

Técnicas de filtrado espacial para señales de electroencefalografía

Profesora a cargo

Dra. Victoria Peterson (Instituto de Matemática Aplicada del Litoral, IMAL, UNL-CONICET Santa Fe, Argentina; Facultad de Ingeniería Química, FIQ-UNL, Santa Fe, Argentina).

Ayudantes

Bioing. Catalina María Gálvan (Instituto de Matemática Aplicada del Litoral, IMAL, UNL-CONICET Santa Fe, Argentina; Facultad de Ingeniería Química, FIQ-UNL, Santa Fe, Argentina).

Bioing. Burno Zorzet (Instituto de Investigación en Señales, Sistemas e Inteligencia Computacional, sinc(i), UNL-CONICET, Santa Fe, Argentina)

Destinatarios

Estudiantes de grado y posgrado.

Requisitos

Conceptos básicos de álgebra lineal, optimización, programación (preferentemente Python).

Descripción General

La actividad cerebral registrada mediante electroencefalografía de superficie (EEG) puede pensarse como el resultado de una mezcla lineal entre diferentes fuentes estadísticas. Estas fuentes pueden provenir del grupo de neuronas subyacentes a dónde se encuentre ubicado el sensor de EEG, así como de grupos de neuronas aledañas. Asimismo, otras fuentes no cerebrales pueden encontrarse en los registros de EEG, que en última instancia serán definidas como artefactos de la señal.

Los modelos generativos estadísticos asumen que las señales cerebrales surgen de la actividad de fuentes no correlacionadas, y que dichas fuentes aparecen distorsionadas en la señal registrada como consecuencia del proceso de mezcla lineal. Es decir, si $x(t) \in R^{N_c}$ denota la actividad cerebral en el espacio del sensor (raw data) al tiempo t , y N_c denota el número de canales del registros, tenemos:

$$x(t) = As(t),$$

donde $s(t) \in R^{N_c}$ son las fuentes (o componentes) y $A \in R^{N_c \times N_c}$ es la matriz de mezcla.

En el contexto de filtrado espacial, el objetivo es estimar $s(t)$ y por lo tanto, transformar la señal que vive en el espacio del "sensor" al espacio de las "fuentes". Esta transformación sensor-fuente puede ser obtenida mediante los llamados métodos de separación de fuente:

$$\hat{s}(t) = W^T x(t),$$

donde $W = \begin{bmatrix} w_1 & \dots & w_i & \dots & w_{N_c} \end{bmatrix}$ es una $N_c \times N_c$ es la matriz de demezcla cuya columna i -ésima corresponde a lo que se denomina en la literatura filtro espacial.

La matriz W a aprender será el resultado de un proceso de optimización dado. La definición de dicha matriz, y por tanto su efecto a ser aplicada como transformación lineal, dependerá de qué tipo de fuentes se desea estimar. Tal es el caso, que métodos de filtrado espacial podrían utilizarse para mejorar la relación señal-ruido, hallar la fuente más correlacionada a un cierto evento, hallar fuentes independientes, etc. Por tanto, la aplicación de filtros espaciales a la señal de EEG podría realizarse tanto para: (i) reducir la dimensionalidad de la señal de entrada, (ii) extracción de características, (iii) eliminación de fuentes de ruido. A lo largo de este curso **se revisarán los principales algoritmos de filtrado espacial** en el ámbito

de procesamiento de la señal de EEG utilizados para mejorar la relación señal-ruido, extracción de características y eliminación de artefactos.

Objetivos

Que el alumno sea capaz de:

- Comprender los conceptos básicos neurofisiológicos relacionados a las señales de electroencefalografía
- Aprender métodos básicos de filtrado espacial de series temporales del cerebro.
- Comprender conceptos básicos del procesamiento estadístico de señales.
- Adquirir las habilidades básicas de implementación en MNE-Python de ciertos métodos de filtrado espacial.

Estructura del Curso

Curso teórico-práctico desarrollado en la plataforma [Google Colaboratory](#).

El curso se divide en dos módulos:

Módulo I (primer encuentro)

Introducción al procesamiento de la señal de EEG. Sus principales características. Introducción general al filtrado espacial. Métodos tradicionales de filtrado espacial y rereferenciación. Métodos más avanzados de filtrado espacial para referenciación.

Módulo II (segundo encuentro)

Métodos de filtrado espacial para extracción de características. Métodos de filtrado espacial para eliminación de artefactos.

Se planean **dos encuentros de 4 horas** cada uno en los cuales revisaremos los siguientes métodos de filtrado espacial:

1. Common Average Reference (CAR)
2. Spatio Spectral Decomposition (SSD)
3. Common Space Patterns (CSP)
4. Independent Component Analysis (ICA)

Material necesario

Computadora con acceso a internet

Bibliografía

- Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., & Müller, K. R. (2008). Optimizing spatial filters for robust EEG single-trial analysis. *IEEE Signal Processing Magazine*, 25(1), 41–56. <https://doi.org/10.1109/MSP.2008.4408441>
- Cohen, M. X. (2014). *Analyzing Neural Time Series Data: Theory and Practice*. MIT Press.
- Cohen, M. X. (2022). A tutorial on generalized eigendecomposition for denoising, contrast enhancement, and dimension reduction in multichannel electrophysiology. *NeuroImage*, 247, 1–48.
- Haufe, S., Dähne, S., & Nikulin, V. v. (2014). Dimensionality reduction for the analysis of brain oscillations. *NeuroImage*, 101, 583–597. <https://doi.org/10.1016/j.neuroimage.2014.06.073>
- McFarland, D. J., and D. J. Krusienski. "Brain-Computer Interfaces: Principles and Practice." (2012).
- Nikulin, V. v., Nolte, G., & Curio, G. (2011). A novel method for reliable and fast extraction of neuronal EEG/MEG oscillations on the basis of spatio-spectral decomposition. *NeuroImage*, 55(4), 1528–1535. <https://doi.org/10.1016/j.neuroimage.2011.01.057>
- Sabbagh, D., Ablin, P., Varoquaux, G., Gramfort, A., & Engemann, D. A. (2020). Predictive regression modeling with MEG/EEG: from source power to signals and cognitive states. *NeuroImage*, 116893. <https://doi.org/10.1016/j.neuroimage.2020.116893>