

Estudio del empleo de información frecuencial en la clasificación en tiempo real de señales EEG

Manuel Morato, Nicolás Medrano, Belén Calvo

Grupo de Electrónica de Potencia y Microelectrónica (GEPM)
Instituto de Investigación en Ingeniería de Aragón (I3A)
Universidad de Zaragoza, Mariano Esquillor s/n, 50018, Zaragoza, Spain.
Tel. +34-976762707, e-mail: mmorato@unizar.es

Resumen

Los sistemas de clasificación de señales electroencefalográficas se basan, en general, en la identificación de patrones a partir de datos de múltiples canales adquiridos en ventanas temporales fijas. Este trabajo presenta un estudio preliminar empleando información frecuencial y su robustez ante efectos de latencia en aplicaciones en tiempo real.

Introducción

La mayoría de las técnicas de clasificación automática de señales bioeléctricas (EEG, ECG, EOG, EMG), emplean como patrones ventanas temporales de tamaño y resolución constantes, definidas de tal forma que su comienzo y final mantengan una posición relativa fija respecto del instante en el que se produce el estímulo asociado a la clase de ese patrón. Por ejemplo, en patrones electroencefalográficos de imaginación motora (Motor Imagery, MI), como los disponibles en la base de datos Physionet [1], se definen patrones de entrada de 3 segundos de duración con una frecuencia de muestreo (resolución) de 160 Hz, y de forma que el evento de imaginación se produce siempre un tiempo fijo tras el comienzo de dicha ventana. Modelos de inteligencia artificial específicos, como puede ser EEGNet [2], basado en una red neuronal convolucional (CNN) reciben en su etapa de entrenamiento/validación las señales de los canales adecuadamente sincronizadas (Figura 1) para su identificación: en el protocolo de adquisición de medidas el paciente es informado mediante algún tipo de estímulo del instante en que debe “pensar” el movimiento, manteniendo así su posición temporal fija dentro de dichas ventanas, o se realiza un postprocesado manual de los datos para su sincronización.

Si bien modelos de Inteligencia Artificial como EEGNet muestran un buen rendimiento en clasificación, ya que aplican secuencialmente filtros temporales por canal y espaciales entre canales,

concentrando la información en tiempo y espacio, en caso de que el modelo entrenado se aplique a un escenario donde no exista sincronismo de la señal o tenga un jitter alto (como las ventanas 1 y 2 de la Figura 1, con un desplazamiento Δt), el perfil temporal puede no coincidir con el utilizado en el entrenamiento del modelo, degradando significativamente la eficiencia en la clasificación.

Clasificación dinámica

Un caso particular de clasificación de señales de MI que puede verse afectado por este desplazamiento de las ventanas temporales es considerando su aplicación a estímulos dinámicos, esto es, supuesto las señales de los electrodos son adquiridas en un flujo temporal continuo y enviadas al módulo de clasificación para determinar el movimiento imaginado, lo que permitiría sistemas de actuación electromecánicos controlados con las señales cerebrales en tiempo real. Para una buena experiencia de usuario, es conveniente que el tiempo transcurrido entre la imaginación del evento y la actuación asociada no supere los 200 a 300 ms. Esta clasificación dinámica de las señales precisa una alta inmunidad al deslizamiento temporal de los patrones-estímulos, que no se consigue con las señales temporales.

La Figura 2 (izquierda) muestra la evolución en la precisión para una arquitectura EEGNet en la clasificación de 4 tipos de movimiento diferentes de la base de datos Physionet (cerrar puño izquierdo, cerrar puño derecho, levantar pies, reposo), en función del tiempo transcurrido entre el comienzo de la ventana temporal del estímulo respecto del origen de sincronismo. Como se puede observar, considerando la máxima precisión del modelo en la clasificación en el tiempo $t = 0$ (es decir, el patrón temporal está completamente sincronizado y coincide con los patrones de entrenamiento), ésta se degrada hasta quedar por debajo de 0.4 para desfases de 150 ms para los tres tipos de movimiento distintos del reposo.

Codificación en frecuencia

Como muestra la Figura 2 (izquierda), un desplazamiento del evento de MI en la ventana temporal produce una considerable degradación en el proceso de clasificación. Por ello, motivados por otros trabajos donde se explora la representación frecuencial de las señales EEG [3][4], en este trabajo se ha hecho un ensayo preliminar consistente en codificar la información de los estímulos en frecuencia, aplicando una transformada rápida de Fourier (FFT) a los datos antes de ser entregados al modelo de inferencia. Debe hacerse notar que se mantiene EEGNet (reentrenada) como arquitectura empleada, si bien su configuración no está optimizada para este formato de señal de entrada.

La Figura 2 (derecha) muestra la evolución en la precisión en la clasificación para los mismos casos mostrados en la Figura 2 (izquierda), con la información codificada en el módulo del espectro. Como puede apreciarse, la pendiente de pérdida de precisión se atenúa en los tres casos principales de movimiento imaginado, y más particularmente en el de movimiento de pies (en rojo).

Conclusiones

Este trabajo presenta el análisis preliminar de cómo afecta la codificación en frecuencia de la información procedente de señales EEG de imaginación motora en la precisión en la inferencia ante deslizamiento de la ventana temporal de datos. Empleando la base de datos Physionet, comparada con la codificación convencional en tiempo, la pérdida de precisión presenta una pendiente más suave para los tres casos principales, llegando a reducirse a la mitad para los

datos correspondientes a movimiento de pie. Teniendo en cuenta que la arquitectura del modelo de inferencia empleado, EEGNet, se encuentra optimizado para datos con información temporal y espacial, y no en frecuencia, los resultados son prometedores. Como siguientes pasos, se considera el desarrollo de una arquitectura de modelo de Red Profunda más adecuado para este tipo de codificación, así como el estudio del empleo wavelets discretas, computacionalmente más costosas, pero con mayor capacidad para capturar la naturaleza no estacionaria de las señales cerebrales.

REFERENCIAS

- [1]. SCHALK, G. EEG Motor Movement/Imagery Dataset (version 1.0.0). PhysioNet, 2009. RRID:SCR_007345. Available from: <https://doi.org/10.13026/C28G6P>
- [2]. LAWHERN, V.J., SOLON, A.J., WAYTOWICH, N.R., GORDON, S.M., HUNG, C.P. and LANCE, B.J. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 2018, 15(5), 056013. DOI: 10.1088/1741-2552/aace8c.
- [3]. KATO, K., TAKAHASHI, K., MIZUGUCHI, N. and USHIBA, J. Online detection of amplitude modulation of motor-related EEG desynchronization using a lock-in amplifier: comparison with a fast Fourier transform, a continuous wavelet transform, and an autoregressive algorithm. *Journal of Neuroscience Methods*, 2018, 293, pp. 289–298. DOI: 10.1016/j.jneumeth.2017.10.015.
- [4]. BASHIVAN, P., RISH, I., YEASIN, M. and CODELLA, N. Learning representations from EEG with deep recurrent-convolutional neural networks. 4th International Conference on Learning Representations (ICLR), 2016. Available from: <https://digitalcommons.memphis.edu/facpubs/13946>




Figura 1. Esquema de un sistema de adquisición de señales EEG para procesos de imaginación motora.




Figura 2. Evolución de la precisión en la detección de patrones de MI de la base de datos Physionet con el deslizamiento de la ventana temporal. Izquierda, información codificada en tiempo; Derecha, codificación en frecuencia.