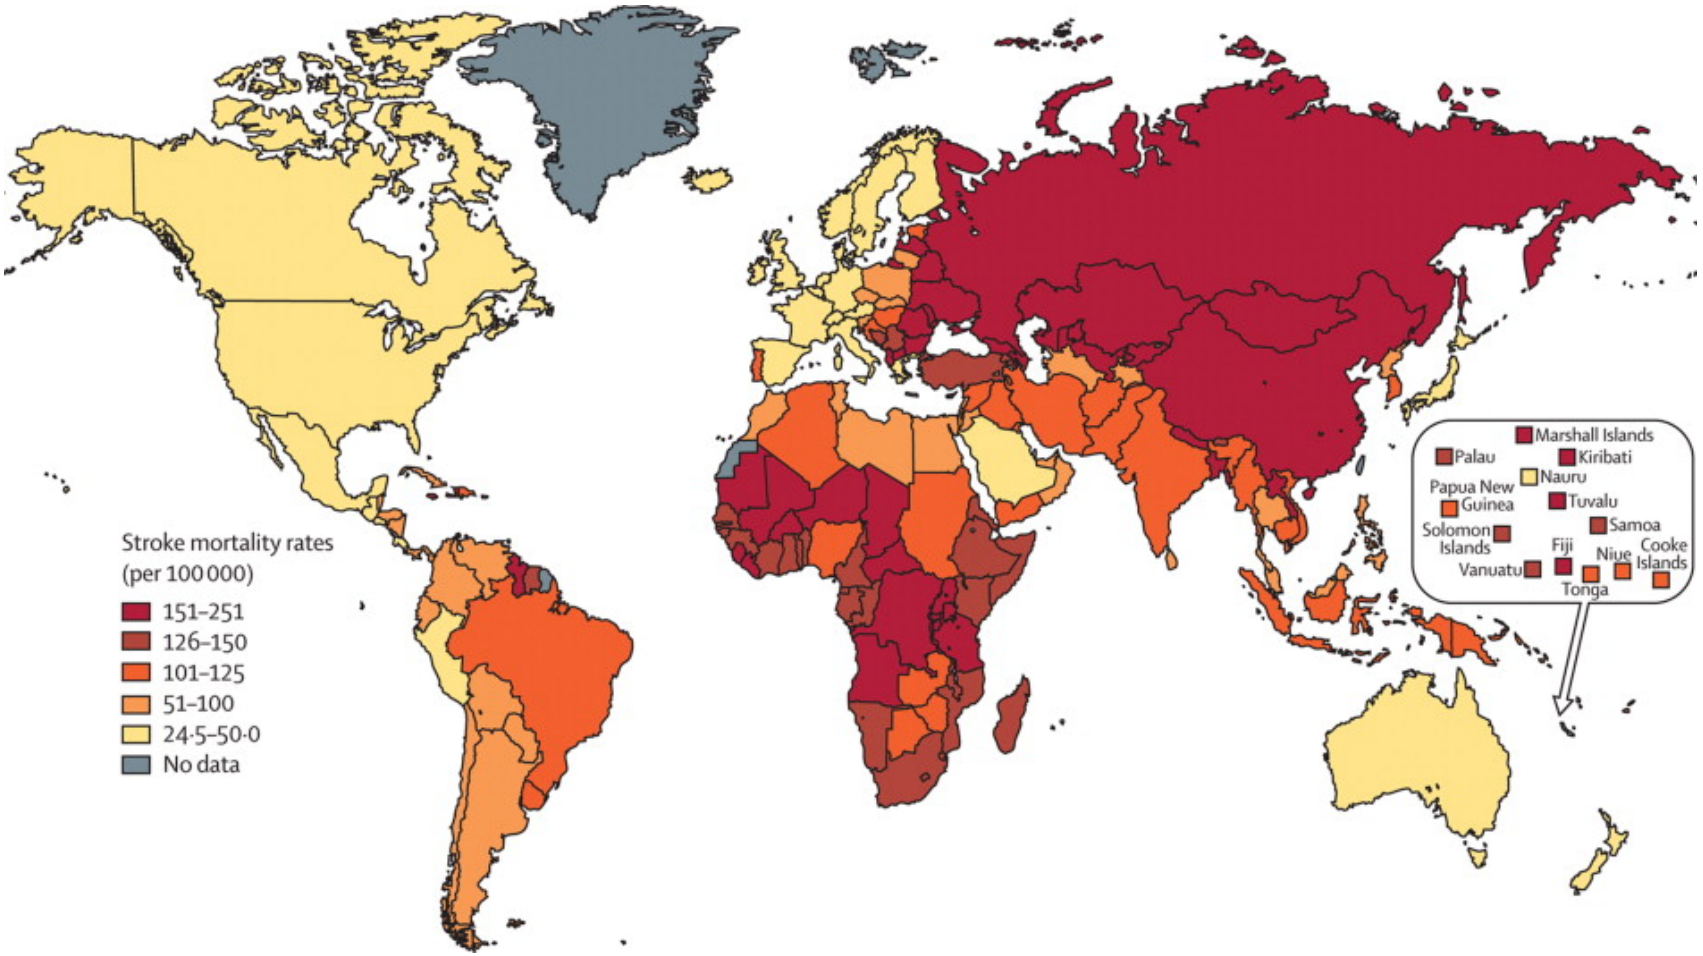

[Norrving and Kissela, 2013]

Accidente Cerebro Vascular (ACV)

Terapias de rehabilitación asistida por robots

	Grounded Exoskeleton	Grounded End-Effector	Wearable Exoskeleton
Upper Extremity	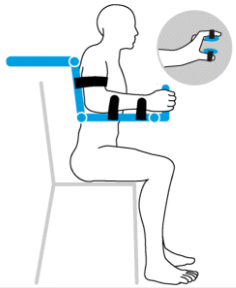	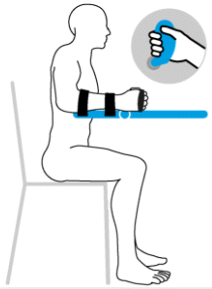	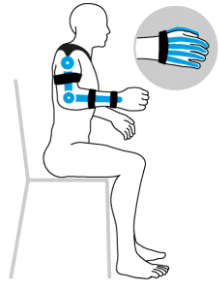
Development Status	Established	Established	Emerging
Technology Reviews	**Upper Limb:** Loureiro 2011, Maciejasz 2014, Sheng 2016 (bilateral) | **Hand:** Lum 2012, Bos 2016		
Clinical Evidence	**Grounded:** Klamroth, 2014 | **End-Effector:** Lo 2010 | **Both:** Kwakkel 2008, Mehrholz 2015, Veerbeek 2017 **Hand:** Balasubramanian 2010, Lambercy 2011		

[Gassert and Dietz, 2018]

Nuevas herramientas de neurorehabilitación

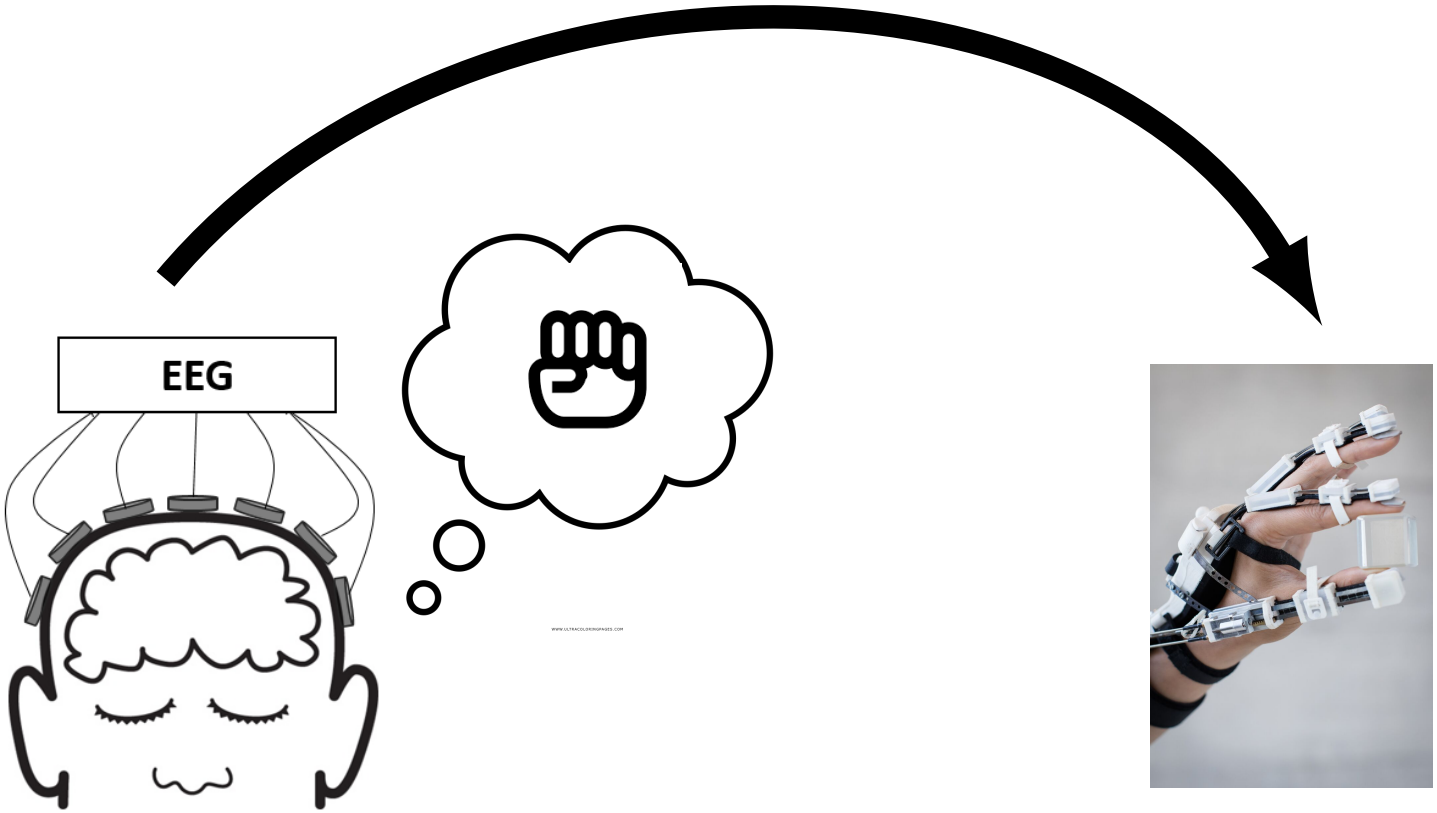

BCI para rehabilitación de miembro superior

Interfaces Cerebro-Computadora (BCIs) [Wolpaw and Wolpaw, 2012]

Definición

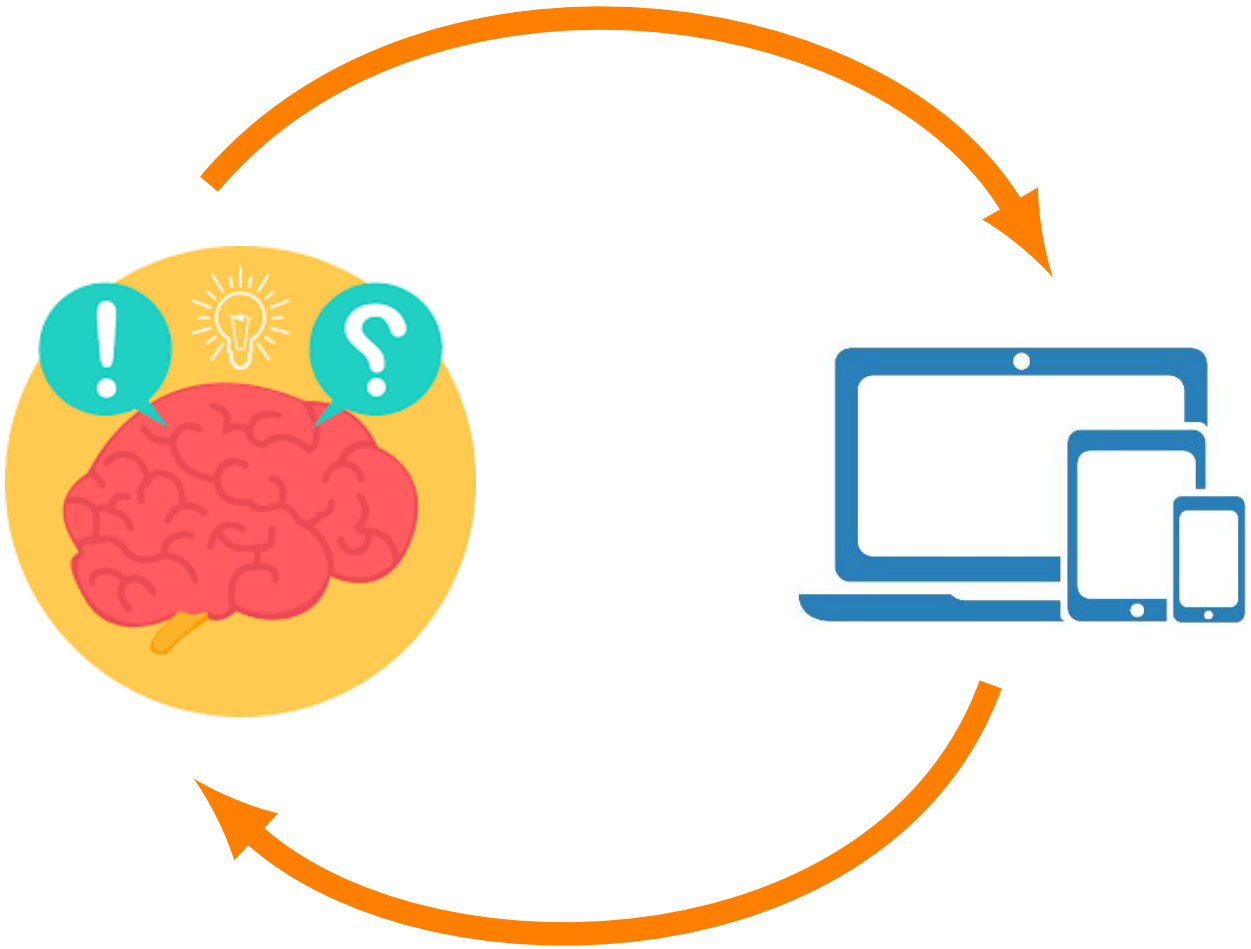

Interfaces Cerebro-Computadora (BCIs) [Wolpaw and Wolpaw, 2012]

Definición

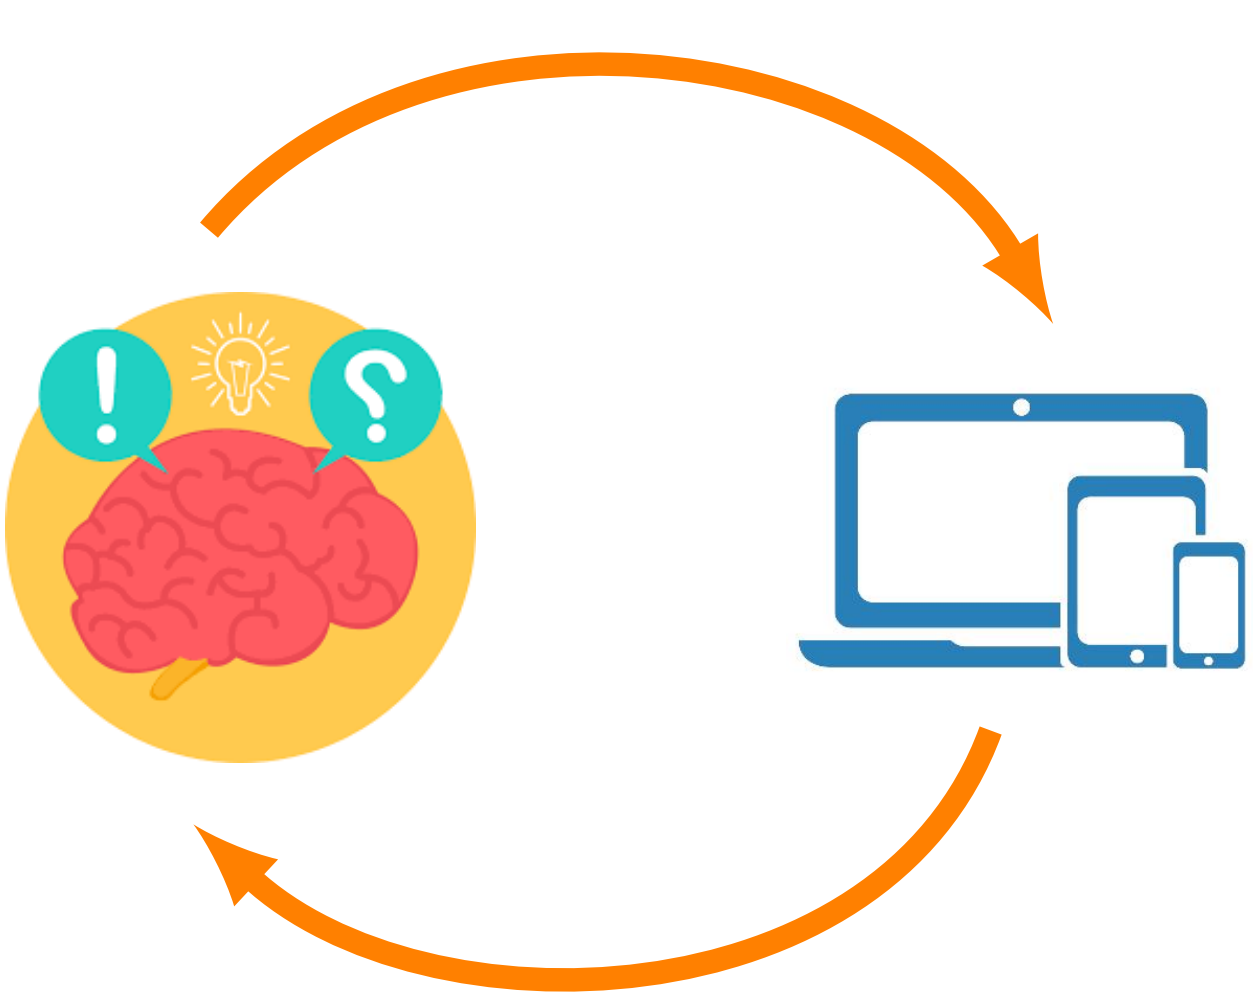

BCI Rehabilitativas

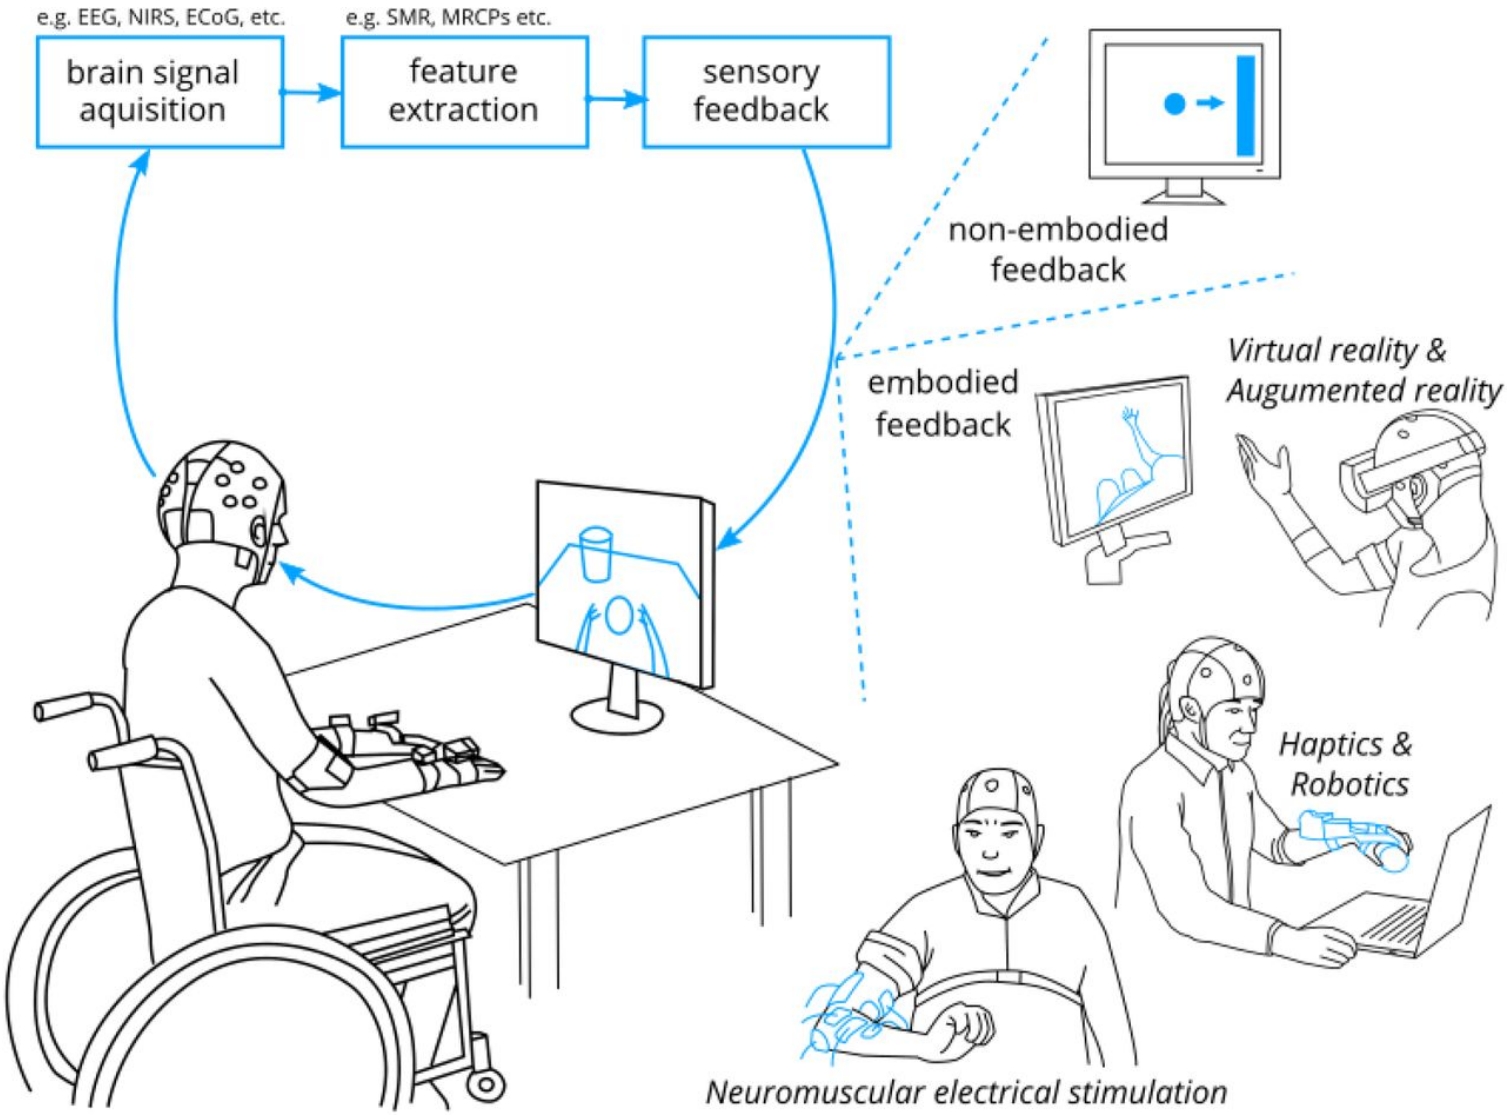

[Cervera et al., 2018]

Interfaces Cerebro-Computadora (BCIs)

[Clerc et al., 2016]

Diagrama en bloques

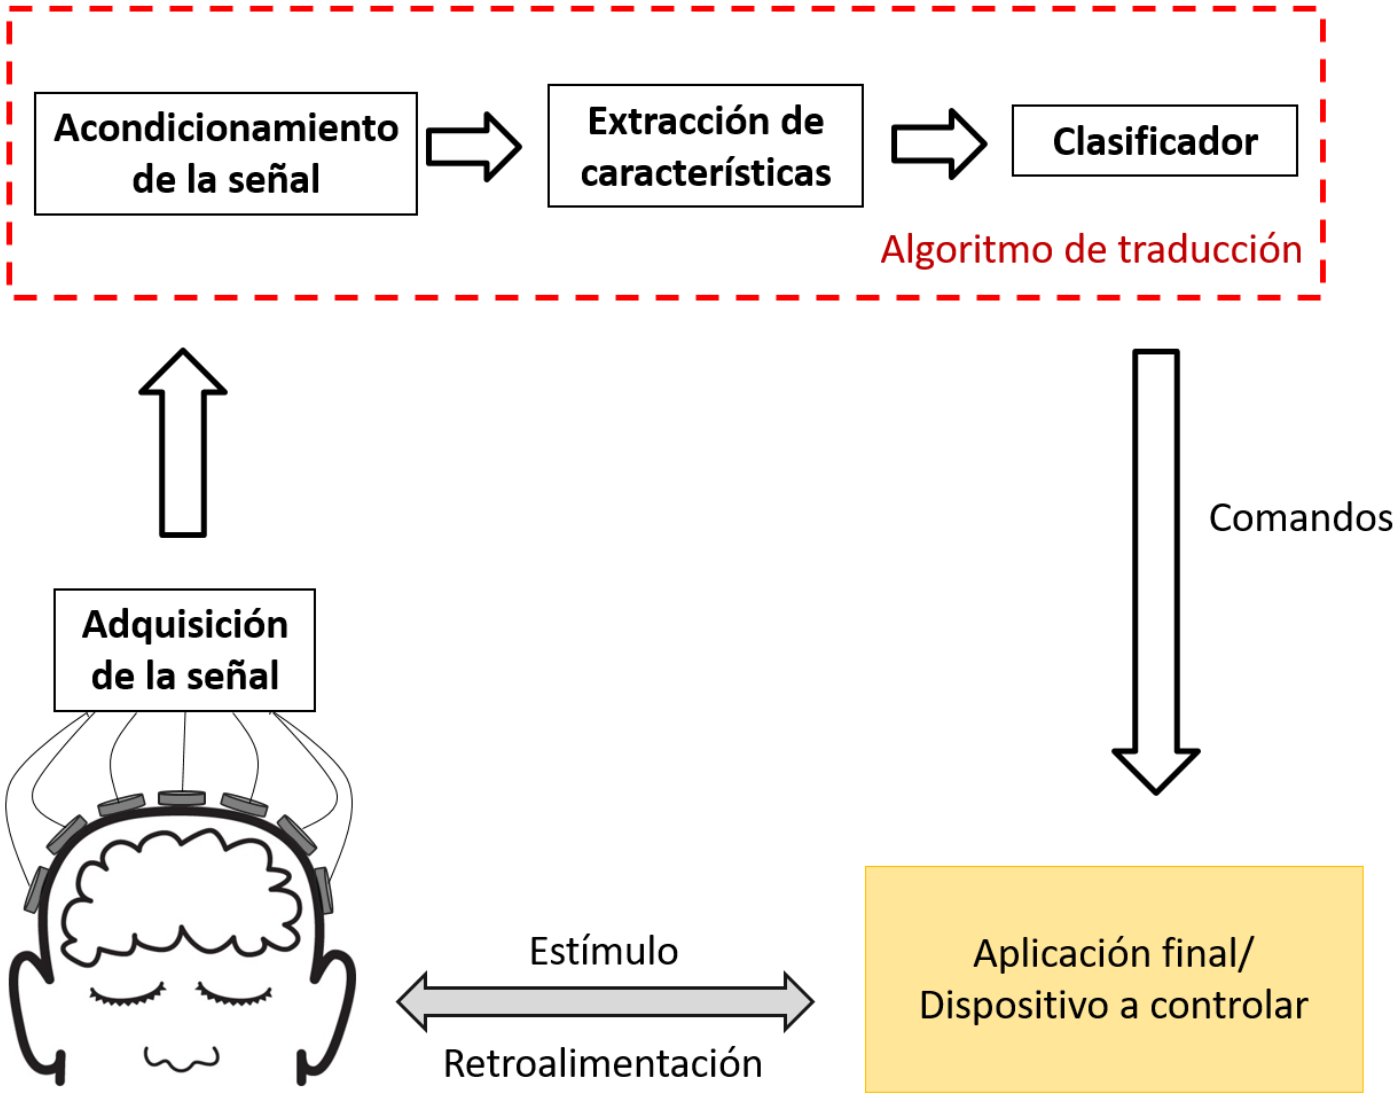

Interfaces Cerebro-Computadora (BCIs)

[Pfurtscheller, 2001]

Ritmos Sensoriomotores (SMRs)

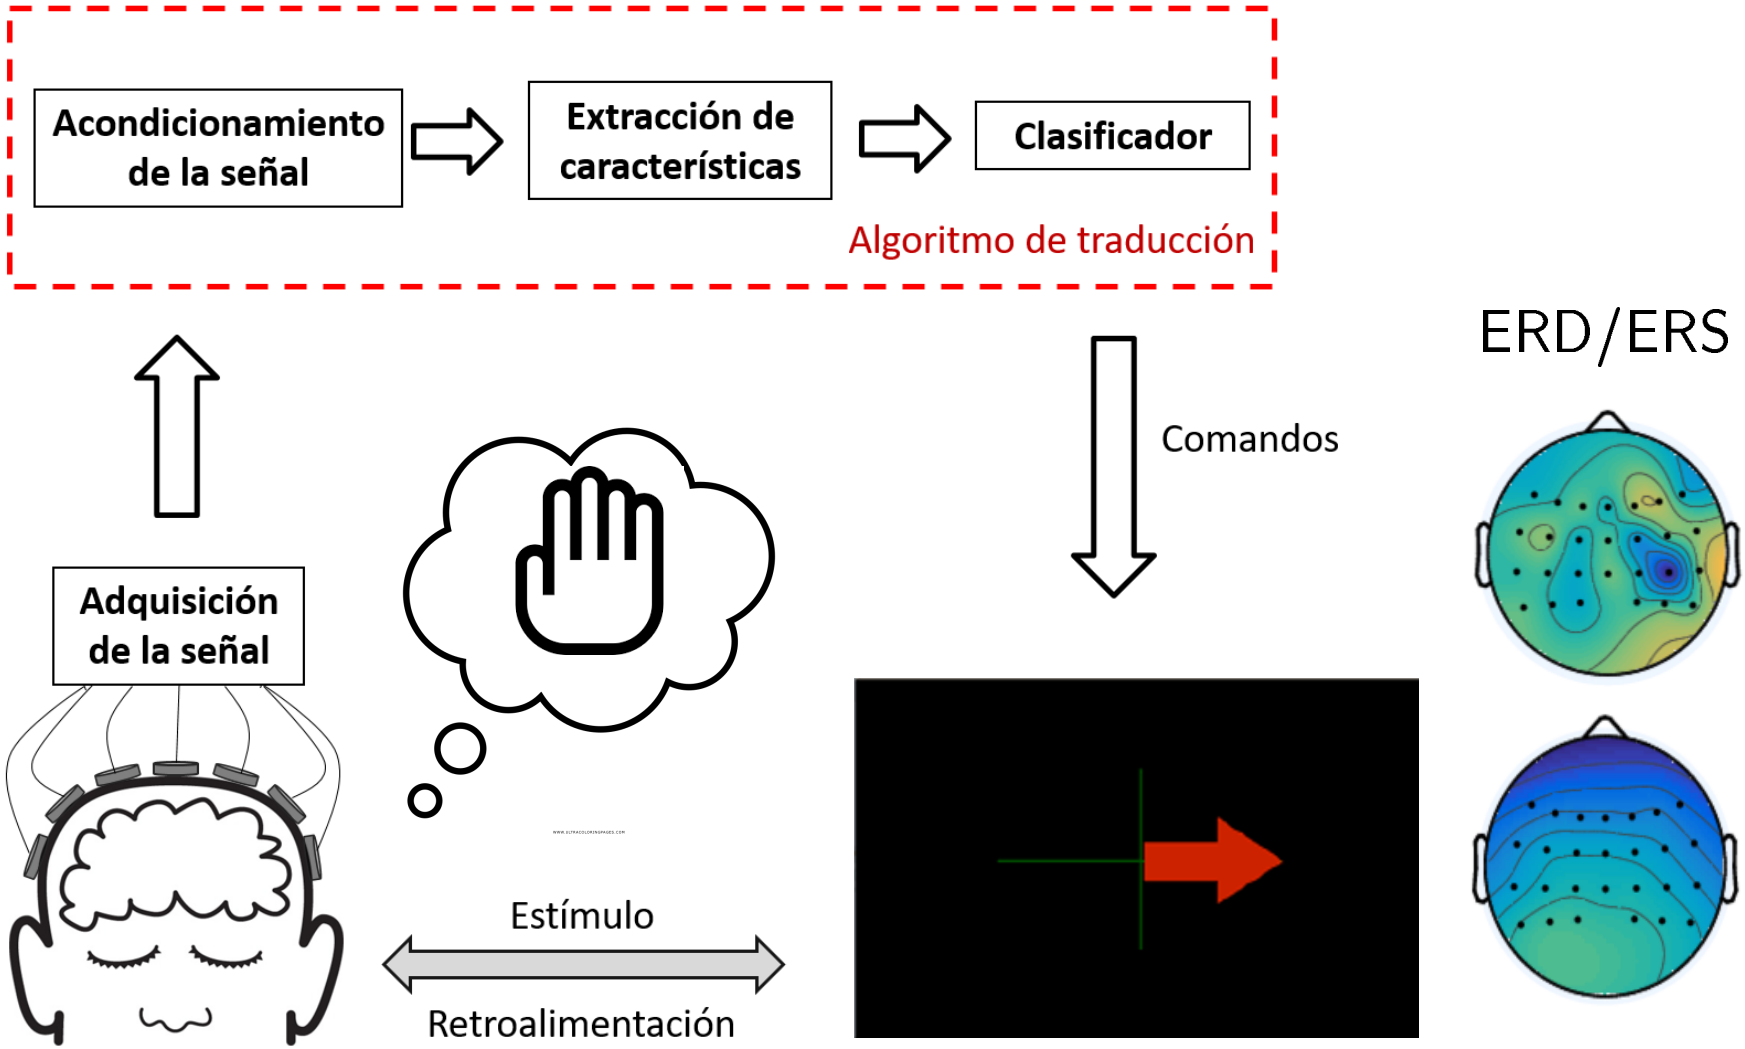

Interfaces Cerebro-Computadora (BCIs)

[Pfurtscheller, 2001]

Ritmos Sensoriomotores (SMRs)

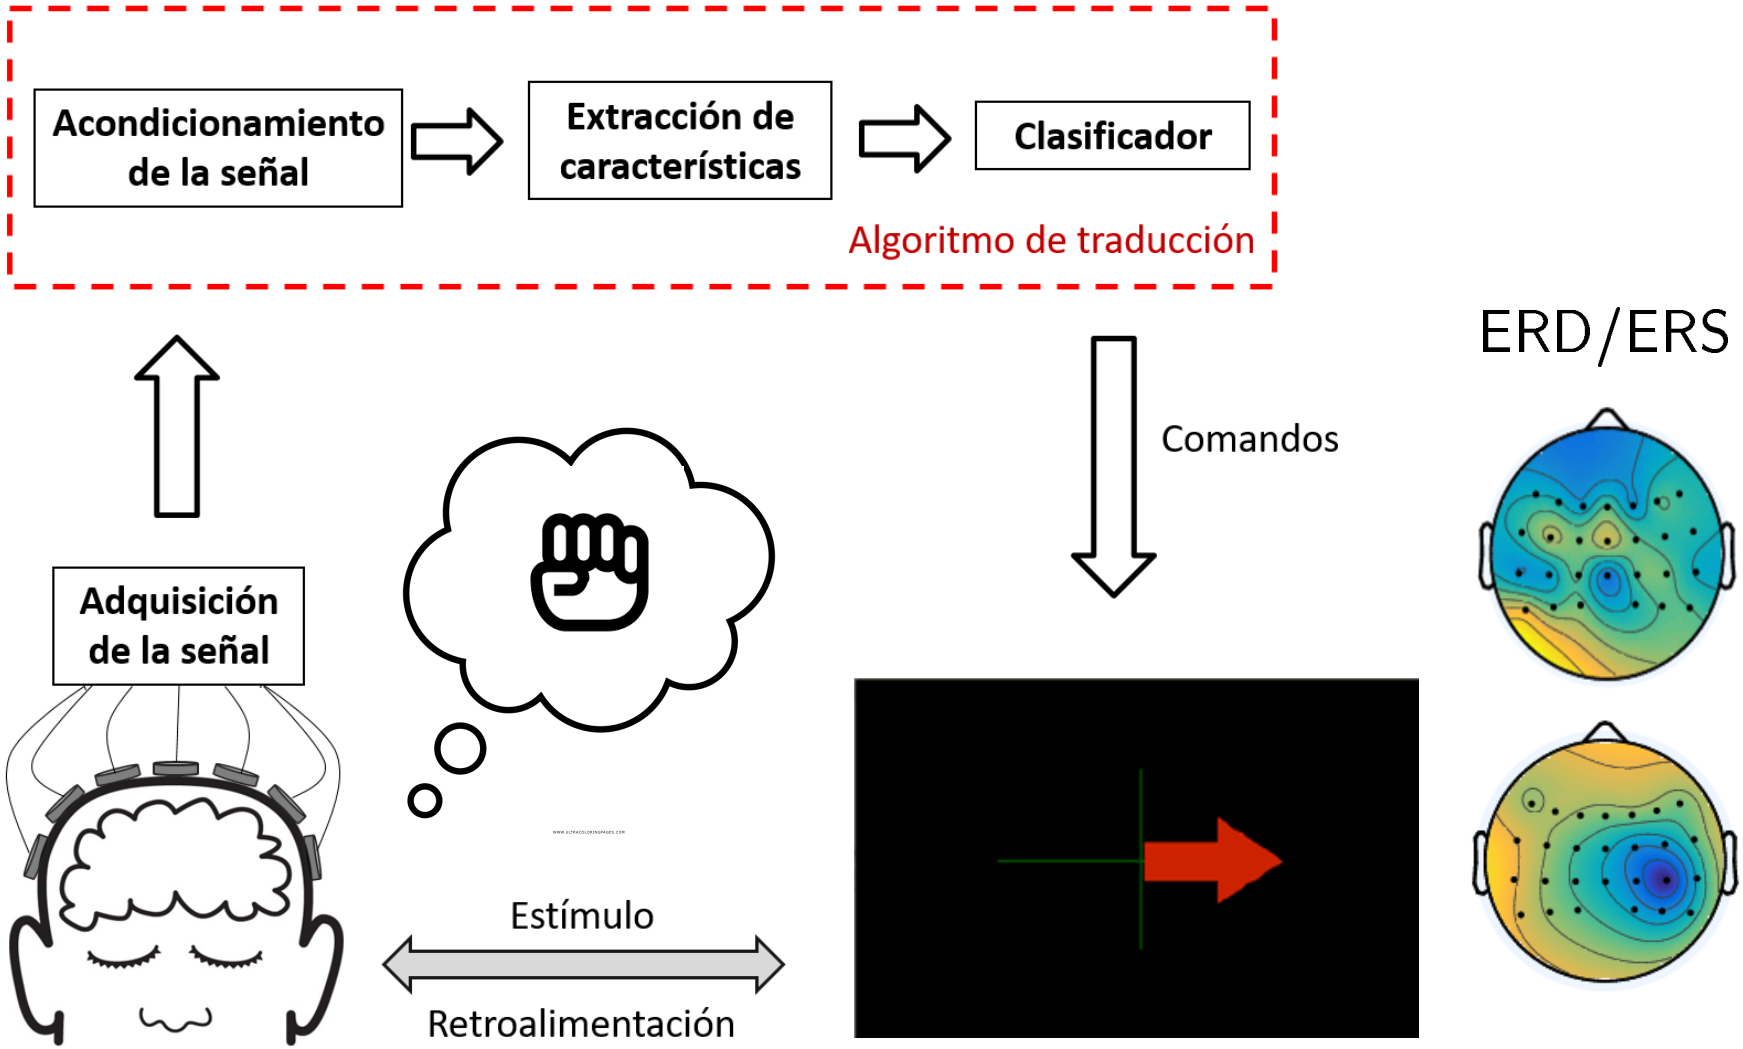

Interfaces Cerebro-Computadora (BCIs)

[Pfurtscheller, 2001]

Ritmos Sensoriomotores (SMRs)

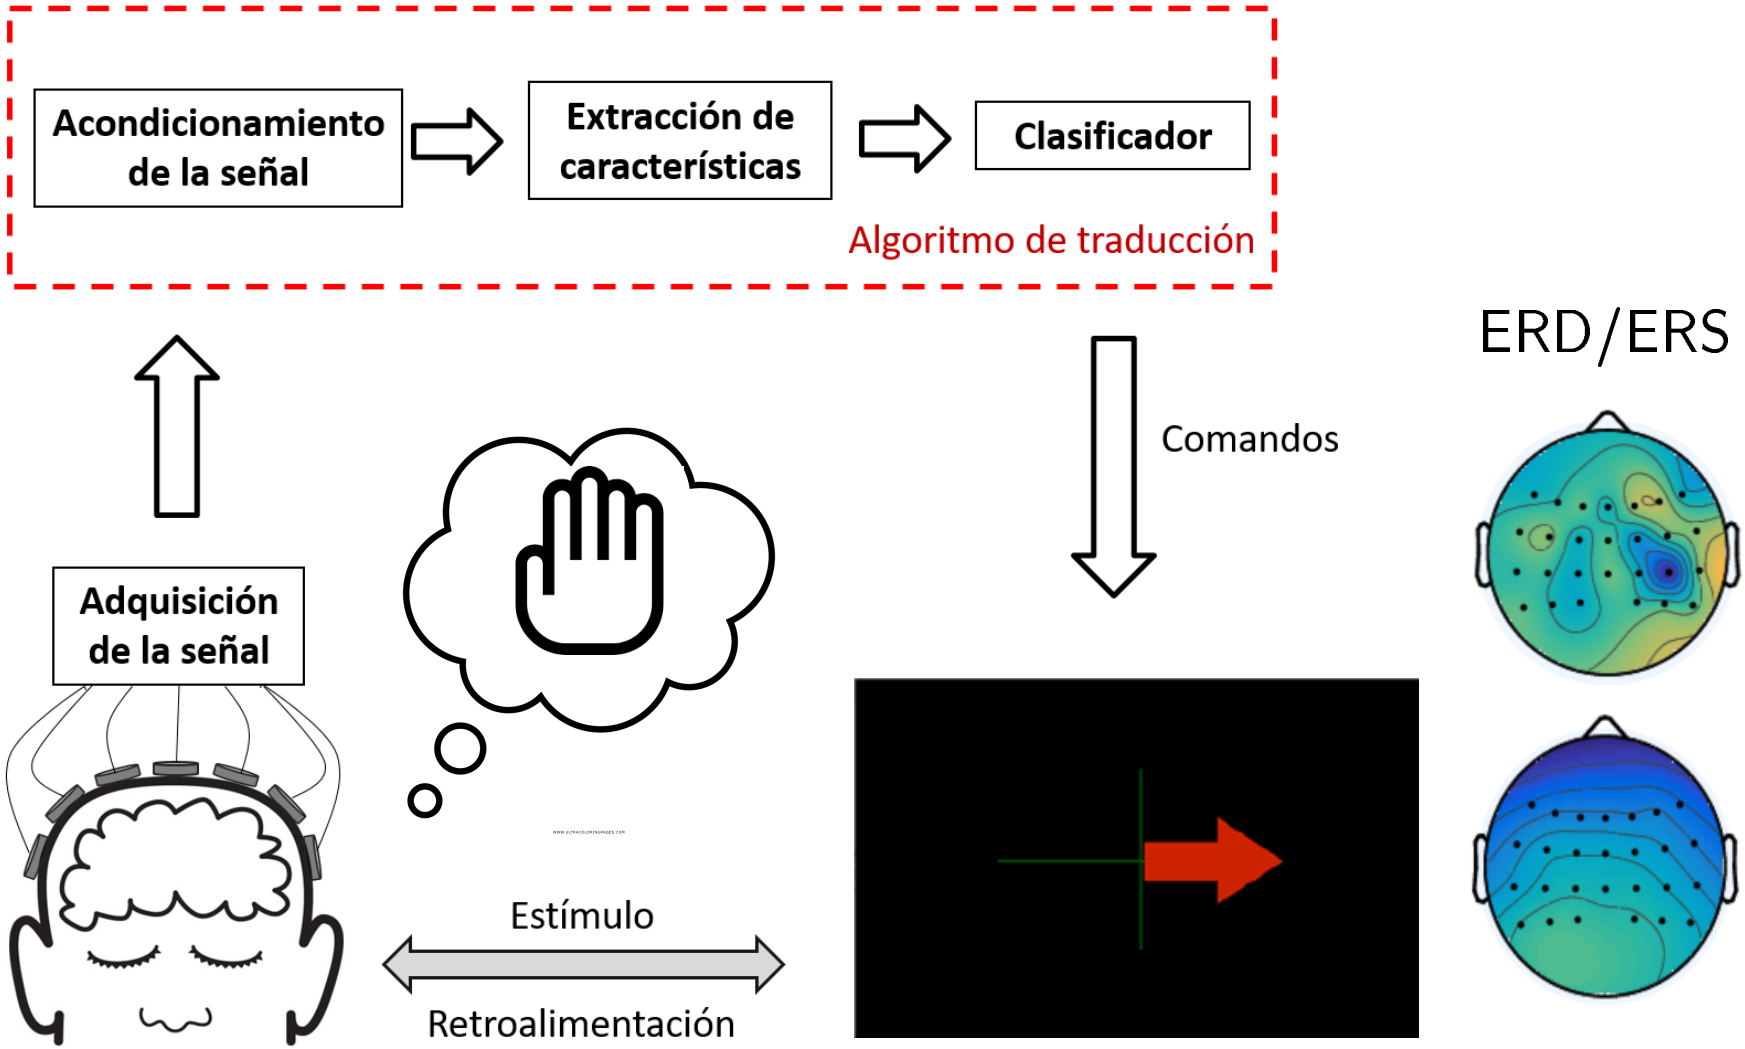

Interfaces Cerebro-Computadora (BCIs)

[Pfurtscheller, 2001]

Ritmos Sensoriomotores (SMRs)

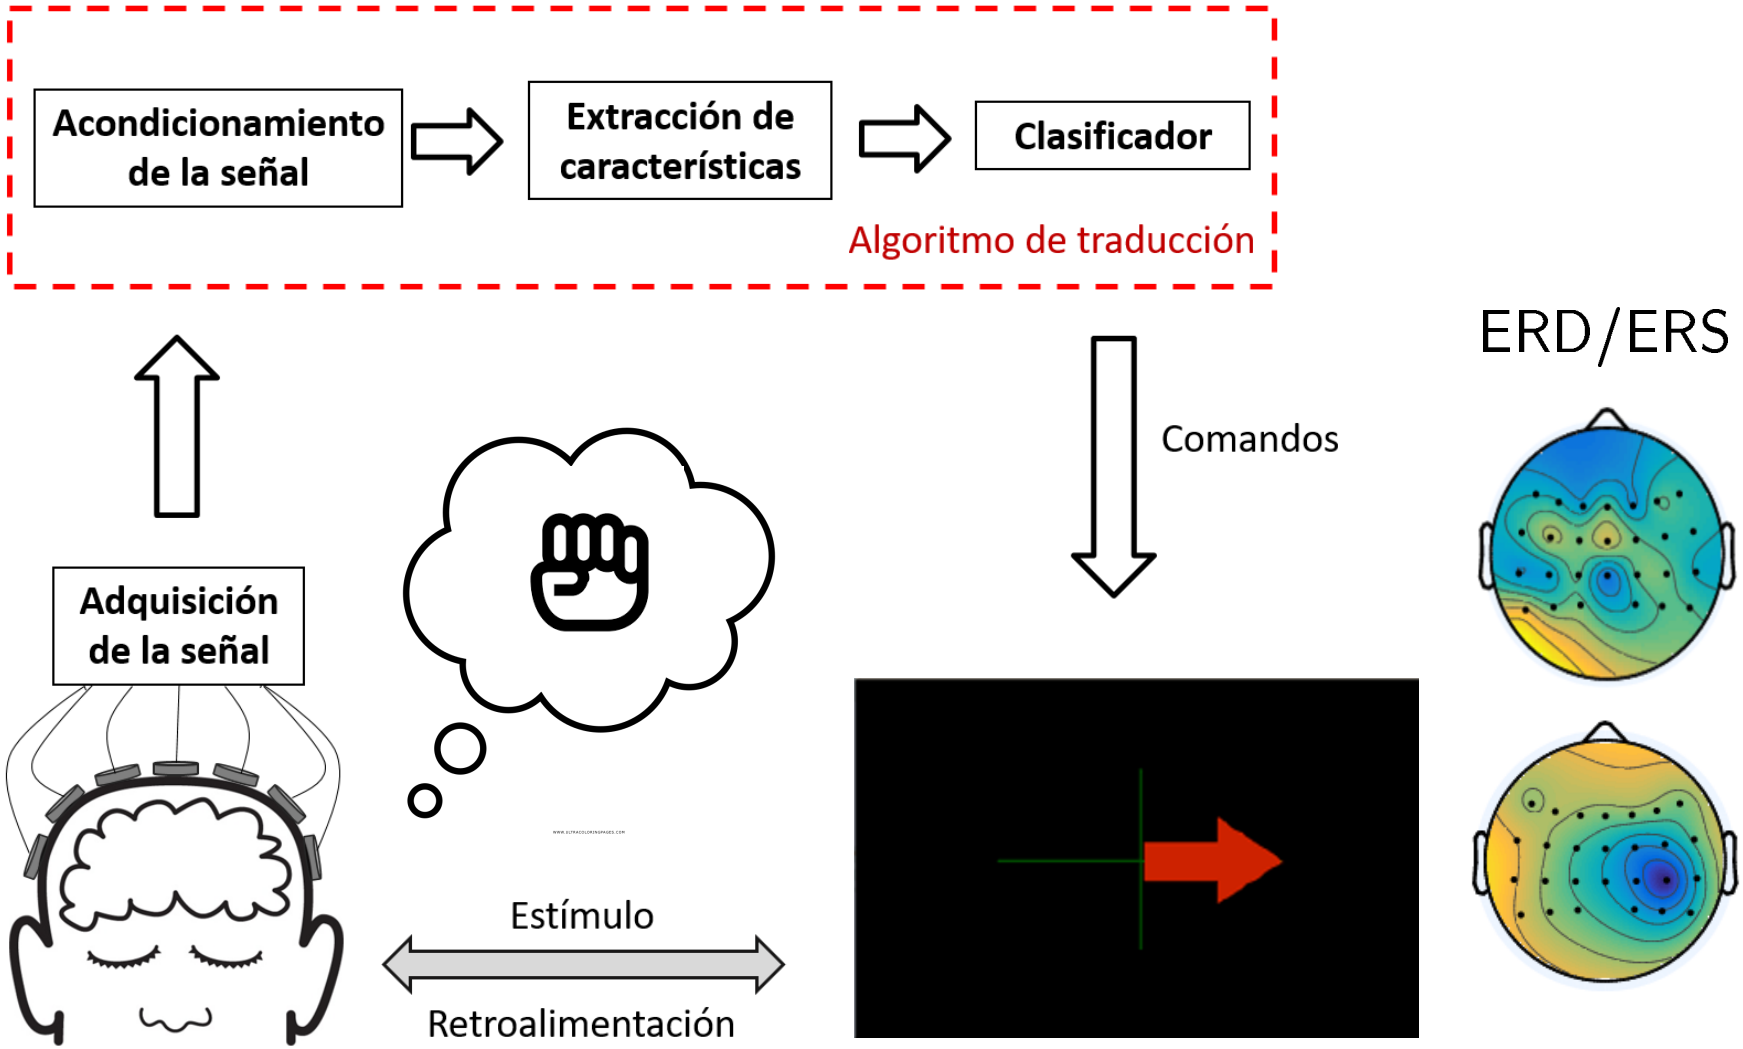

Interfaces Cerebro-Computadora (BCIs)

Ritmos Sensoriomotores (SMRs)

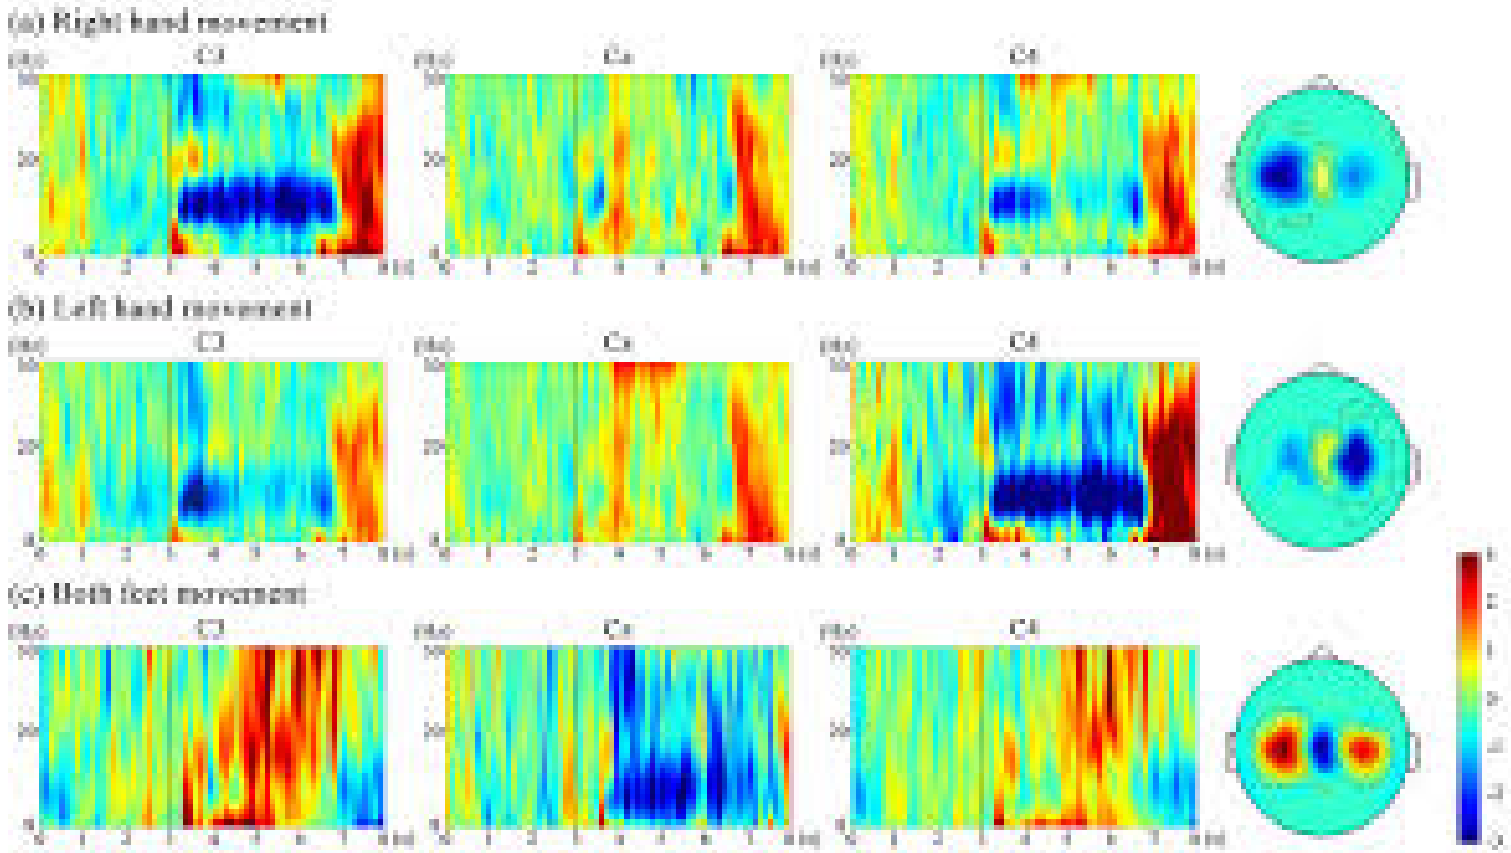

[Tang et al., 2016]

Interfaces Cerebro-Computadora (BCIs)

Problema de clasificación binario

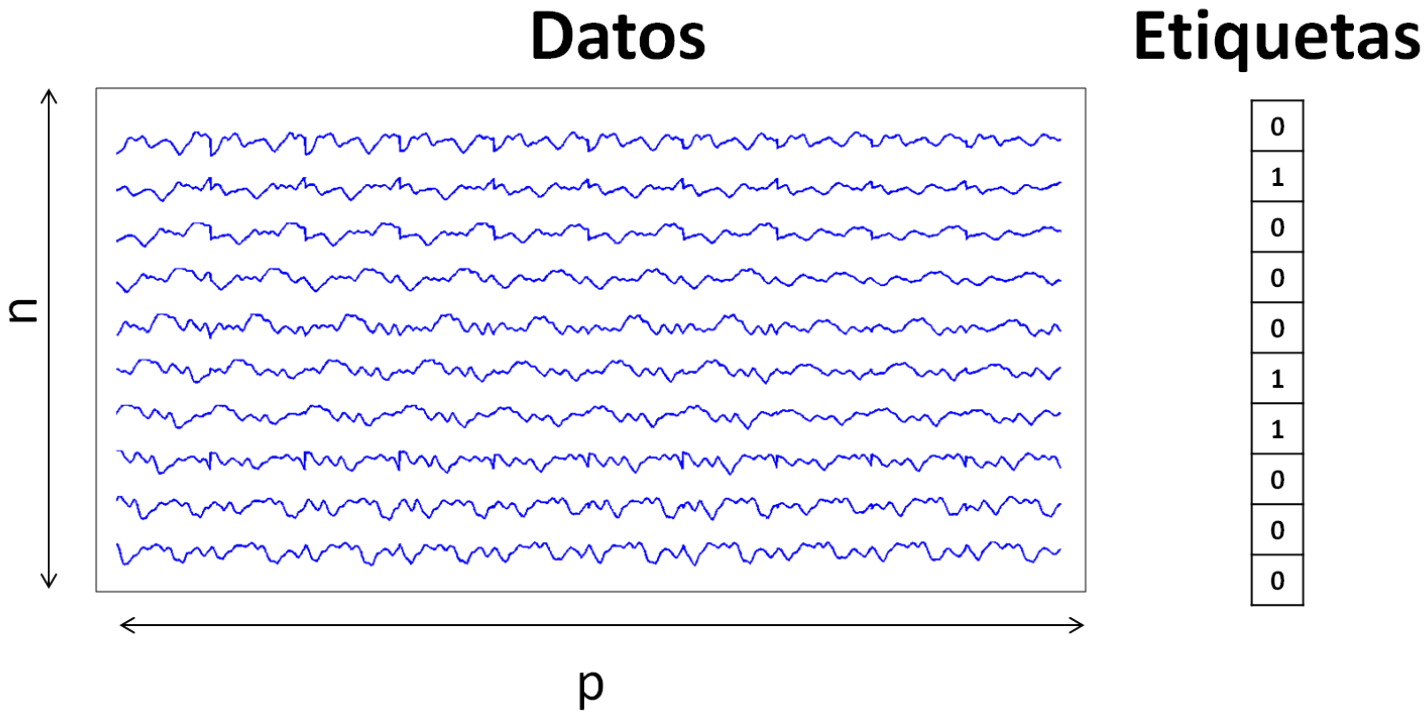

Interfaces Cerebro-Computadora (BCIs)

Desafíos

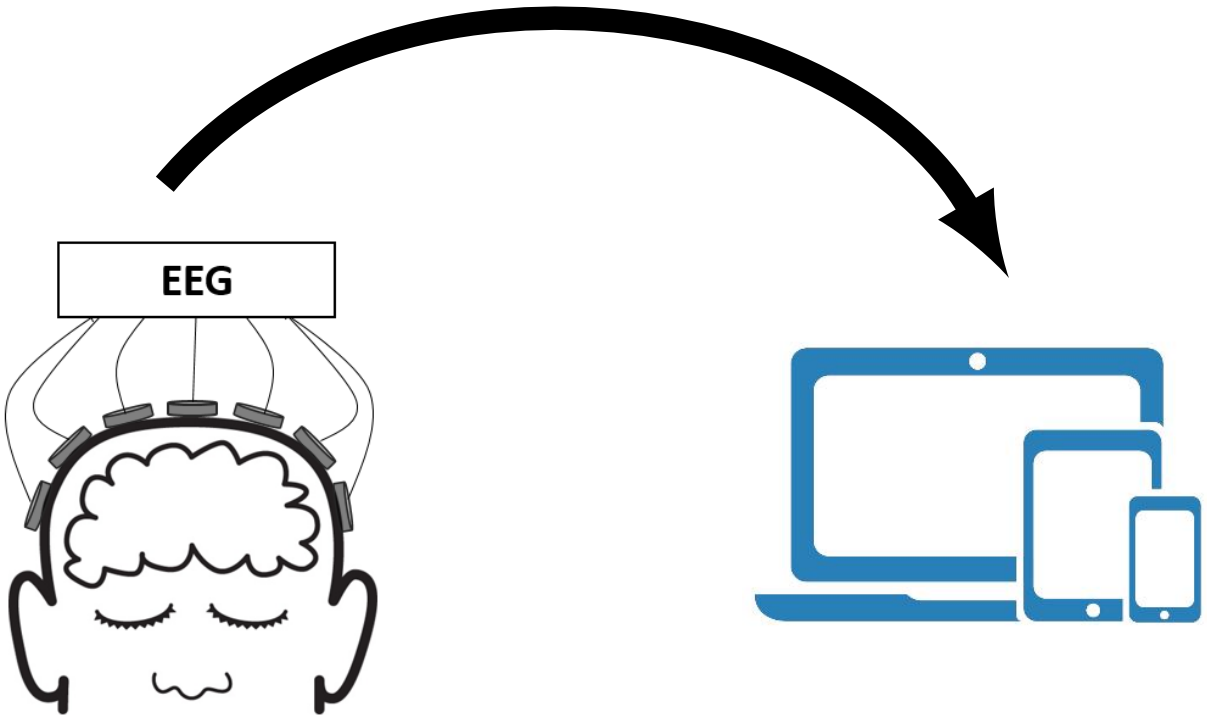

Problema de Clasificación Binario

Interfaces Cerebro-Computadora (BCIs)

Desafíos

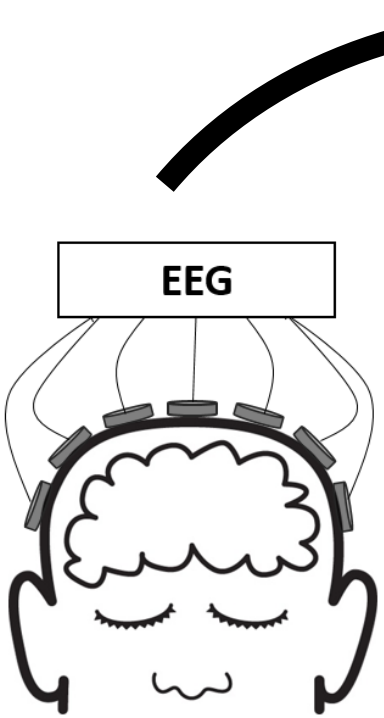

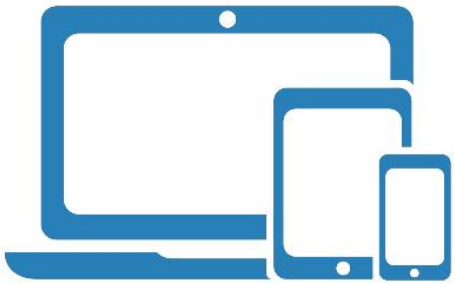

Problema de Clasificación Binario

Bajo costo

Transportable

Buena resolución temporal (ms)

No invasivo

Interfaces Cerebro-Computadora (BCIs)

Desafíos

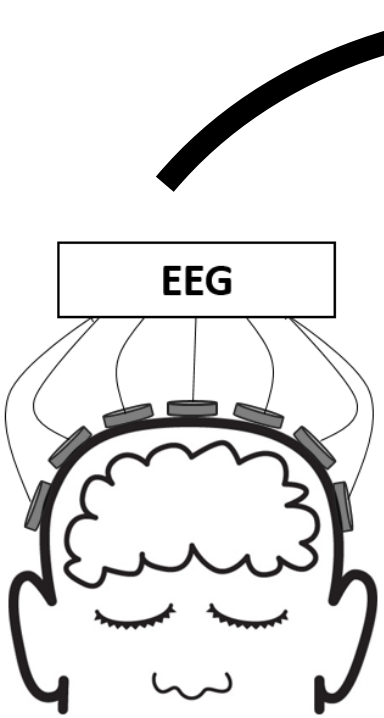

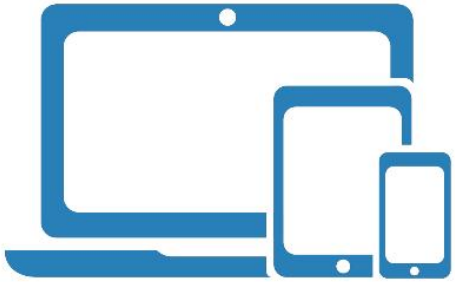

No estacionaria

Alta variabilidad

Mala resolución espacial (cm)

Baja SNR

Bajo costo

Transportable

Buena resolución temporal (ms)

No invasivo

Problema de Clasificación Binario

Filtrado espacial y extracción de características

Motivación I: el clásico CSP

"El método de Patrones Espaciales Comunes (CSP) busca en un segmento de EEG filtrado pasa-banda maximizar la varianza para una clase y minimizarla para la otra clase."

Filtrado espacial y extracción de características

Motivación I: el clásico CSP

Transformación Lineal: $\mathbf{Z} = \mathbf{W}^T \mathbf{X}$

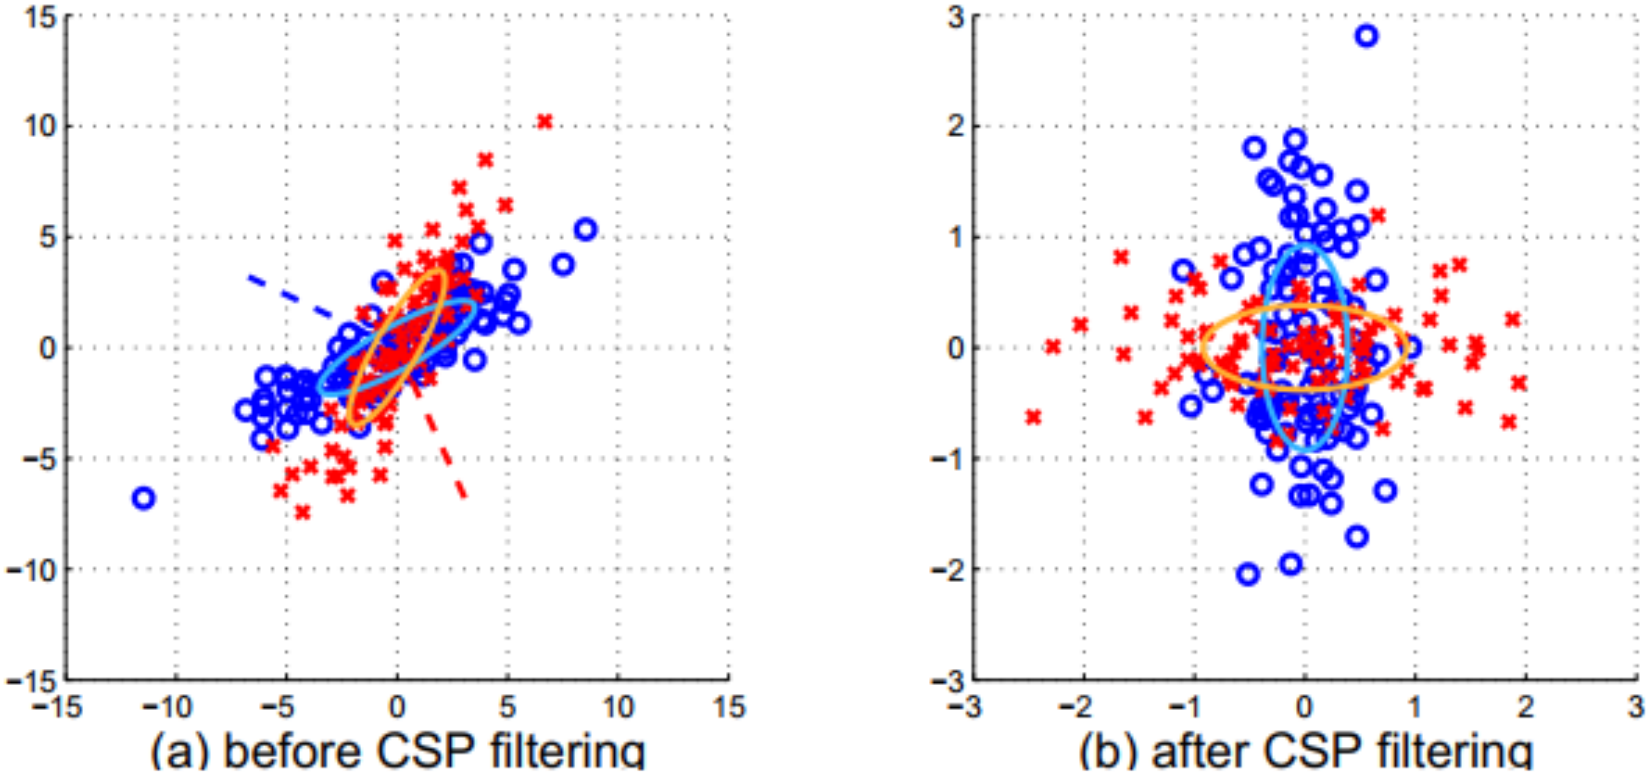

[Blankertz et al., 2008]

Filtrado espacial y extracción de características

Motivación I: el clásico CSP

Transformación Lineal: $\mathbf{Z} = \mathbf{W}^T \mathbf{X}$

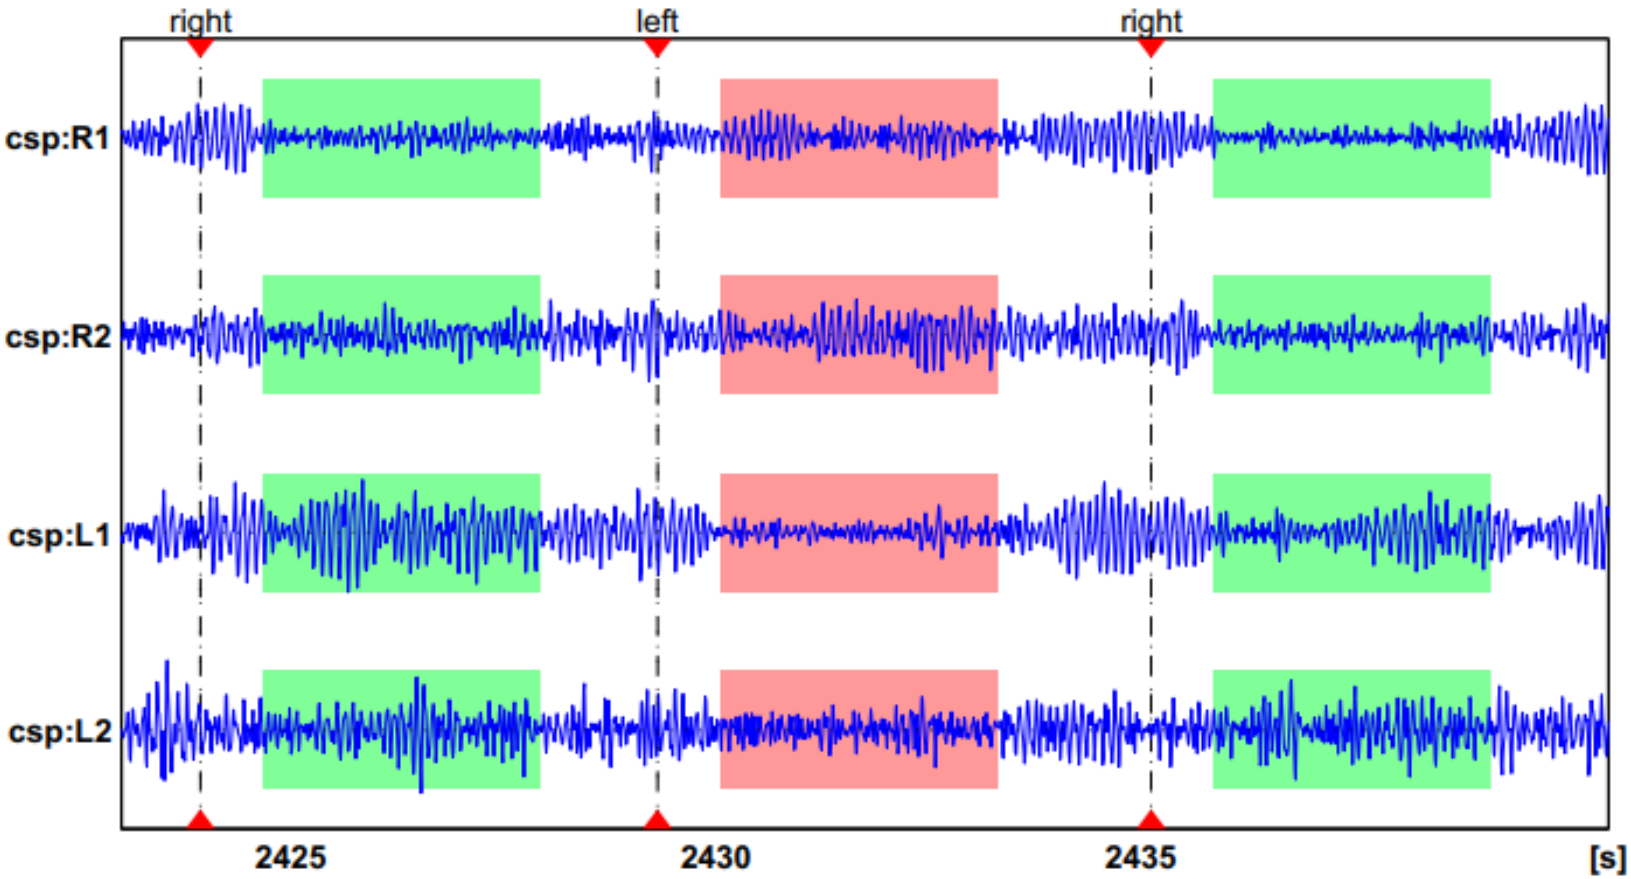

[Blankertz et al., 2008]

Clasificación

Motivación II: LDA

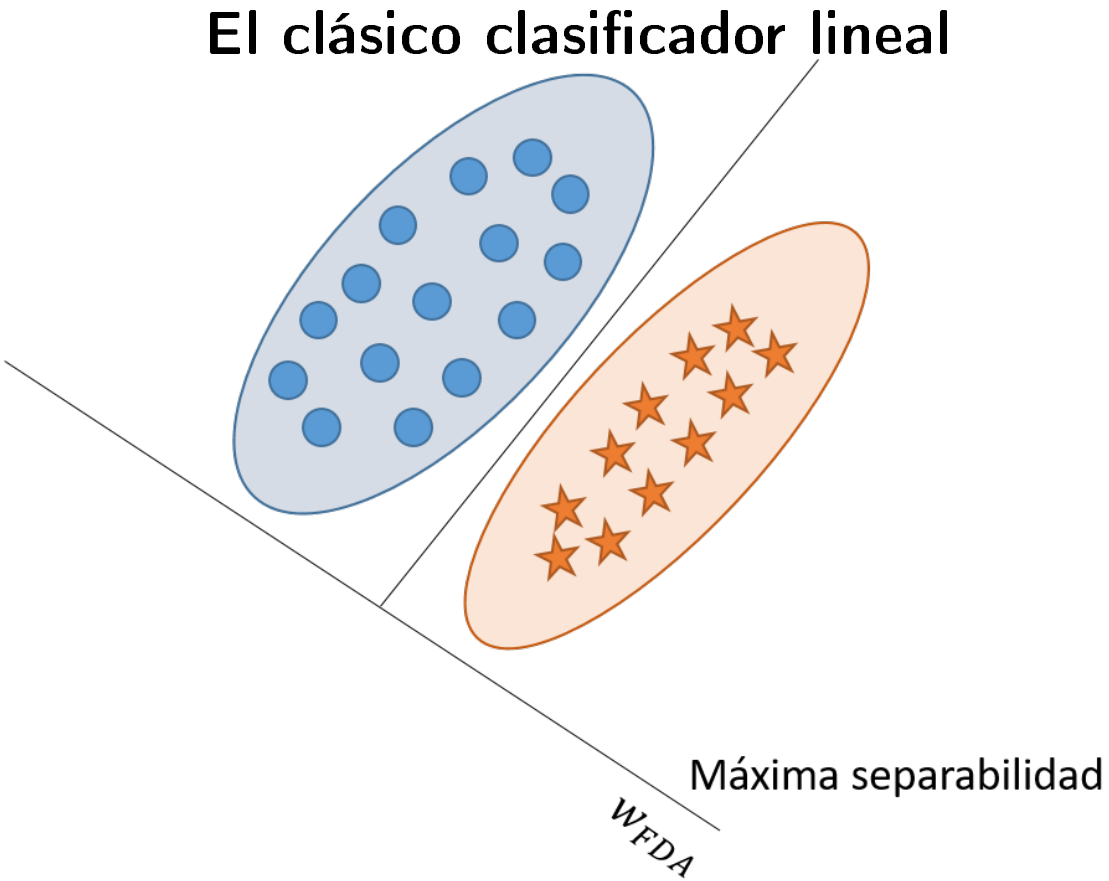

Clasificación

Motivación II: LDA

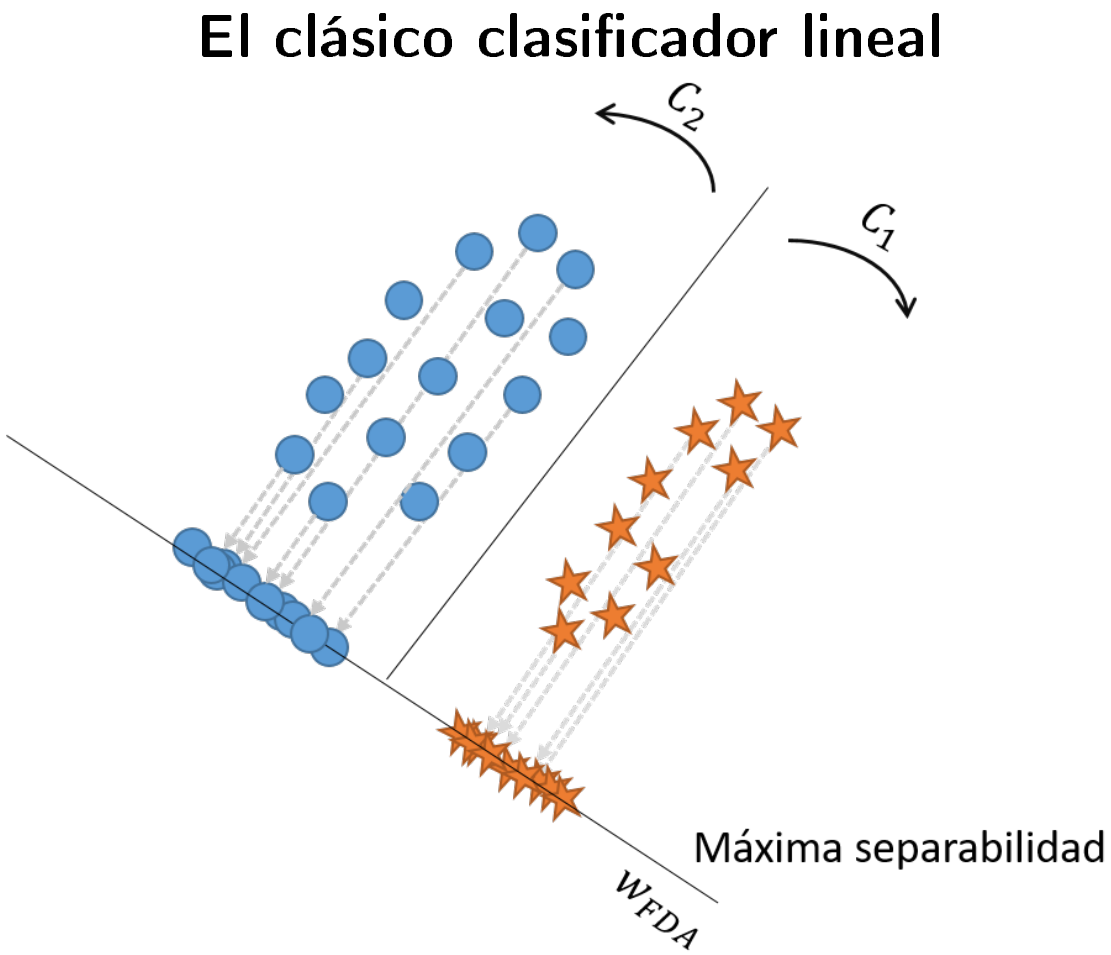

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Esquema

[Peterson et al., 2019]

Representación esquemática

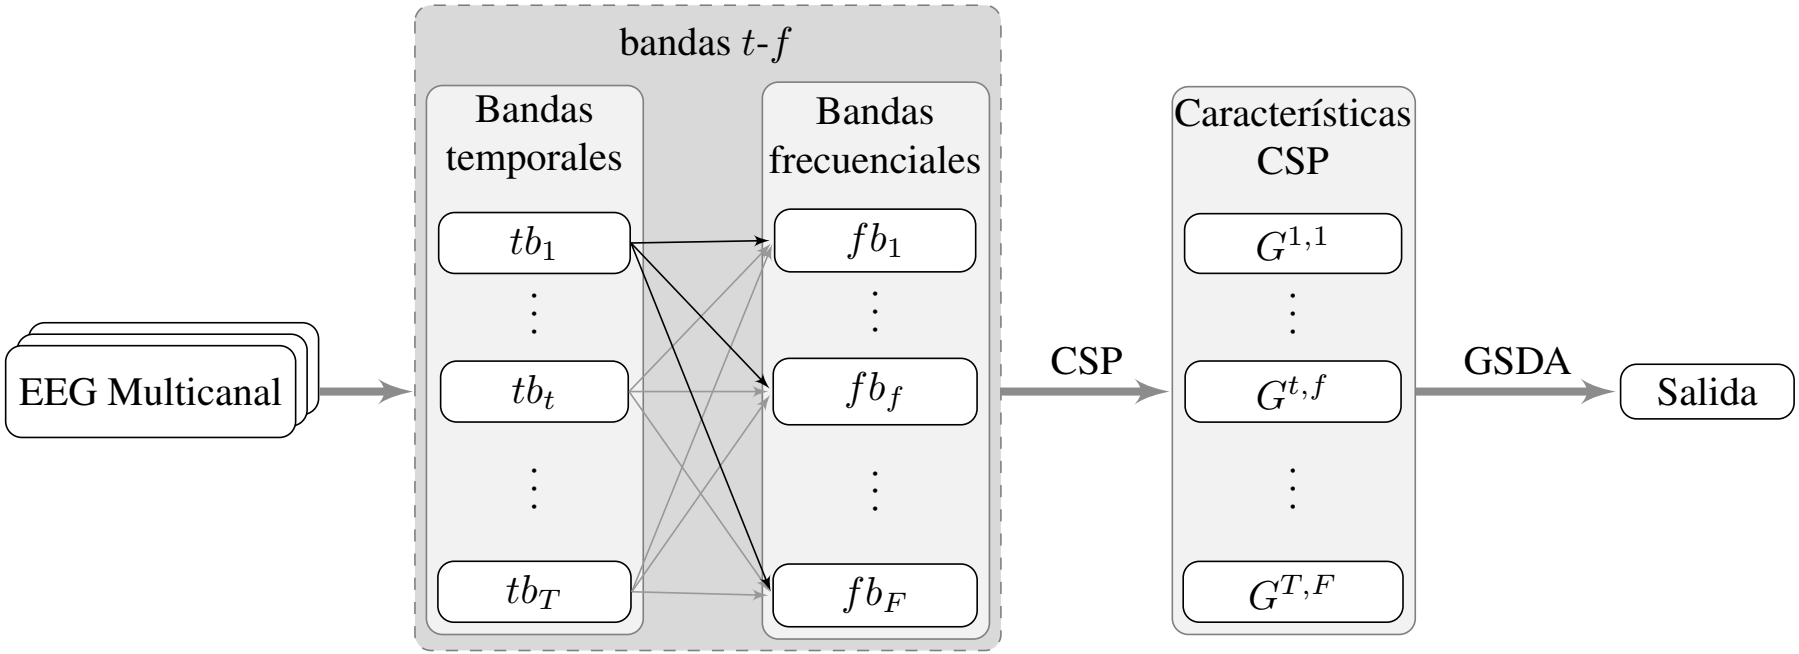

- 17 sub-bandas: $fb_1 = 4-8$ Hz, $fb_2 = 6-10$ Hz ,..., $fb_{17} = 36-40$ Hz.
  - Único segmento temporal: 0,5 – 2,5 ⇒ PFBCSP
  - T segmentos temporales 2 s de duración con un solapamiento de 1,5 s

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Esquema

[Peterson et al., 2019]

Representación esquemática

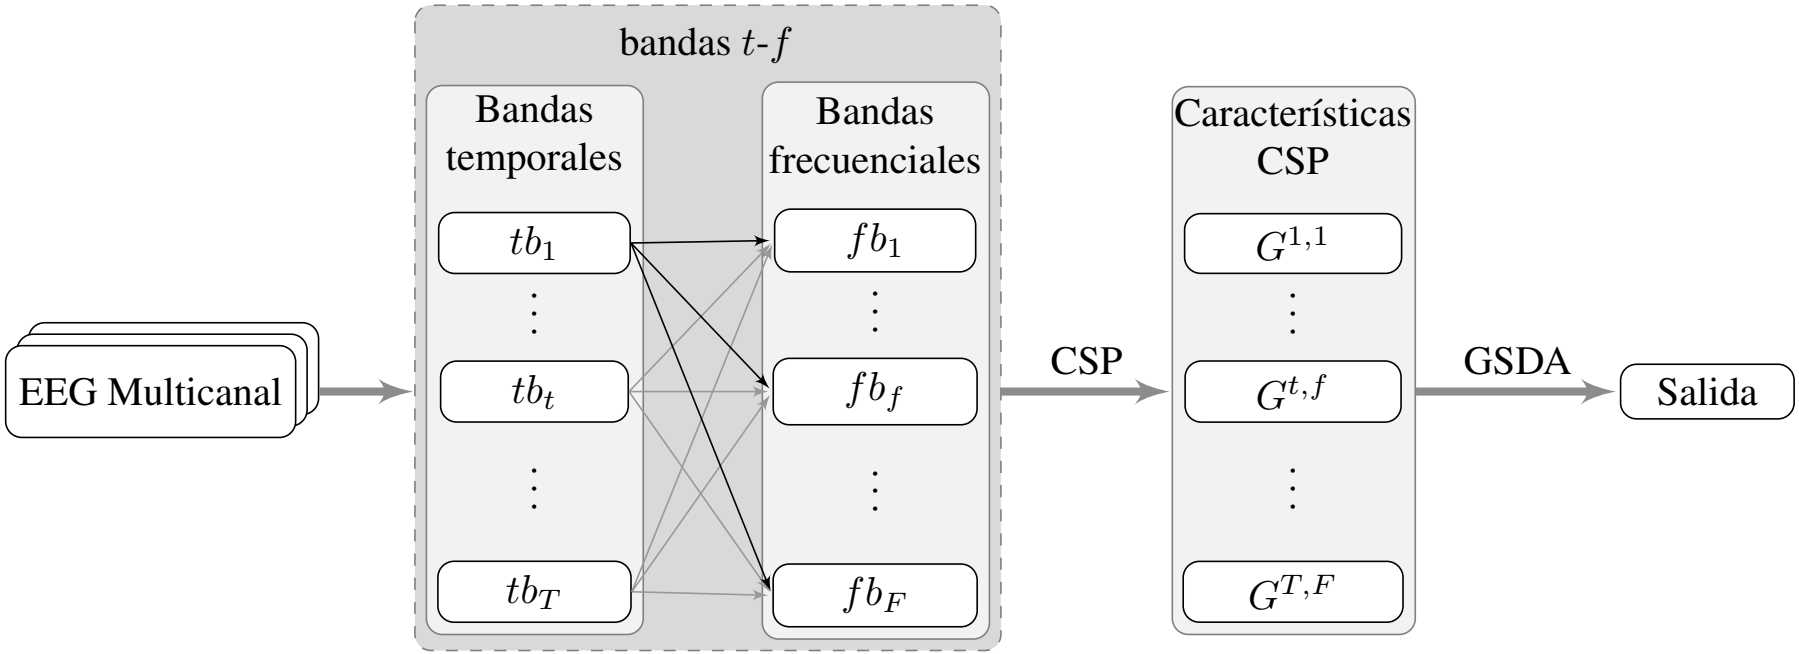

- 17 sub-bandas: $fb_1 = 4-8$ Hz, $fb_2 = 6-10$ Hz ,..., $fb_{17} = 36-40$ Hz.
  - Único segmento temporal: 0,5 – 2,5 ⇒ PFBCSP
  - T segmentos temporales 2 s de duración con un solapamiento de 1,5 s

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Resultados de clasificación [Peterson et al., 2019]

MI-1: Base de datos propia

10 sujetos sanos, 28 canales, MI vs. Rest, 160 ×256

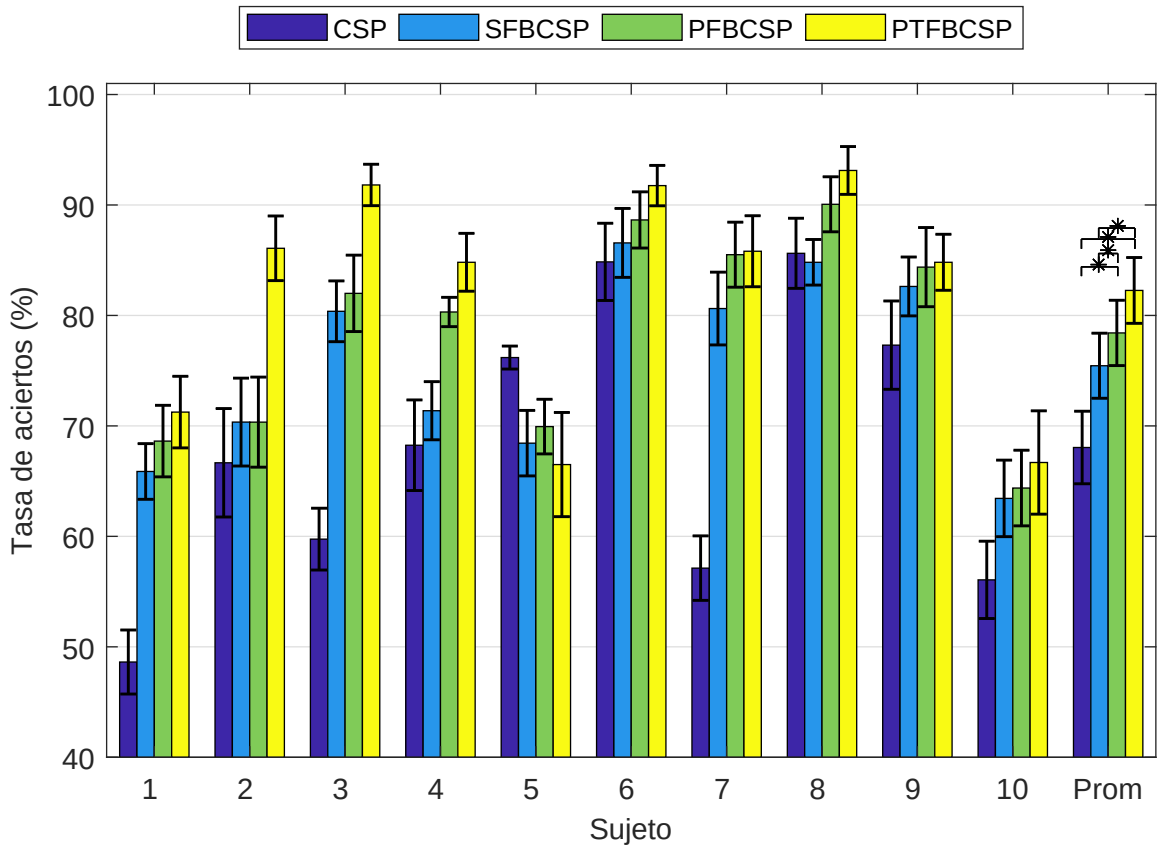

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Resultados de clasificación [Peterson et al., 2019]

MI-2: Base de datos IVa de la Competencia III de BCI

5 sujetos sanos, 28 canales, MI mano derecha vs. MI pie derecho, 280 ×200

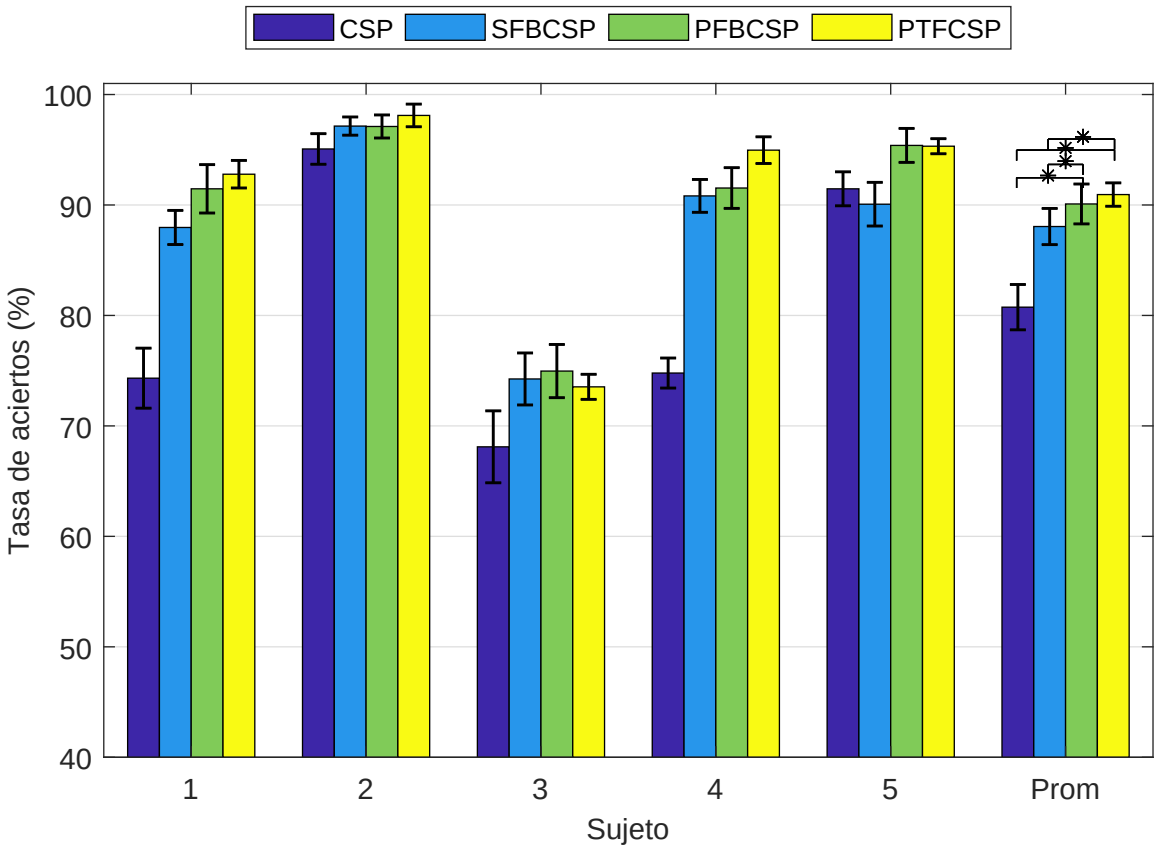

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Resultados de clasificación [Peterson et al., 2019]

MI-3: Base de datos IIb de la Competencia IV de BCI

9 sujetos sanos, 3 canales, MI mano derecha vs. MI mano izquierda, 160 ×500

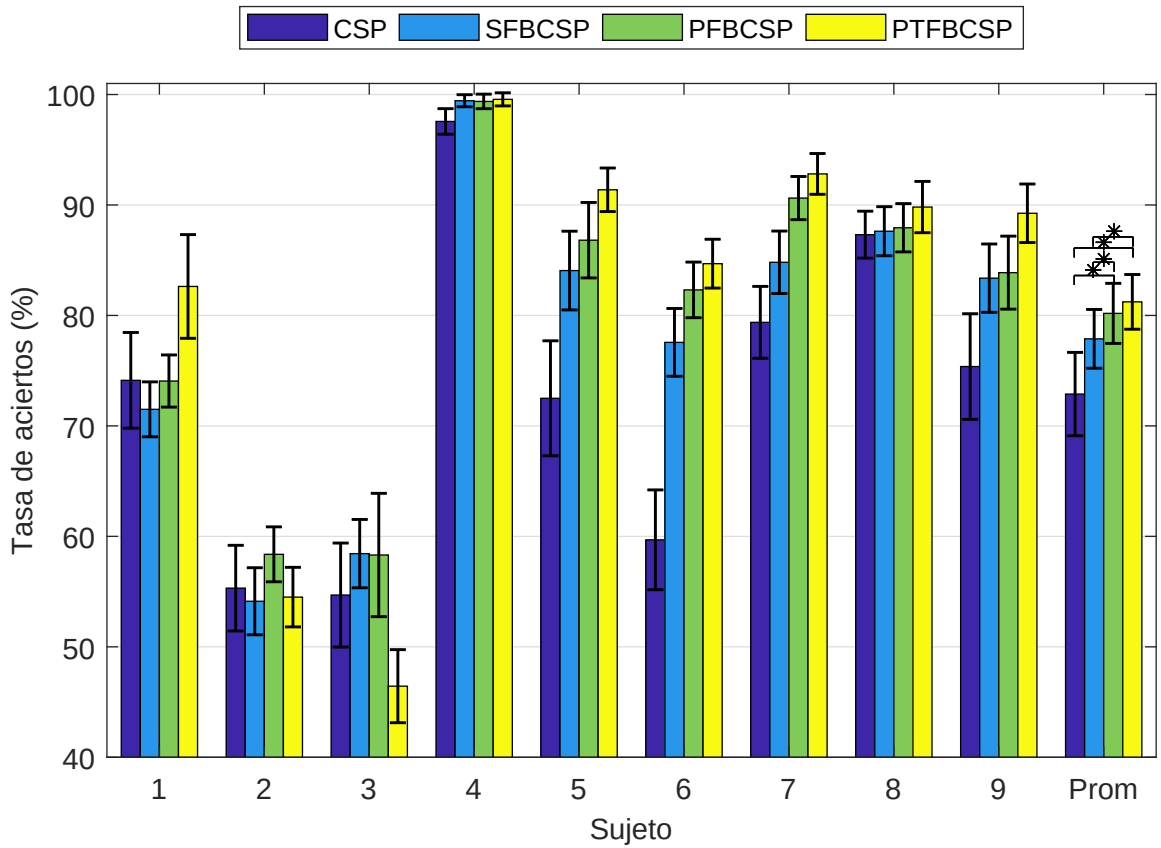

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Resultados de clasificación [Peterson et al., 2019]

Tasa de aciertos (%)

	CSP	SFBCSP	PFBCSP	PTFBCSP
MI-1	68,05 (± 3,28)	75,45 (± 2,95)	78,42 (± 2,96)	**82,26 (± 2,98)***
MI-2	80,75 (± 2,05)	88,05 (± 1,64)	90,09 (± 1,81)	**90,94 (± 1,06)***
MI-3	72,88 (± 3,77)	77,89 (± 2,66)	80,19 (± 2,72)	**81,23 (± 2,46)***

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Mapas topográficos

[Peterson et al., 2019]

SFBCSP

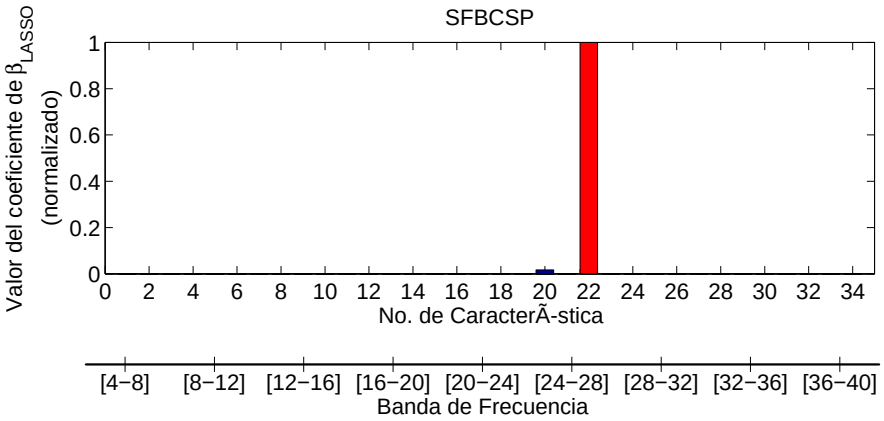

PFBCSP

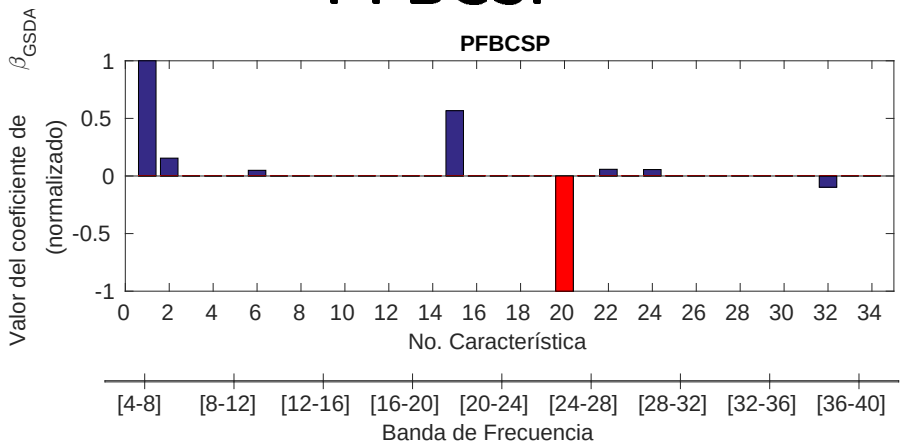

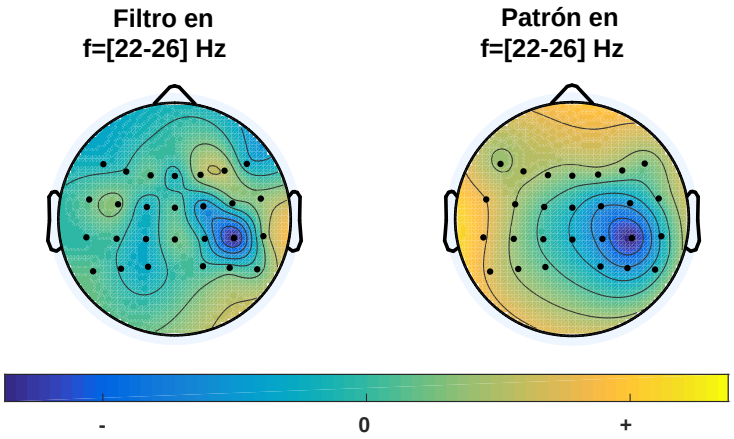

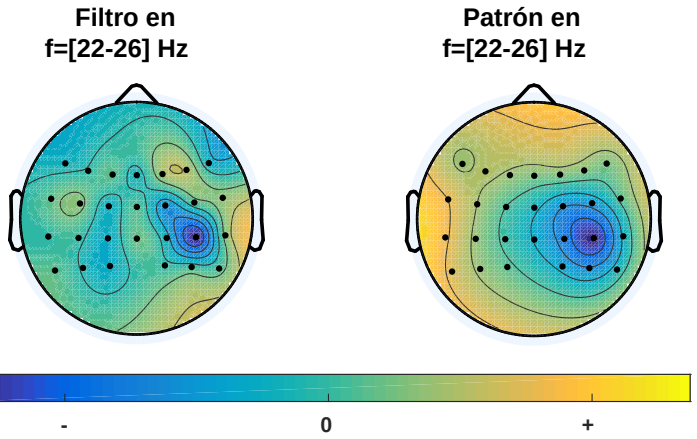

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Mapas topográficos **[Peterson et al., 2019]**

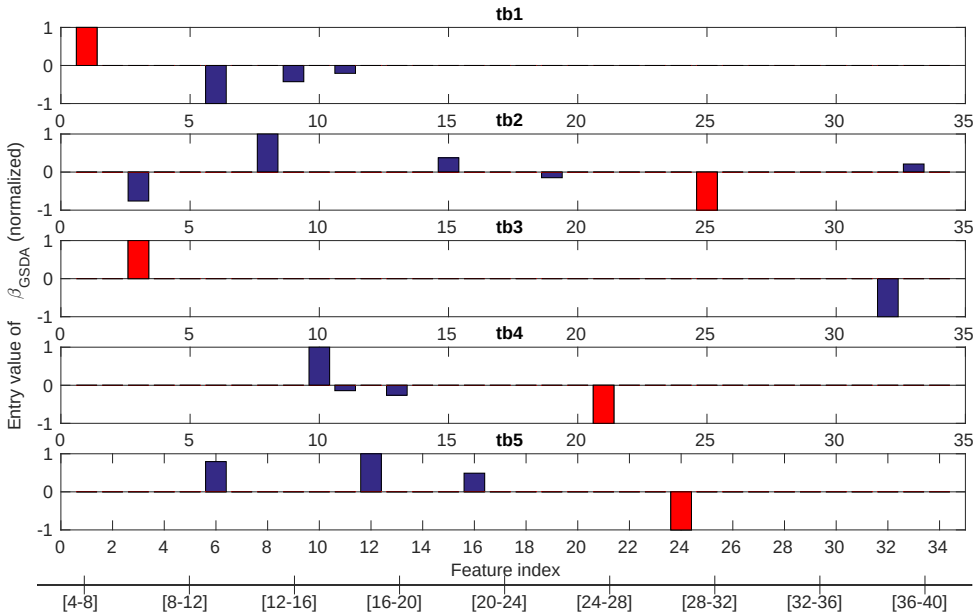

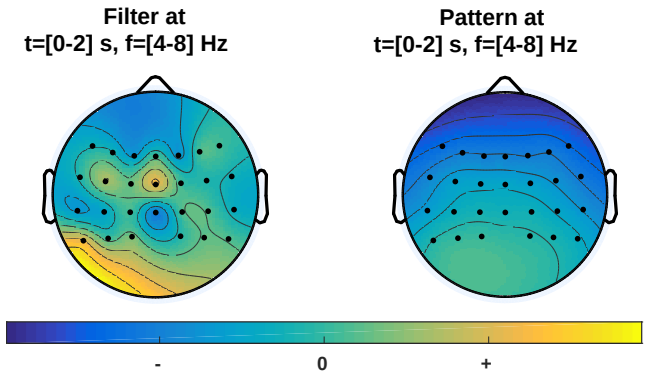

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Mapas topográficos **[Peterson et al., 2019]**

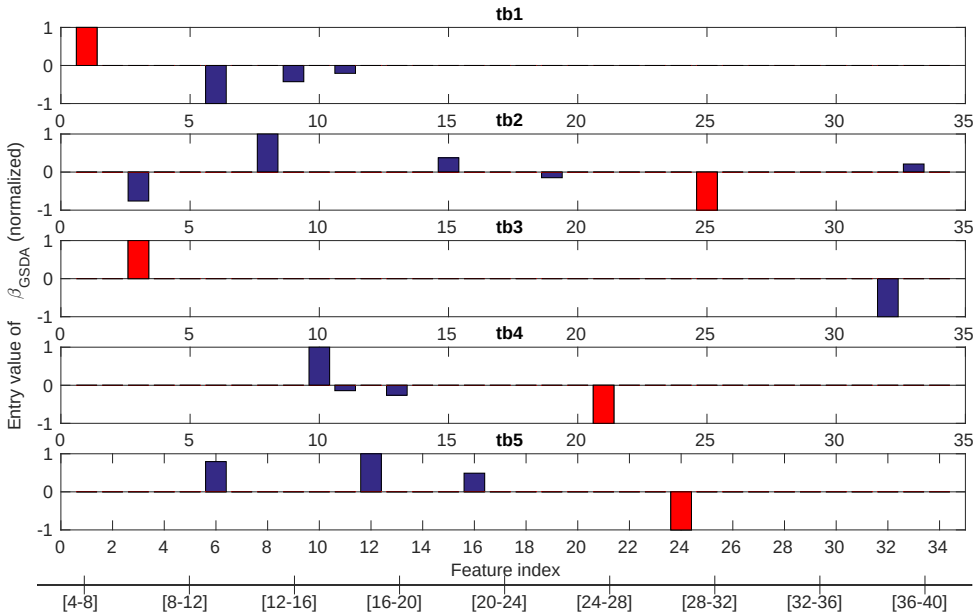

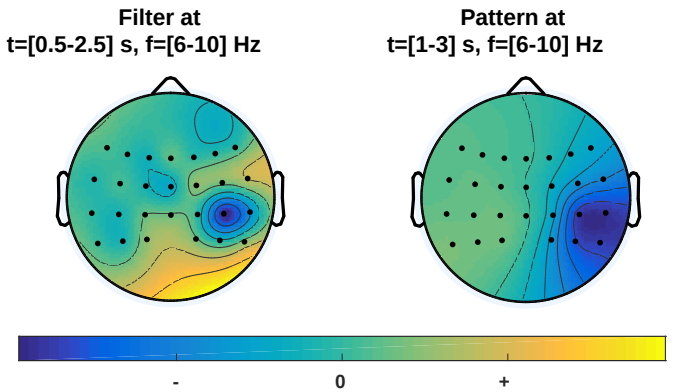

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Mapas topográficos

[Peterson et al., 2019]

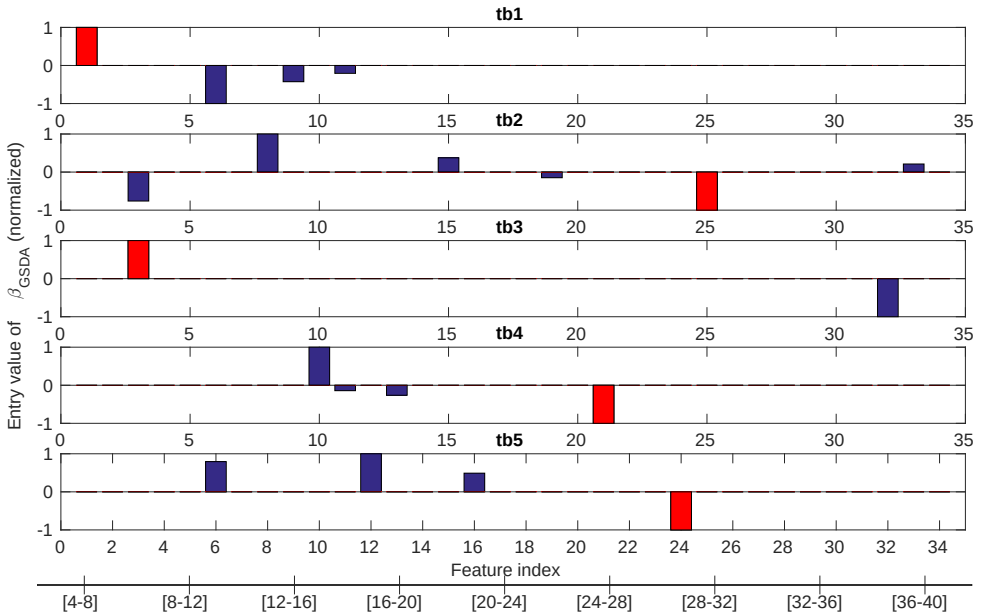

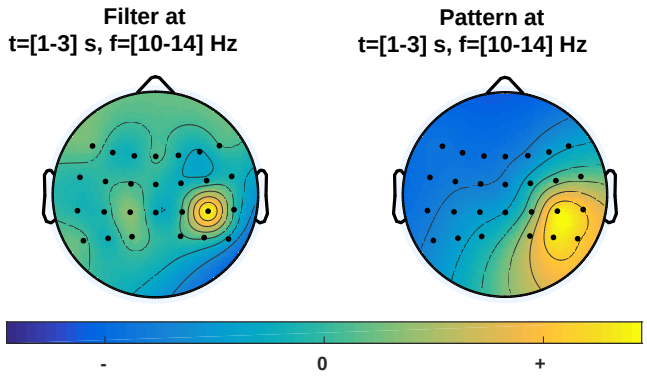

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Mapas topográficos

[Peterson et al., 2019]

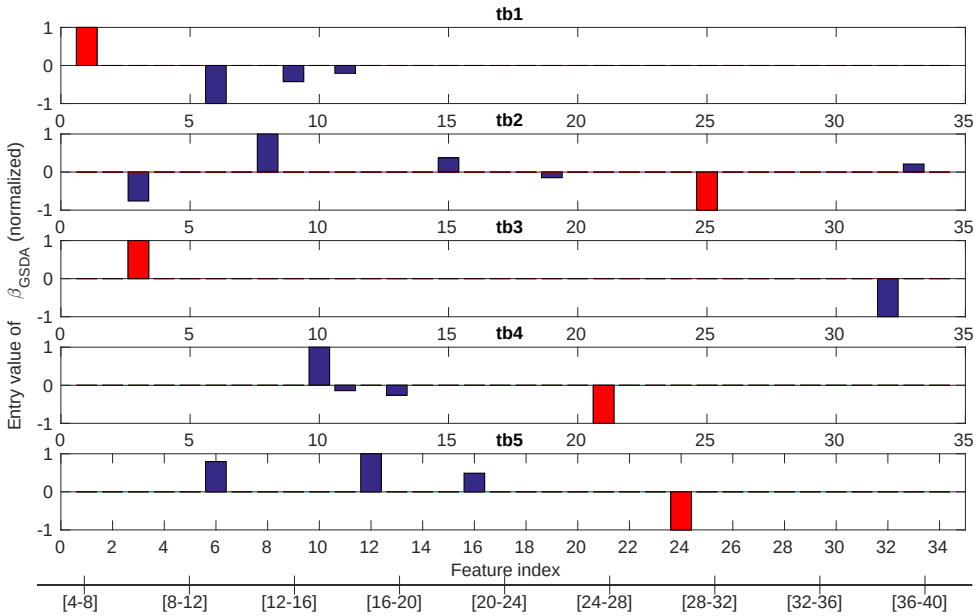

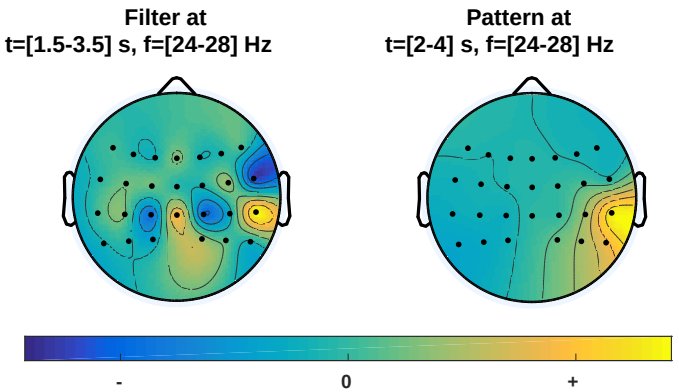

Patrones Espaciales Comunes y Bandas Temporo-Frecuenciales Penalizadas (PTFBCSP)

Mapas topográficos

[Peterson et al., 2019]

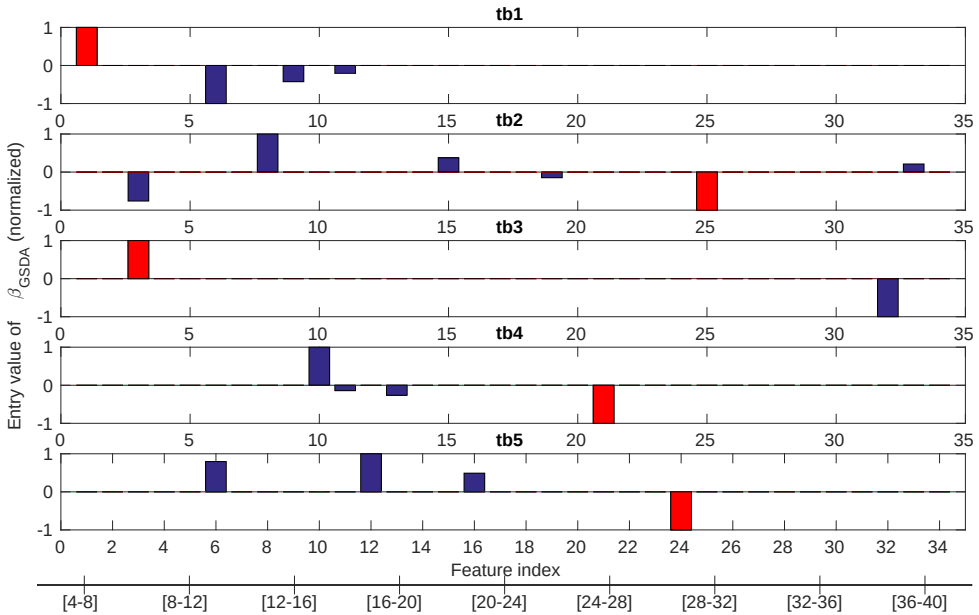

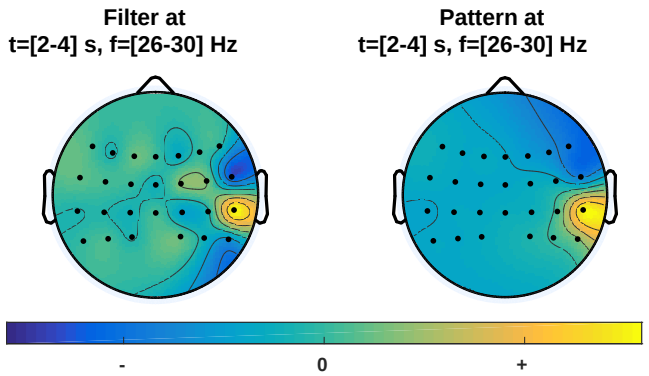

Evaluación en tiempo real

Diseño del experimento

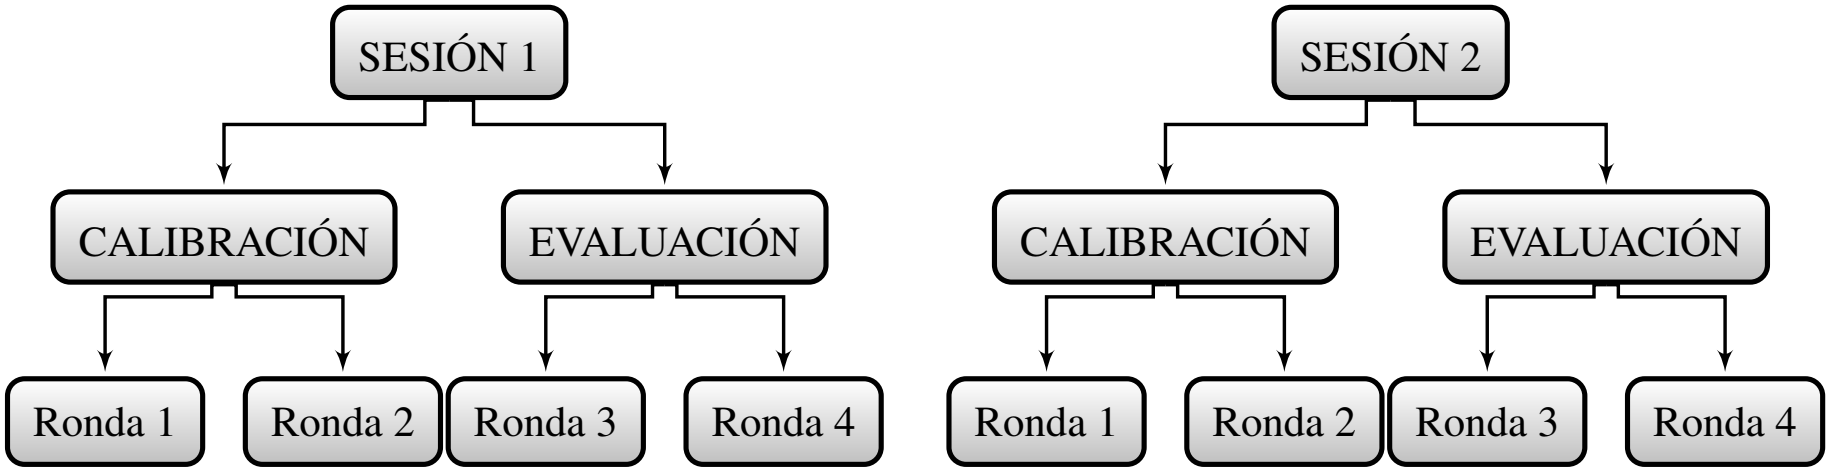

Evaluación en tiempo real

Diseño del experimento

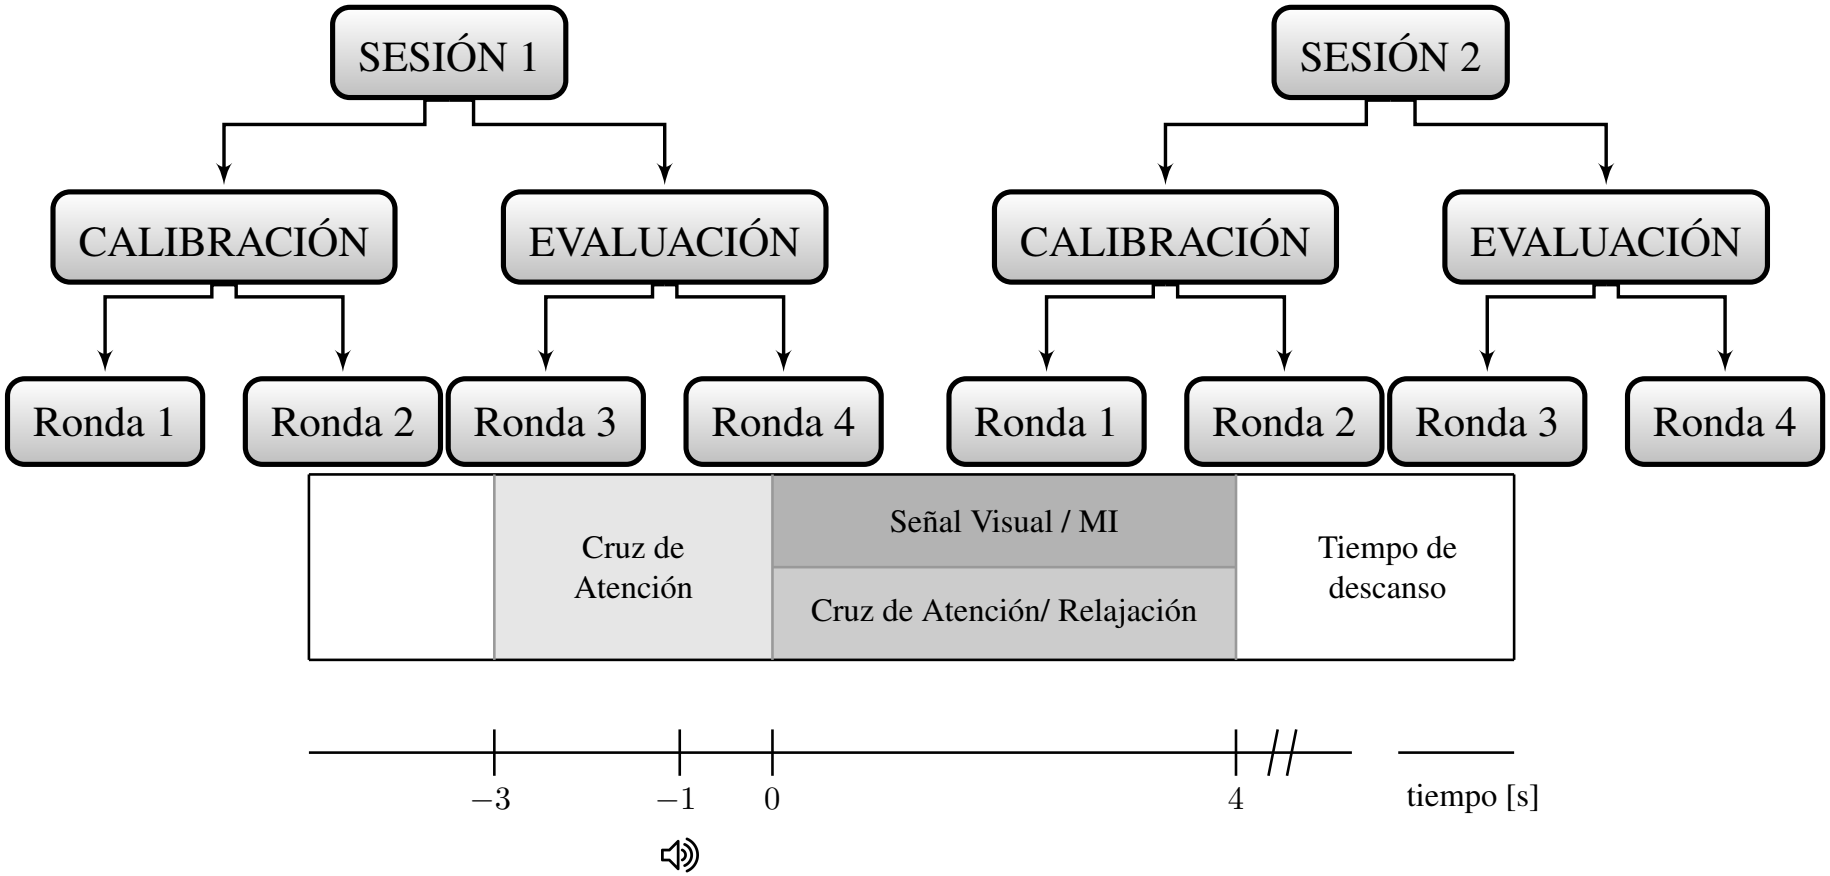

Evaluación en tiempo real

Diseño del experimento

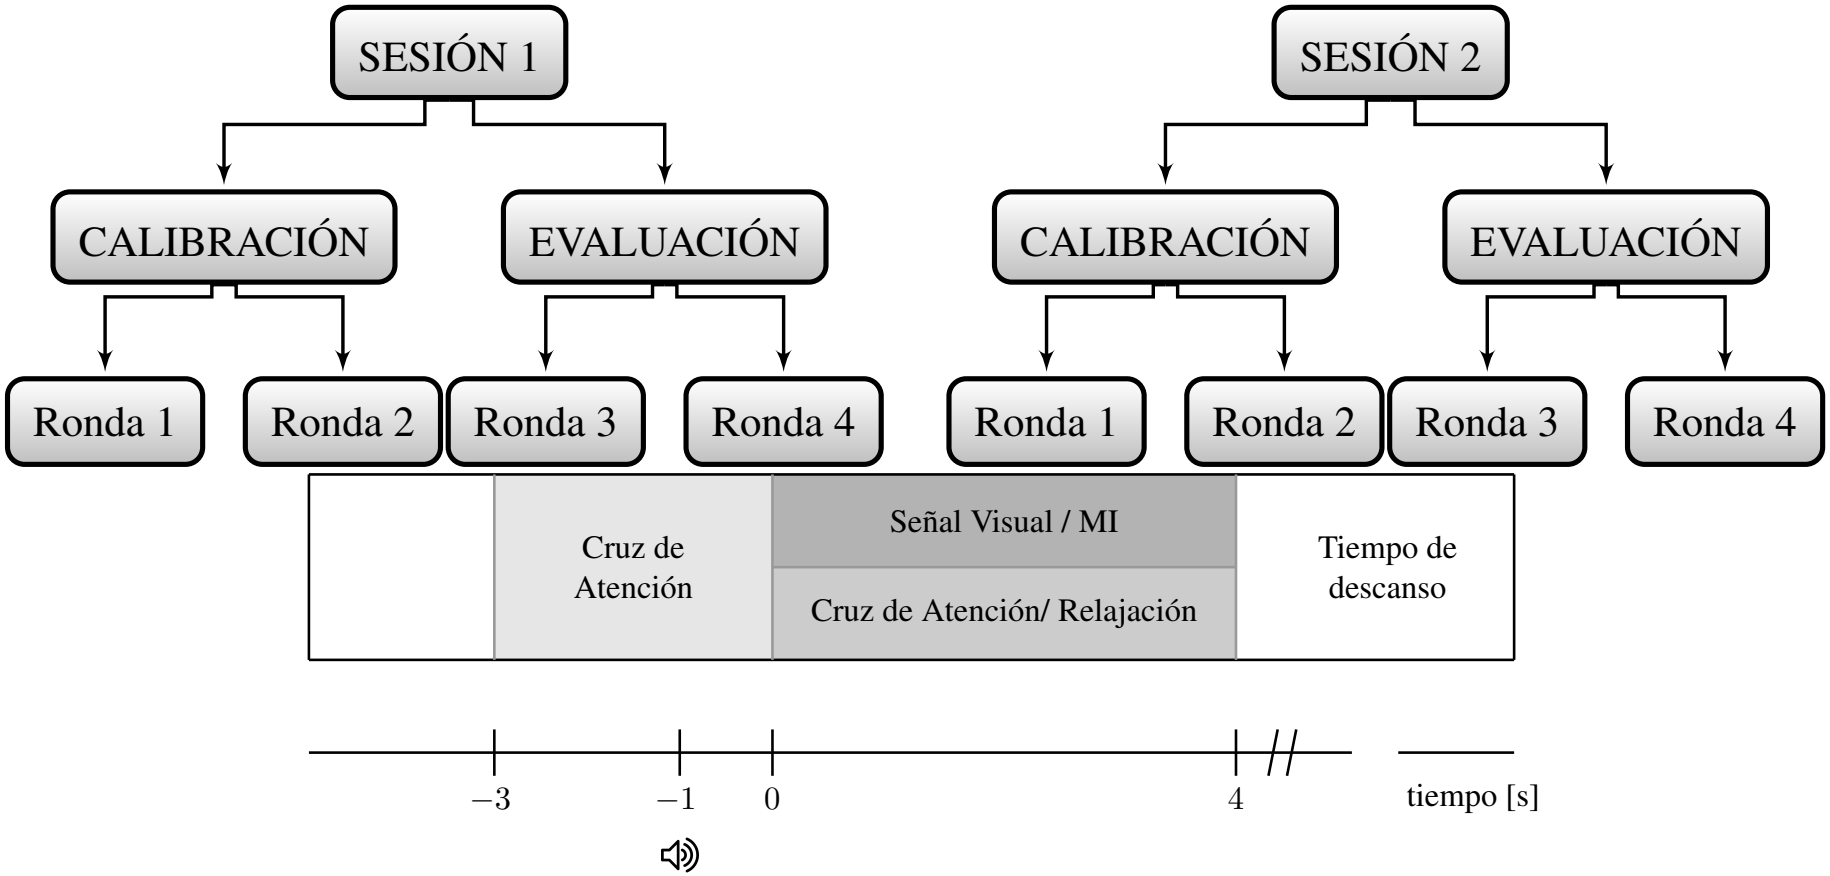

11 Sujetos sanos y 2 Pacientes de ACV

Evaluación en tiempo real

Diseño del experimento

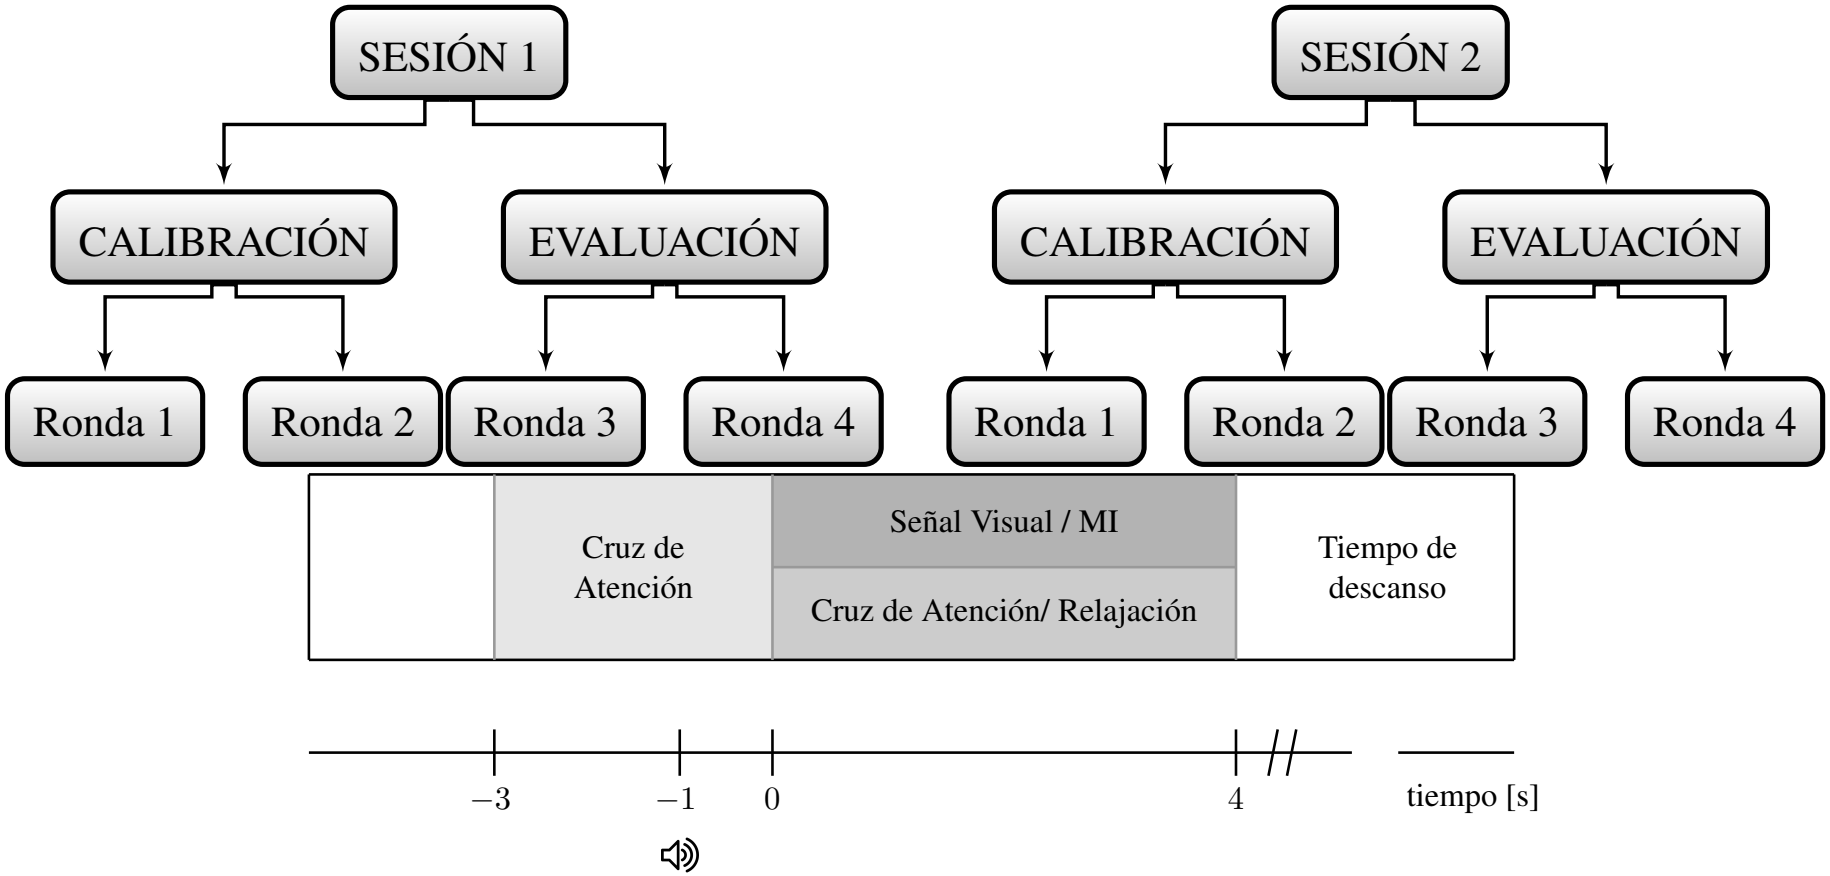

11 Sujetos sanos y 2 Pacientes de ACV

PFBCSP

Evaluación en tiempo real

Montaje del experimento

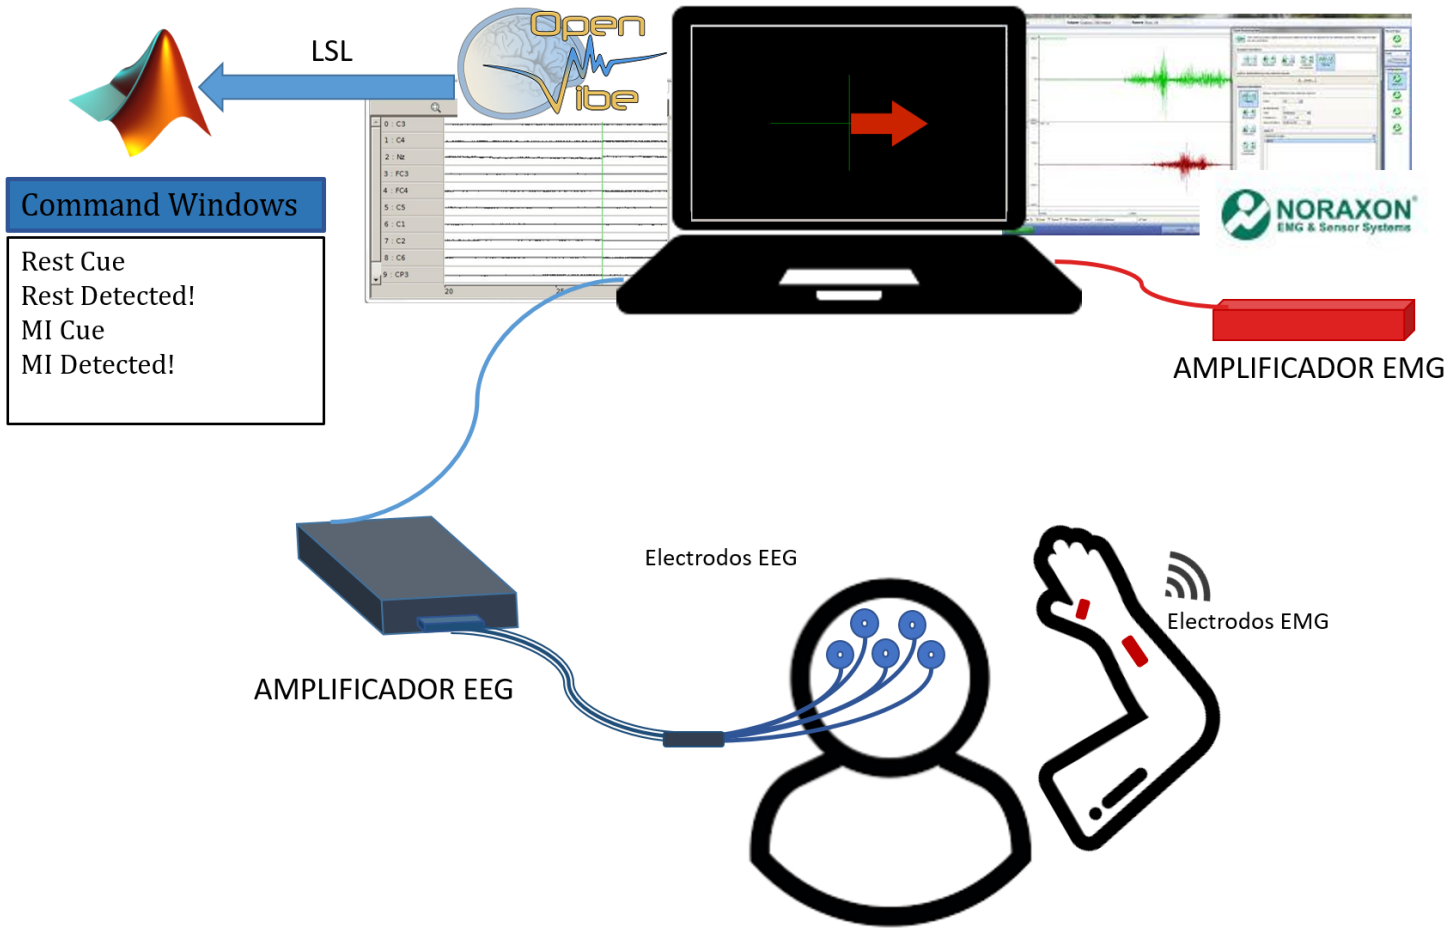

Evaluación en tiempo real

Resultados

Registros de EEG + EMG de 11 sujetos sanos y 2 pacientes de ACV

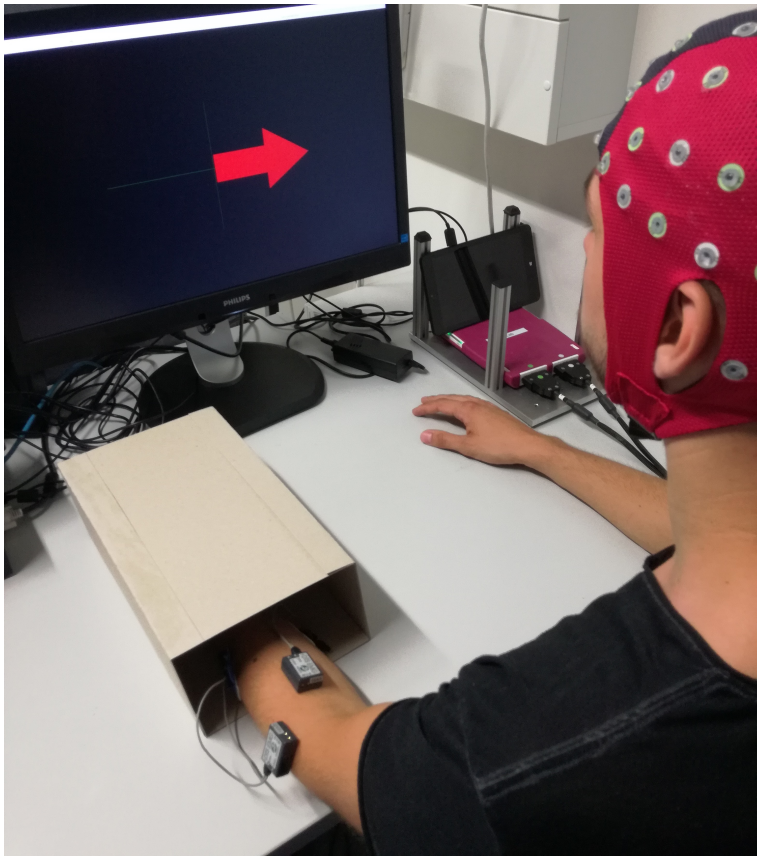

Evaluación en tiempo real

Resultados

Registros de EEG + EMG de 11 sujetos sanos y 2 pacientes de ACV

\+ Cuestionarios de atención y de habilidad en MI (KVIQ).

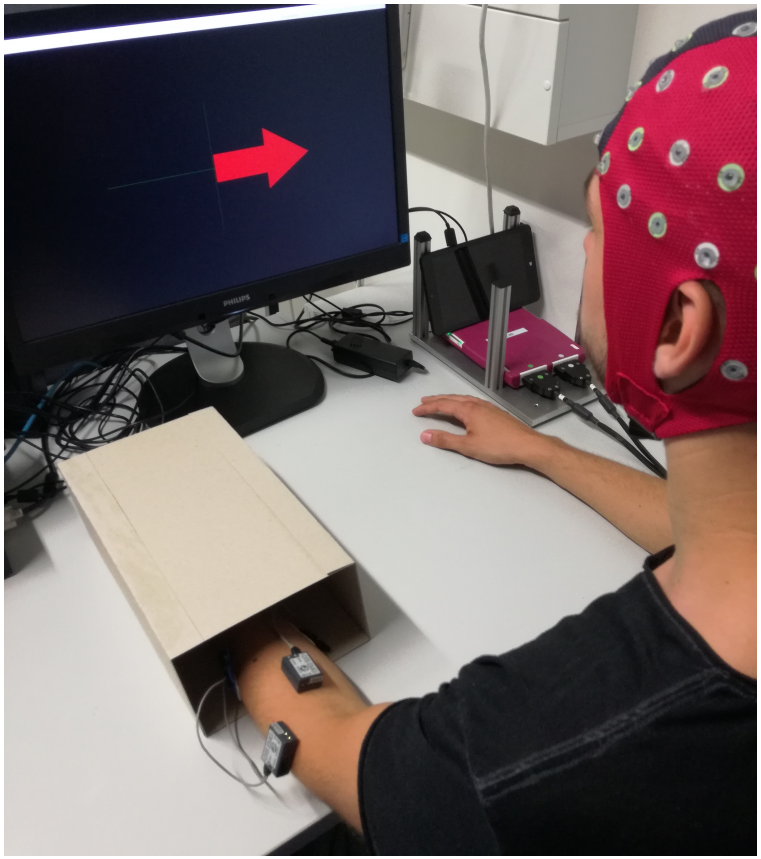

Evaluación en tiempo real

Resultados

Tasa de clasificación en las rondas de evaluación

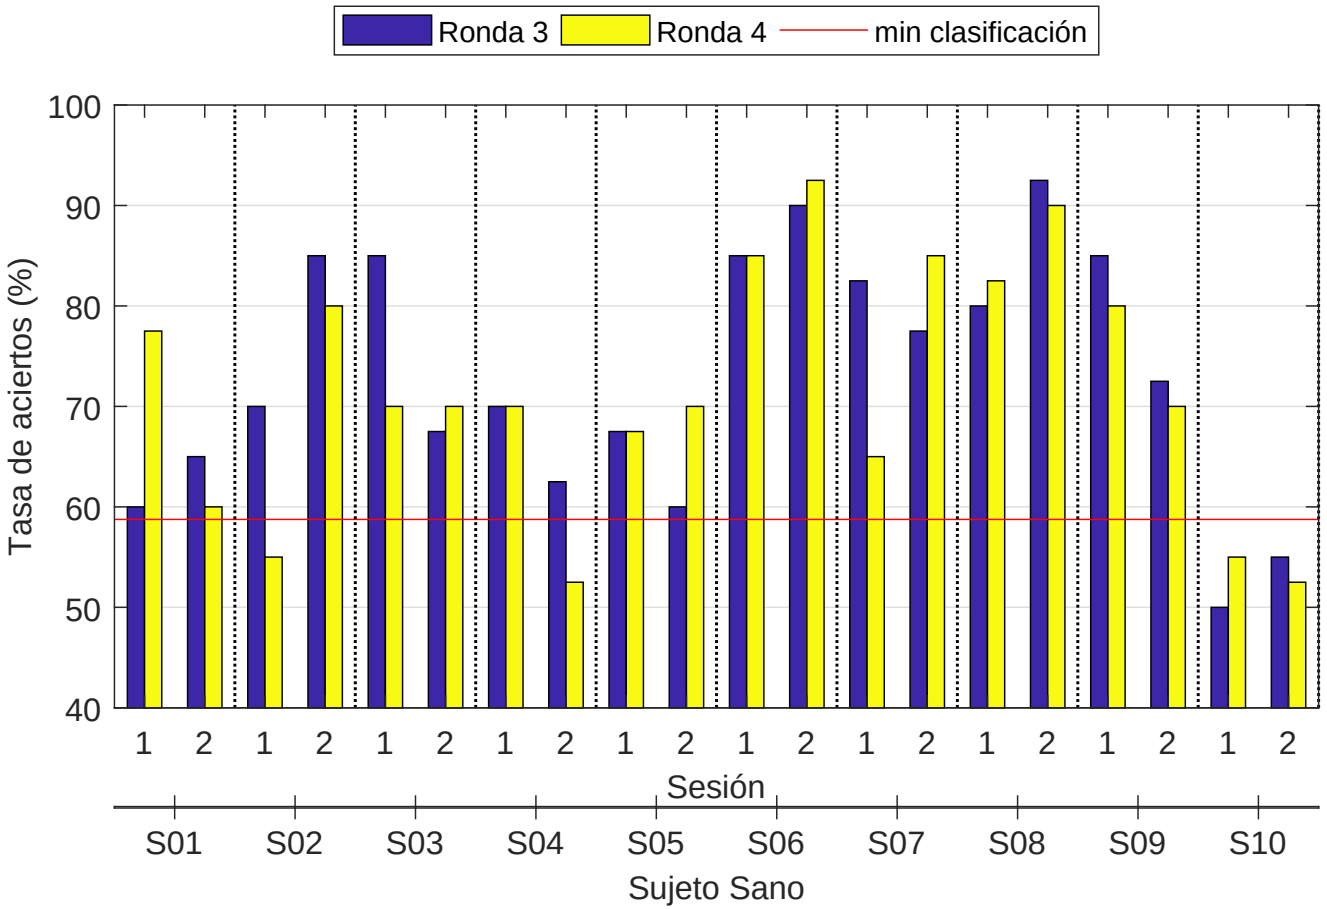

$72{,}31 \pm 12{,}32$

Evaluación en tiempo real

Resultados

Tasa de clasificación en las rondas de evaluación

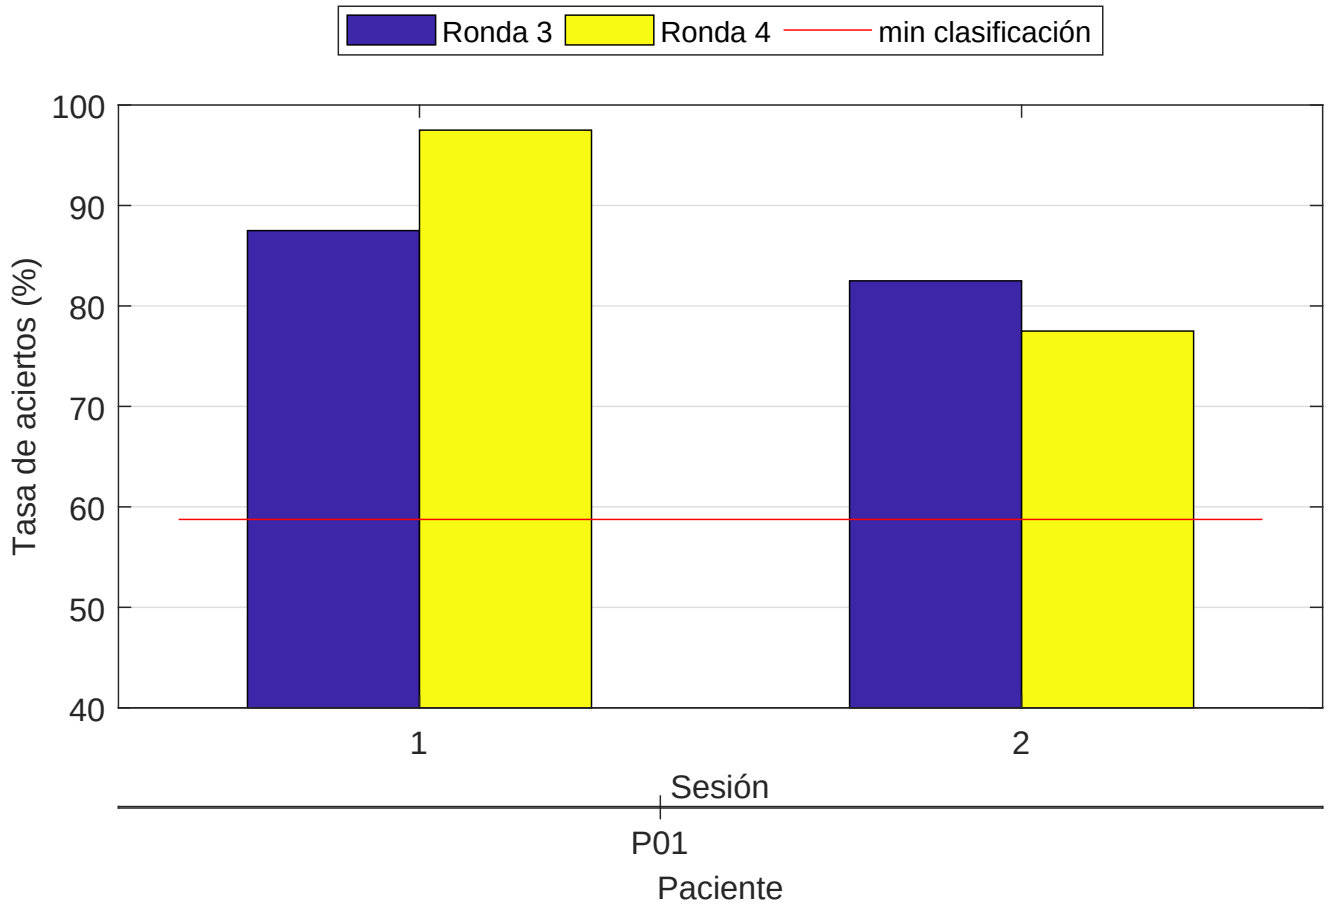

$86{,}25 \pm 8{,}84$

Trabajos a futuro

- ⇒ **Selección de canales** sujeto-específica.
- ⇒ Diseño e implementación de herramientas de **selección automática y sujeto-específica de los parámetros de regularización**.
- ⇒ **Métodos adaptativos** entre sesiones.
- ⇒ Evaluación de MI-BCIs en tiempo real con **feedback**.
- ⇒ Detección zonas de **fuentes activación neuronal**.
- ⇒ Trasladar las BCIs fuera del laboratorio: **clínica**.

Detección de la intención de movimiento

Colaboraciones

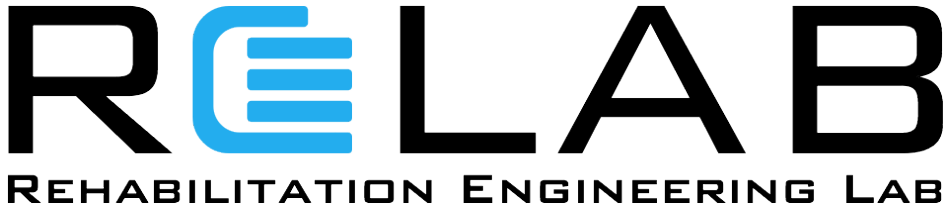

Detección de la intención de movimiento

Colaboraciones

RELAB
REHABILITATION ENGINEERING LAB

Detección de la intención de movimiento

Colaboraciones

RELAB
REHABILITATION ENGINEERING LAB

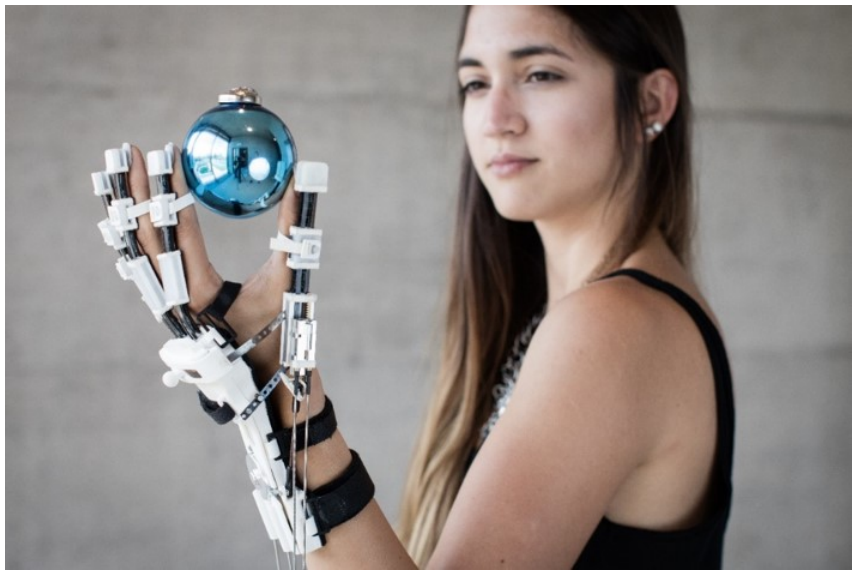

Todo eso detrás de una BCI

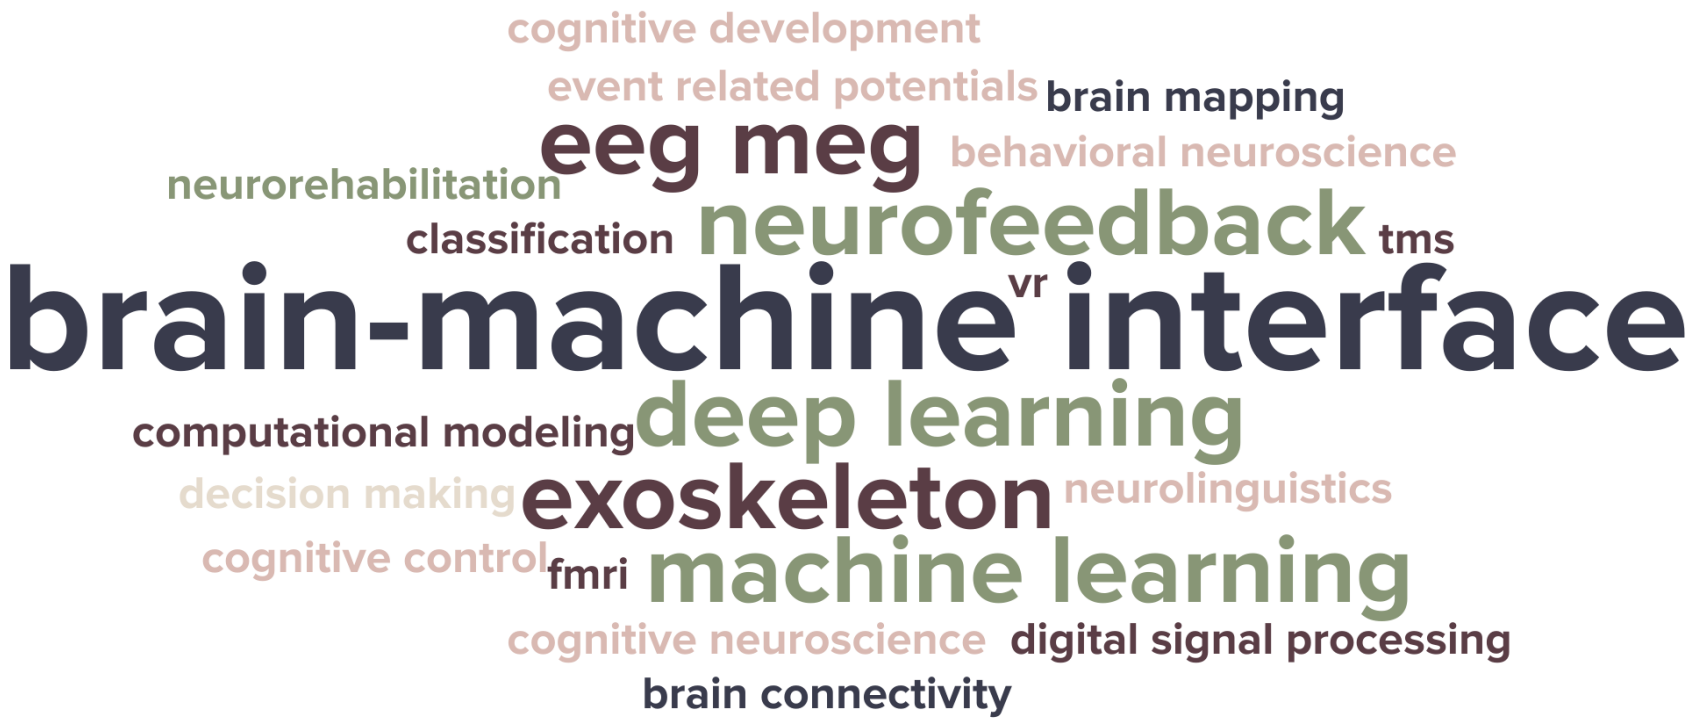

Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., and Muller, K.-R. (2008). Optimizing spatial filters for robust EEG single-trial analysis. *IEEE Signal processing magazine*, 25(1):41–56.

Cervera, M. A., Soekadar, S. R., Ushiba, J., Millán, J. d. R., Liu, M., Birbaumer, N., and Garipelli, G. (2018). Brain-computer interfaces for post-stroke motor rehabilitation: a meta-analysis. *Annals of clinical and translational neurology*, 5(5):651–663.

Clerc, M., Bougrain, L., and Lotte, F. (2016). *Brain–Computer Interfaces 1: Foundations and Methods*. John Wiley & Sons, Inc.

Gassert, R. and Dietz, V. (2018). Rehabilitation robots for the treatment of sensorimotor deficits: a neurophysiological perspective. *Journal of NeuroEngineering and Rehabilitation*, 15(1):46.

Norrving, B. and Kissela, B. M. (2013). The global burden of stroke and need for a continuum of care. *Neurology*, 80 3 Suppl 2:S5–12.

Peterson, V., Rufiner, H. L., and Spies, R. D. (2017). Generalized sparse discriminant analysis for event-related potential classification. *Biomedical Signal Proc. and Control*, 35:70–78.

Peterson, V., Wyser, D., Lambercy, O., Spies, R., and Gassert, R. (2019). A penalized time-frequency band feature selection and classification procedure for improved motor intention decoding in multichannel eeg. *Journal of neural engineering*, 16(1):016019.

Pfurtscheller, G. e. a. (2001). Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, 89(7):1123–1134.

Ramoser, H., Muller-Gerking, J., and Pfurtscheller, G. (2000). Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE transactions on rehabilitation engineering*, 8(4):441–446.

Tang, Z., Sun, S., Zhang, S., Chen, Y., Li, C., and Chen, S. (2016). A brain-machine interface based on erd/ers for an upper-limb exoskeleton control. *Sensors*, 16(12):2050.

Wolpaw, J. and Wolpaw, E. W. (2012). *Brain-Computer Interfaces: principles and practice*. Oxford University Press, USA.

¿ PREGUNTAS ?

¡G R A C I A S!

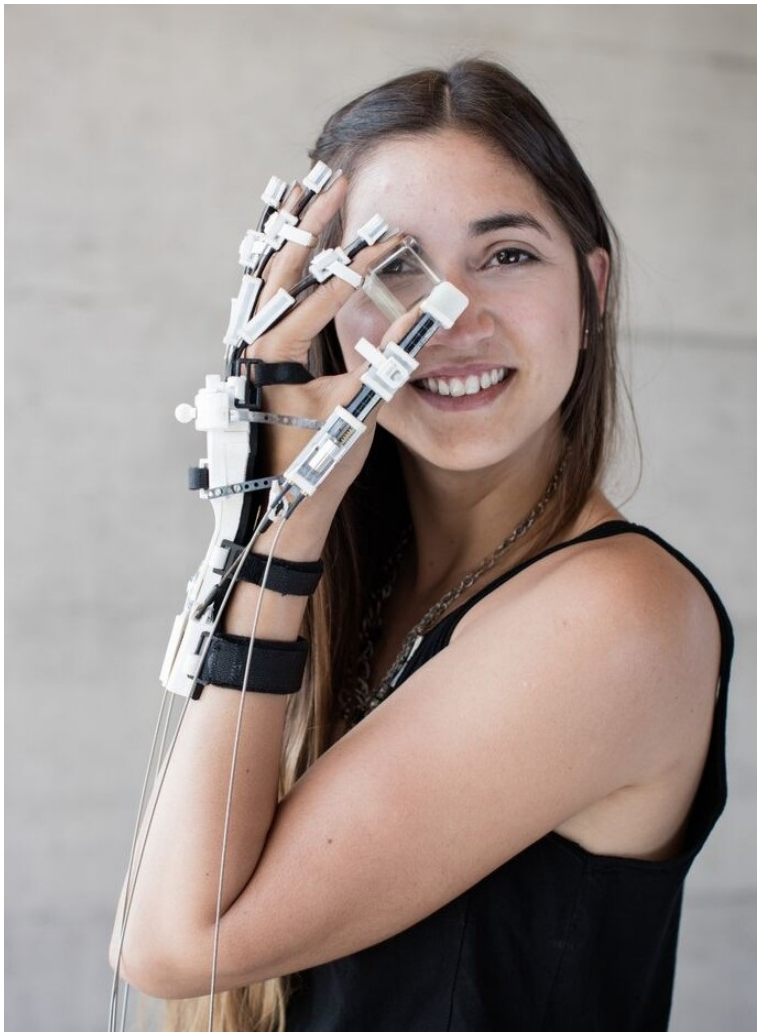

vpeterson09

Formulación CSP

Patrones espaciales comunes (CSP) [Ramoser et al., 2000]

Sea $\{\mathbf{X}_c^i\}_{i=1}^{n_c}$ un conjunto de n_c señales de EEG filtradas, $c = 1, 2$, con $\mathbf{X}_c^i \in \mathbb{R}^{p \times m}$. El método CSP busca encontrar la matriz $\mathbf{W} = [\mathbf{w}_1, \ldots, \mathbf{w_p}]$ de p filtros espaciales, tal que:

$$\mathbf{Z} = \mathbf{W}^T \mathbf{X},$$

donde la j-ésima señal espacialmente filtrada $\mathbf{z}_j$ tiene máxima varianza para una clase, y mínima para la otra.

Formulación CSP

Patrones espaciales comunes (CSP) [Ramoser et al., 2000]

Sea $\{\mathbf{X}_c^i\}_{i=1}^{n_c}$ un conjunto de n_c señales de EEG filtradas, $c = 1, 2$, con $\mathbf{X}_c^i \in \mathbb{R}^{p \times m}$. El método CSP busca encontrar la matriz $\mathbf{W} = [\mathbf{w}_1, \ldots, \mathbf{w_p}]$ de p filtros espaciales, tal que:

$$\mathbf{Z} = \mathbf{W}^T \mathbf{X},$$

donde la j-ésima señal espacialmente filtrada $\mathbf{z}_j$ tiene máxima varianza para una clase, y mínima para la otra.

Observe que $\mathbf{X} = \mathbf{W}^{-T}\mathbf{Z}$, donde $\mathbf{A} = \mathbf{W}^{-T}$ son los patrones espaciales

El vector de características $\mathbf{g}\Omega[g_1, \ldots, g_{2K}]'$ se construye con las primeras y últimas K filas de $\mathbf{Z}$.

Formulación GSDA

GSDA

[Peterson et al., 2017]

Sea $\mathbf{X}$ una matriz de datos de dimensión $n \times p$, $\mathbf{Y}$ una matriz $n \times 2$ de variables binarias tal que y_{ij} es un indicador de si la observación i^{th} pertenece a la j^{th} clase, $\boldsymbol{\theta} \in \mathbb{R}^2$ el vector de *score* y $\boldsymbol{\beta} \in \mathbb{R}^p$ el vector discriminativo. Luego, el método GSDA consiste en resolver el siguiente problema de mínimos cuadrados con restricciones:

$$(\boldsymbol{\beta}^*, \boldsymbol{\theta}^*) = \underset{\boldsymbol{\beta} \in \mathbb{R}^p, \boldsymbol{\theta} \in \mathbb{R}^K}{\arg\min} \{\|\mathbf{Y}\boldsymbol{\theta} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda_1 \|\mathbf{D}_1 \boldsymbol{\beta}\|_1 + \lambda_2 \|\mathbf{D}_2 \boldsymbol{\beta}\|_2^2\},$$

$$s.a \quad \frac{1}{n} \boldsymbol{\theta}^T \mathbf{Y}^T \mathbf{Y} \boldsymbol{\theta} = 1,$$

donde $\mathbf{D}_1$ y $\mathbf{D}_2$ son dos matrices de anisotropía diagonales y definidas positivas de dimensión $p \times p$ que incorporan información discriminativa a-priori sobre la discrepancia entre las clases.

Formulación GSDA

GSDA

[Peterson et al., 2017]

Sea $\mathbf{X}$ una matriz de datos de dimensión $n \times p$, $\mathbf{Y}$ una matriz $n \times 2$ de variables binarias tal que y_{ij} es un indicador de si la observación i^{th} pertenece a la j^{th} clase, $\boldsymbol{\theta} \in \mathbb{R}^2$ el vector de *score* y $\boldsymbol{\beta} \in \mathbb{R}^p$ el vector discriminativo. Luego, el método GSDA consiste en resolver el siguiente problema de mínimos cuadrados con restricciones:

$$(\boldsymbol{\beta}^*, \boldsymbol{\theta}^*) = \underset{\boldsymbol{\beta} \in \mathbb{R}^p, \boldsymbol{\theta} \in \mathbb{R}^K}{\arg\min} \{\|\mathbf{Y}\boldsymbol{\theta} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda_1 \|\mathbf{D}_1 \boldsymbol{\beta}\|_1 + \lambda_2 \|\mathbf{D}_2 \boldsymbol{\beta}\|_2^2\},$$

$$s.a \quad \frac{1}{n} \boldsymbol{\theta}^T \mathbf{Y}^T \mathbf{Y} \boldsymbol{\theta} = 1,$$

donde $\mathbf{D}_1$ y $\mathbf{D}_2$ son dos matrices de anisotropía diagonales y definidas positivas de dimensión $p \times p$ que incorporan información discriminativa a-priori sobre la discrepancia entre las clases.

Formulación GSDA

GSDA

[Peterson et al., 2017]

Sea $\mathbf{X}$ una matriz de datos de dimensión $n \times p$, $\mathbf{Y}$ una matriz $n \times 2$ de variables binarias tal que y_{ij} es un indicador de si la observación i^{th} pertenece a la j^{th} clase, $\boldsymbol{\theta} \in \mathbb{R}^2$ el vector de *score* y $\boldsymbol{\beta} \in \mathbb{R}^p$ el vector discriminativo. Luego, el método GSDA consiste en resolver el siguiente problema de mínimos cuadrados con restricciones:

$$(\boldsymbol{\beta}^*, \boldsymbol{\theta}^*) = \underset{\boldsymbol{\beta} \in \mathbb{R}^p, \boldsymbol{\theta} \in \mathbb{R}^K}{\arg\min} \{\|\mathbf{Y}\boldsymbol{\theta} - \mathbf{X}\boldsymbol{\beta}\|_2^2 + \lambda_1 \|\mathbf{D}_1 \boldsymbol{\beta}\|_1 + \lambda_2 \|\mathbf{D}_2 \boldsymbol{\beta}\|_2^2\},$$

$$s.a \quad \frac{1}{n} \boldsymbol{\theta}^T \mathbf{Y}^T \mathbf{Y} \boldsymbol{\theta} = 1,$$

Datos proyectados $\boldsymbol{X\beta} \in \mathbb{R}^{n \times 1}$ fácilmente separables mediante un sencillo clasificador lineal.