

Clasificación de imaginación motriz mediante la detección de ERD/ERS para aplicaciones BCI

Ramiro Germán Rodríguez Colmeiro¹; Emiliano Statello¹; Sebastián Ezequiel Jaremczuk¹; Juan Carlos Gómez^{1,2}; Claudio Verrastro^{1,3}
GIAR Grupo de Inteligencia Artificial y Robótica, Universidad Tecnológica Nacional, Facultad Regional Buenos Aires, Argentina¹

e-mail: prosecer@gmail.com;

Instituto Nacional de Tecnología Industrial²

e-mail: juanca@inti.gob.ar;

Comisión Nacional de Energía Atómica³

e-mail: cverra@cae.cnea.gov.ar;

Resumen: El reconocimiento de patrones sobre una señal de EEG es crítico para la realización de un sistema BCI. Este documento presenta un método de clasificación de imaginación de movimientos sobre las extremidades superiores a partir de potenciales relacionados a eventos motrices (ERD/ERS). Se describe el filtrado de las bandas de interés mu y beta mediante una transformada continua de Wavelet (CWT) y se detalla el armado del vector de características y su presentación a una red neuronal artificial (RNA) para su clasificación. Finalmente el método es contrastado con un set de BCI Competition II y se reporta el resultado.

I. INTRODUCCIÓN

En el marco del desarrollo de un sistema BCI (del inglés *Brain Computer Interface*) que se define, según Wolpaw, como “una interfaz cerebro-computador que le provee al cerebro un nuevo canal de comunicación sin utilizar músculo alguno” [1]. Se realizó un algoritmo de discriminación de la imaginación motriz de las extremidades superiores izquierda y derecha.

El algoritmo desarrollado conforma la segunda etapa dentro del esquema básico de un BCI (ver Fig. 1). Sus etapas son:

1. Adquisición de la actividad cerebral (señales de EEG).
2. Detección de una actividad cerebral específica asociada a una tarea mental.
3. Ejecución de una acción de control específica.
4. Proveer al usuario una realimentación en tiempo real.

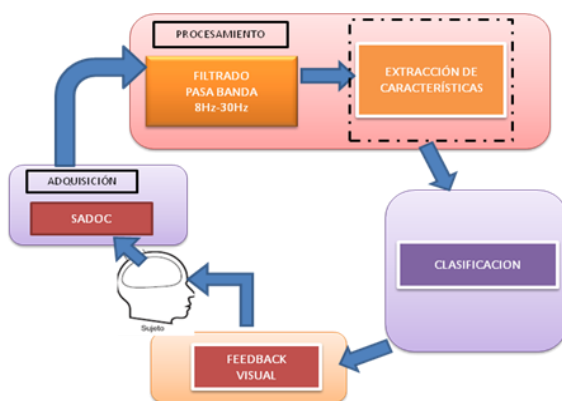


Fig. 1: Esquema básico de un BCI

La lectura de la actividad cerebral de forma efectiva es el primer paso para un sistema BCI, sin embargo con la simple lectura no alcanza ya que un BCI no “lee” la mente o descifra el pensamiento. Un sistema BCI solamente puede detectar y clasificar una señal o evento cerebral específico asociado a una tarea mental determinada.

Para que el usuario del BCI pueda ser capaz de producir estos eventos se requiere implementar una *estrategia mental* (a veces también denominada estrategia experimental o aproximación experimental). La misma es la base fundamental de cualquier sistema BCI.

Una de estas estrategias, entre otras, comúnmente usadas en los BCI es la Imaginación Motriz (*motor imagery*). Es un proceso consciente definido como una simulación mental de un movimiento específico [2]. Éste se basa en el cambio de la actividad de los Ritmos Sensor-Motrices (SMR). Dichos eventos están localizados en el área cortical del cerebro, que se ubica en la zona sensor motriz cercana a la fisura central de la corteza cerebral. Allí se pueden detectar mediante electrodos posicionados en C3, C4 y Cz según la norma 10-20 [3], visualizada en la Fig. 2.




Fig. 2: Sistema internacional de ubicación de electrodos 10-20. En línea punteada se remarca los electrodos C3, C4, Cz.

Los eventos relacionados a esta estrategia mental son las sincronizaciones y desincronizaciones (ERS/ERD) de los ritmos neuronales cuyas ondas son las μ (μ), siendo esta un sub-rango de la alfa, y beta [4] [5](ver Tabla 1). Estos eventos están asociados a una estrategia mental de imaginación motriz, por ejemplo el movimiento de las extremidades superiores que se manifiestan de manera contralateral en el cerebro.

Ritmo	Frecuencia [Hz]	Ocurrencia
Delta	0.5 a 4	Sueño profundo
Theta	4 a 7	Somnolencia
Alfa (μ)	8 a 12	Relajación, actividad sensor-motriz
Beta	12 a 30	Actividad consciente y motriz
Gamma	28 a 30	Determinadas actividades cognitivas

Tabla 1: Clasificación de las ondas cerebrales.

Las ERD son la desincronización de la actividad oscilatoria de aquellas ondas obtenidas en el área sensor motriz. Esta desincronización se manifiesta como un gradiente positivo para el movimiento de las extremidades superiores. Las ERS son la sincronización de dicha actividad y se manifiesta como un gradiente negativo [6](ver Fig. 3).

Los eventos a identificar son multidimensionales, es decir, dependen de la frecuencia, amplitud y ubicación de los electrodos. Estos eventos a diferencia de otros eventos biológicos no tienen un patrón explícito bien definido y varía en cada sujeto. Además, se encuentran mezclados con múltiples procesos biológicos, los cuales en su totalidad conforman la señal de EEG.

Las Redes Neuronales Artificiales (RNA) [7] [8] son aptas para la búsqueda de patrones ante las dificultades mencionadas después de un pre-procesamiento y cálculo de características adecuado de la señal de EEG.

En este trabajo se describe el desarrollo de un algoritmo que permita detectar y clasificar estos eventos con la mayor eficiencia posible.

Se utilizó una base de datos de señales de EEG publicada en la competencia internacional de BCI II [9] y se comparó con los resultados publicados en la misma.

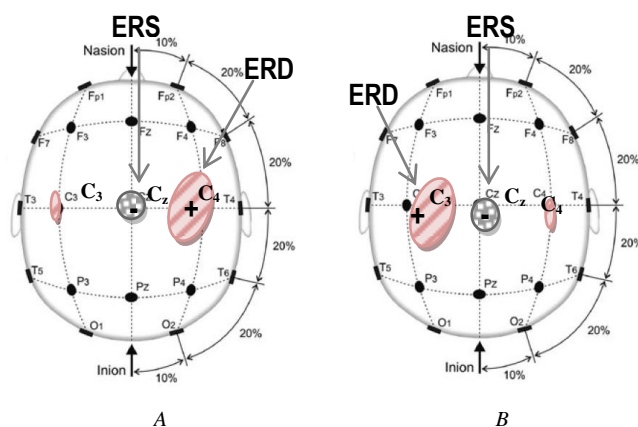


Figura 3: Mapa topográfico de la actividad ERS/ERD respecto al movimiento de la mano. El diagrama A se muestra la actividad de la mano izquierda, se manifiesta el ERD como un gradiente de potencial el electrodo C4. El diagrama B respecto a la actividad de la mano derecha.

II. MÉTODO

La estructura del algoritmo se compone de 2 partes. La primera parte es la búsqueda de las bandas μ (μ) y β (beta) propias del sujeto. Aquí se encuentra la información contenida respecto a la decisión del movimiento. La segunda realiza el entrenamiento de la RNA para discriminar si el movimiento pertenece a la extremidad superior izquierda o derecha. En la Fig. 4 se muestra el esquema de la estructura del método. Una vez entrenada la red el sistema se encuentra listo para trabajar en el reconocimiento.

Para este sistema se definieron 6 características a observar, cuatro características directas y dos características indirectas. Todas las características directas son señales de potencias, que según estudios [10] [11] [12] [13] son ideales para reconocimiento de patrones.

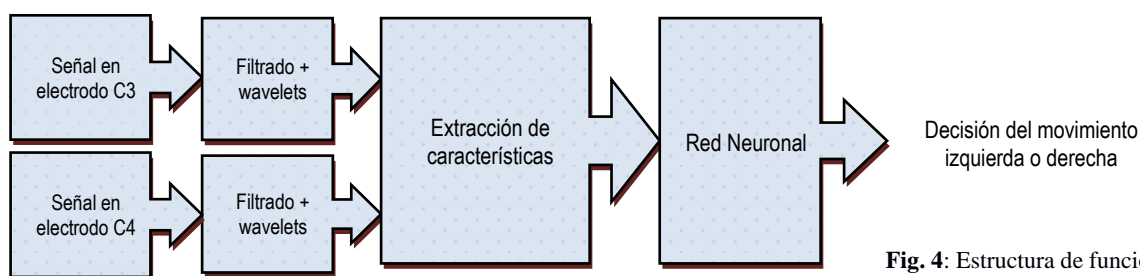


Fig. 4: Estructura de funcionamiento del algoritmo

A. FILTRADO

Cada sujeto tiene las bandas μ y β ubicadas en rangos de frecuencia que no coinciden exactamente con los rangos típicos [6]. La determinación de dichas sub-bandas permite aumentar el nivel de la relación señal ruido (SNR) y reducir el tamaño de la RNA.

Dicha reducción se realiza mediante un análisis de Fisher [14] sobre la CWT [15] (del inglés *continuous wavelet transform*) cuya función wavelet madre elegida es la Morlet [16]. Éste analiza los valores de los coeficientes de la CWT para cada grupo de movimientos (izquierdo o derecho) dentro del set de entrenamiento y devuelve un valor de mérito para cada una de ellas, que indica su poder de discriminación. Este análisis de Fisher se realiza tanto sobre el electrodo C3 como C4.

El valor de mérito hallado por cada coeficiente de la CWT se traduce en un rango de frecuencias. La suma de los rangos de frecuencias de mayor valor de mérito compone la sub-banda de cada electrodo.

En la Figura 5 se observa los resultados obtenidos para el set bajo estudio [9].

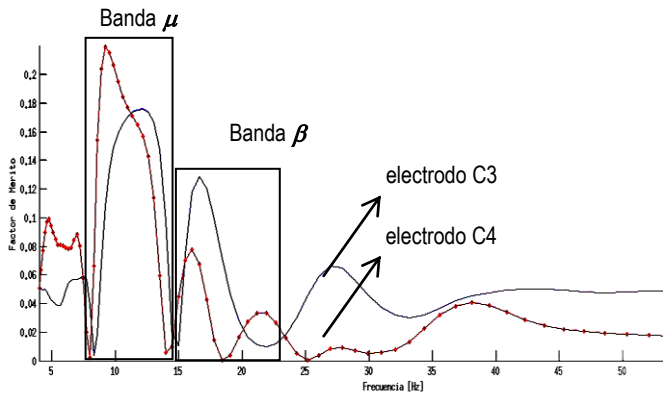


Figura 5: Factor de mérito de la señal de EEG en función de la frecuencia para los electrodos C₃ (línea llena) y C₄ (línea con puntos). Se recuadran las bandas μ y β del sujeto.

B. EXTRACCIÓN DE CARACTERÍSTICAS

Como se ha mencionado anteriormente las cuatro primeras características llamadas directas corresponden al producto del filtrado y transformación mediante wavelets de las bandas con mayor separabilidad del sujeto. Estas quedan definidas como:

- ⤴ Banda μ del electrodo C3 $\rightarrow \mu|_{C3}$
- ⤴ Banda β del electrodo C3 $\rightarrow \beta|_{C3}$
- ⤴ Banda μ del electrodo C4 $\rightarrow \mu|_{C4}$
- ⤴ Banda β del electrodo C4 $\rightarrow \beta|_{C4}$

Las dos características restantes, también llamadas indirectas se obtienen a partir de las primeras cuatro realizando el cociente entre electrodos homónimos, quedando definidas como:

$$\triangleright Rel \mu = \frac{Banda \mu|_{C3}}{Banda \mu|_{C4}} \quad (1)$$

$$\triangleright Rel \beta = \frac{Banda \beta|_{C3}}{Banda \beta|_{C4}} \quad (2)$$

Estas características tienen como principal propiedad ser independientes del nivel de potencia media sobre las bandas y son adimensionales e inmunes a perturbaciones externas que afecten a ambos hemisferios. Su comportamiento refleja la relación entre ERD / ERS del sujeto. Muestran un realce de su valor en los casos de movimiento de la extremidad izquierda y una caída en el caso de la extremidad derecha.

El total de estas características se interpreta como una señal que varía en el tiempo. Las primeras cuatro características representan el valor de potencia instantánea sobre cada banda elegida y las últimas dos son adimensionales.

A. RED NEURONAL ARTIFICIAL

Debido a la naturaleza descrita del evento a reconocer se propuso para el reconocimiento final del movimiento una red neuronal artificial (RNA). Dicha red es del tipo perceptrón multicapa y es entrenada por medio de un algoritmo *back-propagation* de segundo orden [17] [18] [19].

Para determinar la cantidad de neuronas internas dentro de la RNA, se optó por un método empírico eligiendo aquella que dio los mejores resultados. La misma se compone de una capa oculta con 45 neuronas y una capa de entrada con una cadena de retardos para cada característica. La RNA se alimenta con el valor de la muestra actual y N valores anteriores (ver Fig. 6) y habrá una neurona por cada uno de ellos.

El tiempo entre las muestras de cada característica es independiente del tiempo de muestreo de la señal EEG. Éste queda definido según el tiempo estimado de estabilización de un evento de ERD / ERS desencadenado por memoria motriz, que se encuentra alrededor de los 300mseg [20] [21]. Por este motivo se eligió un valor de 125mseg entre muestras.

La señal es entonces promediada en bloques de 125mseg y se obtiene una muestra por cada uno. De este modo se consigue N muestras por característica. El tamaño de la capa de entrada queda definida según:

$$Dim_{entrada} = N * Cantidad\ de\ carateristicas \quad (3)$$

La definición del largo de la red de retardos depende de la precisión, del retardo que se desea obtener a la salida del sistema BCI.

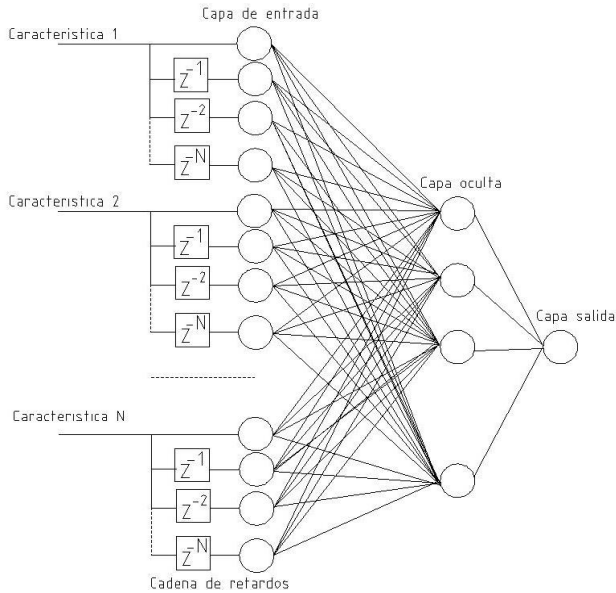


Figura 6: Topología de la Red Neuronal Artificial

III. RESULTADOS

El método desarrollado fue aplicado sobre el set de T.U Graetz BCI Competition II, estos sets constan de grabaciones de eventos motrices de la mano derecha e izquierda de un sujeto sano con *biofeedback*. Cada prueba (*trial*) consta de un tiempo base (*Baseline*) de 3 segundos y un tiempo de ejecución de 6 segundos.

Con el fin de optimizar el tiempo de respuesta del algoritmo, se estudió la sensibilidad del sistema respecto de la variación del *largo de cadena de retardo (LCR)*.

Todas las RNA obtenidas al variar el LCR fueron entrenadas en condiciones idénticas. Las redes obtenidas fueron analizadas mediante dos parámetros:

- La efectividad definida como, cantidad de elecciones correctas del sistema sobre el total de eventos del set de comprobación. Ver Fig. 7.
- La información mutua (MI *mutual information*) utilizada por la competición BCI II para informar los resultados según su método de cálculo. Ver Fig. 8.

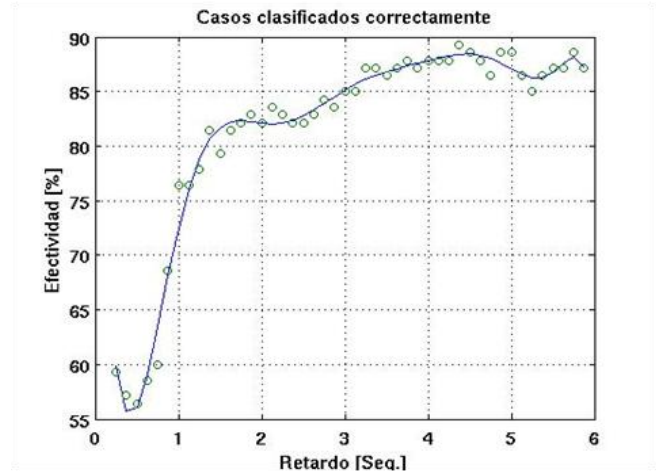


Figura 7: Efectividad del sistema en función del tiempo de respuesta del sistema, para distintos valores del LCR. Los puntos representan el resultado del entrenamiento de la red y en línea llena su interpolación polinómica.

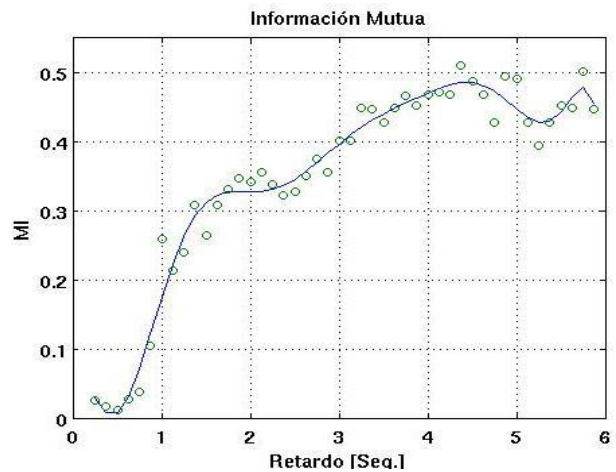


Figura 8: Gráfico de MI (*Mutual Información*) en función del tiempo de respuesta del sistema, para distintos valores del LCR. Los puntos representan el resultado del entrenamiento de la red y en línea llena su interpolación polinómica.

La MI expresa, mediante un valor numérico, la eficiencia que tiene el sistema para reconocer correctamente los eventos motrices considerando a su vez los eventos reconocidos de forma errónea. Lo descrito puede observarse a través de la definición [22].

Observar que en las figuras 7 y 8, el eje de abscisas corresponde al tiempo de respuesta del sistema. Este tiempo de respuesta se define como el tiempo entre que se realiza la acción o imaginación motriz y la toma de decisión.

$$LCR = Baseline + Tiempo\ de\ respuesta \quad (4)$$

A través del análisis de los gráficos, se eligieron 2 valores distintos de cadena de retardo, una con 9 seg. (ensayo GIAR-1) y la otra con 4,45 seg.

(ensayo GIAR-2). Éstos representan la mejor efectividad y la mejor relación de compromiso “tiempo de respuesta –efectividad” respectivamente.

El método obtuvo su mejor resultado con la configuración “GIAR 1”, obteniendo una *mutual information* (MI) de 0,56 y una efectividad del 90%.

Dicho resultado ubica al método en una 2da. posición en la competición BCI II realizado en el 2003 [23] como se puede ver en la Tabla 2 y 3. En esta tabla, el “Tiempo de Clasificación” se corresponde con el LCR y el “Error Mínimo” es el complemento de la efectividad. Cabe aclarar que no había ningún tipo de limitación en tiempo de detección para la competencia.

Puesto	Grupo	Error Mínimo [%]	MI Máximo [bit]	Tiempo de Clasificación [seg.]
1	C	10,71	0,61	7,59
2	GIAR-1	10	0,56	9
3	F	15,71	0,46	5,05
4	B	17,14	0,45	6,7
5	A	13,57	0,44	4,18
6	GIAR-2	17	0,35	4,45
7	G	17,14	0,29	4,66
8	I	23,57	0,26	6,34
9	E	17,14	0,21	6,13
10	D	32,14	0,09	5,66
11	H	49,29	0	9

Tabla 2: Tabla comparativa de los resultados obtenidos con el método propuesto y los resultados de la competencia BCI II del 2003 ordenados por MI.

Puesto	Grupo	Error Mínimo [%]	MI Máximo	Tiempo de Clasificación [Seg.]
1	A	13,57	0,44	4,18
2	GIAR-2	17	0,35	4,45
3	G	17,14	0,29	4,66
4	F	15,71	0,46	5,05

Tabla 3: Extracto de tabla comparativa MI. Reordenada en este caso en función del menor tiempo de clasificación tomando los cuatro mejores tiempos

IV. CONCLUSIONES

Observando la Fig. 7 se puede notar dos realces particulares en la efectividad. El primero y más importante sucede cuando el largo de la cadena de retardos es igual o mayor a 1seg mostrando una efectividad de 80% y un MI del 0,3. Este realce es esperado debido al tiempo de retardo entre la recepción de la orden por parte del individuo más el

tiempo de evocación de la imaginación motriz [20] [21]. Esto permite establecer un límite inferior para el método a la hora de elegir el tiempo de clasificación en función de la relación de compromiso retardo-efectividad para futuros trabajos.

Se detectó también un segundo realce a partir de un tiempo de clasificación de 3,5seg. A partir de aquí los resultados del método propuesto tienen una efectividad mayor al 85% y un MI mayor a 0,45.

De este último punto en adelante también se observó un incremento en la variación de los resultados del entrenamiento de la RNA, traduciéndose en efectividades disimiles para sucesivos entrenamientos. A partir de aquí el agregado de muestras de retardo no introduce información discriminante significativa al sistema y en consecuencia se reduce la SNR. Dicha reducción significaría posiblemente un límite en la capacidad del sujeto de mantener la concentración en la tarea asignada, afectando en consecuencia la capacidad del sistema de discriminar el movimiento a partir de las características propuestas.

V. AGRADECIMIENTOS

Agradecer por la colaboración al Ing. Juan Manuel Perdomo.

Agradecer a la Technische Universität Ilmenau y al Dr.-Ing. Sylvia Bräunig por su apoyo durante la realización de este trabajo.

REFERENCIAS

- [1] J. R. Wolpaw, N. Birbaumer, Gert Pfurtscheller, and T. M. Vaughan, *Brain-Computer Interfaces for communication and control.*: Clin Neurophysiol, 113, Jun., 2002, pp. 767-791.
- [2] Bernhard Graimann, Brendan Allison, and Gert Pfurtscheller, *Brain-Computer Interfaces Revolutionizing Human-Computer Interaction (The Frontiers Collection).*: Springer, 2011, pp. 11-13.
- [3] Robert Oostenveld and Peter Praamstra, "The five percent electrode system for high-resolution EEG and ERP measurement," Elsevier, *Clinical Neurophysiology* 112, 2001.
- [4] Bernhard Graimann, Brendan Allison, and Gert Pfurtscheller, *Brain-Computer Interfaces Revolutionizing Human-Computer Interaction (The Frontiers Collection).*: Springer, 2011, pp. 47-59.

- [5] Bernhard Graimann, Brendan Allison, and Gert Pfurtscheller, *Brain-Computer Interfaces Revolutionizing Human-Computer Interaction (The Frontiers Collection)*.: Springer, 2011, pp. 81-83.
- [6] G. Pfurtscheller and F. H. Lopes da Silva, *Event-Related Desynchronization, 1e (Handbook of Electroencephalography and Clinical Neurophysiol)*, Vol. 6. Amsterdam: Hardcover, Elsevier Scientific Publishing Company, 1999, pp. 254-258.
- [7] Fernando Tanco. (2003, Nov.) Grupo de Inteligencia Artificial y Robótica. [Online]. <http://www.secyt.frba.utn.edu.ar/gia/RNA.pdf>
- [8] Richard O. Duda, Peter E. Hart, and David G. Stork, *Pattern Classification*. Willey, 2007, pp. 282-295.
- [9] Gert Pfurtscheller, "Data set: BCI-experiment 2003," Department of Medical Informatics, Institut für Biomedizinische Engineering, University of Technology Graz., 2003.
- [10] Sijuan Huang and Xiaoming Wu, "Feature Extraction and Classification of EEG for Imagery Movement Based on Mu/Beta Rhythms," in *3rd. International Conference on Biomedical Engineering and Informatics (BMEI)*, 2010.
- [11] M. A. Hassan, A. F. Ali, and M. I. Eladawy, "Classification of the imagination of the left and right hand movements using eeg," *Proceedings of the 2008 IEEE, CIBEC*, 2008.
- [12] Yunfa Fu, Baolei Xu, Lili Pei, and Hongyi Li, "Phase-locked and Non-phase-locked Event-related Oscillations and Channel Power Spectra Analysis during Motor Imagery with Speed Parameters for BCRI," *IEEE, Wuhan, Bioinformatics and Biomedical Engineering (iCBBE) International Conference 2011*.
- [13] Rangaraj M. Rangayyan, "Biomedical signal analysis: a case-study approach," *IEEE Press*, 2002.
- [14] Sa Wang, Cheng-Lin Liu, and Lian Zheng, "Feature Selection by combining Fisher Criterion and Principal Feature Analysis.," *IEEE, Hong Kong, Proceedings of the sixth international conference on machine learning and cybernetics 2007*.
- [15] Christopher Torrence and Gilbert P. Compo. (1998, Jan.) A Practical Guide to Wavelet Analysis. [Online]. <http://paos.colorado.edu/research/wavelets/>
- [16] C. Torrence and G. P. Compo, "A Practical Guide to Wavelet Analysis," *Bulletin of the American Meteorological Society*, vol. 79, no. 1, 1998.
- [17] Richard O. Duda, Peter E. Hart, and David G. Stork, "Pattern Classification," in *Pattern Classification*. Willey, 2007, pp. 318-322.
- [18] Adrian J. Shepherd, "Second Order Methods for Neural Networks," *Springer*, 1997.
- [19] Sue Becker and Yann le Cun, "Improving the Convergence of Back-propagation Learning with Second Order Methods," Dpt. of computer science, University of Toronto, Toronto, Technical Report CRG-TR-88-5, 1988.
- [20] John Polich, "Updating P300: An integrative theory of P3a and P3b," *Clinical Neurophysiology 118*, Elsevier, 2007.
- [21] Torsten Felzer, "On the Possibility of Developing a Brain-Computer Interface (BCI).," *Technical University of Darmstadt, Department of Computer Science, Darmstadt, Technical Report 2001*.
- [22] Alois Schlögl, J. Kronegg, J. E. Huggins, and S. G. Mason, "Evaluation Criteria for BCI Research," in *Evaluation Criteria for BCI Research*, G. Drnhege et al., Eds.: MIT Press, 2007, ch. Towards Brains-Computer Interfacing, pp. 327-342.
- [23] Alois Schlögl, "Outcome of the BCI competition 2003 on the Graz data set," 2003.