



Universidad
Zaragoza

Trabajo Fin de Máster

Extracción y selección de características para un sistema de brain computer interface (BCI) mediante algoritmos genéticos (AG)

Autor/es

Diego Ignacio Mallea Lobera

Director/es

Javier Mínguez Zafra
Javier Civera Sancho

Master en Ingeniería Biomédica

Departamento de Informática e Ingeniería de Sistemas
Escuela de Ingeniería y Arquitectura
Universidad de Zaragoza

Septiembre de 2012

Resumen

Los sistemas Brain Computer Interface (BCI) son una tecnología basada en la adquisición y procesamiento de señales cerebrales para el control de diversos dispositivos. Estos sistemas establecen el camino para interactuar con el exterior mediante nuestro pensamiento, transformándolo en acciones reales en nuestro entorno.

Usualmente estos sistemas se enfocan en reconocer eventos que tienen su reflejo en el electroencefalograma (EEG). Dichos eventos representan distintos estados mentales, que deberán identificarse como distintas clases mediante un sistema de clasificación.

En un sistema BCI, tras la adquisición de las señales cerebrales se realiza un procesado, o extracción de características, cuya clasificación determina la clase a la que pertenece dicha señal.

Para la clasificación de las señales EEG se pueden utilizar infinidad de características, con un coste de procesamiento y fiabilidad dispares. Por ello, la selección de las más discriminativas es imprescindible a la hora de diseñar BCIs funcionales.

En el presente proyecto se implementarán y ampliarán los métodos empleados en trabajos previos, con el fin de ampliar los resultados de clasificación obtenidos hasta la fecha.

Para ello se implementará un sistema, basado en algoritmos genéticos (AG), que permitirá realizar la selección de las características óptimas para la clasificación de señales EEG correspondientes a dos estados mentales distintos.

Este sistema se validará con un problema de clasificación de dos clases, formadas por los estados mentales de los eventos de reposo y movimiento de la mano derecha.

Como parte práctica del proyecto se colaborará en sesiones de experimentación para la adquisición de señales EEG en pacientes de lesión medular, en colaboración con el Hospital Miguel Servet de Zaragoza.

Índice General

1	Introducción.....	1
1.1	Marco de trabajo.....	1
1.2	Motivación.....	2
1.3	Estado del arte.....	2
1.4	Objetivos	2
1.5	Estructura de los contenidos.....	3
2	Metodología.....	5
2.1	Electroencefalograma (EEG).....	5
2.2	Protocolo de captura de la señal del EEG	6
2.3	Eliminación de artefactos.....	7
2.4	Extracción de características.....	7
2.4.1	Preparación de los datos.....	7
2.4.2	Extracción	8
2.5	Selección de características.....	10
2.5.1	Algoritmo Genético (AG).....	10
2.5.2	Objetivos de la selección de características.....	13
2.6	Pruebas de clasificación.....	15
2.6.1	Pruebas de clasificación global	15
2.6.2	Clasificación por sesión.....	16
2.6.3	Clasificación respetando el orden de captura de los datos.....	16
3	Análisis de resultados.....	19
3.1	Pruebas utilizando F_{ALL}	19
3.2	Pruebas utilizando F_i	22
3.3	Pruebas utilizando $F_{1,..,i}$	25
4	Conclusiones	29
5	Trabajos citados.....	31
A.	Anexo de planificación	33
B.	Anexo de funcionamiento básico de un sistema BCI	35
B.1.	¿Qué es un sistema BCI?.....	35
B.2.	Esquema general.....	35
C.	Anexo de características usadas en sistemas BCI.....	37
C.1.	Cálculo de la densidad espectral de potencia (PSD)	37
C.2.	Los momentos espectrales de primer y segundo orden.....	37

C.3.	Potencia en una banda	37
D.	Anexo de algoritmos genéticos.....	39
D.1.	¿Qué es un algoritmo genético?	39
D.2.	¿Cómo saber si es posible usar el algoritmo genético?	39
D.3.	La función de aptitud	39
D.4.	Algoritmo	40
D.5.	Métodos de selección	40
D.5.1.	La Ruleta.....	40
D.5.2.	El torneo	41
D.6.	Recombinación sexual.....	41
D.7.	Mutación.....	42
D.8.	Configuración.....	42
D.9.	Detención.....	42
D.10.	¿Comparación con otras técnicas de búsqueda?.....	43
E.	Anexo de reconocimiento de patrones en sistemas BCI	45
E.1.	Generalidades	45
E.2.	Aprendizaje supervisado.....	46
E.3.	Función discriminante.....	46
E.4.	Validación cruzada (cross-validation).....	47
F.	Anexo de prácticas.....	49
F.1.	Motivación.....	49
F.2.	Objetivos	49

Índice de Ilustraciones

Ilustración 1 - Sistema de captura de EEG.....	1
Ilustración 2 - Estructura de los contenidos.....	3
Ilustración 3 - Relación entre la localización de los electrodos y los canales.....	5
Ilustración 4 - Visualización de la señal de un canal del electroencefalograma.....	5
Ilustración 5 - Estados del protocolo de captura.....	6
Ilustración 6 - Protocolo de captura del EEG de un sujeto.....	6
Ilustración 7 - Datos de experimentación.....	6
Ilustración 8 - Datos de partida para la extracción de características.....	7
Ilustración 9 - Selección de los canales objeto del estudio.....	7
Ilustración 10 Distribución de bandas de frecuencia.....	8
Ilustración 11 - Extracción y etiquetado de características.....	9
Ilustración 12 - Características candidatas para la selección.....	9
Ilustración 13 - Esquema de selección de características.....	10
Ilustración 14 - Ejemplo de la población y sus candidatos.....	10
Ilustración 15 - Codificación de los cromosomas del AG.....	11
Ilustración 16 - Cálculo de la función de aptitud de un cromosoma.....	11
Ilustración 17- Variación del algoritmo de cruce del AG.....	12
Ilustración 18 - Selección del conjunto de características para un sujeto (F_{ALL}).....	13
Ilustración 19 - Selección del conjunto de características por sesión para un sujeto (F_i)	13
Ilustración 20 - Selección del conjunto de características para sesiones acumuladas para un sujeto ($F_{1,...,i}$).....	14
Ilustración 21 - Conjuntos de características seleccionadas.....	15
Ilustración 22 - Datos suministrados al clasificador.....	15
Ilustración 23 - Formato de las pruebas de clasificación.....	15
Ilustración 24 - La disponibilidad de los datos es dependiente del tiempo.....	16
Ilustración 25 - Modo de clasificación en tiempo real.....	16
Ilustración 26 - Modo de clasificación en tiempo real con ventana de validación.....	17
Ilustración 27 - Selección de trials del mismo ensayo.....	17
Ilustración 28 – Clasificación de S_{ALL} con F_{ALL}	19
Ilustración 29 - Parámetros de clasificación de S_{ALL} con F_{ALL}	19
Ilustración 30 - Clasificación de S_i con F_{ALL}	20
Ilustración 31 - Parámetros de clasificación de S_{ALL} con F_{ALL}	20
Ilustración 32 - Clasificación en tiempo real de S_{ALL} con F_{ALL}	21
Ilustración 33 - Parámetros de clasificación en tiempo real de S_{ALL} con F_{ALL}	21
Ilustración 34 - Clasificación de S_i con F_i	22
Ilustración 35 - Parámetros de clasificación de S_i con F_i	22
Ilustración 36 - Clasificación de S_i con F_{i-1}	23
Ilustración 37 - Parámetros de clasificación de S_i con F_{i-1}	23
Ilustración 38 - Clasificación en tiempo real de S_i con F_{i-1}	24
Ilustración 39 - Parámetros de clasificación en tiempo real de S_i con F_{i-1}	24
Ilustración 40 - Clasificación de S_i con $F_{1,...,i}$	25
Ilustración 41 - Parámetros de clasificación de S_i con $F_{1,...,i}$	25
Ilustración 42 - Clasificación de S_i con $F_{1,...,i-1}$	26

Ilustración 43 - Parámetros de clasificación en tiempo real de S_i con F_{i-1}	26
Ilustración 44 - Clasificación en tiempo real de S_i con $F_{1,\dots,i-1}$	27
Ilustración 45 - Parámetros de clasificación en tiempo real de S_i con $F_{1,\dots,i-1}$	27
Ilustración 46 - Formato de las pruebas de clasificación	29
Ilustración 47 - Conjuntos de características seleccionadas	29
Ilustración 48 – Uso de datos históricos frente a datos recientes	29
Ilustración 49 – Uso de datos históricos en sistemas con re-entrenamiento	29
Ilustración 50 - Planificación de la TFM	33
Ilustración 51 - Esquema genérico de un sistema BCI	35
Ilustración 52 - Bloque de adquisición de un sistema BCI	35
Ilustración 53 - Bloque de procesado de un sistema BCI	36
Ilustración 54 - Bloques de aplicación y configuración de un sistema BCI	36
Ilustración 55 - Partes de un sistema de reconocimiento de patrones	45
Ilustración 56 - Reconocimiento de patrones en sistemas BCI	45
Ilustración 57 - Aprendizaje supervisado	46
Ilustración 58 - Conjuntos de test y train	46
Ilustración 59 - Validación Cruzada	47

Índice de Ecuaciones

Ecuación 1 - Re-referenciado de los canales	8
Ecuación 2 - Distribución de bandas de frecuencia.....	8
Ecuación 3 - Calculo de la calidad de la clasificación (Q)	11
Ecuación 4 - Densidad espectral de potencia.....	37
Ecuación 5 - Momentos espectrales de primer y segundo orden.....	37
Ecuación 6 - Potencia en una banda.....	37

1 Introducción

1.1 Marco de trabajo



Ilustración 1 - Sistema de captura de EEG

“La Tecnología de Interfaz cerebro-computador es un sistema de interacción hombre-máquina capaz de traducir nuestras intenciones en interacción real con un mundo físico o virtual. El funcionamiento básico de una BCI es medir la actividad cerebral, procesarla para obtener las características de interés, y una vez obtenidas interactuar con el entorno de la forma deseada por el usuario. Desde un punto de vista de interacción hombre-máquina, esta interfaz tiene dos características que la hacen única frente a todos los sistemas existentes. La primera de ellas es su potencial para construir un canal de comunicación natural con el hombre, la segunda su potencial acceso a la información cognitiva y emocional del usuario.” [1]

1.2 Motivación

Dados los requisitos de rendimiento de los sistemas en tiempo real, el reducir la cantidad de datos a calcular repercute en una disminución del tiempo de cómputo.

En los sistemas Brain Computer Interface (BCI), dicho tiempo viene directamente marcado por el número de características a procesar.

La selección de dichas características manteniendo una buena clasificación permite rebajar los tiempos de cómputo.

Por otra parte el realizar ciertas tareas offline, aprovechando el tiempo entre sesiones, permite aliviar los cálculos durante las sesiones.

1.3 Estado del arte

Uno de los interfaces que se llevan estudiando desde hace tiempo y que se espera que gane protagonismo en un futuro próximo son los sistemas Brain Computer Interface (BCI).

Los sistemas BCI, se basan en el uso de las actividad bioeléctrica cerebral, electroencefalograma (EEG), para interactuar con un computador [ver anexo B].

En estos sistemas tiene un papel importante la selección y extracción de características del EEG.

Las características nos permiten distinguir el comando que se quiere procesar dentro del computador, la capacidad de discernir correctamente viene dada en gran medida por las características seleccionadas.

Existe una gran cantidad de estudios destinados a obtener las mejores características.

1.4 Objetivos

Partiendo y siguiendo métodos empleados en trabajos previos [2], Se busca ampliar los resultados de selección de características para la clasificación de señales del electroencefalograma (EEG) correspondientes a dos estados mentales distintos.

Para ello se diseñara un sistema de selección de características basado en algoritmos genéticos (AG). Este sistema seleccionará el conjunto de características con una mejor calidad de clasificación.

El sistema es sometido a una batería de pruebas de clasificación con el fin de realizar un análisis del mismo.

También queda contempladas sesiones de prácticas relacionadas con la captura de señales del EEG para un sistema de Brain Computer Interface (BCI).

1.5 Estructura de los contenidos

La presente memoria esta dividida en:



Ilustración 2 - Estructura de los contenidos

2 Metodología

2.1 Electroencefalograma (EEG)

El electroencefalograma (EEG), es un análisis de la actividad eléctrica del cerebro. Este procedimiento realiza un seguimiento y registro de las ondas cerebrales. [3]

Para su registro se utilizan pequeños discos metálicos con cables delgados (electrodos) sobre el cuero cabelludo en diferentes localizaciones [4].

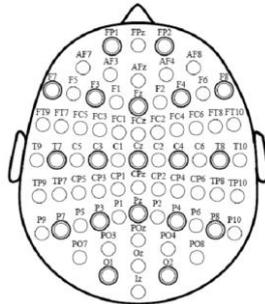


Ilustración 3 - Relación entre la localización de los electrodos y los canales

A dichas localizaciones las llamamos canales del EEG (channels, CH's). Estos canales muestran la medición del voltaje en una coordenada.

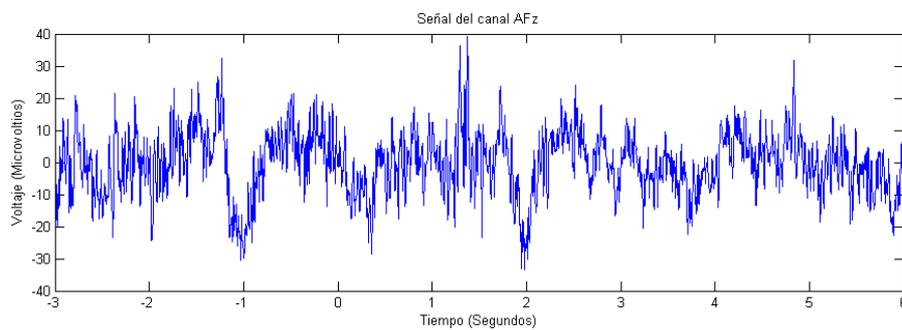


Ilustración 4 - Visualización de la señal de un canal del electroencefalograma

2.2 Protocolo de captura de la señal del EEG

Dependiendo del uso que se le va a dar a la señal del EEG, se plantean distintos protocolos de captura. Según el estudio que queramos realizar se seguirá un protocolo de captura formado por distintos pasos y configuraciones.

En nuestro caso, se estudia la clasificación de señales EEG correspondientes a dos estados mentales distintos, *Baseline* y *Movimiento*.

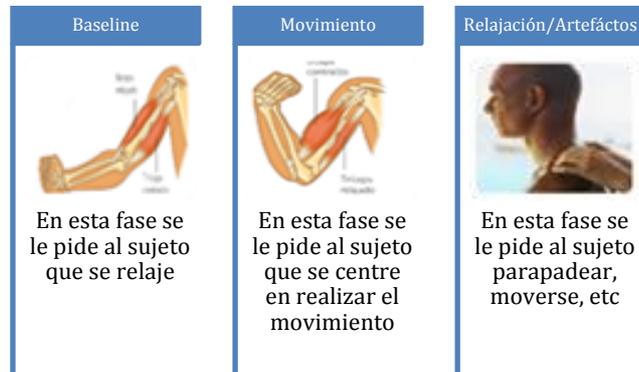


Ilustración 5 - Estados del protocolo de captura

Aunque nos interesan sólo los estados mentales de *Baseline* y *Movimiento*, se añade un tercer estado destinado a la relajación del sujeto de pruebas, permitiéndole un descanso.

El registro del EEG se ha llevado a cabo durante varias sesiones, en cada sesión se ha realizado varios ensayos, constando cada uno de ellos de los tres estados mentales.

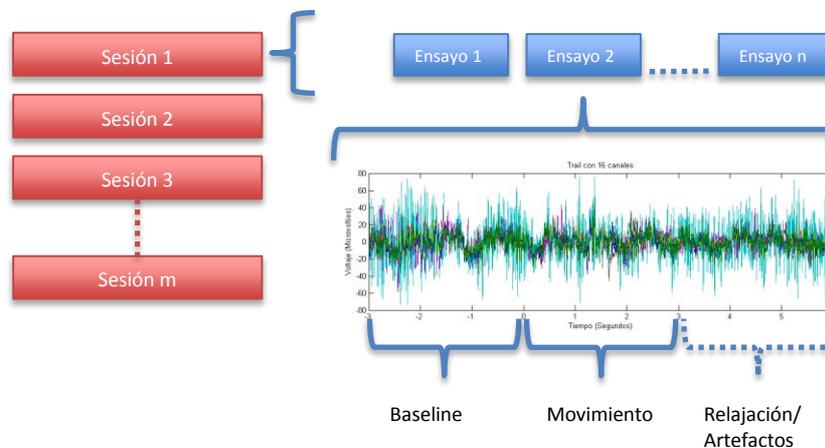


Ilustración 6 - Protocolo de captura del EEG de un sujeto

Los datos utilizados en el presente proyecto se han realizado sobre 5 sujetos, los cuales han participado en 5 sesiones cada uno, las cuales han constado de 60 ensayos con 16 canales cada uno.



Ilustración 7 - Datos de experimentación

2.3 Eliminación de artefactos

Ciertos ensayos son eliminados dada su invalidez debido a los artefactos de la señal. Para ello se procede a su inspección visual. Dichos ensayos si no se eliminasen podrían contaminar los resultados.

2.4 Extracción de características

Con los datos de la señal del EEG ya capturados, se procede a la extracción de características.

2.4.1 Preparación de los datos

Partimos que tenemos por cada sujeto varias sesiones con varios ensayos cada una. De cada ensayo nos quedaremos con dos eventos, el de *Baseline* y *Movimiento*.

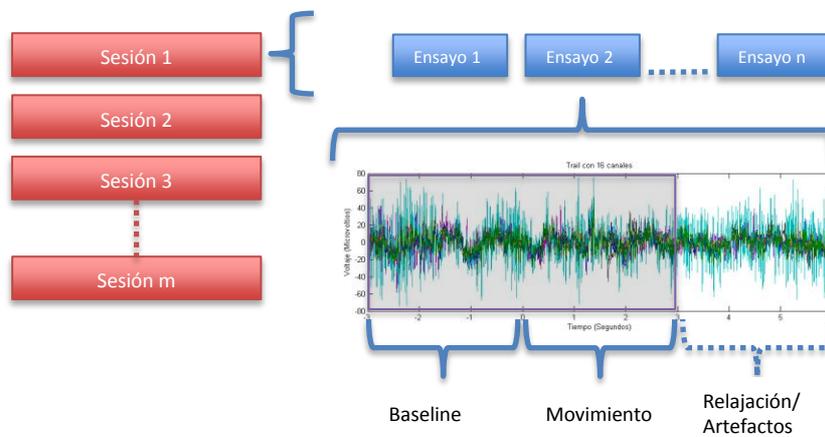


Ilustración 8 - Datos de partida para la extracción de características

Debido a que nuestra área de interés no abarca todos los canales, seleccionaremos los canales que son objeto del estudio, los canales relacionados con las tareas motoras. [5]

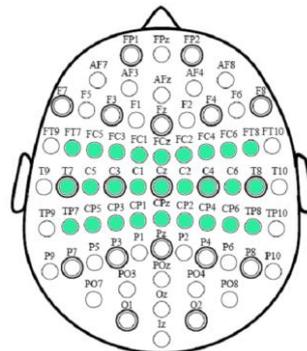


Ilustración 9 - Selección de los canales objeto del estudio

Además de los canales relacionados con una coordenada, se obtienen re-referenciados de los canales. [6]

Por Ejemplo:

$$\text{Rereferenciado de } CH(a) \text{ y } CH(b) = CH(a) - CH(b)$$

Ecuación 1 - Re-referenciado de los canales

De ahora en adelante cuando nos refiramos a los canales nos referiremos tanto a los canales como a sus re-referenciados, a no ser que se especifique expresamente.

2.4.2 Extracción

En nuestro caso las características son cada uno de los valores que definen intrínsecamente los distintos estados del individuo.

Existen infinidad de ellas, dado que en el presente trabajo no pretendemos abordar la implementación de nuevas características sino un sistema para su selección, nos centraremos en características de validez probada [2] [7] [8].

En nuestro caso hemos utilizado los momentos espectrales de primer y segundo orden [ver anexo C.2], así como la potencia en determinadas bandas [ver anexo C.3]

Las bandas de frecuencia se seleccionan en rangos de la siguiente manera siguiendo las conclusiones de otras publicaciones [9]

$$\text{Distribución de bandas} \begin{cases} < 16 \text{ Hz} \rightarrow \text{anchura de 2 Hz} \\ 16 \geq y \leq 32 \text{ Hz} \rightarrow \text{anchura de 4 Hz} \\ > 32 \text{ Hz} \rightarrow \text{anchura de 8 Hz} \end{cases}$$

Ecuación 2 - Distribución de bandas de frecuencia

Las frecuencias que nos interesan serian las que van desde los 7 Hz a los 35 Hz [9] que son las correspondientes a las tareas motoras.

7 Hz	9 Hz	16 Hz	20 Hz	24 Hz	32 Hz
8 Hz	10 Hz	17 Hz	21 Hz	25 Hz	33 Hz
9 Hz	11 Hz	18 Hz	22 Hz	26 Hz	34 Hz
10 Hz	12 Hz	19 Hz	23 Hz	27 Hz	35 Hz
11 Hz	13 Hz	20 Hz	24 Hz		
12 Hz	14 Hz	21 Hz	25 Hz		
13 Hz	15 Hz	22 Hz	26 Hz		
14 Hz	16 Hz	23 Hz	27 Hz		
15 Hz	17 Hz				

Ilustración 10 Distribución de bandas de frecuencia

Las características son extraídas de procesar las señales de cada uno de los eventos y son etiquetadas indicando el estado mental al que pertenecen.

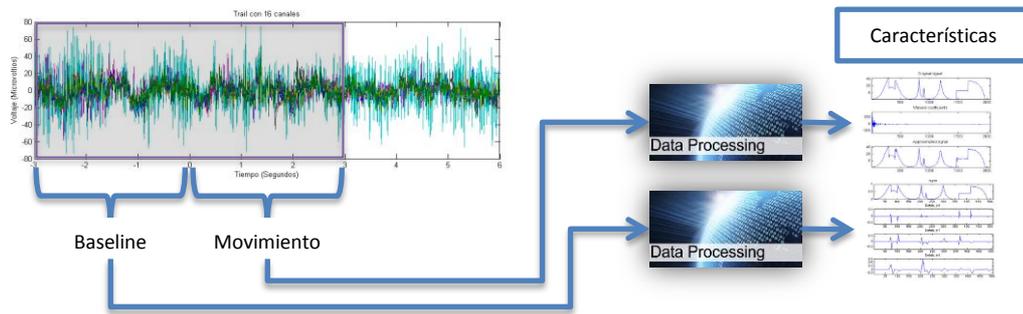


Ilustración 11 - Extracción y etiquetado de características

Las características obtenidas, formaran los candidatos durante el proceso de selección del conjunto de características con una mejor calidad de clasificación [ver sección 2.5].

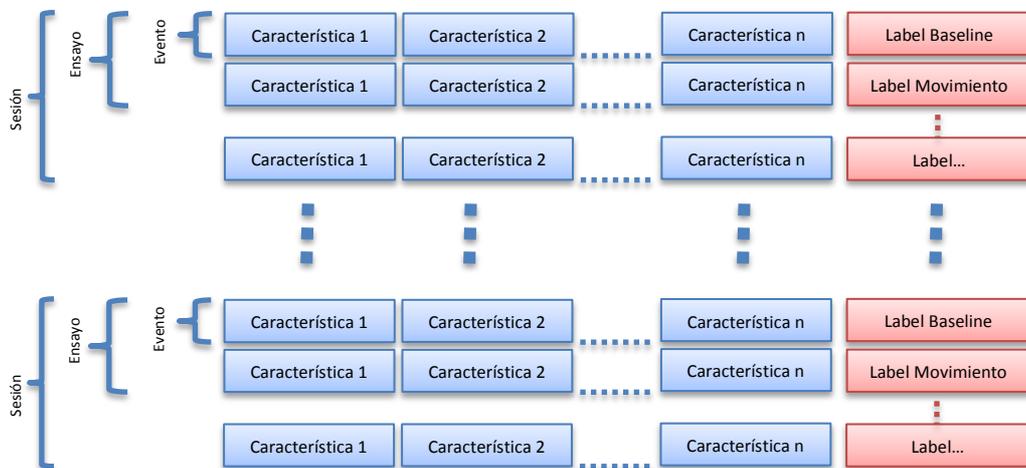


Ilustración 12 - Características candidatas para la selección

2.5 Selección de características

De una señal de EEG se pueden extraer una inmensa cantidad de características. Es de vital importancia el seleccionarlas. Con la selección se reducen los costes de procesamiento y se aumenta la fiabilidad de la clasificación [ver sección 1.2].

Después del proceso de extracción de características, pasamos a buscar el conjunto de características que mejor calidad de clasificación (Q) tengan del conjunto de datos.

Para la selección de las mejores características procederemos utilizando un algoritmo genético (AG) [ver sección 2.5.1].



Ilustración 13 - Esquema de selección de características

2.5.1 Algoritmo Genético (AG)

Un algoritmo genético, sirve para poder seleccionar la combinación que mejor ajusta una función de aptitud dentro de una población [ver anexo D].

En nuestro caso, la población serían las distintas combinaciones que se pueden realizar con las características candidatas, y la función de aptitud se calcula dada la calidad de la clasificación (Q).

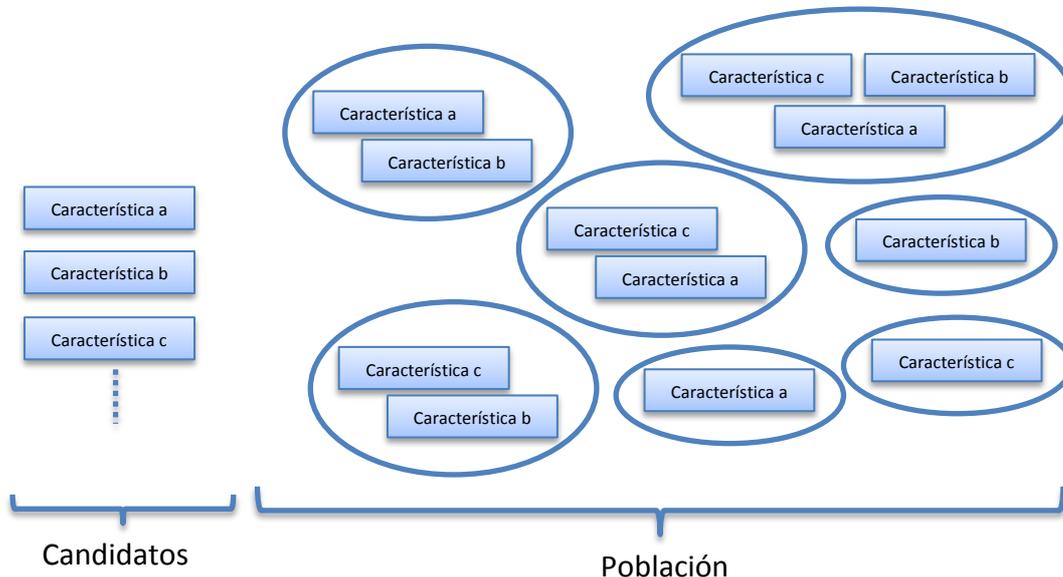


Ilustración 14 - Ejemplo de la población y sus candidatos

En la codificación del AG cada individuo de la población (cromosoma), se representa mediante un vector de ceros y unos, que indican si una característica es incluida o no.

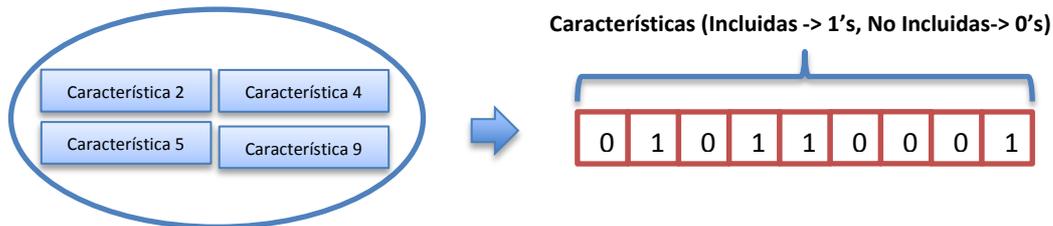


Ilustración 15 - Codificación de los cromosomas del AG

La función de aptitud [ver anexo D.3] elegida viene dada por Q, obtenida usando el conjunto de características incluidas en cada cromosoma.

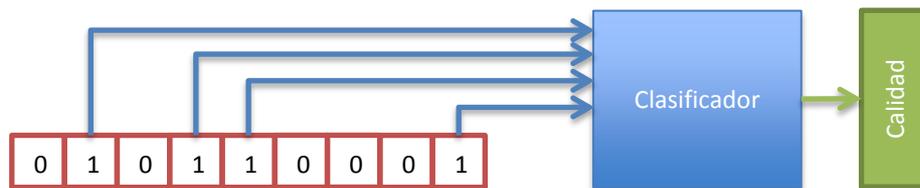


Ilustración 16 - Cálculo de la función de aptitud de un cromosoma

Para calcular la calidad de la clasificación (Q) de un cromosoma se recurre a la utilización de un clasificador [ver anexo E], y se tiene en cuenta tanto el balance como la precisión de los resultados.

$$Q = (\beta) \cdot (\text{precisión de la clasificación}) + (1 - \beta) \cdot (\text{balance de clasificación entre clases})$$

Ecuación 3 - Cálculo de la calidad de la clasificación (Q)

El ratio β se ha fijado a 0.9 después de una calibración con el AG.

Para la selección de las siguientes generaciones del AG se ha decantado por el método de la ruleta [ver anexo D.5], con pequeñas variaciones. Se ha premiado ante una clasificación similar el individuo que tiene menor número de características seleccionadas.

A la hora de realizar la recombinación sexual [ver anexo D.6] se ha variado el algoritmo de un punto de cruce para mantener un número de características activas por debajo de un ratio configurable. Además se ha optado por una versión aleatoria de las mismas.

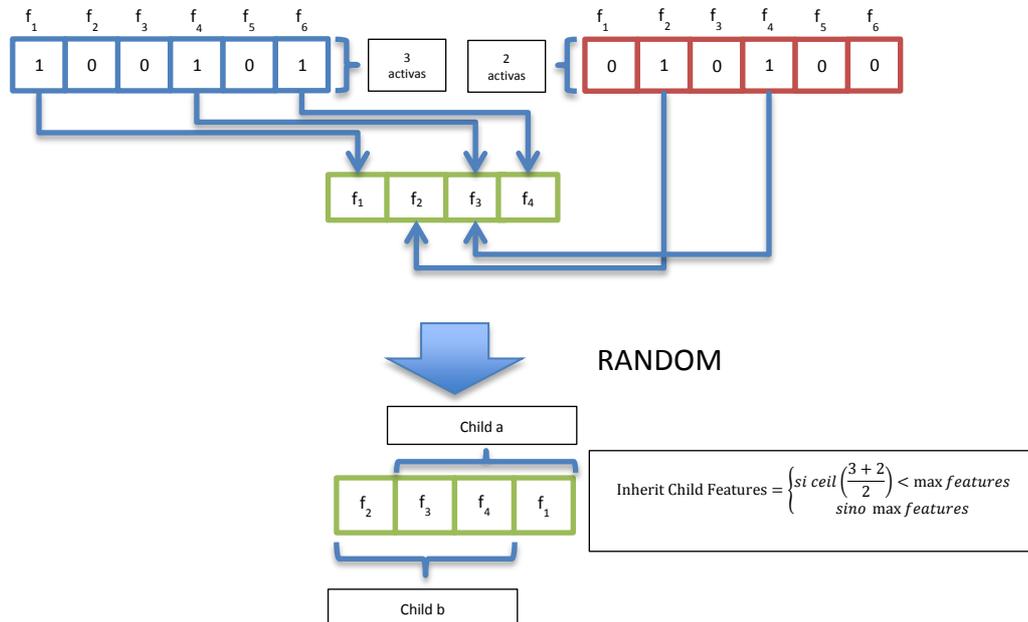


Ilustración 17- Variación del algoritmo de cruce del AG

Esta variación ha sido realizada utilizando las conclusiones sacadas de otros trabajos que sitúan el ratio de características activas sobre el 10% de los datos [2].

2.5.2 Objetivos de la selección de características

En la selección del conjunto de características que mejor Q tienen, se van a seleccionar tres conjuntos:

- Mejor conjunto de características para un sujeto (F_{ALL})
- Mejores conjuntos de características por sesión para un sujeto (F_i)
- Mejores conjuntos de características por sesiones acumuladas para un sujeto ($F_{1,...,i}$)

2.5.2.1 Mejor conjunto de características para un sujeto (F_{ALL})

Seleccionamos mediante el AG el conjunto de las características que mejor calidad de clasificación tiene para un sujeto utilizando todos los datos que disponemos de él, F_{ALL} .

Se alimenta el AG con los datos de todas las sesiones (S_{ALL}) del sujeto, con dicha selección obtendremos F_{ALL} .



Ilustración 18 - Selección del conjunto de características para un sujeto (F_{ALL})

Como contra hemos de decir que F_{ALL} no se puede llevar a un sistema en tiempo real, ya que requiere el uso de todos los datos a la vez, sin respetar el orden de llegada, ni la línea de tiempo.

2.5.2.2 Mejores conjuntos de características por sesión para un sujeto (F_i)

Este caso es similar al anterior, pero nos remitiremos a utilizar solo a los datos de una sesión por vez, F_i .

Se alimenta al AG con los datos de una sesión (S_i), con dicha selección obtendremos F_i .

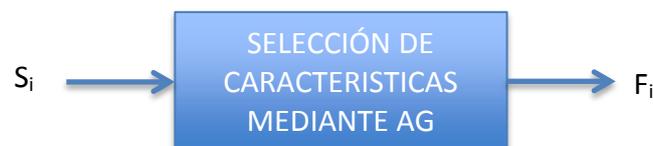


Ilustración 19 - Selección del conjunto de características por sesión para un sujeto (F_i)

Como contra hemos de decir que F_i no permite la clasificación de la primera sesión (S_1) en un sistema en tiempo real.

2.5.2.3 Mejores conjuntos de características por sesiones acumuladas para un sujeto ($F_{1,\dots,i}$)

En este caso no solo queremos utilizar los datos de una sesión sino que queremos utilizar además los datos de las sesiones anteriores, $F_{1,\dots,i}$.

Se alimenta al AG con los datos de la sesión y sus anteriores (S_1, \dots, S_i), con dicha selección obtendremos $F_{1,\dots,i}$.



Ilustración 20 - Selección del conjunto de características para sesiones acumuladas para un sujeto ($F_{1,\dots,i}$)

Este caso también plantea el problema de el anterior apartado no pudiéndose clasificar S_1 en un sistema en tiempo real.

2.6 Pruebas de clasificación

Las pruebas consistirán en clasificar [ver anexo E] los conjuntos de características seleccionadas [ver sección 2.5]:

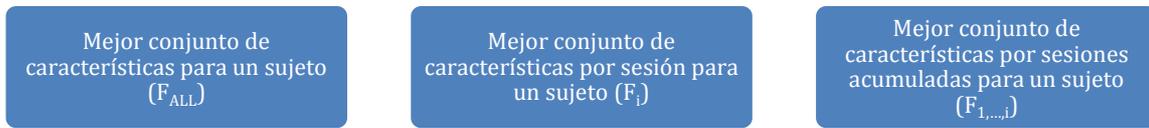


Ilustración 21 - Conjuntos de características seleccionadas

Los datos administrados al clasificador [ver anexo E] constan de *trials* y sus correspondientes *labels*, representados por el conjunto de características y sus etiquetas.

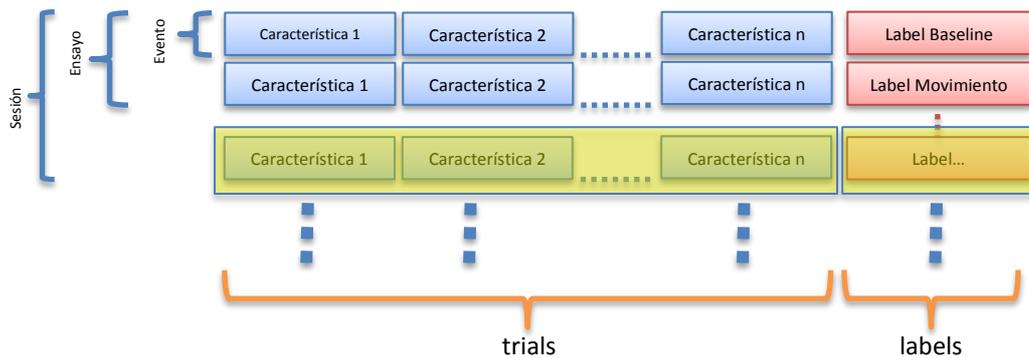


Ilustración 22 - Datos suministrados al clasificador

Se abordan tres formatos para las de pruebas de clasificación:

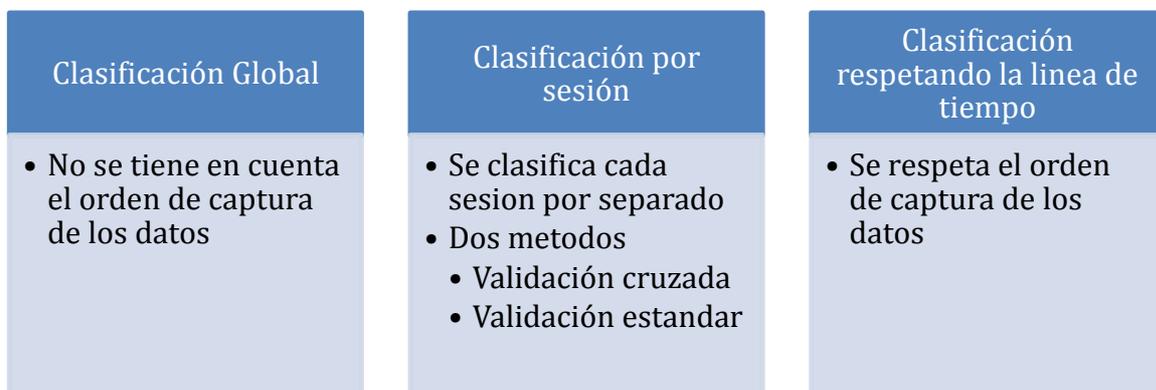


Ilustración 23 - Formato de las pruebas de clasificación

2.6.1 Pruebas de clasificación global

Se utiliza todo el conjunto de datos (S_{ALL}), no se tiene en cuenta el orden de captura de los datos.

Para corroborar la validez de la clasificación se realizan varias repeticiones de la clasificación utilizando validación cruzada [ver anexo E.4], obteniendo un valor promedio menos dependiente de singularidades.

Se procura respetar el balance de clases en la selección de los datos [ver anexo E], así como el balance de los datos por sesión. Cada uno de los datos de entrada esta compuesto por el conjunto de características (*trial*) y sus etiquetas (*label*).

Esta prueba se realizará en cada uno de los sujetos, promediando los resultados de la clasificación con el fin de obtener unos datos estadísticamente más robustos.

2.6.2 Clasificación por sesión

Es parecido al caso anterior pero se busca clasificar solo una sesión, S_i .

Al igual que en el caso anterior, se mantendrá el balance de las clases y se promediarán los resultados de todos los sujetos.

Se implementará según proceda una validación cruzada o una validación estándar consistente en un grupo de *test* y otro de *train*.

2.6.3 Clasificación respetando el orden de captura de los datos

Este caso se asemeja más a lo que sería un sistema de clasificación en tiempo real. Se basa en que la disponibilidad de los datos es dependiente del tiempo.

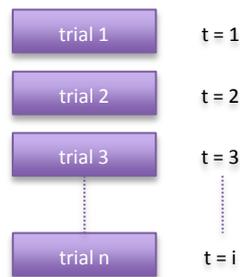


Ilustración 24 - La disponibilidad de los datos es dependiente del tiempo

Así el conjunto de datos de entrenamiento (*train*), son los datos obtenidos hasta el instante anterior al conjunto a validar (*test*) por parte del clasificador [ver anexo E].

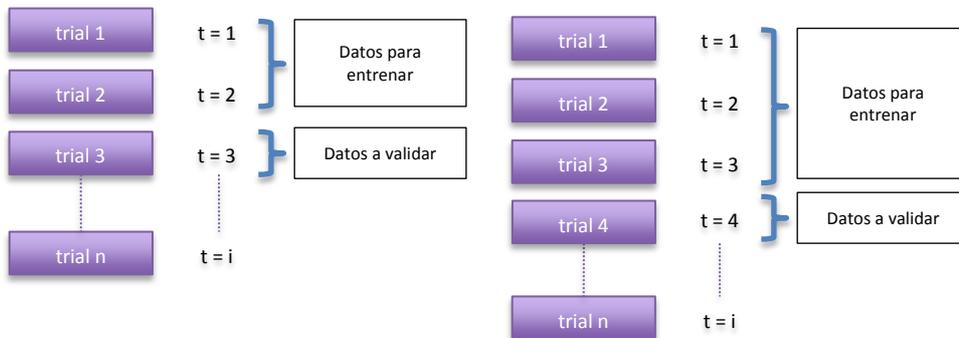


Ilustración 25 - Modo de clasificación en tiempo real

Y el conjunto de datos de validación (*test*), está formado por los datos capturados hasta dicho instante [ver anexo E].

Para obtener una medida de clasificación con un menor ruido, utilizamos una ventana de validación. De este modo se validan más de un trial a la vez.

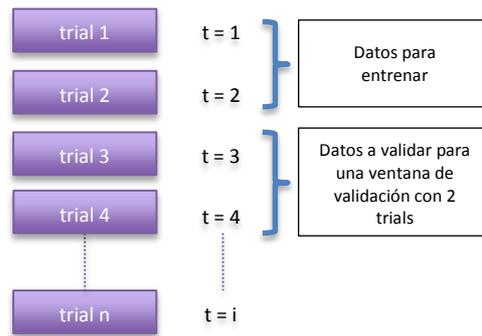


Ilustración 26 - Modo de clasificación en tiempo real con ventana de validación

El tamaño de esta ventana escogido ha sido del 10% de los datos a validar. Además se a procurado que en dicha ventana de validación sea par con el fin que figuren los *trials* del mismo ensayo manteniendo el balance entre las clases [ver anexo E].

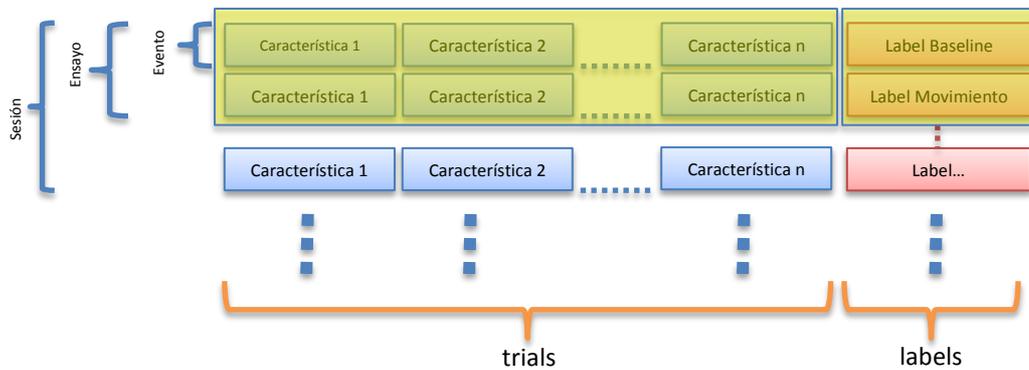


Ilustración 27 - Selección de trials del mismo ensayo

3 Análisis de resultados

En los resultados se muestra el promedio del cálculo de cada uno de los sujetos.

- La clase 1 correspondiente al estado de *Baseline*.
- La clase 2 correspondiente al estado de *Movimiento*.

3.1 Pruebas utilizando F_{ALL}

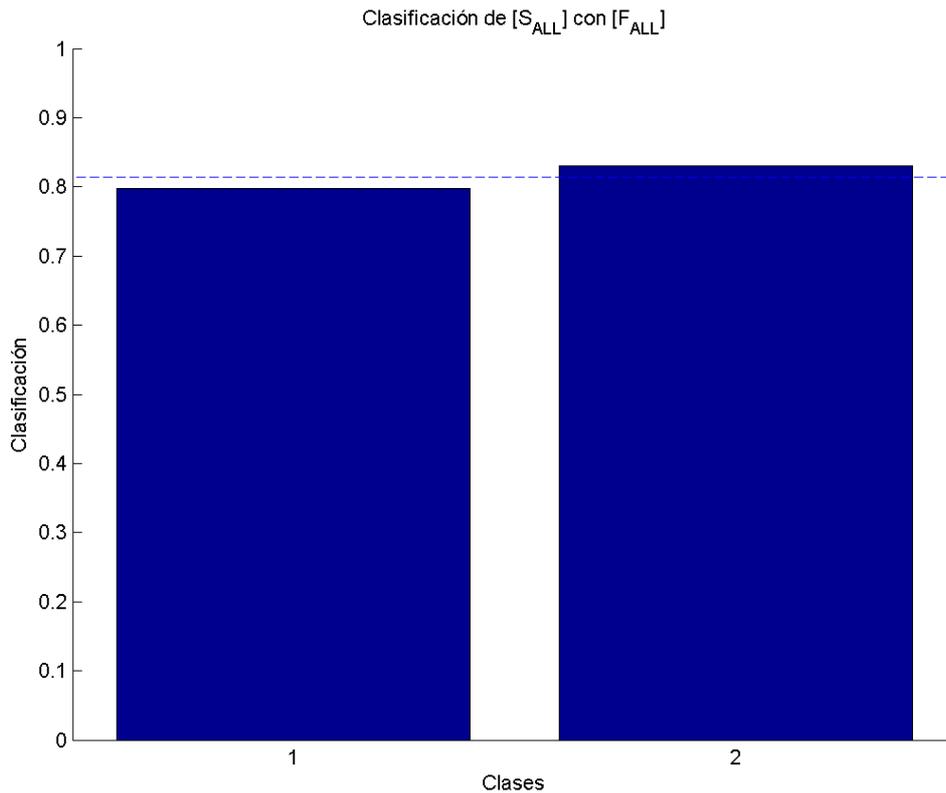


Ilustración 28 – Clasificación de S_{ALL} con F_{ALL}

Tipo de clasificación	Validación cruzada
Conjunto de train	Subconjuntos de S_{ALL}
Conjunto de test	Los datos no seleccionados en el train
Conjunto de características	F_{ALL}

Ilustración 29 - Parámetros de clasificación de S_{ALL} con F_{ALL}

Descripción

Podemos observar que los resultados de clasificación son próximo al 81%. Con el marcamos la base con la que realizar comparaciones de los resultados obtenidos en las sucesivas pruebas.

Este tipo de clasificación es imposible de implementar en un sistema en tiempo real al no tener todos los datos para realizar la clasificación en un momento t_i dado. Tan solo nos sirve de máximo teórico para el conjunto de todos los datos.

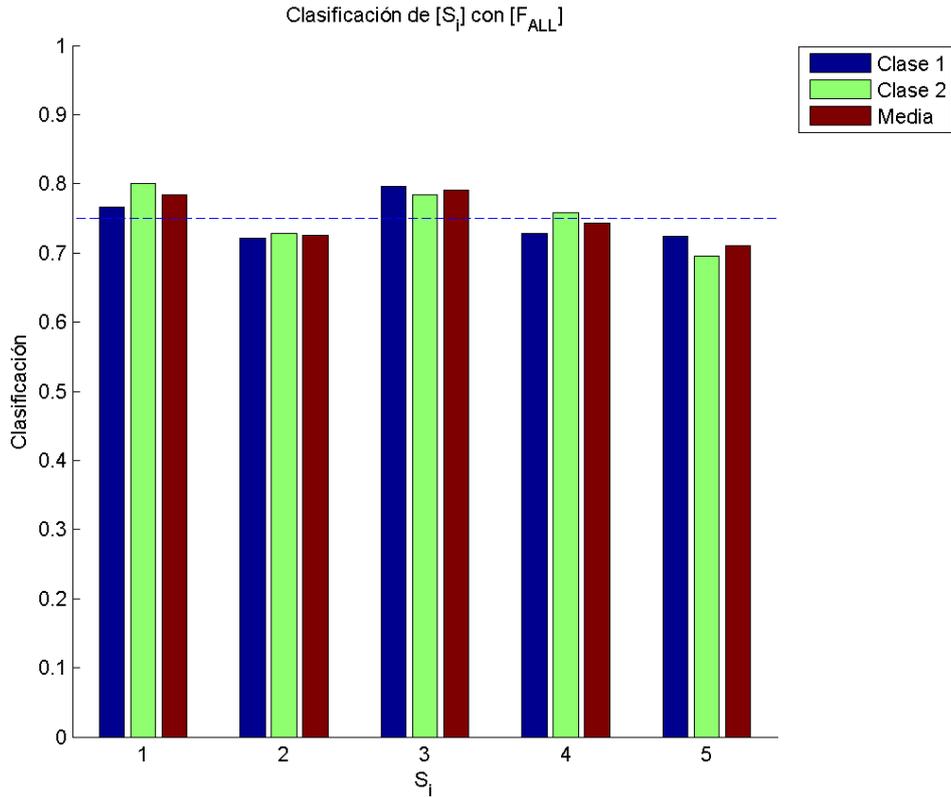


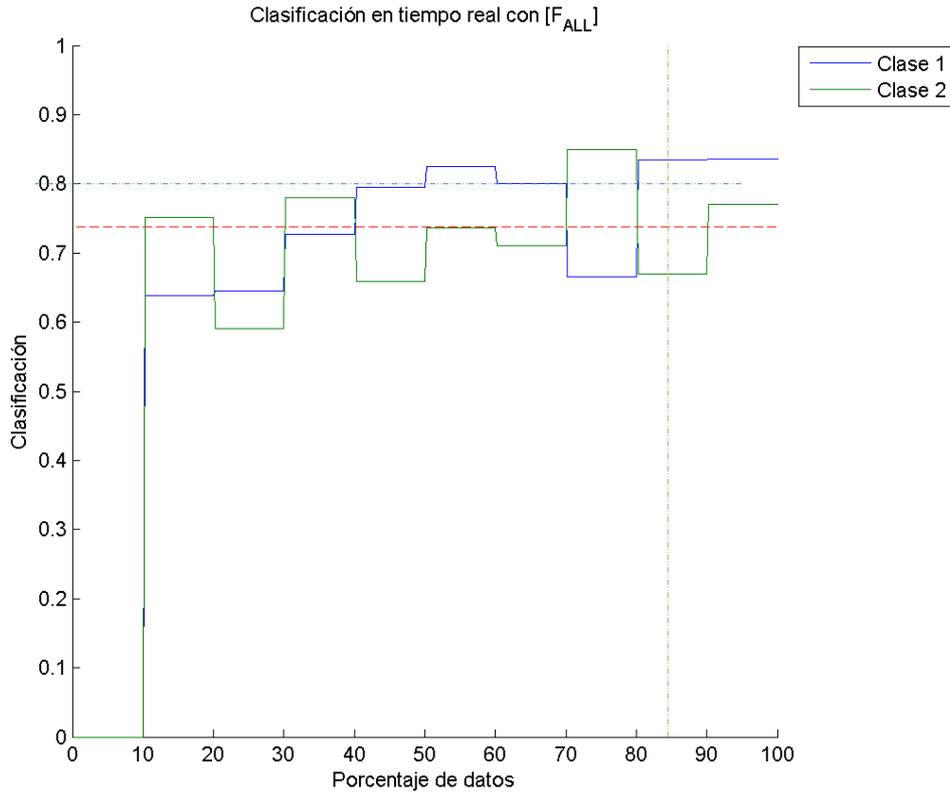
Ilustración 30 - Clasificación de S_i con F_{ALL}

Tipo de clasificación	Validación cruzada
Conjunto de train	Subconjuntos de S_i
Conjunto de test	Los datos no seleccionados en el train de S_i
Conjunto de características	F_{ALL} .

Ilustración 31 - Parámetros de clasificación de S_{ALL} con F_{ALL}

Descripción

Podemos observar que utilizando el conjunto de características F_{ALL} y sólo los datos de una sesión (S_i) la precisión baja comparando con el caso anterior. Esto nos previene de la importancia que tiene la cantidad de datos en los resultados. Dejando entrever, que en un sistema en tiempo real contra mas datos de entrenamiento se tengan mejor clasificación obtendremos.

Ilustración 32 - Clasificación en tiempo real de S_{ALL} con F_{ALL}

Tipo de clasificación	En tiempo real
Conjunto de train	Todos los trials anteriores al test de S_{ALL}
Conjunto de test	Ventanas de validación del 10% de S_{ALL}
Conjunto de características	F_{ALL} .

Ilustración 33 - Parámetros de clasificación en tiempo real de S_{ALL} con F_{ALL} **Descripción**

Dado que el tamaño de ventana de validación es del 10% de los trials, se puede observar que el primer 10% no ha sido clasificado. Esto es debido a que en este instante no hay datos de entrenamiento.

Observamos que la tendencia es de ir situándose hasta casi el 80% de aciertos según se tienen más datos de entrenamiento para el clasificador. Sin embargo hasta que no tenemos todo el conjunto de datos no llega hasta el 80%, momento en el cual se acerca a el máximo teórico (ver Ilustración 28).

Así pues observamos que a pesar de tener un máximo teórico del 80%, si abordamos un sistema en tiempo real esta cota no se alcanza hasta haber re-entrenado el sistema con cerca del 90% de los datos. Como media de los datos clasificados obtenemos cerca de un 73.5%.

3.2 Pruebas utilizando F_i

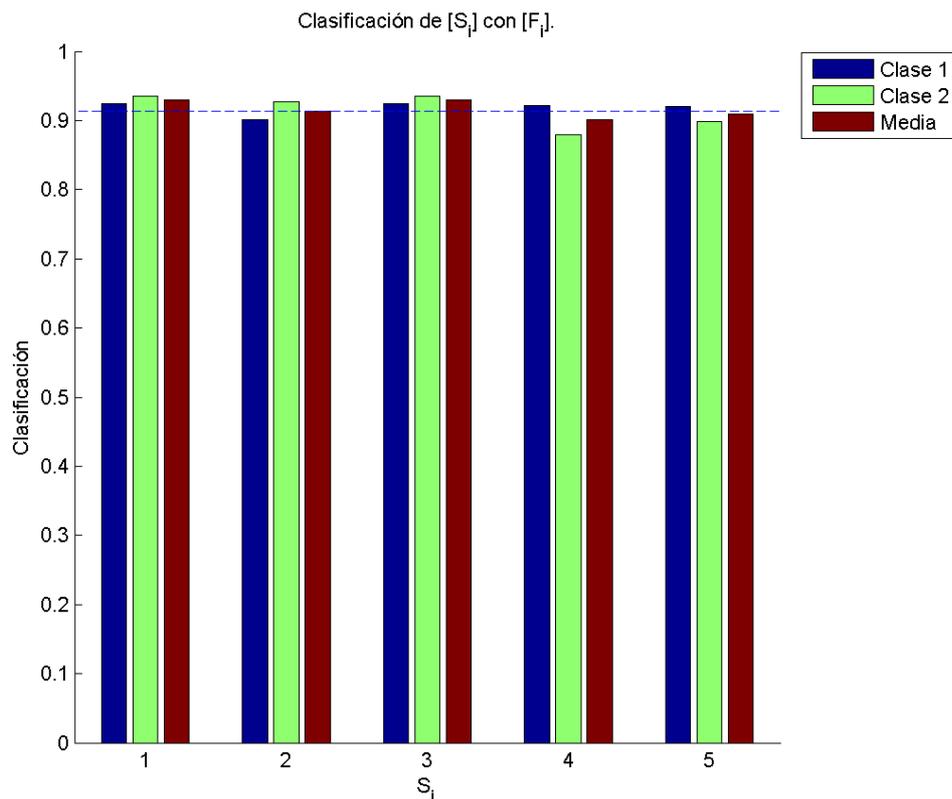


Ilustración 34 - Clasificación de S_i con F_i

Tipo de clasificación	Validación cruzada
Conjunto de train	Subconjuntos de S_i
Conjunto de test	Los datos no seleccionados en el train de S_i
Conjunto de características	F_i

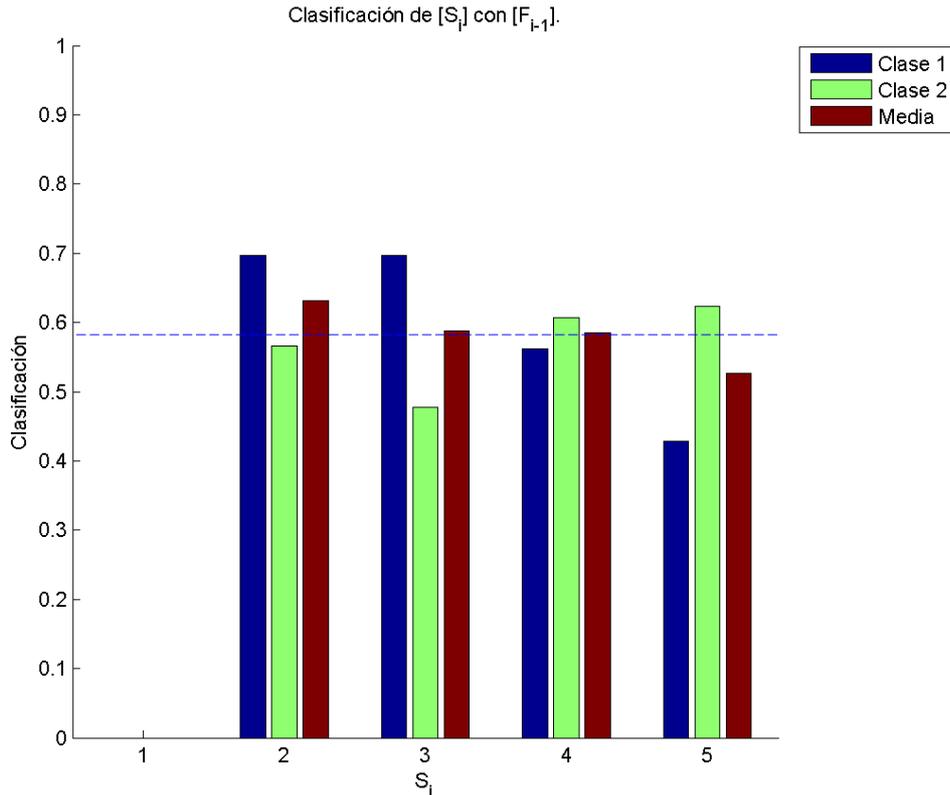
Ilustración 35 - Parámetros de clasificación de S_i con F_i

Descripción

Podemos observar que los resultados de clasificación son próximo al 91%. Con el marcamos una base con la que realizar comparaciones de los resultados obtenidos en las sucesivas pruebas.

Al igual que en el caso de S_{ALL} con F_{ALL} , no es válido para un sistema en tiempo real, pero nos da una media teórica de hasta donde puede llegar la clasificación si solo tenemos el conocimiento de la sesión.

También se observa una gran mejora de la clasificación frente al 80% obtenido usando S_{ALL} con F_{ALL} . (ver Ilustración 28).

Ilustración 36 - Clasificación de S_i con F_{i-1}

Tipo de clasificación	Validación estándar
Conjunto de train	S_{i-1}
Conjunto de test	S_i
Conjunto de características	F_{i-1}

Ilustración 37 - Parámetros de clasificación de S_i con F_{i-1} **Descripción**

La clasificación de la primera sesión S_1 no es posible al no existir un F_0 .

Este esquema de clasificación permitiría realizar los cálculos offline y poder clasificar el sistema en tiempo real, sin apenas coste de cómputo. La selección se haría entre sesiones y el entrenamiento también.

Podemos observar que el rendimiento baja casi un 40% respecto al teórico (ver Ilustración 34). Aunque podría ser una buena solución de cara a los tiempos de cómputo su precisión de clasificación es bajo.

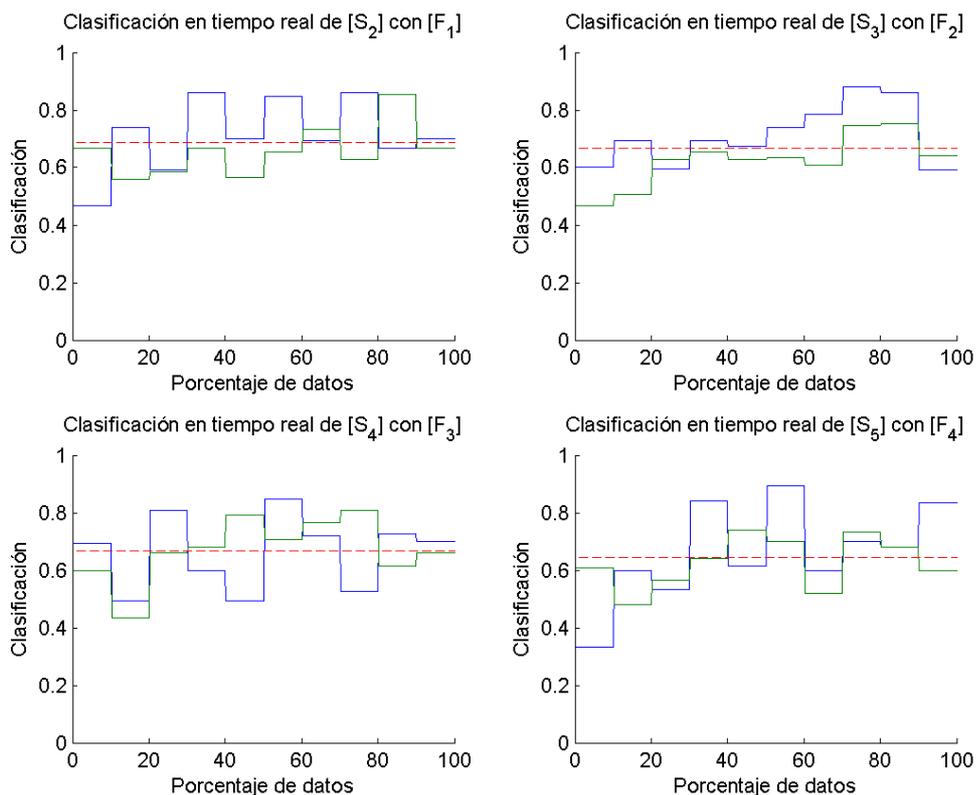


Ilustración 38 - Clasificación en tiempo real de S_i con F_{i-1}

Tipo de clasificación	En tiempo real
Conjunto de test	Ventas de validación del 10% de S_i
Conjunto de train	Todos los trials anteriores al test de S_{i-1} y S_i
Conjunto de características	F_{i-1}

Ilustración 39 - Parámetros de clasificación en tiempo real de S_i con F_{i-1}

Descripción

La clasificación de la primera sesión S_1 no es posible al no existir un F_0 .

Como hemos observado al clasificar S_i con F_{i-1} (ver Ilustración 36), la clasificación media se mantiene por debajo del 60%, en este caso se procura un sistema que se pueda implementar en tiempo real. El sistema se re-entrena según van llegando los datos, de este modo se mejoran los resultados del caso anterior elevándolos por encima del 60%.

3.3 Pruebas utilizando $F_{1,...,i}$

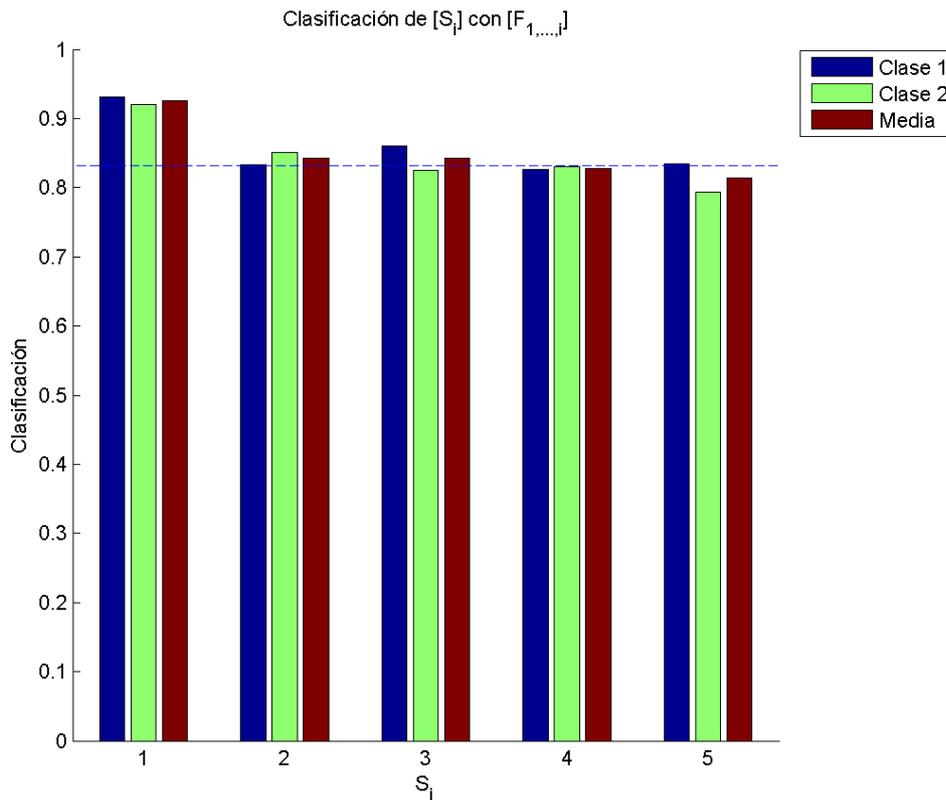


Ilustración 40 - Clasificación de S_i con $F_{1,...,i}$

Tipo de clasificación	Validación cruzada
Conjunto de train	$S_{1,...,i-1}$ y Subconjuntos de S_i
Conjunto de test	Los datos no seleccionados en el train de S_i
Conjunto de características	$F_{1,...,i}$

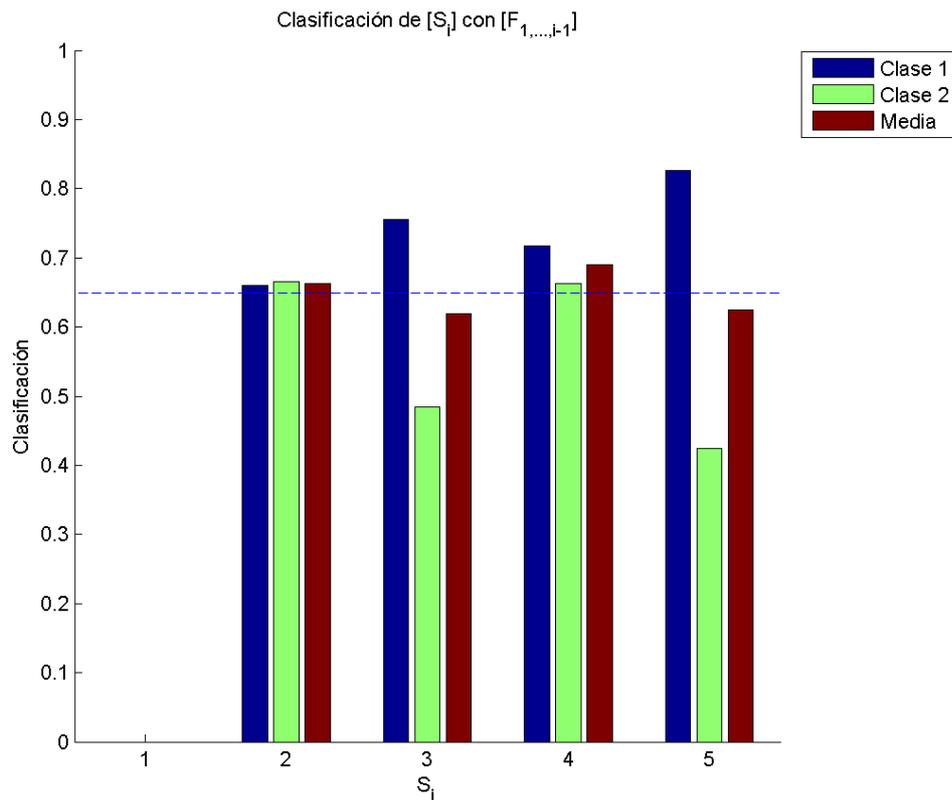
Ilustración 41 - Parámetros de clasificación de S_i con $F_{1,...,i}$

Descripción

Podemos observar que los resultados de clasificación son próximos al 83%. Como podemos observar baja el resultado obtenido por S_i con F_i (ver Ilustración 34).

Al igual que en el casos anteriores, no es valido para un sistema en tiempo real, pero nos da una media teorica.

Aunque apenas se pueda apreciar se observa que contra mas datos historicos se introducen la clasificacion es menos exacta.

Ilustración 42 - Clasificación de S_i con $F_{1,\dots,i-1}$

Tipo de clasificación	Validación estándar
Conjunto de train	$S_{1,\dots,i-1}$
Conjunto de test	S_i
Conjunto de características	F_{i-1}

Ilustración 43 - Parámetros de clasificación en tiempo real de S_i con F_{i-1} **Descripción**

La clasificación de la primera sesión S_1 no es posible al no existir un F_0 .

La clasificación mejora un poco (65%) respecto al caso de S_i con F_{i-1} (ver Ilustración 36). La adición de datos históricos permite una mejor clasificación.

El resultado sigue siendo bastante más bajo (17%) que en el caso ideal de tener el conocimiento de dicha sesión (ver Ilustración 40).

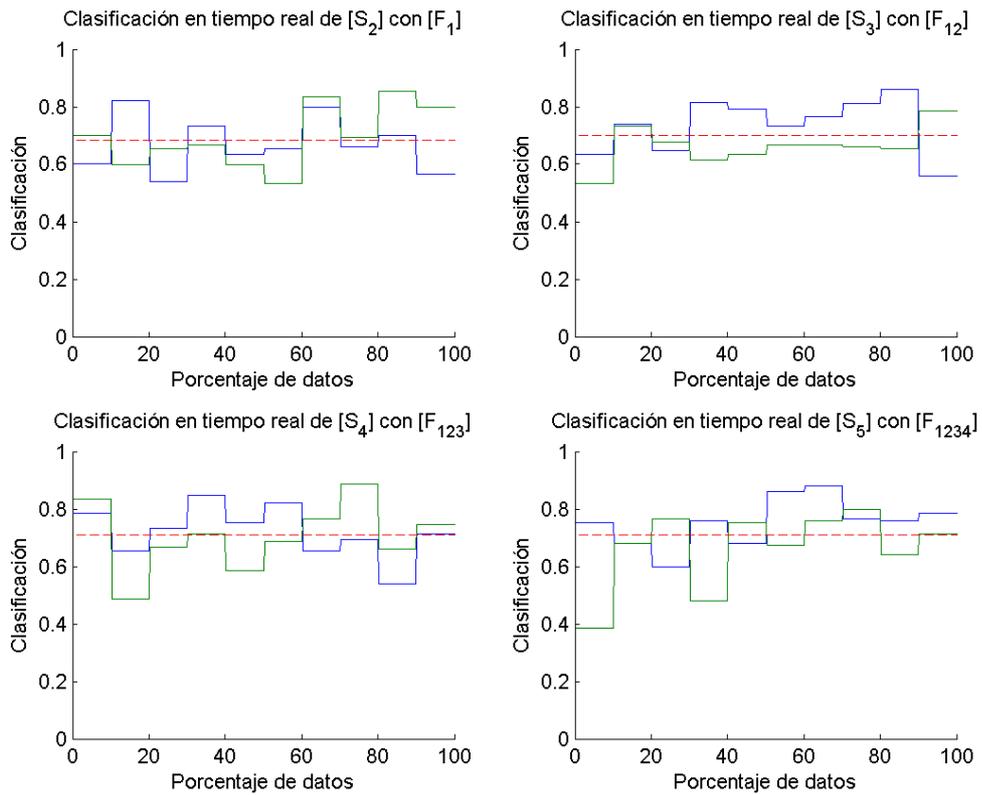


Ilustración 44 - Clasificación en tiempo real de S_i con $F_{1,\dots,i-1}$

Tipo de clasificación	En tiempo real
Conjunto de test	Ventas de validación del 10% de S_i
Conjunto de train	Todos los trials anteriores al test de $S_{1,\dots,i-1}$ y S_i
Conjunto de características	$F_{1,\dots,i-1}$

Ilustración 45 - Parámetros de clasificación en tiempo real de S_i con $F_{1,\dots,i-1}$

Descripción

La clasificación de la primera sesión S_1 no es posible al no existir un F_0 .

La media se mantiene cerca de S_i con $F_{1,\dots,i}$ (ver Ilustración 42), en el que la clasificación media sin re-entrenar se mantenía por debajo del 65%.

En este caso el sistema se re-entrena según van llegando los datos, de este modo se observa que el sistema poco a poco va subiendo de un 65% a un 67%. Si lo comparamos con S_i con F_{i-1} observamos que el comportamiento es ligeramente mejor.

4 Conclusiones

Dadas las pruebas realizadas [ver sección 2.6], en las que se realizaron tres tipos de baterías de test:



Ilustración 46 - Formato de las pruebas de clasificación

Con los conjuntos de características seleccionadas mediante el AG [ver sección 2.5]:

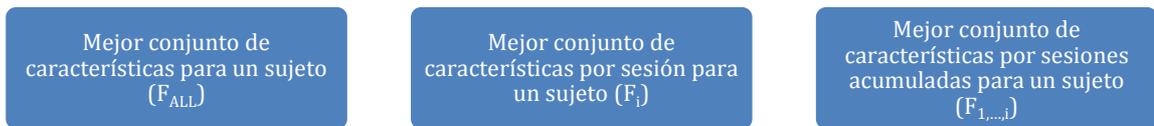


Ilustración 47 - Conjuntos de características seleccionadas

Se obtienen las siguientes conclusiones:

- Se observa que en sistemas en tiempo real sin re-entrenamiento, el uso de datos mas recientes (ver Ilustración 36) obtiene mejores resultados que el uso de todos los datos hasta dicho momento (ver Ilustración 42).

Si no hay re-entrenamiento del sistema, el uso de datos recientes mejoro los resultados de utilizar todos los datos disponibles hasta dicho momento.

Ilustración 48 – Uso de datos históricos frente a datos recientes

- Sin embargo, en sistemas con re-entrenamiento el uso de datos históricos (ver Ilustración 44) mejoro un poco el rendimiento respecto a utilizar solo los datos más recientes (ver Ilustración 38).

En sistemas con reentrenamiento el uso de datos históricos mejoro el rendimiento respecto a utilizar solo los datos mas recientes.

Ilustración 49 – Uso de datos históricos en sistemas con re-entrenamiento

En ambos casos se empleo una selección de características extraídas antes de la sesión a validar. Esto permitiría implementar un sistema que realice dicha selección en un AG de manera offline.

5 Trabajos citados

- [1] J. Minguez, «Tecnología de Interfaz Cerebro - Computador,» de *Jornadas II Internacionales de Mayores y Nuevas Tecnologías*, Zaragoza, España, Abril 2010.
- [2] R. Corralejo, «Feature Selection Using a Genetic Algorithm in a Motor Imagery-Based Brain Computer Interface,» de *33rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Boston, Massachusetts USA, 2011.
- [3] A. d. A. d. I. L. E. RAE, «Diccionario de la lengua española - Vigésima segunda edición,» 2009.
- [4] «KidsHealth,» [En línea]. Available: http://kidshealth.org/parent/en_espanol/medicos/eeg_esp.html.
- [5] G. Von Bonin, «Architecture of the precentral motor cortex and some adjacent areas,» P. Bucy (Ed.), *The Precentral Motor Cortex*, University of Illinois Press, Urbana, p. 7–82, 1944.
- [6] G. I. E., A. R. C., A. Y. V., M. B. V., R. H. L. y G. G. G., «Efecto de la cantidad y dimensión de los patrones en una interfaz cerebro computadora basada en discriminante lineal de Fisher,» de *Memorias del V Congreso Latinoamericano de Ingeniería Biomédica (CLAIB2011)*, Cuba, 2011.
- [7] A. Rakotomamonjy y V. Guigue, «BCI competition III: dataset II- ensemble of SVMs for BCI P300 speller,» *IEEE Trans Biomed Eng*, 55, pp. 1147-1154, Mar 2008.
- [8] R. Ruiz Ceres y L. J. Bravo Barrios, «Técnicas de BCI y de Análisis de la Actividad Cerebral Asociada ,» de *Red Temática de Tecnología de Apoyo a la Discapacidad y Mayores*, 2008.
- [9] B. Graimann, J. Huggins, S. Levine y G. Pfurtscheller, «Visualization of significant ERD/ERS patterns in multichannel EEG and ECoG data,» *Clinical Neurophysiology*, p. 43–47, Enero 2002.
- [10] T. Ebrahimi, U. Hoffmann y J.-M. Vesin, «Recent advances in brain-computer interfaces,» *Multimedia Signal Processing, IEEE 9th Workshop on*, 2007.
- [11] G. M. Daniel, «Introducción a los sistemas Brain Computer Interface,» 2008. [En línea]. Available: <http://www.lacofa.es/index.php/general/introduccion-a-los-sistemas-brain-computer-interface>.
- [12] «Wikipedia - Interfaz Cerebro Computadora,» [En línea]. Available: http://es.wikipedia.org/wiki/Interfaz_Cerebro_Computadora.
- [13] «Wikipedia - Densidad espectral,» [En línea]. Available: http://es.wikipedia.org/wiki/Densidad_espectral.
- [14] D. G. M. John G. Proakis, Tratamiento digital de señales. Principios, algoritmos y aplicaciones, Prentice Hall.
- [15] «Wikipedia - Wiener–Khinchin theorem,» [En línea]. Available: http://en.wikipedia.org/wiki/Wiener%E2%80%93Khinchin_theorem.
- [16] D. W. Ricker, *Echo Signal Processing*, Springer.
- [17] C. I. Leon W., *Digital and Analog Communications Systems*, New Jersey: Prentice

- Hall, 2001.
- [18] P. D. Welch, The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms, 1967.
- [19] C. Coello A., «Algoritmos Genéticos y sus Aplicaciones».
- [20] G. Rodríguez Bermúdez, P. J. García Laencina, J. L. Roca González, J. Roca González y J. Roca Dorda, «Técnicas de reconocimiento de patrones para la clasificación de señales EEG en sistemas BCI,» *Revista V Jornadas de introducción a la investigación de la UPCT*, 2012.
- [21] T. Mitchell, «Generative and Discriminative Classifiers: Naive Bayes and Logistic Regression,» *Draft Version*, 2005.
- [22] Devijver, P. A. y K. J., «Pattern Recognition: A Statistical Approach,» *Prentice-Hall*, 1982.
- [23] E. Lopez-Larraz, J. M. Antelis, A. G.-A. Luis Montesano y J. Minguez, «Continuous decoding of Motor Attempt and Motor Imagery from EEG Activity in Spinal Cord Injury Patients,» 2012 .
- [24] Facultad de Ciencias Exactas, Apuntes de Transformada Wavelet, Buenos Aires, 2006.
- [25] «Transformada wavelet continua,» [En línea]. Available: http://coco.ccu.uniovi.es/brahms/modelos_mat/twc.htm.
- [26] R. D. Reyes de Luna, Aplicación de la transformada wavelet en el análisis de calidad de la energía, México, D.F, 2009.
- [27] «Wikipedia - Ondícula,» [En línea]. Available: <http://es.wikipedia.org/wiki/Ond%C3%ADcula>.

A. Anexo de planificación

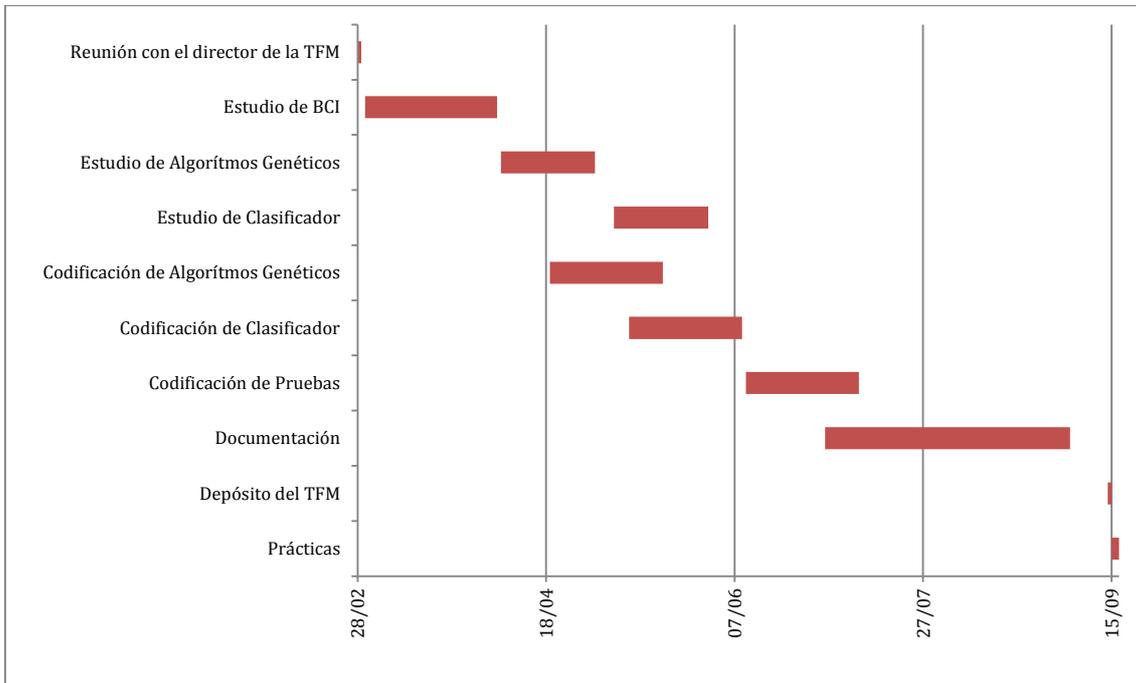


Ilustración 50 - Planificación de la TFM

Reunión con el director de la TFM

- Reunión con el director de la tesis de fin de master para hacer un esbozo de la finalidad a perseguir y marcar las líneas principales de las tareas a abordar.

Estudio de BCI

- Periodo de estudio de los sistemas Brain Computer Interface.

Estudio de Algoritmos Genéticos

- Periodo de estudio de los algoritmos genéticos

Estudio de Clasificador

- Periodo de estudio de los metodos de clasificación

Codificación de Algoritmos Genéticos

- Tiempo dedicado a codificar un algoritmo genético y adaptarlo a el sistema.

Codificación de Clasificador

- Tiempo a codificación del clasificador.

Codificación de Pruebas

- Tiempo a codificar la bateria de pruebas

Documentación

- Tiempo dedicado a documentar

Deposito del TFM

- Hito de depósito del proyecto

Prácticas

- Realización de las practicas de BCI

B. Anexo de funcionamiento básico de un sistema BCI

B.1. ¿Qué es un sistema BCI?

Cualquier sistema de comunicación que traduce las intenciones del usuario, registradas a partir de las señales eléctricas, magnéticas, térmicas o químicas que genera nuestro cerebro, en órdenes que son interpretadas y ejecutadas por una máquina o un ordenador [10]. De esta forma, un sistema BCI crea un nuevo canal que permite a los usuarios interactuar con su entorno únicamente mediante su actividad cerebral, sin utilizar por tanto el sistema nervioso periférico ni, en consecuencia, el sistema muscular [11].

B.2. Esquema general

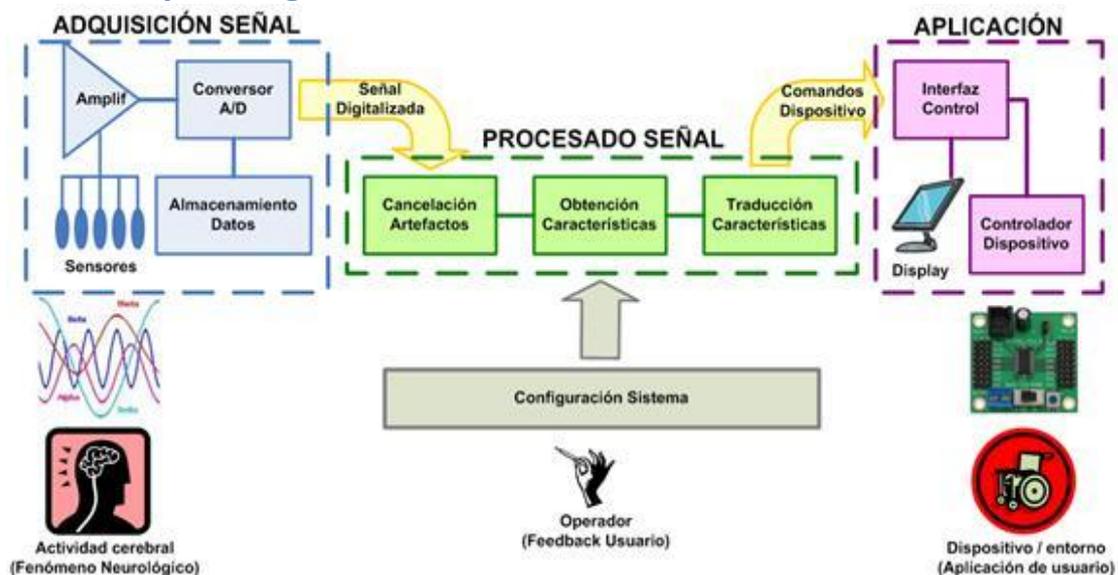


Ilustración 51 - Esquema genérico de un sistema BCI

Se distinguen 4 bloques funcionales

Adquisición de la señal

Bloque donde se adquiere la señal, se amplifica y se le realiza la conversión A/D. Normalmente los sistemas BCI trabajan a tiempo real, pero opcionalmente también se incluye la posibilidad de registrar la señal obtenida para un estudio posterior de ésta.

Ilustración 52 - Bloque de adquisición de un sistema BCI

Procesado de la señal

En ese bloque se extraen las características de interés de la señal digitalizada para que el dispositivo sobre el que el usuario está actuando sea capaz de interpretar sus órdenes.

Cancelación de artefactos

- Aquí se eliminan los ruidos que provienen de otras actividades bioeléctricas como los movimientos musculares (estas actividades se denominan artefactos) que distorsionan la señal. Algunos dispositivos consideran de utilidad las señales de los artefactos y no incluyen esta etapa.

Obtención de características

- Se traduce la señal de entrada en un vector de características en relación al fenómeno neurológico asociado a la señal.

Traducción de características

- Es donde se transforma el vector de características a una señal de control adecuada para el dispositivo que se quiere controlar

Ilustración 53 - Bloque de procesado de un sistema BCI

Aplicación

Es el bloque en el que se recibe la señal de control y realiza las acciones correspondientes en el dispositivo a través del controlador del mismo.

Configuración

Se permite al usuario definir los parámetros del sistema.

Ilustración 54 - Bloques de aplicación y configuración de un sistema BCI

La señal obtenida es de naturaleza limitada, da instrucciones del tipo “si/no” o “mueve arriba/abajo” adecuadas al dispositivo. [12]

C. Anexo de características usadas en sistemas BCI

C.1. Cálculo de la densidad espectral de potencia (PSD)

La PSD (*Power Spectral Density*), en castellano *densidad espectral de potencia*, nos informa como esta distribuida la potencia en la señal sobre las distintas frecuencias de las que esta formada [13] [14].

Una señal $x(t)$ es definida en potencia si su potencia media es finita, i.e, $0 < P_x < \infty$ y por tanto, su energía media es infinita, $E_x = \infty$

La PSD se calcula utilizando el teorema de Wiener-Khinchin [15] [16] [17], el cual relaciona la PSD con la transformada de Fourier de la función de autocorrelación.

$$S_{xx}(f) = TF\{R_{xx}(\tau)\} = \int_{-\infty}^{\infty} R_{xx}(\tau) e^{2\pi i f \tau} d\tau \text{ expresado en [W/Hz]}$$

Ecuación 4 - Densidad espectral de potencia

Donde TF significa Transformada de Fourier y R_{xx} es la función de autocorrelación de $x(t)$.

En 1967 Welch [18] propuso un método (Welch's Method) para aproximar a la PSD.

C.2. Los momentos espectrales de primer y segundo orden

Consiste en agrupar características obtenidas mediante la PSD [ver anexo C.1]. Vienen dados por las siguientes formulas

Calculo de los momentos espectrales de primer (M_1) y segundo (M_2) orden [8].

$$M_1 = \frac{\sum_{i=0}^N f_i PSD(i)}{\sum_{i=0}^N PSD(i)} \quad M_2 = \frac{\sum_{i=0}^N (f_i - \bar{f})^2 PSD(i)}{\sum_{i=0}^N PSD(i)}$$

Ecuación 5 - Momentos espectrales de primer y segundo orden

C.3. Potencia en una banda

Consiste en agrupar características obtenidas mediante la PSD [ver anexo C.1]. El valor de la potencia se obtiene como el área bajo el PSD entre las banda de frecuencia correspondiente [8].

$$P_{banda (a \text{ Hz} - b \text{ Hz})} = \int_{i \rightarrow f_i = b \text{ Hz}}^{i \rightarrow f_i = a \text{ Hz}} PSD(i)$$

Ecuación 6 - Potencia en una banda

D. Anexo de algoritmos genéticos

D.1. ¿Qué es un algoritmo genético?

Es un algoritmo matemático altamente paralelo

- Transforma un conjunto de objetos matemáticos individuales con respecto al tiempo usando operaciones modeladas de acuerdo al principio **Darwiniano**.
 - **Reproducción**
 - **Supervivencia del más apto**
- Tras haberse presentado de forma natural una serie de operaciones genéticas de entre las que destaca la **recombinación sexual**.

Cada uno de estos objetos matemáticos suele ser una cadena de caracteres (letras o números) de longitud fija que se ajusta al modelo de las cadenas de cromosomas, y se les asocia con una cierta función matemática que refleja su aptitud.

D.2. ¿Cómo saber si es posible usar el algoritmo genético?

Su espacio de búsqueda (i.e., sus posibles soluciones) debe estar delimitado dentro de un cierto rango.

Debe poderse definir una función de aptitud que nos indique qué tan buena o mala es una cierta respuesta.

Las soluciones deben codificarse de una forma que resulte relativamente fácil de implementar en la computadora.

D.3. La función de aptitud

No es más que la función objetivo de nuestro problema de optimización.

- El algoritmo genético únicamente maximiza.
- La minimización puede realizarse fácilmente utilizando el recíproco de la función maximizante.
- Una característica que debe tener esta función es que debe ser capaz de "castigar" a las malas soluciones, y de "premiar" a las buenas, de forma que sean estas últimas las que se propaguen con mayor rapidez.

D.4. Algoritmo

```

generar población inicial, G(0);
evaluar G(0);
t:=0;
repetir
    t:=t+1;
    generar G(t) usando G(t-1);
    evaluar G(t);
hasta encontrar una solución;

```

Primero, se genera aleatoriamente la población inicial.

Constituida por un conjunto de **cromosomas**

C=10100100 (cadena binaria = 1 cromosoma)

A cada uno de los cromosomas de esta población se le aplicará la función de aptitud a fin de saber qué tan buena es la solución que está codificando.

Sabiendo la aptitud de cada cromosoma, se procede a la **selección** de los que se cruzarán en la siguiente generación (presumiblemente, se escogerá a los "mejores").

D.5. Métodos de selección

Dos son los métodos de selección más comunes

- La Ruleta
- El torneo

D.5.1. La Ruleta

Este método es muy simple, y consiste en crear una ruleta en la que cada cromosoma tiene asignada una fracción proporcional a su aptitud.

Nº Cromosoma	Cadena	Aptitud	% del Total
1	11010110	254	24.5
2	10100111	47	4.5
3	00110110	457	44.1
4	01110010	194	18.7
5	11110010	85	8.2
Total		1037	100.0

Esta ruleta se gira 5 veces para determinar qué individuos se seleccionarán.

Debido a que a los individuos más aptos se les asignó un área mayor de la ruleta, se espera que sean seleccionados más veces que los menos aptos.



D.5.2. El torneo

Se baraja la población y después se hace competir a los cromosomas que la integran en grupos de tamaño predefinido (normalmente compiten en parejas) en un torneo del que resultarán ganadores aquéllos que tengan valores de aptitud más altos.

Si se efectúa un torneo binario (i.e., competencia por parejas), entonces la población se debe barajar 2 veces.

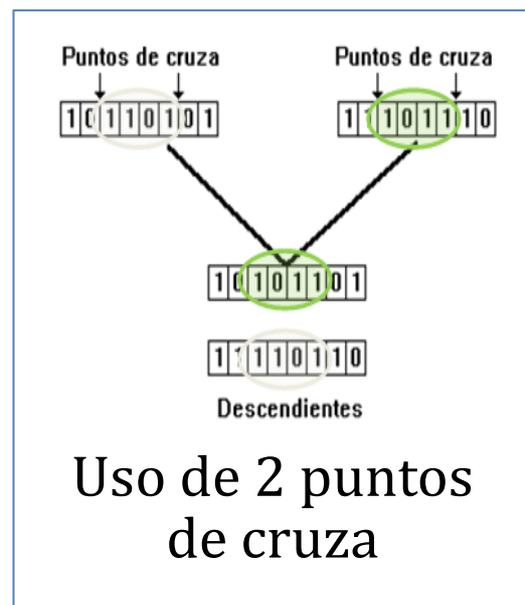
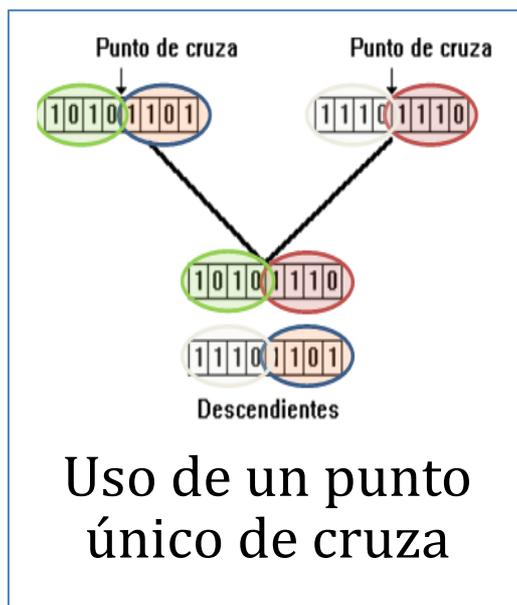
Nótese que esta técnica garantiza la obtención de múltiples copias del mejor individuo entre los progenitores de la siguiente generación (si se efectúa un torneo binario, el mejor individuo será seleccionado dos veces).

D.6. Recombinación sexual

Una vez realizada la selección, se procede a la **reproducción sexual** o cruce de los individuos seleccionados.

En esta etapa, los sobrevivientes intercambiarán material cromosómico y sus descendientes formarán la población de la siguiente generación.

Las dos formas más comunes de recombinación sexual son:



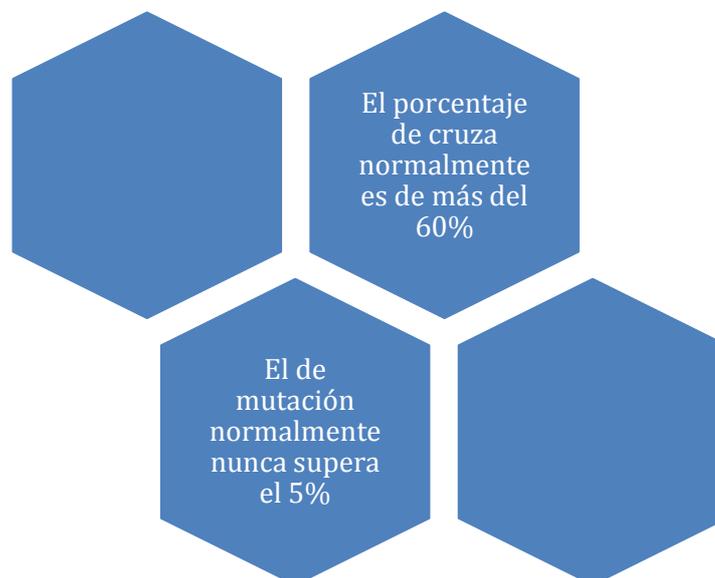
D.7. Mutación

Además de la selección y la cruce, existe otro operador llamado **mutación**, el cual realiza un cambio a uno de los genes de un cromosoma elegido aleatoriamente. Cuando se usa una representación binaria, el gene seleccionado se sustituye por su complemento.

Este operador permite la introducción de nuevo material cromosómico en la población, tal y como sucede con sus equivalentes biológicos.

Al igual que la cruce, la mutación se maneja como un porcentaje que indica con qué frecuencia se efectuará, aunque se distingue de la primera por ocurrir mucho más esporádicamente.

D.8. Configuración



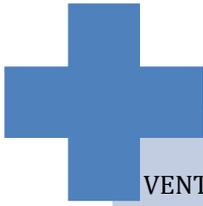
D.9. Detención

Si supiéramos la respuesta a la que debemos llegar de antemano, entonces detener el algoritmo genético sería algo trivial.

Sin embargo, eso casi nunca es posible, por lo que normalmente se usan dos criterios principales de detención:

- Correr el algoritmo genético durante un número máximo de generaciones.
- Detenerlo cuando la población se haya estabilizado (i.e., cuando todos o la mayoría de los individuos tengan la misma aptitud).

D.10. ¿Comparación con otras técnicas de búsqueda?



VENTAJAS

- No necesitan conocimientos específicos sobre el problema que intentan resolver.
- Operan de forma simultánea con varias soluciones, en vez de trabajar de forma secuencial como las técnicas tradicionales.
- Cuando se usan para problemas de optimización maximizar una función objetivo resulta menos afectados por los máximos locales (falsas soluciones) que las técnicas tradicionales.
- Resulta sumamente fácil ejecutarlos en las modernas arquitecturas masivas en paralelo.
- Usan operadores probabilísticos, en vez de los típicos operadores determinísticos de las otras técnicas.

DESVENTAJAS

- Pueden tardar mucho en converger, o no converger en absoluto, dependiendo en cierta medida de los parámetros que se utilicen - tamaño de la población, número de generaciones, etc.-.
- Pueden converger prematuramente debido a una serie de problemas de diversa índole.

E. Anexo de reconocimiento de patrones en sistemas BCI

El reconocimiento de patrones es la ciencia que se ocupa de los procesos sobre ingeniería, computación y matemáticas relacionados con objetos físicos o abstractos, con el propósito de extraer información que permita establecer propiedades de entre conjuntos de dichos objetos. [20]

E.1. Generalidades

Un sistema de reconocimiento de patrones completo consiste en un sensor, un sistema de extracción de características y un sistema de clasificación.

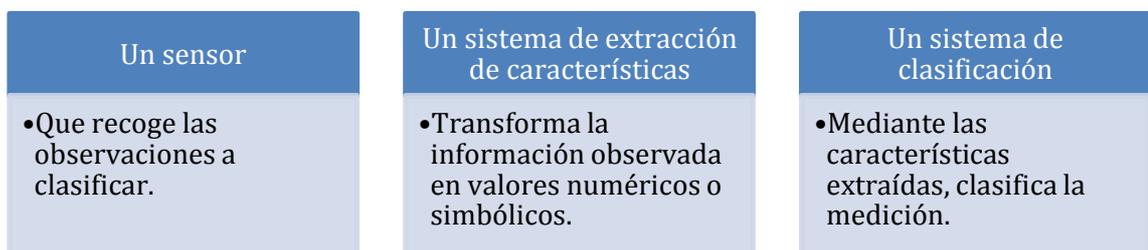


Ilustración 55 - Partes de un sistema de reconocimiento de patrones

El punto esencial del reconocimiento de patrones es la clasificación. Se quiere clasificar unos datos dependiendo de sus características.

El objetivo es asignar un patrón a la clase a la que pertenece lo más automáticamente posible.

Para el reconocimiento automático, es importante que:

- Patrones que describen objetos de una misma clase, presenten características similares.
- Patrones que describen objetos de diferentes clases presenten características diferenciadas.

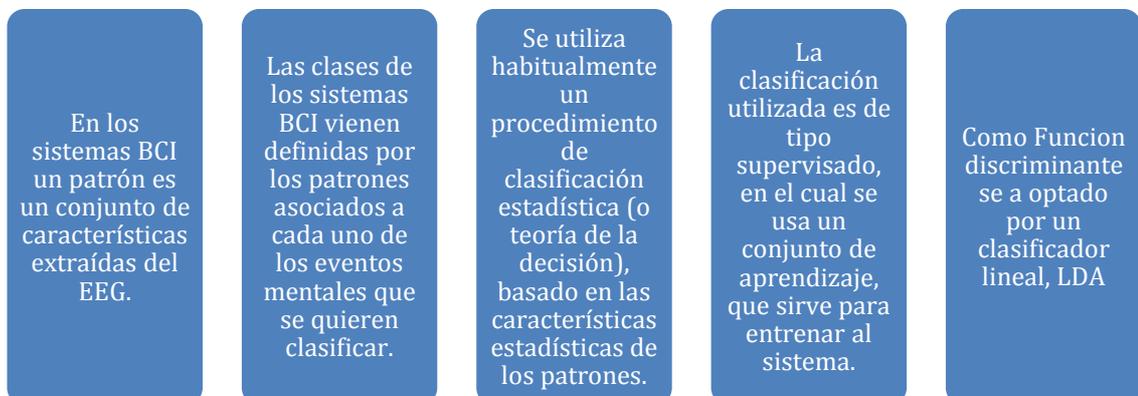


Ilustración 56 - Reconocimiento de patrones en sistemas BCI

E.2. Aprendizaje supervisado

El aprendizaje supervisado consiste en aprender una función, a partir de ejemplos etiquetados anteriormente (train), que establezca una correspondencia entre las entradas y las salidas deseadas del sistema. El sistema de aprendizaje trata de etiquetar (clasificación) una serie de vectores de características (test) utilizando una entre varias categorías (clases).

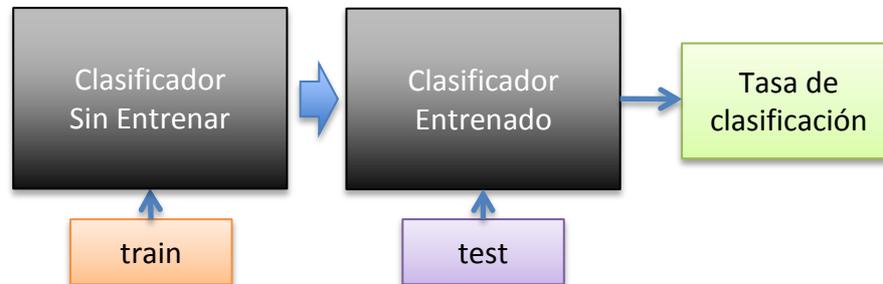


Ilustración 57 - Aprendizaje supervisado

Así pues existe:

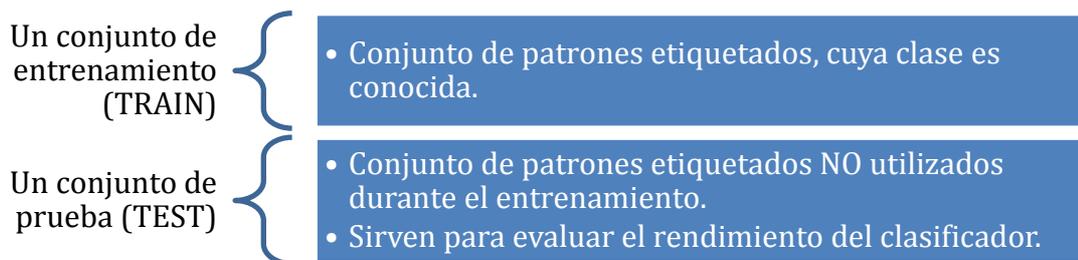


Ilustración 58 - Conjuntos de test y train

Mediante el conjunto de train se aprende la función discriminante. Y con el conjunto de test se la prueba.

E.3. Función discriminante

En el campo del aprendizaje automático, el objetivo del aprendizaje supervisado es usar las características de un objeto para identificar a qué clase (o grupo) pertenece.

Existen gran cantidad de funciones, pero en el presente proyecto se ha empleado una función LDA (Análisis discriminante lineal).

Un clasificador lineal logra esto tomando una decisión de clasificación basada en el valor de una combinación lineal de sus características. Las características de un objeto son típicamente presentadas en un vector llamado vector de características. [21]

E.4. Validación cruzada (cross-validation)

Es una técnica empleada para la validación de datos estadísticos, garantizando su independencia de la partición de los datos de entrenamiento y prueba. Consiste en promediar las diferentes evaluaciones [22].

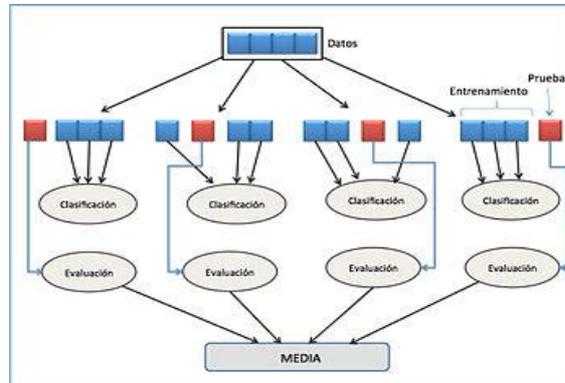


Ilustración 59 - Validación Cruzada

F. Anexo de prácticas

F.1. Motivación

La lesión de la médula espinal (SCI) se asocia a una reorganización del cerebro por una pérdida de la representación cortical. Este efecto es más pronunciado en el estado crónico, que suele aparecer aproximadamente 6 meses después de la lesión.

Muchas de las interfaces cerebro computador (BCI) desarrolladas hasta la fecha se basan en la actividad motora del usuario, la pérdida de esta actividad dificulta la aplicación de la tecnología BCI para la rehabilitación o la aplicación de una compensación motora en estos pacientes [23].

F.2. Objetivos

Abordar dos cuestiones:

- Si sigue siendo posible usar la tecnología BCI para detectar intención motor de la paralización de la mano en este estado de cronicidad.
- Si es mejor para la decodificación de BCI el confiar en el intento de motor o la imaginación motor de la mano como paradigma mental.

Dado que la realización de las prácticas se ha proyectado una vez transcurrido el depósito, el método y datos de las mismas serán detallados en la presentación de la presente TFM.