

Selección de parámetros en el enfoque de bolsa de características para clasificación de habla imaginada en electroencefalogramas

Jesús S. García-Salinas, Luis Villaseñor-Pineda, Carlos A. Reyes-García,
Alejandro A. Torres-García

Instituto Nacional de Astrofísica Óptica y Electrónica,
Laboratorio de Bioseñales y Cómputo Médico, México

{jss.garcia,villasen,kargaxxi,alejandro.torres}@inaoep.mx

Resumen. El uso de las interfaces cerebro-computadora como un nuevo canal de comunicación ha despertado un gran interés, no obstante aún hay muchos retos por resolver para alcanzar una comunicación natural. En el caso particular de las BCIs basadas en habla imaginada aún se presentan dificultades para analizar las señales cerebrales. En este trabajo se explora una representación de bolsa de características para identificar patrones en la señal cerebral adquirida a través de electroencefalogramas. Esta técnica ha demostrado ser útil en tareas relacionadas. Sin embargo, determinar la bolsa de características más adecuada al problema depende de diversos parámetros. El presente trabajo describe el uso de algoritmos genéticos para encontrar la configuración más adecuada para la clasificación de habla imaginada. Los resultados, calculados en una base de datos de habla imaginada de 27 sujetos, muestran la pertinencia del método alcanzando resultados comparables con el estado del arte.

Palabras clave: interfaces cerebro-computadora, electroencefalogramas (EEG), habla imaginada, bolsa de características, algoritmos genéticos.

Parameter Selection in Bag of Features to Classify Imagined Speech on Electroencephalograms

Abstract. The use of brain-computer interfaces as a new communication channel has become an interest topic, nevertheless, there are many challenges to achieve a natural communication. In the particular case of imagined speech BCIs, there are difficulties to analyze the brain signals. In this work, a bag of features representation to identify patterns in electroencephalograms is explored. This method has shown to be useful in similar tasks. Nevertheless, to determine the most adequate bag of features to the problem depends on many parameters. The present work describes the use of genetic algorithms to find an adequate configuration to imagined speech classification. The results, obtained from an imagined speech database of 27 subjects, show the relevance of the method achieving results which are comparable with related work.

Keywords: brain-computer interfaces, electroencephalograms, imagined speech, bag of features, genetic algorithms.

1. Introducción

Cada vez existe un mayor interés en las interfaces cerebro computadora (BCI). Inicialmente se despertó este interés al brindar un nuevo canal de comunicación a personas con discapacidad. No obstante, debido a la reducción de costos de los dispositivos para lectura de la señal cerebral, esta nueva forma de comunicación puede ser utilizada por cualquier persona.

Para controlar un dispositivo a través de una BCI, el usuario debe producir un patrón de actividad cerebral, ya sea evocado internamente o por un estímulo externo, el cual será identificado por el sistema y transformado en comandos para dicho dispositivo. La lectura de la actividad cerebral puede realizarse con diferentes instrumentos, en particular en este trabajo se utiliza el electroencefalograma (EEG) para registrar la señal electrofisiológica. Además, este trabajo se orienta a analizar la señal cerebral evocada por el habla imaginada, es decir, cuando el sujeto imagina la dicción de la palabra sin emitir ni articular sonidos.

A pesar de contar con diferentes métodos computacionales para el procesamiento, caracterización y clasificación de las señales cerebrales en EEG [10] el análisis de las señales cerebrales resultado del habla imaginada, presentan propiedades que complican su análisis [8]. Distintas soluciones se han propuesto para realizar esta tarea, sin embargo, aún existen retos importantes para lograr una comunicación natural y fluida mediante una BCI basada en habla imaginada.

El presente trabajo muestra la generación de una representación del habla imaginada a partir del método de bolsa de características. Las bolsas de características tienen como objetivo lograr una caracterización automática al obtener, en primera instancia, *unidades características* de la señal, y posteriormente generar un patrón representativo a partir de ellas. De esta forma, el método encuentra un conjunto de unidades características representativo de cada clase (i.e. cada palabra imaginada), y estos conjuntos son usados para el reconocimiento y clasificación del vocabulario imaginado por el sujeto. El descubrimiento de las unidades características se realiza a partir de la señal utilizando algún método de *clustering*. Los prototipos calculados se consideran las unidades características, comúnmente llamadas *codewords*. Cada *codeword* es una entrada del diccionario general, llamado *codebook*.

Para la generación de las *codewords* es necesario tener en cuenta el método de extracción de características de la señal cerebral, además de definir *a priori* el tamaño del *codebook*. El objetivo de los experimentos mostrados en este trabajo consiste en encontrar la configuración más apropiada entre las combinaciones posibles de estos parámetros. Para ello, se utilizó un algoritmo genético evaluado sobre una base de datos de habla imaginada (5 palabras) de 27 sujetos. En un intento por generalizar los parámetros, el método es aplicado a todos los sujetos utilizando los mismos parámetros, y la evaluación se realizó obteniendo la exactitud promedio de entre todos ellos. Los resultados obtenidos, a pesar de

ser preliminares, muestran la factibilidad del método, al discriminar segmentos representativos de la señal para las distintas palabras en habla imaginada.

2. Trabajo relacionado

2.1. Primeros enfoques

La comunicación a través de señales cerebrales comenzó con la detección de potenciales eléctricos indirectamente relacionados al proceso cognitivo del habla. Uno de los primeros trabajos reportados, presentado en [3], hace uso de la activación o bloqueo de los ritmos alfa, un rango de frecuencias de la señal cerebral, para generar código Morse. Esto requiere entrenamiento previo que consiste en manipular la configuración oculomotora para lograr el control de los ritmos alfa.

En [4] se utilizan señales P300 para detectar respuestas visuales sobre caracteres mediante un alfabeto en una pantalla, este sistema detecta la respuesta del cerebro a un estímulo visual que se mueve a través de esta pantalla, la respuesta cerebral permite determinar el carácter que el sujeto desea comunicar.

2.2. Habla imaginada

Métodos anteriormente usados en BCIs involucran que el usuario aprenda a generar señales cerebrales específicas, o aprovechan la respuesta cerebral natural a cierto estímulo externo. Una BCI basada en habla imaginada, trabaja con la señal evocada por el proceso cognitivo del habla, con la gran ventaja que el sujeto no tiene que aprender a generar señales cerebrales específicas.

A continuación se presentan diversos trabajos relacionados al habla imaginada. Cabe hacer notar que cada uno de ellos difieren no sólo en el método usado, sino también en la evaluación, donde se experimentó con diferentes conjuntos de sujetos y distintos vocabularios de palabras imaginadas.

La clasificación de palabras imaginadas fue presentada inicialmente en [14], donde se analizan las señales EEG y EMG para clasificar siete palabras (*first, second, third, yes, no, right, left*). La caracterización se basó en la Transformada Rápida de Fourier (FFT) y filtros pasa banda, para después aplicar la Transformada Inversa de Fourier (IFFT). La clasificación se realizó mediante mínimos cuadrados para comparar la señal con un prototipo creado a partir de la media de las muestras, obteniendo una exactitud promedio de 52.57 ± 20 para cinco sujetos.

En [2] se propone la clasificación de dos vocales imaginadas a través de patrones espaciales comunes (CSP), Support Vector Machines (SVM) y filtros pasa banda, logrando una exactitud promedio de 62.6 ± 8.3 para tres sujetos.

En [16] se utilizó un vocabulario en español de cinco palabras (*arriba, abajo, izquierda, derecha, seleccionar*), se utilizaron canales de EEG cercanos al área de lenguaje y se aplicó un filtro pasa banda entre 4 y 25 Hz. La caracterización se realizó mediante la Transformada Wavelet Discreta (DWT) y se entrenaron

cuatro clasificadores: Naive Bayes, Random Forest, Support Vector Machines y Bagging Random Forest, y se obtuvo una exactitud de 41.96 ± 3 para tres sujetos.

Un esquema más simple, mostrado en [13], clasifica entre dos palabras en árabe (*Si*, *No*). Se analizaron los ritmos alfa y beta de un EEG de un solo canal mediante dos métodos, el primero obtiene datos estadísticos de la señal (mínimo, máximo y media) y el segundo aplica la DWT con seis niveles de descomposición. La clasificación se llevo a cabo mediante SVM, Linear Discriminant Analysis (LDA), Self-Organized Maps (SOM), Multilayer Perceptron y ensambles de ellos, la exactitud promedio obtenida fue de 56 para un conjunto de siete sujetos.

Recientemente, en [17] se exploraron diversas familias wavelet y clasificadores para clasificación multiclase de cinco palabras (*arriba*, *abajo*, *izquierda*, *derecha*, *seleccionar*). Se implementó una selección de canales automática basada en inferencia difusa para reducir el conjunto de datos y obtuvo una exactitud de 68.18 ± 16 .

2.3. Bolsa de características

Este método está basado en el enfoque tradicional de *cuantificación vectorial* (Vector Quantization) cuyo objetivo es lograr una caracterización automática de la señal, discretizando su representación. En el área de análisis de señales se han presentado diferentes variantes y adaptaciones; y recibe diferentes nombres de acuerdo a su área de aplicación como, por ejemplo, bolsa de patrones, bolsa de imágenes o bolsa de segmentos.

En breve, la señal es segmentada y las unidades representativas son generadas mediante una técnica de *clustering*, los prototipos de cada clúster reciben el nombre de *codewords* y en conjunto forman el *codebook*. Una vez generado el *codebook*, se toma la señal segmentada y por cada segmento se identifica aquella *codeword* más similar. Una vez codificada la señal se calcula un histograma de las *codewords* presentes en la señal (véase la siguiente sección para su descripción formal).

En el caso específico de señales de EEG, la bolsa de características fue usada por [18], con el uso de señales de EEG (y EKG) para detección de epilepsia. Las señales fueron obtenidas mediante un EEG de un solo canal y se extrajeron características mediante la DWT, posteriormente fueron agrupadas mediante *k-means*. Los histogramas se crearon mediante *1-Nearest Neighbor* y finalmente se clasificó con un clasificador *1-Nearest Neighbor*, la exactitud obtenida fue de 87.8 ± 2.3 .

En [12], se presenta una modificación al método de *clustering*, al que llaman *Bag of Super-Features* o Bolsa de Super-Características. El método consiste en generar clústers para cada una de las clases y posteriormente unirlos. Realizar esta división y calcular de esta forma el codebook reduce la pérdida de información de las clases [9].

3. Método

3.1. Bolsa de características

Una serie de tiempo está definida por $x^i = (x_1^i, x_2^i, \dots, x_p^i)$, para p muestras. Cada instancia x^i esta asociada con una clase y^i para $i = 1, 2, \dots, n$ y $y^i \in \{1, 2, \dots, C\}$ donde n es el número de instancias y C es el número de clases. Para extraer patrones locales, es necesario deslizar una ventana w sobre las series de tiempo, el deslizamiento m no puede ser mayor al tamaño de la ventana $m \leq w$. Las subsecuencias extraídas serán $\lceil \frac{p-w+1}{m} \rceil$, por lo tanto, el conjunto de datos tendrá $n(\lceil \frac{p-w+1}{m} \rceil)$ subsecuencias. A continuación se aplica un algoritmo de *clustering* con k centroides, que serán los *codewords* de nuestro *codebook* $K \in \mathbb{R}^{(w \times d)}$ [7].

El método propuesto está basado en el trabajo presentado en [18] al que le fueron realizadas adaptaciones, el esquema general se muestra en la fig. 1, y se aplica individualmente a cada uno de los sujetos en la base de datos, y finalmente los resultados son promediados en un intento por observar de forma general los resultados alcanzados por el modelo para todos los sujetos.

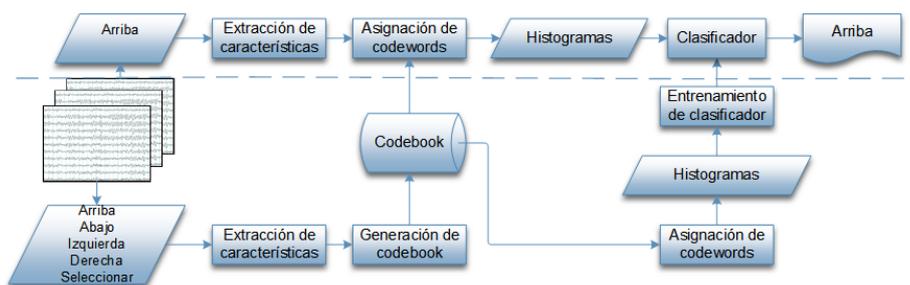


Fig. 1. Diagrama del método.

El resultado es la exactitud total de clasificación de las palabras imaginadas en el conjunto de datos. En nuestro caso, es la exactitud la que se toma como función objetivo en el algoritmo genético, y con ello determinar los valores más adecuados para el conjunto de parámetros en cada una de sus etapas.

Datos. El conjunto de datos fue obtenido en [6], se registraron los EEG de 27 sujetos hablantes nativos de español a través de un kit EPOC de la compañía Emotiv que cuenta con 14 canales (AF3, AF4, F3, F4, F7, F8, FC5, FC6, P7, P8, T7, T8, O1, O2) y una frecuencia de muestreo de 128 Hz. Los datos consisten en 5 palabras imaginadas ("arriba", "abajo", "izquierda", "derecha" y "seleccionar") repetidas 33 veces cada una, con un tiempo de descanso entre cada repetición.

Los datos fueron procesados mediante la Referencia Promedio Común (CAR), por sus siglas en inglés, para reducir el ruido obtenido en la toma de muestras.

El CAR es una técnica computacionalmente simple y ha demostrado superar algunas técnicas de referenciado eléctrico [11]. También se aplicó un filtro pasa bajas Butterworth con corte en 50 Hz, para eliminar algunos artefactos.

Ya que cada conjunto de datos está conformado de 14 canales, se procesó cada señal de forma independiente, es decir, el procesamiento fue realizado a cada una de ellas por separado. Cabe señalar que para el proceso de creación del clasificador se tomaron, para cada sujeto, 25 repeticiones aleatoriamente para entrenamiento y generación del *codebook*, y las 8 restantes fueron utilizadas para pruebas de clasificación.

Extracción de características. La extracción de características de la señal se llevó a cabo mediante una ventana en movimiento, con un tamaño W y un desplazamiento M que podía tener sobreposición pero no saltos, es decir, $M \leq W$ donde $M > 0, W \geq 8$, además se tiene un límite superior de 128, que es la frecuencia de muestreo de la señal.

En este caso se utilizaron únicamente los coeficientes obtenidos por la transformada rápida de Fourier [5] y la energía relativa de la transformada Wavelet, $C = FFT, DWT$. La transformada Wavelet es la integral de una señal multiplicada por versiones escaladas y desplazadas de una función wavelet. Una vez obtenidos los coeficientes de la DWT, se obtiene la energía relativa mediante el método mostrado en [15].

Clustering. El algoritmo de *clustering* utilizado fue k-means++ [1], a partir de cada una de las señales se obtuvieron K prototipos o *codewords* que forman el *codebook*.

Cabe señalar que para conformar el *codebook* se aplicó el *clustering* por separado a cada una de las clases (i. e. las palabras a reconocer), el número de clústers se divide entre el número de clases para tener una distribución equitativa de los clústers, una vez generados los prototipos de cada una de las clases son concatenados para formar el *codebook*.

Generación de histogramas. Una vez generado el *codebook*, el siguiente paso es codificar los segmentos de las señales, esto es, decidir a cual de los elementos del *codebook* son más parecidos. Esta asignación se realiza utilizando una búsqueda del vecino mas cercano (1-NN) tomando como medida la distancia Euclidiana.

Una vez asignados los *codewords*, se genera un histograma por cada señal. Los histogramas fueron etiquetados según la palabra imaginada a la que corresponden, y esta información fue utilizada para crear el clasificador. En nuestro caso se utilizó el método de *Naive Bayes Multinomial*.

3.2. Algoritmo genético

Dada la combinatoria entre los parámetros para calcular la bolsa de características, se aplicó un algoritmo genético para determinar la configuración más

adecuada. Los parámetros a definir en la generación de la bolsa de características son entonces: el tipo de extracción de características ($C = \text{FFT}, \text{DWT}$), el tamaño de ventana para la extracción de características ($8 \leq W \leq 128$), el desplazamiento de la ventana ($8 \leq M \leq 128$), y el número de clústers ($K \leq 1000$); dando un total de 4 parámetros.

C = FFT	K = 100	W = 128	M = 32
Tipo de caracterización	Tamaño de <i>codebook</i>	Tamaño de ventana	Movimiento de la ventana

Fig. 2. Ejemplo de un individuo del algoritmo genético.

La función objetivo del algoritmo se orientó a reducir el error de clasificación promedio de todos los sujetos.

El tamaño de población y las generaciones se fijaron en 100, la fracción de cruce de individuos es de 80 % y se lleva a cabo tomando una mezcla de promedios pesados de los padres. El proceso de selección se lleva a cabo mediante una función estocástica uniforme que se mueve a través del conjunto de individuos con un número de pasos fijo. Además, se considera un elitismo de 2 %, es decir, 2 individuos pasan sin alteraciones a la siguiente generación. Las probabilidades de mutación de un sujeto en cada generación es de 1 %. Este sujeto será alterado aleatoriamente para diversificar los parámetros obtenidos.

No se definieron límites de tiempo o de aptitud que detuvieran la ejecución del algoritmo, es decir, el algoritmo podrá continuar hasta completar las generaciones ignorando el tiempo y la exactitud obtenida en cada generación. El único criterio de paro es no encontrar un cambio en el promedio de aptitud después de 20 generaciones, en este caso el algoritmo habrá llegado a un estancamiento y detendrá su ejecución, tomando el mejor sujeto hasta ese instante.

4. Experimentos y resultados

Los resultados de clasificación se obtuvieron separando aleatoriamente el 75 % de las instancias para entrenamiento y 25 % para pruebas. Se clasificaron cinco clases que corresponden a cada una de las palabras imaginadas mediante un clasificador *Naive Bayes Multinomial*.

El algoritmo genético obtuvo como parámetros óptimos: una caracterización C mediante FFT, un tamaño de *codebook* K de 75, una ventana W de tamaño 40 con un desplazamiento M de 8. Tomando en cuenta estos parámetros se obtuvieron los resultados de clasificación mostrados en la figura 4.

Como es de esperar, el algoritmo genético minimiza la aptitud del método en cada generación, en este caso se reduce el error de clasificación. En la figura 3 se puede observar la aptitud obtenida en cada generación del algoritmo genético,

se llegó a un estancamiento de la aptitud en la generación número setenta y uno, es decir, la variación de la exactitud obtenida en cada generación fue menor a 1×10^{-6} .

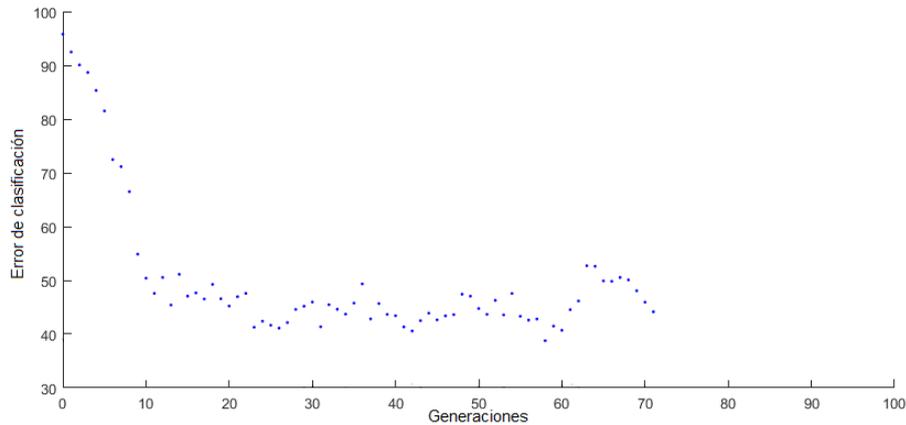


Fig. 3. Comportamiento del algoritmo genético.

El experimento con los parámetros obtenidos fue repetido diez veces, la exactitud promedio alcanzada se muestra en la figura 4. La exactitud se obtiene del total obtenido por las cinco clases. La desviación del promedio representa la desviación de las exactitudes de los veintisiete sujetos.

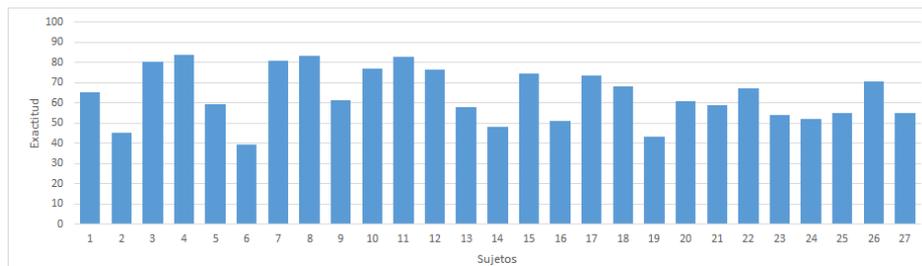


Fig. 4. Exactitud promedio para 10 iteraciones del método al aplicarlo a cada uno de los 27 sujetos de nuestra base de datos.

Para tener una idea de como se comporta la clasificación a nivel de palabras, se presenta una matriz de confusión promedio en la tabla 2. La matriz se calculó al promediar y normalizar con los resultados obtenidos de todos los sujetos considerando las 10 iteraciones del método.

Tabla 1. Resultados promedio de exactitud para 10 iteraciones por sujetos con su desviación estándar, comparado con los resultados alcanzados en [17].

Sujeto	Método propuesto	Torres et al. 2016
1	65.3 ± 5.5	88.38
2	45.3 ± 5.5	50.77
3	80.3 ± 4.5	69.74
4	83.8 ± 7.6	77.46
5	59.3 ± 6.5	73.34
6	39.5 ± 6.3	40
7	80.8 ± 7.7	70.62
8	83.5 ± 6.8	89.7
9	61.5 ± 3.8	81.21
10	77.0 ± 6.2	70.92
11	83.0 ± 6.9	90.33
12	76.5 ± 5.6	75.11
13	58.0 ± 6.9	66.65
14	48.3 ± 8.1	48.01
15	74.5 ± 9.3	85.44
16	51.3 ± 6.0	63.53
17	73.8 ± 7.8	67.87
18	68.3 ± 4.7	81.8
19	43.5 ± 5.2	46.76
20	61.0 ± 6.6	83.09
21	59.0 ± 6.7	48.42
22	67.0 ± 2.8	70.33
23	54.3 ± 4.6	63.2
24	52.0 ± 9.1	57.46
25	55.0 ± 6.2	29.78
26	70.5 ± 7.2	67.24
27	55.0 ± 7.0	83.64
Prom.	64.0 ± 13.24	68.18 ± 15.9

Tabla 2. Matriz de confusión promedio considerando todos los sujetos.

Arriba	Abajo	Izquierda	Derecha	Seleccionar	
0.73	0.12	0.05	0.06	0.06	Arriba
0.11	0.62	0.08	0.14	0.06	Abajo
0.04	0.08	0.60	0.14	0.15	Izquierda
0.06	0.16	0.14	0.58	0.08	Derecha
0.05	0.08	0.15	0.06	0.67	Seleccionar

Como puede observarse la palabra con menor confusión es *arriba* y la de mayor confusión es *derecha*. Cabe notar que esta última palabra se confunde principalmente con las palabras *abajo* e *izquierda*.

5. Conclusiones

Los parámetros obtenidos con el algoritmo genético lograron una configuración que permitió crear representaciones basadas en bolsa de características cuya clasificación fue comparable con lo reportado en el estado del arte. La exactitud promedio alcanzada fue de 64 ± 13.24 para 5 palabras imaginadas por 27 sujetos.

Como se muestra en la figura 3, el algoritmo logró converger a una solución óptima en menos generaciones de las esperadas, esto abre la posibilidad de aumentar el número de parámetros. Entre los parámetros a añadir pueden considerarse los parámetros propios de las técnicas de extracción de características. Por ejemplo, la familia Wavelet o el número de niveles de descomposición. Por otro lado, aún falta observar el resultado al aplicar el método de forma individual, es decir, ajustar los parámetros a cada sujeto. Esto podría mejorar los resultados individuales de clasificación pero incidir sobre las conclusiones generales sobre los parámetros del método.

Como trabajo futuro, se desea explorar con distintos métodos en algunas de las etapas en el cálculo del *codebook*. Por ejemplo, utilizar un método de *clustering*, como *Expectation Maximisation*, esto permitiría eliminar el parámetro de tamaño de clúster del algoritmo genético. Así como la modificación en la generación de histogramas, donde es posible considerar secuencias de *codewords*, incluyendo de esta forma información temporal de la señal.

Agradecimientos. Los autores agradecen al Consejo Nacional de Ciencia y Tecnología (CONACyT) por el apoyo a esta investigación a través de la beca # 702603 y del proyecto 2016-01-2228. Asimismo, agradecen al apoyo del Ministerio de Asuntos Exteriores y de Cooperación Internacional de Italia y la Agencia Mexicana de Cooperación Internacional para el Desarrollo (AMEXCID) bajo el proyecto MX14MO06 INAOE-Universidad de Florencia.

Referencias

1. Arthur, D., Vassilvitskii, S.: K-means++: The advantages of careful seeding. In: Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms. pp. 1027–1035. SODA '07, Society for Industrial and Applied Mathematics, Philadelphia, PA, USA (2007), <http://dl.acm.org/citation.cfm?id=1283383.1283494>
2. DaSalla, C.S., Kambara, H., Sato, M., Koike, Y.: Single-trial classification of vowel speech imagery using common spatial patterns. *Neural Networks* 22(9), 1334 – 1339 (2009), <http://www.sciencedirect.com/science/article/pii/S0893608009000999>, brain-Machine Interface

3. Dewan, E.M.: Occipital alpha rhythm eye position and lens accommodation. *Nature* 214, 975–977 (1967)
4. Farwell, L., Donchin, E.: Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology* 70(6), 510 – 523 (1988), <http://www.sciencedirect.com/science/article/pii/0013469488901496>
5. Frigo, M., Johnson, S.G.: The design and implementation of fftw3. *Proceedings of the IEEE* 93(2), 216–231 (2005), <http://ieeexplore.ieee.org/abstract/document/1386650/>
6. González Castañeda, E., Torres-García, A., Reyes-García, C., Villaseñor-Pineda, L.: Applying Brain Signals Sonification for Automatic Classification. *Revista Mexicana de Ingeniería Biomédica* 36(3), 233–248 (Sep 2015)
7. Gui, Z.W., Yeh, Y.R.: Time Series Classification with Temporal Bag-of-Words Model, pp. 145–153. Springer International Publishing, Cham (2014)
8. Klonowski, W.: Everything you wanted to ask about eeg but were afraid to get the right answer. *Nonlinear Biomedical Physics* 3(1), 1 – 5 (2009), <http://dx.doi.org/10.1186/1753-4631-3-2>
9. Lazebnik, S., Raginsky, M.: Supervised learning of quantizer codebooks by information loss minimization. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 31(7), 1294–1309 (July 2009)
10. Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F., Arnaldi, B.: A review of classification algorithms for eeg-based brain-computer interfaces. *Journal of Neural Engineering* 4(2), R1 (2007), <http://stacks.iop.org/1741-2552/4/i=2/a=R01>
11. Ludwig, K.A., Miriani, R.M., Langhals, N.B., Joseph, M.D., Anderson, D.J., Kipke, D.R.: Using a common average reference to improve cortical neuron recordings from microelectrode arrays. *Journal of Neurophysiology* 101(3), 1679–1689 (2009), <http://jn.physiology.org/content/101/3/1679>
12. Plinge, A., Grzeszick, R., Fink, G.A.: A bag-of-features approach to acoustic event detection. In: 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). pp. 3704–3708 (May 2014)
13. Salama, M., Lashin, H., Gamal, T.: Recognition of unspoken words using electrode electroencephalographic signals. *COGNITIVE 2014 : The Sixth International Conference on Advanced Cognitive Technologies and Applications* pp. 51–55 (2014)
14. Suppes, P., Lin, L.Z., Bing, H.: Brain wave recognition of words. *Proceedings of the National Academy of Sciences* 94(26), 14965 – 14969 (1997), <http://www.pnas.org/content/94/26/14965.abstract>
15. Torres-García, A., Reyes-García, C., Villaseñor-Pineda, L., Ramírez, J.: Análisis de señales electroencefalográficas para la clasificación de habla imaginada. *Revista mexicana de ingeniería biomédica* 34(1), 23–39 (2013)
16. Torres-García, A.A., Reyes-García, C.A., Villaseñor-Pineda, L.: Toward a silent speech interface based on unspoken speech. *Proceedings of biosignals* pp. 370 – 373 (2012)
17. Torres-García, A.A., Reyes-García, C.A., Villaseñor-Pineda, L., García-Aguilar, G.: Implementing a fuzzy inference system in a multi-objective {EEG} channel selection model for imagined speech classification. *Expert Systems with Applications* 59, 1 – 12 (2016), <http://www.sciencedirect.com/science/article/pii/S0957417416301774>
18. Wang, J., Liu, P., She, M.F., Nahavandi, S., Kouzani, A.: Bag-of-words representation for biomedical time series classification. *Biomedical Signal Processing and Control* 8(6), 634 – 644 (2013), <http://www.sciencedirect.com/science/article/pii/S174680941300089X>