



Universidad
Zaragoza

Proyecto Fin de Carrera
Ingeniería en Informática

**Evaluación de técnicas de clasificación
para detección del movimiento a partir
de EEG**

Autor
Roldán Galán Lafarga

Director
Mauricio Antelis

Ponente
Luis Montesano del Campo

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

Fecha: Noviembre de 2012

Evaluación de técnicas de clasificación para detección del movimiento a partir de EEG

RESUMEN

El objetivo del presente proyecto ha sido evaluar diferentes técnicas de clasificación que permitan inferir, a partir de una actividad cerebral capturada con EEG, la detección e intención de movimiento en pacientes con hemiplejia. Este tipo de información es muy valiosa en terapias de rehabilitación ya que permite automatizar parte del tratamiento con prótesis robóticas y evaluar de una forma independiente y objetiva el grado de involucración del paciente en la tarea. Se enmarca dentro del proyecto CONSOLIDER HYPER, que investiga en el uso de técnicas de aprendizaje automático para el desarrollo de sistemas robóticos aplicados a la rehabilitación. El uso de estas técnicas resulta necesario debido a que las señales eléctricas obtenidas mediante los EEG suponen un enorme conjunto de datos con un espacio de dimensiones muy amplio para realizar análisis manual o por inspección visual.

En particular, se han estudiado dos aproximaciones diferentes para la clasificación del movimiento y de la intención del mismo. Por un lado, se han estudiado clasificadores del EEG para cada instante de tiempo independientemente (por puntos de trayectoria). Este tipo de técnicas son las más habituales en la mayoría de investigaciones de clasificación de señales capturadas por EEG, aunque debemos destacar que en su mayor parte se realizan sobre pacientes sanos. La novedad de este trabajo radica en su condición de haber sufrido un infarto cerebral, lo cual complica el análisis. Hemos seleccionado maquinas lineales como Análisis Discriminante (LDA) y no lineales como Máquinas de Soporte Vectorial (SVM). La segunda aproximación, menos habitual en el campo del EEG, se ha realizado analizando clasificadores que tienen en consideración información de la secuencia completa a analizar. Dentro de este área, nos hemos centrado en los el Modelo Oculto de Márkov (HMM) y en el Campo Aleatorio Condicional (CRF).

Hemos trabajado con ondas cerebrales, grabadas con anterioridad, correspondientes al movimiento y al reposo de pacientes que han sufrido infarto cerebral, estudiando los resultados tanto del lado con parálisis como del lado sano. En este proyecto se ha realizado la extracción de las características más adecuadas para, a continuación, evaluar la eficiencia de los distintos algoritmos de aprendizaje automático estudiados.

Índice

1. Introducción	7
1.1. Contexto y motivación	7
1.2. Objetivos	8
1.3. Herramientas	11
2. Descripción de los datos a estudiar	11
2.1. Captura de la señal	11
2.2. Tratamiento de la señal	12
2.2.1. Extracción de características	13
2.2.2. Muestreado de la señal	14
3. Clasificación del movimiento en señales capturadas por EEG	16
3.1. El problema de clasificación y etiquetado de secuencias	17
3.2. Validación cruzada de datos	18
3.3. Modelos estáticos	18
3.3.1. LDA - Análisis Discriminante Lineal	19
3.3.2. SVM - Máquina de Soporte Vectorial	20
3.4. Modelos dinámicos	21
3.4.1. HMM - Modelo Oculto de Márkov	21
3.4.2. CRF - Campo Aleatorio Condicional	25
4. Resultados	29
4.1. Definición de la organización de resultados	29
4.2. Subobjetivo 1: Clasificación de trayectoria completa	30
4.3. Subobjetivo 2: Clasificación por puntos de trayectoria	31
4.4. Caso específico: Córtez Sano	32
4.4.1. Evaluación de los modelos en clasificación por trayectoria completa	32
4.4.2. Comparación de los clasificadores por puntos de trayectoria	35
5. Conclusiones	36
Anexos	41
A. Captura y procesamiento de la señal	41
A.1. Sujetos	41
A.2. Protocolo de experimentación	42
A.3. Proceso de grabación	43
A.4. Procesado previo del EEG y del EMG	43
A.5. Tareas relacionadas con la modulación en potencia	44
A.6. Selección de características	44
B. Planificación	46
C. Resultados completos por modelo	47
C.1. LDA	48
C.2. SVM	54
C.3. HMM	62
C.4. CRF	75

Índice de figuras

1.	Representación de la onda capturada mediante EEG en diferentes canales correspondiente a un sujeto con brazo y córtex sano. Se han seleccionado los 48 canales que presentan más variabilidad entre reposo y movimiento.	8
2.	Representación de la onda capturada mediante EEG en diferentes canales correspondiente a un sujeto con brazo incapacitado y córtex dañado. Se han seleccionado los 8 canales que presentan más variabilidad entre reposo y movimiento.	9
3.	Sujeto en mitad de experimento. Se pueden apreciar los detectores EEG (en la cabeza) y EMG (en el brazo). Abajo a la izquierda, diagrama de la posición de los electrodos en el cráneo del sujeto.	12
4.	Gráfica r^2 mostrando la variabilidad de cada canal y frecuencia entre las dos condiciones. Por ejemplo, podemos ver que el canal C3 en F=20Hz presenta las mayores diferencias significativas. . .	13
5.	Ejemplo de discretización de la señal a intervalos de 0.25 segundos. La línea azul es la señal correspondiente a un canal en una de las frecuencias. Los puntos rojos representan los únicos valores utilizados para su decodificación que se utilizarían tras la discretización.	15
6.	Comparación de los diferentes tipos de submuestreado. La línea negra superior representa la señal completa. El tamaño del intervalo es i . Los triángulos representan los puntos de la señal que se toman individualmente. Los fragmentos verdes es el sistema por ventanas y los azules son las ventanas solapadas.	16
7.	Ejemplo de red HMM (fuente: contribución libre a la wikipedia)	22
8.	Izquierda: Representación gráfica de un HMM. Los nodos oscurecidos se corresponden con las observaciones $x_1, x_2 \dots x_n$. Los nodos claros a las variables estado $y_1, y_2 \dots y_n$. Derecha: Representación gráfica de un CRF. El nodo grande se corresponde con toda la secuencia X . Como en el HMM, los nodos claros se corresponden con las variables estado. Fuente [1]	26
9.	LDA en clasificación por trayectoria completa	33
10.	SVM en clasificación por trayectoria completa	33
11.	HMM en clasificación por trayectoria completa	34
12.	CRF en clasificación por trayectoria completa	34
13.	Sujeto en mitad de experimento. Se pueden apreciar los detectores EEG (en la cabeza) y EMG (en el brazo). Abajo a la izquierda, diagrama de la posición de los electrodos en el cráneo del sujeto.	42
14.	Esquema donde se aprecia la secuencia de estados <i>rest</i> (descanso) y <i>reaching movement</i> (movimiento).	44

Índice de cuadros

1.	Canales y frecuencias con mayor variabilidad en el movimiento por cada sujeto para el córtex sano. En negrita, encabezando cada lista, el canal identificado como mejor.	14
----	--	----

2.	Canales y frecuencias con mayor variabilidad en el movimiento por cada sujeto para el córtex dañado. En negrita, encabezando cada lista, el canal identificado como mejor.	15
3.	Formato de la matriz de transición de estados del HMM.	23
4.	Comparación de los mejores resultados de los cuatro modelos bajo las cuatro condiciones de córtex y brazos para la clasificación de trayectoria completa. Todos los valores son porcentajes calculados con la media de todos los sujetos.	30
5.	Comparación de los mejores resultados de los cuatro modelos bajo las cuatro condiciones de córtex y brazos para la clasificación por puntos de trayectoria. Todos los valores son porcentajes calculados con la media de todos los sujetos.	31
6.	Comparación en porcentaje de aciertos para diferentes retardos (en segundos) - Arm Healthy Cortex Healthy - Todos los canales	36
7.	Comparación en porcentaje de aciertos para diferentes retardos (en segundos) - Arm Impaired Cortex Healthy - Modelos con todos los canales, excepto la segunda columna de HMM (indicado con asterisco) debido a la mejora de clasificación con un único canal.	36
8.	LDA - Arm Healthy Cortex Healthy - Mejor canal	48
9.	LDA - Arm Healthy Cortex Healthy - Todos los mejores canales	48
10.	LDA - Arm Impaired Cortex Healthy - Mejor canal	49
11.	LDA - Arm Impaired Cortex Healthy - Todos los mejores canales	49
12.	LDA - Arm Healthy Cortex Injured - Mejor canal	50
13.	LDA - Arm Healthy Cortex Injured - Todos los mejores canales .	51
14.	LDA - Arm Impaired Cortex Injured - Mejor canal	52
15.	LDA - Arm Impaired Cortex Injured - Todos los mejores canales	53
16.	SVM - Arm Healthy Cortex Healthy - Mejor canal	54
17.	SVM - Arm Healthy Cortex Healthy - Todos los mejores canales	54
18.	SVM - Arm Impaired Cortex Healthy - Mejor canal	55
19.	SVM - Arm Impaired Cortex Healthy - Todos los mejores canales	55
20.	SVM - Arm Healthy Cortex Injured - Mejor canal	56
21.	SVM - Arm Healthy Cortex Injured - Todos los mejores canales .	56
22.	SVM - Arm Impaired Cortex Injured - Mejor canal	57
23.	SVM - Arm Impaired Cortex Injured - Todos los mejores canales	57
24.	SVM (train 0.75 - test variado) - Arm Healthy Cortex Healthy - Mejor canal	58
25.	SVM (train 0.75 - test variado) - Arm Healthy Cortex Healthy - Todos los mejores canales	58
26.	SVM (train 0.75 - test variado) - Arm Impaired Cortex Healthy - Mejor canal	59
27.	SVM (train 0.75 - test variado) - Arm Impaired Cortex Healthy - Todos los mejores canales	59
28.	SVM (train 0.75 - test variado) - Arm Healthy Cortex Injured - Mejor canal	60
29.	SVM (train 0.75 - test variado) - Arm Healthy Cortex Injured - Todos los mejores canales	60
30.	SVM (train 0.75 - test variado) - Arm Impaired Cortex Injured - Mejor canal	61
31.	SVM (train 0.75 - test variado) - Arm Impaired Cortex Injured - Todos los mejores canales	61

32.	HMM - Arm Healthy Cortex Healthy - Mejor canal	62
33.	HMM - Arm Healthy Cortex Healthy - Todos los mejores canales	62
34.	HMM - Arm Impaired Cortex Healthy - Mejor canal	63
35.	HMM - Arm Impaired Cortex Healthy - Todos los mejores canales	63
36.	HMM - Arm Healthy Cortex Injured - Mejor canal	64
37.	HMM - Arm Healthy Cortex Injured - Todos los mejores canales	65
38.	HMM - Arm Impaired Cortex Injured - Mejor canal	66
39.	HMM - Arm Impaired Cortex Injured - Todos los mejores canales	67
40.	HMM - Arm Healthy Cortex Healthy - Mejor canal - Viterbi . .	68
41.	HMM - Arm Healthy Cortex Healthy - Todos los mejores canales - Viterbi	69
42.	HMM - Arm Impaired Cortex Healthy - Mejor canal - Viterbi . .	69
43.	HMM - Arm Impaired Cortex Healthy - Todos los mejores canales - Viterbi	70
44.	HMM - Arm Healthy Cortex Injured - Mejor canal - Viterbi . .	71
45.	HMM - Arm Healthy Cortex Injured- Todos los mejores canales - Viterbi	72
46.	HMM - Arm Impaired Cortex Injured - Mejor canal - Viterbi . .	73
47.	HMM - Arm Impaired Cortex Injured- Todos los mejores canales - Viterbi	74
48.	CRF - Arm Healthy Cortex Healthy - Mejor canal	75
49.	CRF - Arm Healthy Cortex Healthy - Todos los mejores canales	75
50.	CRF - Arm Impaired Cortex Healthy - Mejor canal	76
51.	CRF - Arm Impaired Cortex Healthy - Todos los mejores canales	76
52.	CRF - ArmHealthy CortexInjured - Mejor canal	77
53.	CRF - ArmHealthy CortexInjured - Todos los mejores canales . .	77
54.	CRF - ArmImpaired CortexInjured 1Ch CRF	77
55.	CRF - ArmImpaired CortexInjured - Todos los mejores canales .	77
56.	CRF - Arm Healthy Cortex Healthy - Mejor canal - Viterbi . .	78
57.	CRF - Arm Healthy Cortex Healthy - Todos los mejores canales - Viterbi	78
58.	CRF - Arm Impaired Cortex Healthy - Mejor canal - Viterbi . .	79
59.	CRF - Arm Impaired Cortex Healthy - Todos los mejores canales - Viterbi	79
60.	CRF - ArmHealthy CortexInjured - Mejor canal - Viterbi . . .	80
61.	CRF - ArmHealthy CortexInjured - Todos los mejores canales - Viterbi	80
62.	CRF - ArmImpaired CortexInjured - Mejor canal - Viterbi . . .	80
63.	CRF - ArmImpaired CortexInjured - Todos los mejores canales - Viterbi	80

1. Introducción

1.1. Contexto y motivación

Las interfaces cerebro-ordenador, en adelante BCI (del inglés *Brain-Computer Interfaces*), son una tecnología que permite la comunicación directa entre una máquina y una persona mediante la captura de las señales eléctricas generadas por el cerebro. A la hora de leer estas ondas existen varias aproximaciones, dos de las más habituales son: los dispositivos invasivos, en los que se introducen los electrodos en el propio cerebro mediante intervención quirúrgica obteniendo una electrocorticografía (ECoG); y los no invasivos, donde la actividad eléctrica se realiza desde el exterior mediante un electroencefalograma (EEG). En el primer tipo la señal es mucho más clara y se puede conseguir mayor precisión, pero a cambio supone más riesgos al precisar de una operación. Los métodos no invasivos, a pesar de tener una peor resolución por la distorsión que supone el cráneo, son los que se prefieren en la experimentación con humanos debido a su simplicidad y para eludir los posibles riesgos inherentes a una intervención.

El grupo de Robótica de la Universidad de Zaragoza está inmerso desde hace unos años en la investigación y aplicación de técnicas BCI orientadas a la rehabilitación. En la actualidad participan en el proyecto CONSOLIDER-HYPER. Este proyecto intenta avanzar en la investigación de aparatos neurorobóticos (NR) y prótesis neuronales motorizadas (MNP), tanto para rehabilitación como para recuperar la funcionalidad de los desórdenes motores en la actividades cotidianas. Los NR son prótesis robóticas que realizan el movimiento por sí mismas y las NRP son un sistema capaz de electro-estimular los músculos del sujeto en el que están implantadas para efectuar el movimiento. Dicho proyecto centra sus actividades en nuevos implantes NR-MNP, que combinen estructuras biológicas y artificiales para mejorar las grandes limitaciones de las actuales soluciones de rehabilitación para los casos particulares de accidentes cerebro-vasculares, parálisis cerebral y lesión de médula espinal.

Las personas que han sufrido infartos cerebrales y padecen daños severos en un hemisferio del cerebro pueden perder la movilidad de un lado del cuerpo pese a continuar teniendo los músculos en perfectas condiciones. En estos casos, es posible volver a mover las extremidades aprendiendo de nuevo con el córtex cerebral sano, para lo cual se requieren unas largas sesiones de rehabilitación. Para el terapeuta encargado de esta rehabilitación disponer de una herramienta que permita conocer el involucramiento real del paciente, y si realmente está enviando las órdenes adecuadas desde el cerebro, es una información de incalculable valor. El presente proyecto analiza diferentes modelos matemáticos de clasificación para encontrar cuáles serán los más apropiados para construir estas herramientas de asistencia en la rehabilitación.

1.2. Objetivos

Las señales eléctricas obtenidas mediante los EEG suponen un enorme conjunto de datos con un espacio de dimensiones tan amplio que hace muy compleja la realización un análisis manual o por inspección visual en busca de las características que permitan diferenciar las diferentes acciones que las producen. Normalmente lo que se hace es aplicar técnicas de procesado de la señal para extraer las características para clasificación y la detección de comandos. Una de las dificultades que presentan es que estas señales son no estacionarias, es decir, varían con el tiempo, lo que dificulta su análisis. También contienen una gran cantidad de ruido –producido, por ejemplo, por otra actividad muscular o cerebral distinta a la que se trata de encontrar– presentando mucha variabilidad. Por todo ello se aplican algoritmos de aprendizaje automático que sean capaces de extraer la información adecuada a la hora de tratar la señal para decodificarla correctamente.

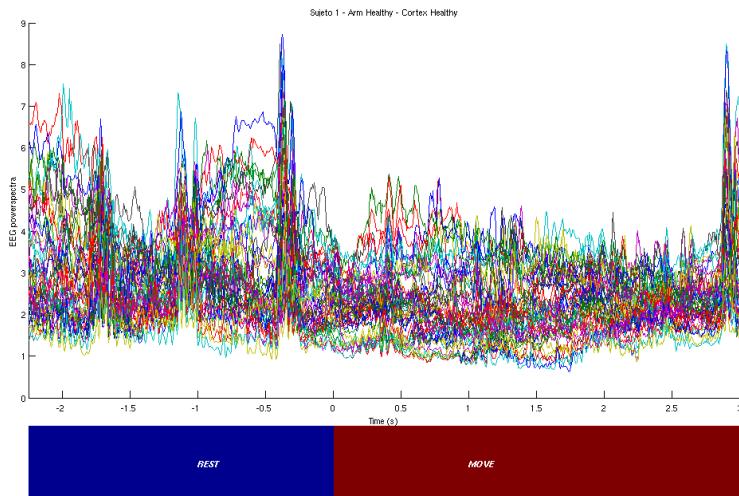


Figura 1: Representación de la onda capturada mediante EEG en diferentes canales correspondiente a un sujeto con brazo y córtex sano. Se han seleccionado los 48 canales que presentan más variabilidad entre reposo y movimiento.

En nuestro proyecto trabajamos con ondas cerebrales correspondientes al movimiento y al reposo de pacientes que hayan sufrido infarto cerebral, estudiando los resultados tanto del lado con parálisis como del lado sano. Además de la complejidad antes reseñada, en este ámbito se complica más debido al estado de los pacientes: no sólo tienen un brazo prácticamente incapacitado y que apenas pueden mover (motivo por el cual necesitan tareas de rehabilitación), sino que además el córtex dañado presenta una actividad más irregular que uno sano. En las imágenes 1 y 2 se puede ver un ejemplo de cómo son estas señales que se pretenden clasificar, donde se puede apreciar la enorme cantidad de ruido y la dificultad de discriminar el movimiento a partir de esta información.

La figura 1 se corresponde con una selección de canales del córtex sano y la figura 2 corresponda a canales del córtex dañado (en la sección 2.2.1 se explica por qué hay distinto número de canales en cada imagen, lo cual todavía no nos interesa detallar).

Dado que las BCI son un campo relativamente reciente, todavía no se ha determinado qué modelos de aprendizaje automático –de todas las de aproximaciones que existen– son los más adecuados para decodificar el electroencefalograma que se produce durante el movimiento de los brazos en pacientes con infarto cerebral. Es por ello que en este trabajo nos centraremos en la capacidad de algunos modelos para diferenciar correctamente las ondas cerebrales para ambos estados, estudiando los resultados tanto del lado con parálisis como del lado sano. Estamos interesados en evaluar, por un lado, el porcentaje de aciertos de cada modelo y, por otro, en el tiempo requerido para llevar a cabo correctamente esta clasificación. Esta importancia en la latencia en la detección del cambio del reposo al movimiento se debe a que esta información podría ser utilizada como asistencia en tareas de rehabilitación. Esto significa que el modelo podría ser la parte que tome las decisiones de rehabilitación en tiempo real en un aparato neurorobótico o de una prótesis neuronal motorizada. Por lo tanto, de existir demasiada latencia en la clasificación, el robot tendría un retardo que imposibilitaría sus funciones.

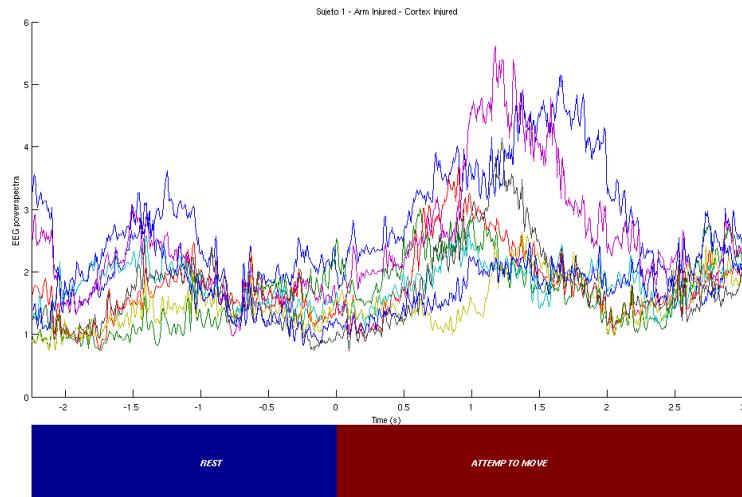


Figura 2: Representación de la onda capturada mediante EEG en diferentes canales correspondiente a un sujeto con brazo incapacitado y córtex dañado. Se han seleccionado los 8 canales que presentan más variabilidad entre reposo y movimiento.

Para decodificar correctamente las señales que genera la actividad cerebral durante el movimiento, en el presente estudio se analizarán diferentes modelos de aprendizaje automático. Algunas de estas técnicas (LDA y SVM) son las más habituales en el campo de los EEG (véase [2]), y por ello representarán

el primer paso para estudiar cómo se comportan estos modelos cuando el EEG representa la actividad cerebral de pacientes con hemiplejia. En estas técnicas se clasifica la señal para cada instante de tiempo independientemente, por lo que una observación se clasificará en una misma categoría sin importar su posición o qué otras observaciones tiene a su alrededor. A este tipo de clasificación la denominaremos **estática** en contraposición al siguiente tipo que vamos a proceder a describir.

Las técnicas novedosas en el análisis de señales obtenidas por EEG, pero de reconocido uso en otros campos, serán los modelos en grafo basados en la propiedad de Márkov. Estos modelos (CRF y HMM), a diferencia de los anteriores, a la hora de clasificar no sólo utilizan la señal observada en un instante determinado, sino que tienen en cuenta el orden de la secuencia. Dado que se espera que la señal obtenida en un cierto instante esté relacionada con el resto de ondas vecinas, estas técnicas de clasificación deberían obtener mejores resultados que las que son independientes del tiempo. A lo largo de este trabajo nos referiremos a estos tipos de clasificación como **dinámicos** para resaltar este comportamiento en el que una misma observación se clasificaría en categorías distintas en función del momento en que se observe.

De este modo distinguiremos dos tipos de situaciones bien diferenciadas para analizar la clasificación del movimiento. Por un lado partiremos del hecho de que poseemos la señal completa EEG realizada en los experimentos y la utilizaremos en su totalidad. A este tipo de análisis lo denominaremos *clasificación de la trayectoria completa*, y sólo se puede ejecutar con posterioridad a la obtención total de la señal. Por otro lado, simularemos la gradual adquisición de la señal que se daría en condiciones reales de rehabilitación, de modo que no se dispondrá desde el principio de la clasificación de la señal EEG completa. Esto, como veremos más adelante en la descripción matemática de los modelos dinámicos, supone una diferencia sustancial en la clasificación. A esta última metodología la denominaremos *clasificación por puntos de trayectoria* y nos gustaría enfatizar que su ejecución sería equivalente a decodificar la señal en tiempo real mientras se está realizando el experimento.

Para sintetizar, podemos ver en la siguiente lista los objetivos que nos planteamos resolver en este trabajo:

Objetivo: Clasificación del movimiento en pacientes que hayan sufrido infarto cerebral mediante el análisis de la actividad cerebral capturada por EEG.

Subobjetivo 1: Clasificación de la trayectoria completa para evaluación de los modelos matemáticos. Se asumirá que se dispone de la señal completa en el momento de clasificarla.

Subobjetivo 2: Clasificación por puntos de trayectoria para utilización en rehabilitación. Se simulará utilizando en cada instante de tiempo el subconjunto de la señal que se dispondría en condiciones reales.

1.3. Herramientas

Para la elaboración de este análisis se ha seleccionado el lenguaje de programación Matlab ya que el grupo de la Universidad de Zaragoza con el que se colabora ya está utilizando este lenguaje, por lo que todos los archivos con los que se va a trabajar están en este formato y esto facilitará el intercambio de resultados. El tipo de datos básico de Matlab es la matriz, siendo casi todo su conjunto de instrucciones vectorial y, puesto que vamos a trabajar con enormes cantidades de datos en formato matricial a las que deberemos aplicar operaciones como normalización, filtrados, etc., este lenguaje supondrá una gran ayuda a la hora de programar. Exactamente trabajaremos con la versión R2011a.

Dado lo extenso y complejo que supondría desarrollar nuestras propias herramientas para cada una de estas técnicas de clasificación, en cuyo caso nos tendríamos que limitar a una o dos de ellas y no podríamos realizar una comparación detallada entre tantos modelos, se han buscado librerías que las implementen para uso en el propio Matlab y cuyos detalles se especificarán más adelante. Sus nombres son: libSVM, pmtk3 y HCRF2.0b. Para LDA no se utilizan librerías externas ya que el propio Matlab en su *Statistics ToolBox* incluye el código necesario para generar este modelo. Así, durante la fase de documentación para iniciar el proyecto, además de estudiar y comprender los modelos de clasificación a estudiar, se tuvieron que buscar las librerías adecuadas y probarlas hasta entender su funcionamiento.

En el anexo B se puede consultar una descripción en detalle de la planificación seguida en la elaboración de este proyecto.

2. Descripción de los datos a estudiar

2.1. Captura de la señal

La obtención de datos para este análisis se realizó sobre pacientes con hemiplejia producida por haber sufrido un infarto cerebral. El protocolo completo de experimentación más detallado puede verse en el anexo A ya que no se llevó a cabo en este trabajo, pero en esta sección se explica lo fundamental para entender el contexto de la memoria.

La grabación de la señal EEG se realiza a través de 64 electrodos situados en el cráneo del sujeto. La detección del movimiento se realiza mediante detectores de movimiento (EMG) y se verifica mediante inspección visual posterior, ya que todos los experimentos se graban en vídeo. En la imagen 3 se puede observar una fotografía obtenida en mitad de uno de los experimentos y un esquema de la situación en la cabeza de dichos electrodos.

Se realizaron dos experimentos equivalentes, uno en el que el paciente ejecutaba las acciones con el brazo sano, y otro en el que intentaba realizarlas con el

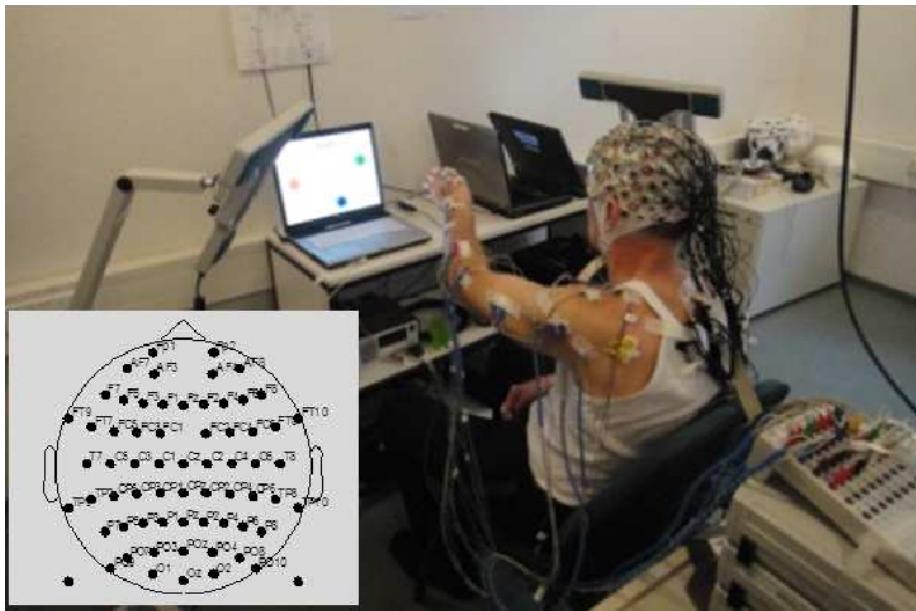


Figura 3: Sujeto en mitad de experimento. Se pueden apreciar los detectores EEG (en la cabeza) y EMG (en el brazo). Abajo a la izquierda, diagrama de la posición de los electrodos en el cráneo del sujeto.

brazo dañado. En ambos casos se grabaron al mismo tiempo las ondas generadas por cada córtex cerebral junto con la información generada por los detectores situados en el brazo. Una vez finalizados, se extrajo la señal de ambos experimentos separando en cada paciente las cuatro combinaciones posibles (Brazo Sano—Córtex Sano, Brazo Sano—Córtex Dañado, Brazo Dañado—Córtex Sano, Brazo Dañado—Córtex Dañado). Será a partir de estos cuatro conjuntos de datos sobre los que se analizarán los diferentes modelos de clasificación.

El experimento se ejecutó en cuatro bloques de seis minutos cada uno, con cuarenta ejercicios por bloque, resultando un total de 160 ensayos (80 con cada brazo). Después de cada bloque el paciente podía descansar tanto como fuera necesario para evitar la fatiga. Cada grabación de EEG y EMG tiene una duración de nueve segundos, utilizando una referencia de tiempo desde los segundos -3 a 6 con respecto a la aparición de la segunda señal (inicio del movimiento), por lo que éste comienza en el instante cero. El movimiento se realiza en los tres primeros segundos después del cero, mientras que los tres últimos son para la relajación del sujeto y se descartan.

2.2. Tratamiento de la señal

La señal, tal y como se lee mediante EEG no es directamente utilizable, ya que es conveniente realizar un procesado previo para aprovechar mejor determinadas características que faciliten identificar el movimiento y el reposo.

2.2.1. Extracción de características

En nuestros modelos matemáticos la información que se ha de analizar (variables independientes) para determinar si se trata de movimiento o reposo van a ser el conjunto de señales capturadas por EEG obtenidas en el experimento descrito en la sección anterior. Pese a capturar la actividad cerebral mediante 64 electrodos (canales), sería impensable utilizarlos todos; no sólo por la enorme cantidad, que los haría intratables, sino porque las zonas del córtex que no controlan directamente la actividad motora no contienen información relevante para tratar nuestro problema, de forma que añadirían un ruido innecesario que dificultaría la decodificación. Por ello, para cada sujeto es necesario realizar una selección de los canales que presentan variaciones más significativas entre reposo y movimiento.

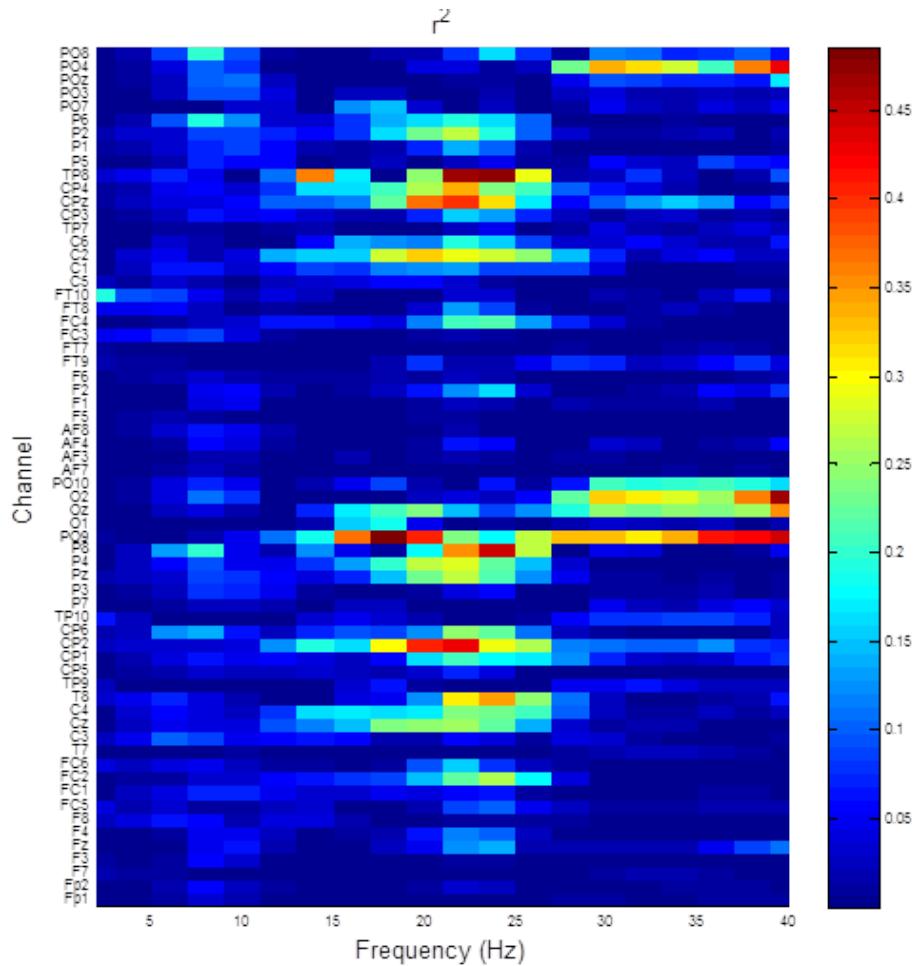


Figura 4: Gráfica r^2 mostrando la variabilidad de cada canal y frecuencia entre las dos condiciones. Por ejemplo, podemos ver que el canal C3 en $F=20\text{Hz}$ presenta las mayores diferencias significativas.

Una vez finalizados dichos experimentos, y con la señal ya grabada, se le aplicaron varios filtros para suavizar el ruido. Después se aplica una transformada *wavelet* para calcular la potencia espectral en cada banda de frecuencia para cada canal (véase el anexo A para más detalle). Una vez se tiene la señal convertida al dominio de la frecuencia se pasa a realizar un análisis r^2 entre las señales del estado de reposo y de movimiento para determinar qué canales y en qué frecuencias presentan más variabilidad. Este análisis se realiza de forma independiente para cada sujeto y con cada condición (córtez sano y córtex dañado). Se puede ver un ejemplo de este análisis en la imagen 4. Aunque algunos canales se comparten entre diversos sujetos –a fin de cuentas, todos están centrados en la zona del córtex que ejecuta la actividad motora del brazo–, cada uno de ellos tiene su propia selección que no tiene por qué coincidir con el resto.

Además, para cada sujeto se seleccionó un único canal que era el que tenía la variación más significativa de todos ellos. Cuando realicemos nuestra comparativa de de modelos de aprendizaje efectuaremos dos análisis independientes, uno utilizando esta selección de varios canales, y otro utilizando únicamente el mejor (con todas sus frecuencias). El objetivo de utilizar un sólo canal es descubrir si alguno de los otros que no presentan tanta variabilidad como éste puedan estar añadiendo ruido que pueda inducir a una incorrecta clasificación.

A continuación vamos a detallar, para cada sujeto, cuáles son los canales y las frecuencias que se han seleccionado, en los que se presentaba una mayor variabilidad estadística a fin de facilitar la decodificación de la señal. Primero vemos la tabla con los canales y las frecuencias seleccionados cuando decodificamos la señal generada por el córtex sano y, después, los correspondientes al córtex dañado. El primer canal de cada enumeración se trata del que se ha identificado como el mejor para ese sujeto.

<i>Sujeto</i>	<i>Canales</i>	<i>Frecuencias (Hz)</i>
41	C2 , Cz, C4, CP2, P4, CPz, CP4, P2	12, 14, 16, 22, 24, 26
42	C1 , C3, Cz, CP2, P3, CPz, CP4, P2	12, 18
43	CP2 , Cz, C4, P4, C2, CPz, CP4, P2	20, 22, 24
44	CP1 , CP2, C1, CP3	16, 20
45	CP2 , Cz, C4, P4, C2, CPz, CP4, P2	18, 20
46	C3 , Cz, CP3	12, 16, 22

Cuadro 1: *Canales y frecuencias con mayor variabilidad en el movimiento por cada sujeto para el córtex sano. En negrita, encabezando cada lista, el canal identificado como mejor.*

2.2.2. Muestreado de la señal

Una vez hemos filtrado y seleccionado las características principales de la señal, tenemos las ondas EEG ya dispuestas para su inmediato análisis, con un marcador indicando el inicio del movimiento. Cada muestra dura aproximadamente 5.25 segundos que, con una frecuencia de muestreo de 160 Hz, resulta

Sujeto	Canales	Frecuencias (Hz)
41	C1, C3, CP1, CP3	20, 22
42	C2, C4, CP2, CP4	12, 18
43	CP1, C3, C1, CP3	20, 22, 24
44	C2, C4	16, 20
45	CP1, C3, C1, CP3	18, 20
46	C4, C2	12, 16, 22

Cuadro 2: Canales y frecuencias con mayor variabilidad en el movimiento por cada sujeto para el córtex dañado. En negrita, encabezando cada lista, el canal identificado como mejor.

en un total de 840 lecturas para cada electrodo (y que finalmente tenemos en los canales para cada frecuencia). Tratar una cantidad tan grande de datos es muy costoso computacionalmente con algunos modelos (principalmente SVM y CRF), por lo que se requiere discretizar la señal para trabajar con unos conjuntos más reducidos.

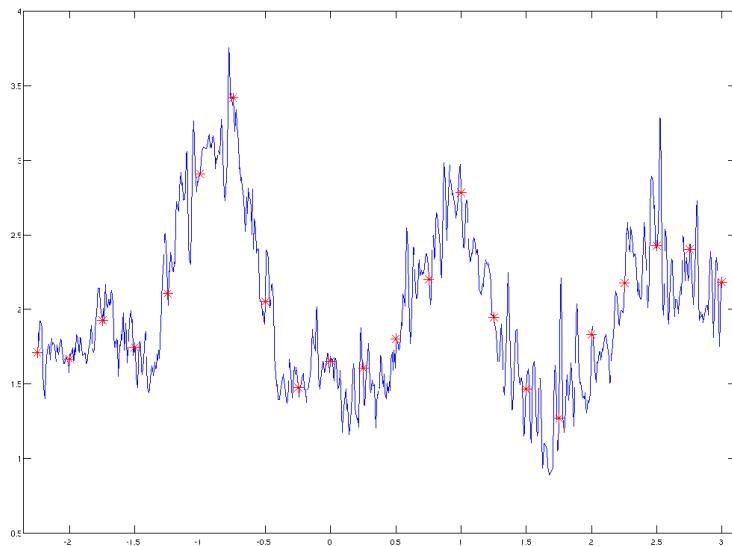


Figura 5: Ejemplo de discretización de la señal a intervalos de 0.25 segundos. La línea azul es la señal correspondiente a un canal en una de las frecuencias. Los puntos rojos representan los únicos valores utilizados para su decodificación que se utilizarían tras la discretización.

Es por ello que se realizará un subsampleo, tomando muestras cada distintos intervalos de tiempo. En la imagen 5 se puede apreciar un ejemplo con una señal real discretizada a intervalos de 0.25 segundos, los cuales están marcados con asteriscos rojos sobre la señal completa en azul (esta señal, real, representa los valores de un único canal en una banda de frecuencia). Esos asteriscos repre-

sentan los únicos puntos que se considerarían de la señal completa a la hora de evaluar los clasificadores.

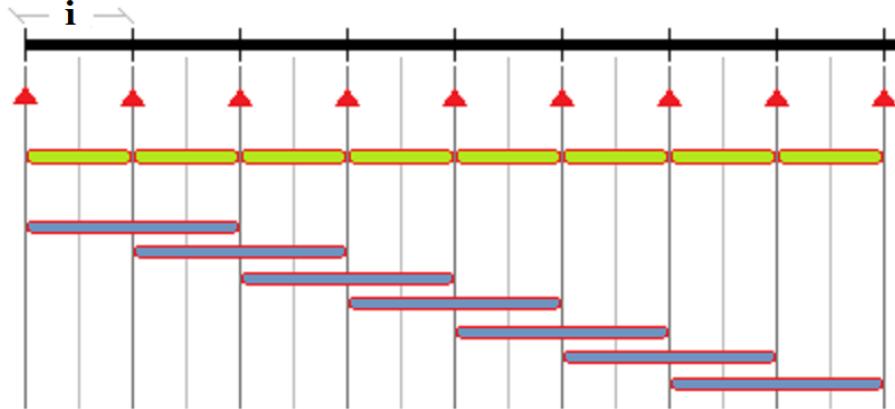


Figura 6: Comparación de los diferentes tipos de submuestreo. La línea negra superior representa la señal completa. El tamaño del intervalo es i . Los triángulos representan los puntos de la señal que se toman individualmente. Los fragmentos verdes es el sistema por ventanas y los azules son las ventanas solapadas.

Ahora bien, esta reducción de la señal se ha realizado desde tres puntos de vista diferentes. Por un lado, tomando los puntos independientemente a cada intervalo i . Por otro, tomando toda la señal en la ventana entre dos puntos consecutivos y calculando la media, así para el punto t se toma toda la secuencia hasta $t + i$. El último punto también calcula la media sobre una ventana, pero en este caso es de mayor tamaño y se va solapando con la última mitad de la anterior, de forma que los datos se utilizan en dos ventanas consecutivas, tomando para el punto t la ventana desde $t - 1$ hasta $t + 1$. En la imagen 6 puede verse una representación gráfica de estos sistemas que denominaremos, respectivamente, por puntos, por ventanas y por ventanas solapadas.

Los otros modelos (LDA y HMM) permiten utilizar toda la señal, pero también se han evaluado sus capacidades utilizando estos submuestreos, porque al hacer la media de diferentes fragmentos de la señal en lugar de utilizarla punto a punto, en realidad se está considerando más información y su comportamiento ha de cambiar, ya que aglutina información de una secuencia de observaciones.

3. Clasificación del movimiento en señales capturadas por EEG

En esta sección se describen los métodos utilizados para clasificación de la señal EEG en movimiento o reposo. Para ello se utilizan las características extraídas de la señal descritas en la sección anterior y se comparan diferentes métodos de aprendizaje supervisado con el fin de evaluar cuáles son los más

apropiados para identificar el movimiento de los brazos en pacientes que hayan sufrido una hemiplejia.

Con el propósito de alcanzar estos objetivos, primero describiremos formalmente el problema de etiquetar un conjunto de datos bajo diferentes categorías. A continuación fundamentaremos cómo utilizar este reducido conjunto de datos de forma que se aprovechen al máximo mediante la validación cruzada. Para terminar, modelaremos matemáticamente cada uno de los métodos a analizar, describiendo sus características más importantes y cómo las hemos utilizado y explotado en el marco de nuestra investigación.

3.1. El problema de clasificación y etiquetado de secuencias

En los campos de la estadística y la inteligencia artificial el **problema de clasificación** es dilema muy recurrente y que, pese a parecer muy simple de definir, tiene multitud de soluciones y variantes. Se parte de una serie de n observaciones $X = x_1, \dots, x_n$ que se corresponden con dos o más categorías pertenecientes al conjunto finito Υ . Consiste en encontrar una función $f(x)$ que pueda asignar a cada nueva observación x'_i la etiqueta correcta $y_i \in \Upsilon$. Cada x_i puede ser una única variable o un número arbitrario d de ellas, bien discretas o continuas, que se denominan variables independientes.

De entre los diferentes modelos que permiten calcular la $f(x)$, en esta investigación vamos a estudiar el Análisis Discriminante Lineal (LDA) y las Máquinas de Soporte Vectorial (SVM), los cuales describiremos en detalle más adelante.

El **etiquetado de secuencias** es un caso particular del problema de clasificación en el que, en lugar de clasificar cada x_i de forma independiente, se utilizan algoritmos que utilicen la información de su posición en la secuencia completa X de forma que se encuentre conjunto de etiquetas $Y = y_1, \dots, y_n \forall y_i \in \Upsilon$ que mejor se corresponda con la secuencia global. Nótese que utilizaremos las mayúsculas X e Y para referirnos a la secuencia completa y las minúsculas x_i e y_i para cada elemento individual de dicha secuencia.

Puesto que las señales capturadas por EEG son no estacionarias, se ha creído que el etiquetado de secuencias puede aportar más valor que la clasificación de observaciones independientes. Entre los modelos que permiten etiquetar secuencias en el presente trabajo se estudiarán modelos probabilistas que calculan la $P(Y|X)$. Las técnicas matemáticas seleccionadas a analizar son: el Modelo Oculto de Markov (HMM) y el Campo Aleatorio Condicional (CRF). Dado su carácter dependiente del tiempo, en el que una misma observación x_i se podría clasificar bajo diferentes etiquetas en función de su posición en la secuencia completa X se ha optado por denominar a estos modelos dinámicos, en contraposición de los anteriores que denominaremos estáticos.

En nuestro caso particular sólo contamos con dos estados $\Upsilon = \{reposto, movimiento\}$ y nuestras observaciones X proceden de la lectura de las señales

del EEG una vez procesadas y trasladadas al dominio de la frecuencia. Cada x_i representa un conjunto de d variables continuas que, dependiendo del caso, serán un total de entre $2 < d < 48$. Este tamaño d viene de los canales y frecuencias indicados en la sección 2.2.1 que se utilizan en cada sujeto.

3.2. Validación cruzada de datos

Puesto que las observaciones (cada secuencia X capturada por EEG) disponibles para el trabajo son limitadas, hay que dividirlas en dos subconjuntos no vacíos disjuntos. Uno mayor, el de entrenamiento (*train*), se utilizará junto con las etiquetas Y correspondientes como información inicial de los modelos de inteligencia artificial para que estimen los pesos y valores oportunos que permitan clasificar correctamente las observaciones. El segundo, el de *test*, se reserva para, una vez completado el entrenamiento, probar la eficiencia de nuestro clasificador con observaciones para las cuales no estaba entrenado (ya que no se han utilizado previamente). Esta separación garantiza que el clasificador no esté sobre-entrenado para el conjunto de datos con el que se va a evaluar.

La validación cruzada de datos, más conocida por su nombre inglés *cross-validation*, es una técnica muy utilizada en la evaluación de cualquier análisis estadístico del que se dispone un conjunto finito de datos con el objetivo de exprimirlos al máximo, ya que permite replicar varios entrenamientos independientes con esos mismos datos como si fuesen distintos. Además, previene el caso de que una selección arbitraria de los subconjuntos de test y train no fuese representativa del total, por lo que se realiza esta división K veces, con K parejas de subconjuntos test-train. En cada una de estas divisiones el subconjunto de test representa $1/K$ del total de observaciones, y se seleccionan de forma que sean todas distintas, es decir, la unión de los K subconjuntos de test resulta ser el conjunto completo original X . Con cada pareja de K subconjuntos de test-train se entrena y evalúa el mismo modelo y, finalmente, se calcula la media aritmética entre los resultados de clasificación. Esto es la variante conocida como *k-fold cross-validation*. En este proyecto se utilizará en todos los casos $K = 10$, de forma que el conjunto de test represente siempre el 10 % de las muestras.

3.3. Modelos estáticos

Primero vamos a estudiar los modelos estáticos que responden al problema de clasificación. Como se ha indicado antes, y se deducirá de los modelos matemáticos de estos algoritmos, no existe una diferencia real entre disponer o no de la señal completa de observaciones X a la hora de clasificar un estado x_i , pues se etiquetará independientemente de los que existan en el resto de la secuencia. Es por ello que con estos modelos se resuelve al mismo tiempo el subobjetivo 1 y el 2.

3.3.1. LDA - Análisis Discriminante Lineal

Dentro de los métodos estáticos comenzaremos con el LDA (siglas en inglés de Linear Discriminant Analysis), que es un método usado en estadística para expresar una variable dependiente como la combinación lineal de otras variables de forma que definan o separen dos o más categorías. La combinación resultante puede ser usada como un clasificador lineal. Se publicaron originalmente por Fisher en 1936 [3].

A diferencia de otros análisis estadísticos donde la variable dependiente puede ser continua, en LDA la variable dependiente ha de ser de tipo cualitativo, es decir, aquellas que tienen dos o más categorías en las cuales no existe un orden intrínseco. En LDA también se asume que las variables independientes conforman una distribución normal multivariante y con las covarianzas homogéneas entre los grupos.

Una forma de entender un modelo de clasificación lineal es verlo como una reducción de la dimensionalidad. Suponiendo que tenemos que clasificar una observación x_i , que es un vector de dimensión d compuesto por los canales y frecuencias seleccionados, lo proyectamos en una única dimensión mediante el producto escalar el vector columna L , denominado *de coeficientes lineales*:

$$y' = L \cdot x_i$$

Así, cada observación x_i se mapea a un único valor y' , de modo que su etiquetado se realizará en función de si supera o no, un determinado umbral. Exactamente, en los LDA, lo que se hace es añadir un término constante K a la ecuación para desplazar nuestro umbral de clasificación al 0. De este modo, el problema de clasificar una observación x_i como *reposo* o *movimiento* se reduce a encontrar unos coeficientes K y L tales que se cumpla la ecuación 1. Ésta será nuestra $f(x)$ mencionada en el problema de clasificación.

$$\begin{aligned} \text{Si } 0 < K + L \cdot x_i &\quad \text{entonces } y_i \text{ es reposo} \\ \text{Si } 0 \geq K + L \cdot x_i &\quad \text{entonces } y_i \text{ es movimiento} \end{aligned} \tag{1}$$

Esto significa que la construcción de nuestro modelo LDA pasa por obtener estos valores K y L adecuados que maximicen la separación de las clases al proyectarlas sobre una dimensión. Sean m_1 , m_2 , S_1 , S_2 los vectores de medias y las matrices de covarianzas de las muestras X disponibles de cada clase Υ_1 (reposo) y Υ_2 (movimiento), y n_1 y n_2 el número de observaciones de cada una, entonces la matriz de covarianzas ponderada S_p es:

$$S_p = (n_1 S_1 + n_2 S_2) / (n_1 + n_2 - 2)$$

Como buscamos maximizar la variabilidad entre las clases, $(Lm_2 - Lm_1)^2$,

y minimizar la variabilidad dentro de cada clase, $LS_p L^T$, tenemos que maximizar la función 2 para obtener nuestros coeficientes lineales L . Nótese que el superíndice T representa la traspuesta de un vector.

$$J(L) = \frac{(Lm_2 - Lm_1)^2}{LS_p L^T} \quad (2)$$

Para realizar la clasificación de la señal EEG mediante LDA en nuestro trabajo se ha utilizado la función *classify*(train, test, labels) que incorpora el propio Matlab en su *Statistic Toolbox*. Esta función devuelve, por un lado, los coeficientes K y L calculados y, por otro, la clase bajo la que se clasifica cada observación indicada en el parámetro *test*.

3.3.2. SVM - Máquina de Soporte Vectorial

Una SVM (por sus siglas en inglés: Support Vector Machine) es un modelo estadístico para un conjunto de métodos de aprendizaje supervisado que analizan y reconocen patrones, usados para clasificación y análisis de regresión. El SVM buscará un hiperplano que tenga la máxima distancia a los puntos frontera de cada grupo a clasificar. Este concepto es una de las principales diferencias con un clasificador lineal convencional. Hemos visto que el LDA maximiza la distancia entre las medias de cada clase, mientras que el SVM, además, utiliza los **puntos frontera**, que son aquellas observaciones de cada categoría que caen más cerca del plano de clasificación, para ajustar el hiperplano de forma que su distancia sea máxima a estos puntos, y no al núcleo de cada clase completa.

Un hiperplano se puede definir como un conjunto de puntos x que satisfagan: $w \cdot x - b = 0$, donde w es el vector normal del hiperplano y $b/\|w\|$ es el desplazamiento del hiperplano desde el origen sobre w . Entonces, dado un conjunto de entrenamiento de parejas observación-etiqueta (x_i, y_i) , $i = 1 \dots l$ donde $x_i \in R^n$ e $y \in \text{receso, movimiento}^l$, deberíamos encontrar dos hiperplanos $w \cdot x - b = 1$ y $w \cdot x - b = -1$ tales que podamos establecer para cada i , la función 3, que es la que denominamos $f(x)$ en nuestro problema de clasificación.

$$\begin{array}{lll} \text{Si } w \cdot x_i - b \leq -1 & \text{entonces } y_i \text{ es reposo} \\ \text{Si } w \cdot x_i - b \geq 1 & \text{entonces } y_i \text{ es movimiento} \end{array} \quad (3)$$

Como sabemos que la distancia entre los dos hiperplanos que separan cada clase es $\frac{2}{\|w\|}$ el objetivo será minimizar $\|w\|$, para lo cual hay diversos algoritmos de optimización como los propuestos en [4] y [5].

SVM no lineales

Lo más básico para separar dos grupos sería una línea recta, que es lo que se propuso en el paper original [6] resultando un modelo equivalente a un clasificador lineal puro; sin embargo esto no es aplicable en muchas ocasiones de trabajo real, por lo que en la práctica se utilizan las denominadas funciones kernel [7], que son una variación en el espacio de dimensiones, para ampliar su funcionalidad. Entre los kernel más comunes podemos encontrar: funciones de base radial, signoideo, polinómico homogéneo y no homogéneo, tangente hiperbólica... En nuestro proyecto nosotros utilizaremos las primeras, que se corresponden con la ecuación 4.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \text{ for } \gamma > 0. \quad (4)$$

Otro investigador de la Universidad de Zaragoza ha estado estudiando las máquinas de soporte vectorial a fin de obtener una clasificación satisfactoria de esta misma señal mediante estos modelos. Para realizar el entrenamiento de nuestro SVM se han utilizado los parámetros publicados en [8]) pues se han considerado como los mejores para tratar con este tipo de señal. También se determinó que se comportan mejor previa normalización de las observaciones X , por lo que también se realizó. Específicamente, los parámetros utilizados para el entrenamiento son los que estableció este investigador como más adecuados: **svmTrain(labels, signal, '-s 0 -c 1 -t 2 -d 3 -e 0.00001 -b 1')**. Esta función sale de la librería LibSVM elaborada por Chih-Chung Chang y Chih-Jen Lin [9] y que es utilizada para nuestro estudio de las Máquinas de Soporte Vectorial.

En su estudio incluía una variación en el estudio de los modelos, y es que realizaba el entrenamiento segmentando la señal cada 0.75 segundos, mientras que la señal utilizada para test variaba. En este proyecto en todo momento se ha utilizado la misma segmentación (como se explica en 2.2) tanto para entrenamiento como para test en todos los modelos, pues se han hecho pruebas en los diferentes modelos con este sistema y su eficiencia bajaba, por lo que no se ha considerado oportuno incluirlos aquí. Pero a la hora de evaluar los resultados de los SVM se ha considerado este sistema como algo extraordinario ya que en este modelo sí que mejoran los resultados al aplicar esta divergencia entre entrenamiento y test.

3.4. Modelos dinámicos

3.4.1. HMM - Modelo Oculto de Márkov

Un HMM (siglas inglesas de Hidden Markov Model) es un modelo estadístico en el que asumimos que el sistema a modelar es un proceso de Márkov con estados no observables (ocultos). Un proceso de Márkov es un proceso estocástico que satisface la propiedad de Márkov, la cual se cumple cuando la probabilidad condicionada de los estados futuros depende únicamente del estado presente, y no de la secuencia de eventos anteriores. Véase [10].

En un modelo de Márkov, el estado es directamente visible por el observador, en un modelo oculto el estado no es visible directamente, pero sí las salidas que dependen de ese estado. Cada estado tiene una probabilidad sobre las posibles salidas, por lo que la secuencia de salidas da información sobre la secuencia de estados.

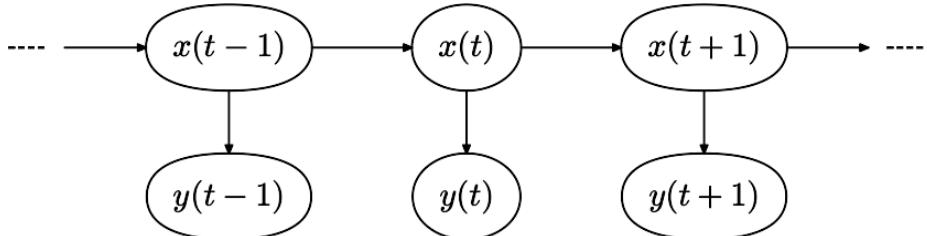


Figura 7: Ejemplo de red HMM (fuente: contribución libre a la wikipedia)

Los modelos ocultos de Márkov basan su funcionamiento en tres matrices:

- Matriz de estado inicial (π): La cual indica la probabilidad de que el primer elemento de la serie pertenezca a uno de los estados posibles y que será la $p(y_1)$.
- Matriz de transición de estados (A): que contiene las probabilidades a_{ij} que existen de pasar de cada uno de los estados i a otro j (o permanecer en el mismo): $a_{ij} = p(Y = j|Y = i)$ y que también podemos describir como $p(y_i|y_{i-1})$.
- Matriz de probabilidad de observaciones (B): que indica la probabilidad de observar un x_i mientras estemos en un estado oculto y_i (en inglés le denominan *emission probabilities*): $p(x_i|y_i)$.

De ese modo, la probabilidad de observar la secuencia Y de h estados ocultos (en nuestro caso $h = 2$) a partir de una serie de observaciones X es:

$$p(Y|X) = p(y_1) \prod_i^h p(y_i|y_{i-1})p(x_i|y_i)$$

Esa matriz de probabilidades B se utiliza cuando las observaciones son una variable discreta. Cuando trabajamos con variables continuas sobre una distribución gaussiana –como es nuestro caso– se emplea la media y varianza de cada estado, utilizando la función de densidad de probabilidad (*pdf*) de esta distribución que nos permita determinar la $p(x_i|y_i)$. Para una distribución gaussiana la *pdf* se calcula con la fórmula 5.

$$\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (5)$$

Para realizar el análisis de este modelo hemos utilizado la librería *pmtk3.0*, escrita por Matt Dunham, Kevin Murphy y otros autores que es un kit que soporta una gran variedad de modelos probabilísticos. Ésta nos ofrece el método *hmmFit(signal, n_states, type)* que nos permite un entrenamiento no supervisado simplemente pasando como argumentos la señal, el número de estados ocultos (dos en nuestro caso: reposo y movimiento/intención) y el tipo de distribución que más se ajusta a nuestra señal entre cuatro prefijados (en nuestro caso sabemos que se trata de una distribución gaussiana). Este método nos devuelve un objeto *model* con la información característica del modelo entrenado que luego utilizaremos para realizar la clasificación.

Entrenamiento supervisado

Como explicamos anteriormente un HMM requiere de una matriz de probabilidades de estado inicial, una matriz de transiciones entre estados y la información de medias y covarianzas de los mismos. Todos estos son datos que se pueden calcular previamente a partir de nuestro subconjunto de entrenamiento ya que disponemos de la información suficiente que nos aportan las etiquetas *Y*. Así pues, procedimos a extraer esta información para realizar un entrenamiento supervisado que mejore el porcentaje de clasificación. Los resultados que se analizan en este proyecto son los obtenidos mediante este entrenamiento supervisado, la diferencia obtenida comparado con el entrenamiento no supervisado es suficiente como para no incluir este último en el contexto de nuestra investigación. A continuación, se detallan los procesos que se siguieron para calcular estos parámetros para nuestro HMM supervisado.

El primero y más sencillo es la matriz de probabilidad inicial. Todos los estados comienzan en el estado de reposo, por lo que $\pi = [10]$, siendo la primera etiqueta la correspondiente al reposo y la segunda al movimiento. A continuación, pasamos a calcular la matriz de transición de estados, cuyo formato general podemos ver en el cuadro 3.

Estado $i \setminus$	Estado $i+1$	reposto	movimiento
reposto	$P(R \rightarrow R)$	$1 - P(R \rightarrow R)$	
movimiento	$1 - P(M \rightarrow M)$	$P(M \rightarrow M)$	

Cuadro 3: Formato de la matriz de transición de estados del HMM.

En nuestro caso, todos los ensayos se comienzan con el estado de reposo para, tras un tiempo prefijado e igual en todos, pasar al movimiento –o a la intención del mismo–, etiqueta en la cual finaliza cada experimento. Esto significa que una única vez en cada ensayo se pasa de reposo a movimiento, y nunca al revés. Esto significa que la probabilidad de estar en movimiento y pasar a reposo es 0. De este modo, la matriz de transición seguirá el siguiente patrón:

$$A = \begin{pmatrix} 1 - \varepsilon & \varepsilon \\ 0 & 1 \end{pmatrix}$$

La probabilidad de estar en el estado de reposo y pasar al estado de movimiento en el ensayo j , se obtiene de sumar la cantidad de veces r_j que aparece la etiqueta de reposo en $Y_j = y_1, \dots, y_n$ y hacer la inversa. Es decir, si hay r_j etiquetas de reposo seguidas, significa que en $r_j - 1$ ocasiones nos quedamos en el reposo y una única ocasión pasamos al movimiento ($\frac{1}{r_j}$).

Para obtener ϵ en los m ensayos que componen nuestro subconjunto de entrenamiento, vemos que el paso del reposo al movimiento sucede en m ocasiones (una por cada ensayo), por lo que dividiremos este valor entre el sumatorio del número de veces r_j que aparece la etiqueta de reposo en cada ensayo j :

$$\varepsilon = \frac{m}{\sum_j^m r_j}$$

Como en nuestro caso específico el reposo dura lo mismo en cada experimento ($r_0 = r_1 = \dots = r_m$) entonces $\sum_i^m r_j = r \cdot m$, de modo que no tenemos más que sumar el número de veces r que aparece el estado de reposo en la señal con la que entrenamos nuestro modelo y dividir, como vemos en la fórmula 6. El cálculo de medias y covarianzas se supone trivial disponiendo de las observaciones X , por lo que no se detalla en esta memoria.

$$\varepsilon = \frac{1}{r} \tag{6}$$

Clasificación de variables ocultas

Una vez calculadas todas estas características ya podemos proceder a la clasificación de la señal. El método más común para estimar las variables ocultas es el algoritmo de Viterbi [11], el cual analiza todas las X (la secuencia completa de t observaciones) para tratar de encontrar la secuencia más probable de etiquetas Y que maximice la función de probabilidad como vemos en 7. Este algoritmo se fundamenta en técnicas de *forward-backward* por lo que utiliza la información de toda la secuencia para clasificar cada y_i :

$$p(y_{1:t}|x : 1 : t) \tag{7}$$

Para realizar la clasificación de trayectoria completa (subobjetivo 1), en la que se dispone de toda la secuencia en el momento de análisis, éste algoritmo es exactamente lo que necesitamos. En la librería utilizada viene directamente implementado mediante la función ***hmmMap(model, señal)*** que nos devolverá los estados ocultos que se corresponden con los valores de la señal. En la variable *model* se han asignado previamente los valores de las características antes mencionadas como la matrices de transición de estados, varianzas, etc.

Pese a ser muy útil en otras situaciones como la anterior, no podemos utilizar el algoritmo Viterbi para cumplir el subobjetivo 2 (clasificación por puntos

de trayectoria). El motivo es que Viterbi toma toda la secuencia completa y busca la mejor combinación de estados ocultos que maximice el porcentaje de aciertos. En nuestro caso estamos estudiando la capacidad de este algoritmo de aprendizaje para clasificar la señal en tiempo real –para que sea útil en tareas de rehabilitación–, de modo que en una situación práctica no tendríamos la secuencia completa de n observaciones X . Con este método, para la clasificación del elemento y_i utilizamos únicamente las observaciones $x_{1:i}$ obtenidas hasta ese punto, maximizando la ecuación 8.

$$p(y_i|x_{1:i}) \quad (8)$$

Para solucionar este problema tuvo que implementarse un método intermedio que fuese simulando la gradual adquisición de los datos. Para conseguir esto, en lugar de utilizar la señal completa X directamente sobre nuestra función de clasificación, hubo que realizar n clasificaciones –una por observación en la secuencia–, utilizando como entrada un subvector $x_{1:i}$ en cada iteración, y asignando únicamente la última etiqueta obtenida a su y_i correspondiente de la secuencia completa Y , garantizando de este modo el cumplimiento de la fórmula 8. Este mismo proceso iterativo tuvo que ser utilizado en los CRF.

3.4.2. CRF - Campo Aleatorio Condicional

Un CRF (siglas de Conditional Random Field) es un método de modelado estadístico aplicado a menudo al reconocimiento de patrones. Mientras un clasificador ordinario predice una etiqueta para una única muestra sin tener en cuenta las muestras vecinas, un CRF tiene en cuenta el contexto donde la encuentra. Del mismo modo que en un HMM se tiene en consideración la categoría anterior para determinar la etiqueta presente, en un CRF se puede seleccionar arbitrariamente qué otras observaciones de la secuencia se utilizarán. La otra gran diferencia entre un HMM y un CRF es que en el primero la función de transición entre estados ocultos es constante (la matriz de transición de estados llamada A en la sección anterior) mientras que en el CRF se define mediante unas funciones que pueden variar dependiendo de la secuencia de observaciones.

Desarrollados en 2001 por Lafferty, McCallum y Pereira (véase [12]) han conseguido gran popularidad para etiquetar datos secuenciales como problemas de visión por computador o secuencias biológicas, destacando principalmente en el procesamiento del lenguaje natural.

Un CRF define un conjunto de observaciones X y variables aleatorias Y del siguiente modo: Sea $G = (V, E)$ un grafo tal que $Y = (Y_v)_{v \in V}$, de modo que Y está indexado por los vértices de G . Entonces (X, Y) es un CRF en el que, cuando se condiciona en X , las variables aleatorias Y_v cumplen la propiedad de Márkov con respecto al grafo ($w \sim v$ indica que w y v son vecinos en G):

$$p(Y_v|X, Y_w, w \neq v) = p(Y_v|X, Y_w, w \sim v)$$

El grafo más simple es una cadena tal que $G = (V = \{1, 2, \dots, n\}, E = \{(i, i + 1)\})$. Pueden construirse tan complejos como se desee, pero en nuestra investigación nos limitaremos a éstos, denominados **en cadena** (*linear-chain CRF* en inglés). Esto significa que su modelo gráfico es el mismo que un HMM, en el que cada x_t está conectado con x_{t+1} . No es necesario asumir que X tiene la misma estructura que Y , aunque suele ser lo habitual y nuestro caso. Además de la cadena simple incluiremos una variable w , llamada tamaño de ventana, que indicará el número de vecinos con los que está conectada. Así, la arista del vértice i en lugar de ser $e_i = \{i + 1\}$ pasará a ser $e_i = \{i - w, w - 1 + 1, \dots, i, \dots, i + w - 1, i + w\}$.

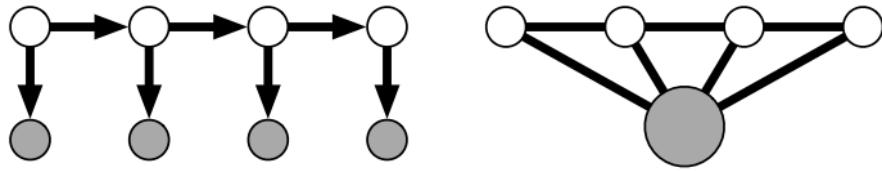


Figura 8: Izquierda: Representación gráfica de un HMM. Los nodos oscurecidos se corresponden con las observaciones $x_1, x_2 \dots x_n$. Los nodos claros a las variables estado $y_1, y_2 \dots y_n$. Derecha: Representación gráfica de un CRF. El nodo grande se corresponde con toda la secuencia X . Como en el HMM, los nodos claros se corresponden con las variables estado. Fuente [1]

Para calcular la probabilidad de una secuencia de etiquetas Y dadas unas observaciones X los CRF utilizan dos conjuntos de lo que se denominan *feature-functions* multiplicadas por sus pesos correspondientes (λ_j y μ_k) como vemos en la ecuación 9. Las *feature-functions* son las que definen al modelo y el entrenamiento consiste en encontrar los pesos apropiados para que obtener la secuencia Y correcta.

$$P(Y|X) = \exp\left(\sum_j \lambda_j t_j(y_{i-1}, y_i, x, i) + \sum_k \mu_k s_k(y_i, x, i)\right) \quad (9)$$

Donde $t_j(y_{i-1}, y_i, x, i)$ son las j *feature-functions* de transición y $\mu_k s_k(y_i, x, i)$ son las k *feature-functions* de estados. Se pueden implementar un número arbitrario de j y k features, cada una utilizando distintos criterios, y esto será lo que defina el tipo de CRF que se está utilizando. En nuestro modelo en cadena las *feature-functions* se corresponden con las de la ecuación 10. Nótese que tenemos tantas como el doble del tamaño de ventana (una por cada observación que tiene en cuenta en cada instante i), es decir $k = 2w + 1$. Puede verse que en el caso de la cadena simple, sin utilizar observaciones vecinas, se utilizaría una única *feature-function* con el valor de la propia observación x_i .

$$\begin{aligned}
s_1(y_i, X, i) &= x_{i-w} \\
s_2(y_i, X, i) &= x_{i-(w-1)} \\
&\vdots \\
s_k(y_i, X, i) &= x_{i-(w-k+1)}
\end{aligned} \tag{10}$$

Por lo tanto, en el modelo de CRF en cadena que estamos analizando, el parámetro más importante que tenemos que estudiar, y sobre el que fue necesario hacer más pruebas para obtener los mejores resultados, es el del tamaño de ventana (*wsize*). Con el tamaño de la ventana se le indica al modelo que ha de tomar tantos vecinos, hacia delante y atrás, como sea el valor del parámetro. Así, para $wsize = 2$ además de la muestra correspondiente se tomarán las dos muestras anteriores y posteriores $(x_{i-2}, x_{i-1}, x_i, x_{i+1}, x_{i+2})$ para obtener el estado Y_i a partir de la muestra la posición x_i .

Este empleo de las muestras vecinas es muy útil y lo que nos impulsó a utilizar el CRF en esta investigación, pues lo convierte en una herramienta muy potente. Sin embargo el utilizar las muestras siguientes para realizar la predicción tiene el inconveniente de introducir un retardo en la clasificación, ya que hay que esperar a que lleguen para tener una clasificación correcta. Así con una ventana de tamaño 2, como en el ejemplo anterior, una vez hubiésemos leído la muestra x_t podríamos obtener el resultado de la clasificación de la etiqueta y_{t-2} .

El coste computacional en tiempo de entrenar un CRF en cadena es cuadrático sobre el número L de categorías (Υ), lineal en el número F de feature-functions (denominadas más arriba j y k) y casi cuadrático en el tamaño T del subconjunto de entrenamiento de observaciones (X). Es decir, $O(L^2FT^2)$ (para la demostración matemática véase [13]). Este tamaño T serían las 840 lecturas que se capturan en cada experimento, multiplicado por los $2 < d < 48$ canales-frecuencias utilizados, multiplicado por el número de ensayos que se incluyan en el subconjunto de entrenamiento. Por esto, como se explicó en 2.2, cada ensayo cuenta con una cantidad demasiado grande de información para tratar entera, por lo que se segmentó la señal para reducir el coste computacional.

También aquí fue necesario realizar varias pruebas, combinándolo con diferentes tamaños de ventana, para llegar a un compromiso aceptable entre el porcentaje de aciertos y el retardo en obtener la clasificación, así como el tiempo de entrenamiento. El estudio preliminar de los CRF nos mostró que no había diferencias significativas entre utilizar los diferentes métodos de segmentación de la señal que hemos estado utilizando con el resto de modelos así que, dado que los CRF tienen otro parámetro más interesante (las observaciones vecinas, y que resulta ser ciertamente similar a nuestra segmentación por ventanas), dejamos de utilizar los métodos de agrupar los datos entre intervalos por ventanas o ventanas solapadas, limitándonos a tomar los datos por puntos individuales según los diferentes intervalos que definamos. A fin de cuentas los CRF ya hacen esto de forma natural mediante la ventana de observaciones vecinas.

Esta latencia que produce la combinación de discretizar la señal y el tamaño de ventana se entenderá mejor con un ejemplo. Si decidimos quedarnos con

una lectura cada 0.0625 segundos (que equivale a una muestra de cada diez ya que la señal tiene una frecuencia de 160Hz) y tenemos una ventana de tamaño 20 en nuestro CRF, resulta que no podremos clasificar una muestra dada hasta $0.0625 \cdot 20 = 1.25$ segundos desde el instante en que hayamos realizado la lectura de la x_i correspondiente a la etiqueta Y_i . Dicho de otro modo, una vez leamos del EEG la señal de x_t podremos clasificar el estado y_{t-20} recibido 1.25 segundos antes.

Además de los CRF comunes, más tarde se publicó otro paper definiendo las modificaciones necesarias para que los CRF trabajasen más adecuadamente cuando se asume que las observaciones están modeladas como una distribución gaussiana. Las feature-function a utilizar pasar a ser tres por observación, las cuales derivan de la función de densidad d probabilidad 5. Aquí ponemos directamente cómo quedarían las feature-functions, si quiere consultarse todos los fundamentos teóricos puede acudirse al paper original en [1].

$$\begin{aligned} s_1 &= 1 \\ s_2 &= x_i \\ s_3 &= x_i^2 \end{aligned} \tag{11}$$

Para realizar el análisis de los CRF nosotros utilizamos la librería *HCRF2.0* de Louis-Philippe Morency. Esta librería, escrita en C++ pero cuenta con una interfaz para ejecutar desde Matlab, implementa el CRF original en cadena tal y como fue descrito por Lafferty et al y por Sha y Pereira y dos versiones basadas en éste: Hidden-state Conditional Random Fields (HCRF) y Latent-Dynamic Conditional Random Fields (LDCRF).

Esta librería ya viene implementada con aprendizaje supervisado, por lo que no es necesario calcular previamente los parámetros del modelo ha ocurrido en el caso de los HMM. Se ejecuta la función *trainCRF(signal, labels, params)* donde *labels* es el valor de la secuencia de estados ocultos Y para cada *signal*. Dentro de *params* se indican algunos parámetros como el tipo de CRF que se desea entrenar. Se realizaron pruebas iniciales con algunos de los modelos alternativos que implementa la librería, pero los resultados no eran tan satisfactorios como con los CRF estándar, por lo que no se ahondó más en ellos ni se han considerado de interés para incluir en esta memoria.

La librería que hemos utilizado implementa los CRF básicos publicados en [12]. Los CRF diseñados para reconocimiento de distribuciones gaussianas no estaban desarrollados en la librería, por lo que hubo que modificar el código original para utilizar features gaussianas. Estas modificaciones consistieron en introducir las fórmulas descritas en 11. Para ello se tuvo que modificar el núcleo de la librería en C++ y la interfaz que comunica con Matlab para poder utilizarlas. Por su complejidad se implementó únicamente la versión para un CRF en cadena simple, por lo que no se permite la selección de una ventana de vecinos para ampliar las observaciones.

4. Resultados

En esta sección mostraremos los principales resultados de cada modelo junto con algunos comentarios que se deducen de su observación. Es un resumen en el que se incluirán las tablas y gráficas de los casos más destacados y de interés. El resto pueden consultarse en el anexo C para ver los resultados detallados divididos por modelos.

Hay que tener en cuenta que la cantidad de casos analizados ha sido inmensa. En cada uno de los seis sujetos se partía de cuatro conjuntos de datos (dependiendo del brazo y del córtex), de los cuales se tomaba una selección de los canales más interesantes y, por otro lado, el canal con más variabilidad. En estos 48 casos se estudiaban cuatro modelos de aprendizaje, los cuales tenían diferentes parámetros y se seleccionaban diferentes intervalos de entrada, quedando aproximadamente una docena por cada uno. Finalmente, todo ello estudiado en los dos escenarios planteados en los subobjetivos. Todo esto suma cerca de 5000 casos distintos analizados, cuyo resumen se pasa a exponer en esta sección.

4.1. Definición de la organización de resultados

Vamos a dividir esta sección en dos apartados, uno para mostrar los resultados de la clasificación de trayectoria completa y otro para la clasificación por puntos de trayectoria, de modo que analicemos nuestros dos subobjetivos. En estos apartados podremos ver unas tablas de doble entrada en las que cada fila representará uno de los cuatro modelos estudiados (LDA, SVM, HMM, CRF) y en cada columna se mostrarán los cuatro conjuntos de datos. Recordemos que se realizaron dos experimentos, uno moviendo el brazo sano y otro moviendo el brazo incapacitado. Las señales grabadas en cada experimento se separaron en dos conjuntos: el correspondiente a los electrodos situados en el córtex sano y el de los electrodos situados en el córtex dañado. De las combinaciones entre ambos córtex y ambos brazos salen estos cuatro conjuntos de datos. En cada uno de los 16 casos mostrados en estas tablas se muestran los porcentajes de aciertos correspondientes al estado de reposo y al de movimiento (o intento de movimiento).

Las gráficas que vamos a utilizar para mostrar la eficiencia de nuestros clasificadores están divididas en tres partes bien diferenciadas que pasamos a detallar. En azul vamos a representar siempre el reposo (*rest*) y en rojo el movimiento (*move*), o el intento del mismo (*attempt*). Primero vemos a qué se corresponde la secuencia real que se ejecutó en el experimento según la información disponible en los marcadores, después observamos cómo se clasificó cada experimento individual y, finalmente, agrupamos esta información en forma de histograma para ver exactamente la cantidad de aciertos que obtuvimos. Adicionalmente se agrega en esta última parte una línea de puntos indicando el porcentaje medio de aciertos en cada estado. Además, en la parte superior de cada gráfica podemos ver un título con información sobre el modelo de entrenamiento y sus variables, dado su reducido tamaño hemos pasado a escribir las partes más relevantes en

el pie de la figura en este trabajo.

4.2. Subobjetivo 1: Clasificación de trayectoria completa

Cuando disponemos de la señal completa observamos que los modelos dinámicos (CRF y HMM) son considerablemente mejores que los estáticos (LDA y SVM). Esto es así porque, como se detalló en la definición de estos modelos, utilizan información de toda la secuencia de datos para maximizar los resultados correctos. Los modelos estáticos, que no hacen uso activo de esta información, no se ven beneficiados por ello. Aún así, no podemos considerar los resultados de estos modelos como deficientes, pero quedan significativamente por detrás de los métodos dinámicos.

	ArmH-CorH		ArmI-CorH		ArmH-CorI		ArmH-CorI	
	Rest	Move	Rest	Attempt	Rest	Move	Rest	Attempt
LDA	67.23	80.62	61.19	71.00	59.21	67.50	59.06	64.83
SVM	71.48	72.25	67.40	63.82	63.17	62.29	61.82	67.70
HMM	72.23	86.07	68.69	81.62	69.06	74.86	62.91	76.04
CRF	70.97	97.50	88.00	93.73	89.31	92.77	88.64	92.46

Cuadro 4: Comparación de los mejores resultados de los cuatro modelos bajo las cuatro condiciones de córtex y brazos para la clasificación de trayectoria completa. Todos los valores son porcentajes calculados con la media de todos los sujetos.

Los modelos estáticos obtienen significativamente más aciertos utilizando todos los canales seleccionados como mejores que únicamente el mejor de todos ellos. Esta mejora de la clasificación es mucho más destacable en la categoría de reposo que en la de movimiento. También la mejora de aciertos en el uso de los canales es menor en el córtex dañado que en el sano. Los dos modelos obtienen un promedio similar, pero en general el LDA identifica mejor el reposo y el SVM el movimiento (excepto con córtex dañado y brazo lesionado, que mejora el SVM). Al no imponer restricciones temporales, veremos que estos modelos estáticos aquí presentan unos resultados mejores que en la clasificación por puntos de trayectoria ya que algunos de los métodos de submuestreado permiten agrupar varias observaciones. En concreto, los mejores resultados –que son los mostrados en la tabla 4–, de todos estos modelos se obtuvieron con el submuestreado de ventanas solapadas por intervalos de 500 milisegundos. En todos los casos todos los modelos se entrenaron y se testearon utilizando el mismo subsampleado. Sin embargo, en el paper [8] se indicaba que se utilizaban distintos intervalos para cada conjunto de entrenamiento y test. En nuestra investigación hemos comparado ambos planteamientos y, efectivamente, los SVM con estos datos presentan un mejor comportamiento cuando el conjunto de entrenamiento se submuestra a 750 milisegundos y empleando distintos subsampleados para el test, siendo el mejor en este caso el citado anteriormente de 500 milisegundos.

En los modelos dinámicos, el HMM también obtiene en casi todos los casos mejores resultados que con uno solo, aunque la diferencia es considerablemente

menor que con los modelos estáticos (incluso en el caso del brazo lesionado llega a ser ligeramente mejor un único canal). Los HMM son mejores en todos los aspectos que los dos modelos estáticos comparados, se quedan muy cerca en la clasificación del reposo, pero mejoran ostensiblemente en la parte del movimiento. Con los CRF, bajo todas las condiciones, se obtienen más aciertos con el entrenamiento sobre el mejor canal para valores altos del parámetro *wsize*, y conforme lo reducimos es otra vez la combinación de todos los canales la que arroja mejores resultados. Esto puede ser debido a que un abuso en el número de observaciones (muchos canales más las observaciones vecinas que utiliza el CRF) suponga un exceso de información que impida una correcta clasificación. Los resultados mostrados en la tabla 4 se corresponden, en el caso del HMM al submuestreado de ventanas solapadas por intervalos de 500 milisegundos. En el caso del CRF se submuestreó por puntos a 62.5 milisegundos y se aplicó una ventana de tamaño 20 (lo que equivale a 1.25 segundos).

4.3. Subobjetivo 2: Clasificación por puntos de trayectoria

Aquí la clasificación baja en todos los modelos porque nos autoimponemos un límite de 125 milisegundos en cuanto a la cantidad de observaciones que permitimos acumular a nuestros modelos, ya que debemos obtener un etiquetado rápido para que pueda ser útil en tareas de rehabilitación. Al ser tan limitada, los modelos dinámicos ven mermadas sus capacidades, especialmente los CRF con unos resultados muy negativos. Los HMM reducen su capacidad, equiparándose a los modelos estáticos, aunque continúa haciéndolo mejor con el córtex dañado. En la tabla 5 podemos ver los resultados que se obtienen para esta latencia de 125 milisegundos.

	ArmH-CorH		ArmI-CorH		ArmH-CorI		ArmH-CorI	
	Rest	Move	Rest	Attempt	Rest	Move	Rest	Attempt
LDA	65.26	77.88	60.34	70.33	56.67	66.03	57.20	63.34
SVM	66.98	75.00	60.52	69.01	54.49	66.23	56.01	65.92
HMM	58.62	90.10	59.26	85.84	65.65	76.30	62.29	73.49
CRF	24.68	97.13	25.50	95.91	20.58	98.78	21.52	98.93

Cuadro 5: Comparación de los mejores resultados de los cuatro modelos bajo las cuatro condiciones de córtex y brazos para la clasificación por puntos de trayectoria. Todos los valores son porcentajes calculados con la media de todos los sujetos.

Al reducir el retardo, los resultados empeoran, pero el comportamiento de los modelos estáticos sigue siendo muy similar al caso anterior, presentando una cantidad de aciertos superior utilizando todos los canales que uno, y presentando mejoras sensiblemente superiores en el reposo que en el movimiento. Al igual que antes, el reconocimiento del brazo sano es mejor que el del brazo lesionado, y el del córtex sano es mejor que el del dañado. Ambos continúan teniendo resultados muy similares, e incluso más igualados que antes. Se difuminan más las diferencias que presentaban en las que los LDA identificaban mejor el movimiento y los SVM el reposo, incluso se invierte ligeramente la tendencia para el

c ortex sano.

En el caso de los HMM, para el brazo sano se clasifica mejor el reposo con todos los canales seleccionados, y para el brazo lesionado hay una sustancial mejora al considerar s olo uno. En particular, con el caso del c ortex sano mejora un 10% la detecci n del reposo (de 53.66 % con todos, al 59.26 % con uno). En la clasificaci n del movimiento hay menos diferencias y, por lo general, existen m as aciertos al utilizar todos los canales. Los CRF, con tan poco margen para agrupar observaciones y sin tener conocimiento de la secuencia completa, presentan un comportamiento p esimo, clasificando pr cticamente las secuencias completas como movimiento. Al contrario que en el apartado anterior, aqu  se ven beneficiados del uso de todos los canales seleccionados, quiz s para suplir la carencia de observaciones que produce la baja latencia.

En ambos modelos din micos existe un claro predominio del etiquetado del movimiento demasiado pronto. Esto puede deberse a que sus representaciones internas de transici n entre clases incluyen un sesgo que aumenta la probabilidad de que una secuencia evolucione al terminar hacia el movimiento. Como lo que se hace aqu  es aumentar gradualmente las observaciones $x_{1:i}$ cada vez que se quiere obtener la etiqueta y_i , esta etiqueta siempre se identifica como la \'unica en cada clasificaci n.

4.4. Caso espec fico: C ortex Sano

4.4.1. Evaluaci n de los modelos en clasificaci n por trayectoria completa

Veamos ahora los resultados de clasificaci n completos de cada experimento para cada modelo. Dado el limitado espacio del que se dispone en esta memoria, nos vamos a centrar \'unicamente en la condici n de brazo sano y c ortex sano ya que, de lo contrario, nos extender mos demasiado. Unas pocas p ginas m as atr s, en el apartado 4.1, hemos descrito el formato de estas gr aficas por lo que lo obviamos aqu .

Primero tenemos los modelos est ticos, en los que se ve claramente su clasificaci n de las observaciones de forma independiente donde cambia de estado en varias ocasiones por cada experimento. En particular el LDA (figura 9) clasifica mejor el movimiento que el SVM (figura 10). Con los HMM (figura 11) se pretende evitar esto mismo, ya que en los par metros con los que se dise a se indica la imposibilidad de volver al reposo una vez se ha identificado el movimiento (mediante la matriz de transici n de estados). Por eso vemos una gr afica de clasificaci n m as "limpia" que en los modelos est ticos. A n as , como puede apreciarse, tiene el inconveniente de que si identifica una observaci n como movimiento demasiado pronto en la secuencia ya no puede corregirse como s i podr a suceder en otros modelos.

Para terminar nos encontramos con los CRF (figura 12), que son realmente

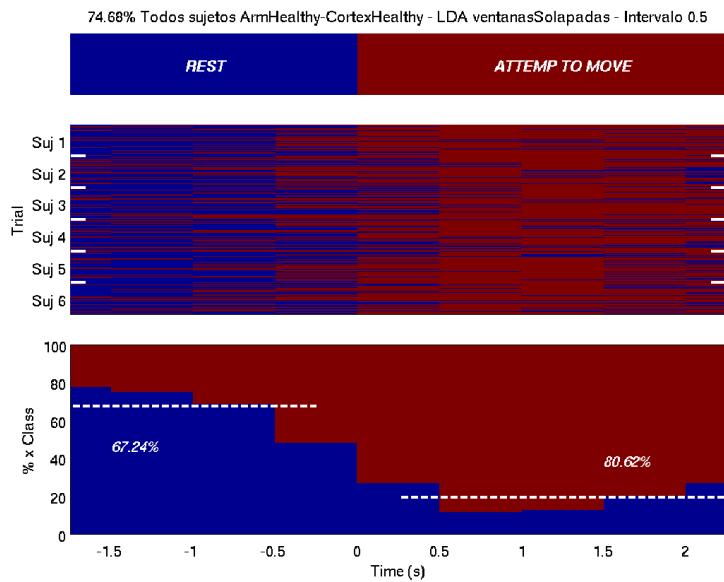


Figura 9: LDA en clasificación por trayectoria completa

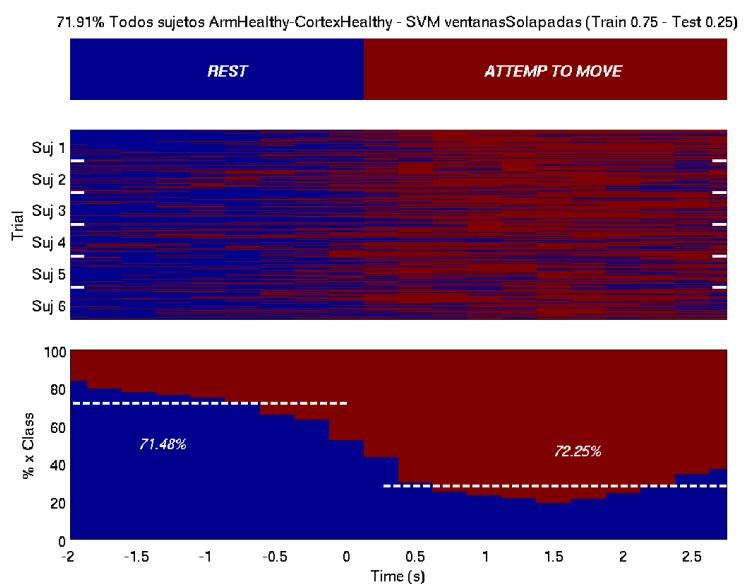


Figura 10: SVM en clasificación por trayectoria completa

los modelos que mejor resuelven el problema de etiquetado de secuencias completas. Al utilizar la información de un gran número de observaciones anteriores y posteriores a la que se desea clasificar, obtienen resultados muy precisos. En

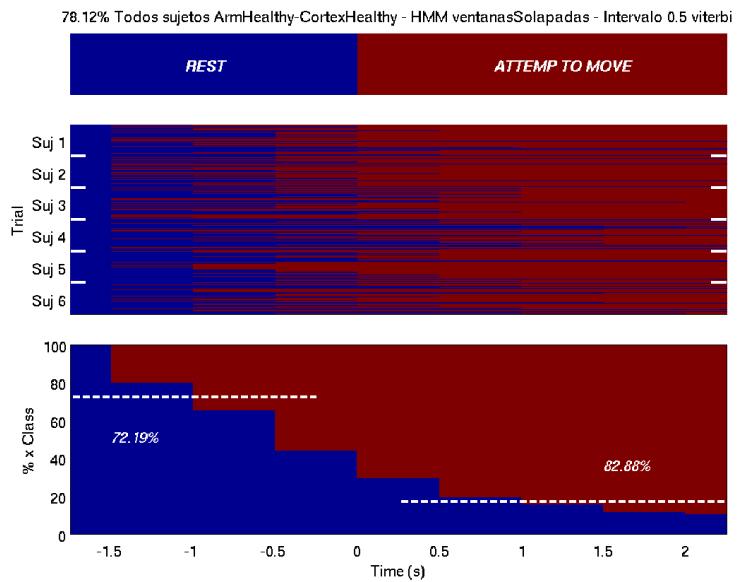


Figura 11: HMM en clasificación por trayectoria completa

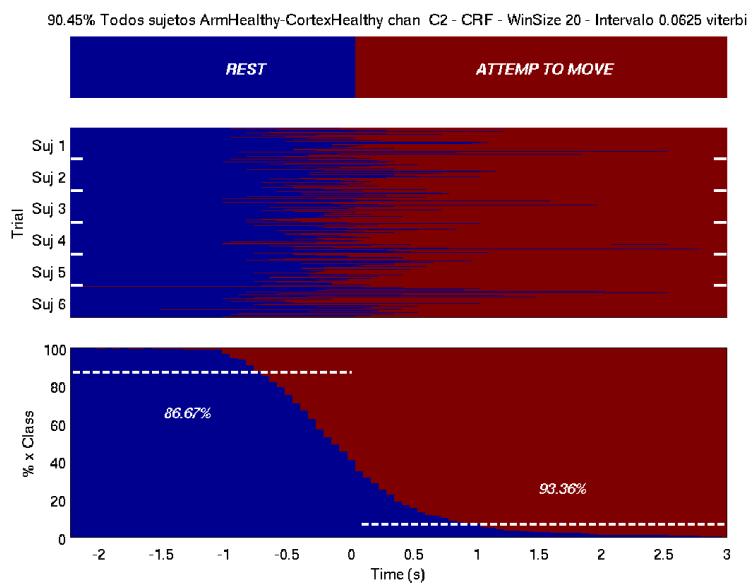


Figura 12: CRF en clasificación por trayectoria completa

este caso en particular está evaluando 40 observaciones (20 anteriores y otras 20 posteriores). Si nos fijamos en el punto de transición entre estados, vemos que todas las transiciones están muy cerca de donde deberían.

En nuestra investigación hemos contado con experimentos realizados por 6 sujetos distintos. Una particularidad que hay que tener en cuenta es que cada uno tiene sus peculiaridades y que, pese a haber realizado una selección independiente para los mejores canales de cada uno, hay algunos sujetos que presentan unos índices de clasificación muy por debajo del resto. Esto puede deberse a que tuvieran una menor involucración en los experimentos –hay que realizarlos muy concentrado para no generar actividad cerebral ruidosa–, a que tuviesen distintos grados de afección –ya en el córtex o en los brazos–, o a una selección no tan correcta de los canales adecuados entre otros factores. En estas gráficas se muestra la clasificación de las secuencias por sujetos y se pueden apreciar algunos matices. Para nuestra evaluación hemos producido gráficas de cada sujeto a mayor tamaño para facilitar la inspección visual, pero el espacio del que aquí disponemos es limitado por lo que se ha optado por mostrarlos de esta manera todos juntos. En general, el sujeto dos y el sujeto cinco presentan unos índices de clasificación por debajo del resto de compañeros, y los sujetos uno y cuatro suelen obtener una mayor cantidad de aciertos en promedio.

4.4.2. Comparación de los clasificadores por puntos de trayectoria

Como se ha indicado anteriormente, para cumplir el subobjetivo 2 no sólo buscamos un modelo con el mayor índice de clasificación, sino que además nos interesa que obtenga el resultado en el menor tiempo posible. Así, estamos dispuestos a sacrificar parte del porcentaje de aciertos de nuestro clasificador a cambio de reducir este retardo (*delay*) todo lo posible.

A continuación se muestran unas tablas comparando los porcentajes de clasificación de los diferentes modelos para los dos brazos con el córtex sano. Los resultados eran mejores en todos los casos utilizando la selección de mejores canales, así que los resultados se corresponden con ellos. Hay una excepción, en la segunda tabla podremos ver que se han incluido también los resultados de los HMM únicamente con el mejor canal, ya que los resultados eran mejores que con todos.

Puesto que estamos considerando únicamente los resultados que se puedan aplicar para un uso real de clasificación en tareas de rehabilitación, nos limitamos a buscar los mejores modelos para un retardo máximo de 125 milisegundos, a modo de comparación incluiremos los aciertos obtenidos sin retardo y con 250 milisegundos. Por ello en estas tablas no incluimos la comparación con los CRF, pues los porcentajes de aciertos de reposo son menores del 30 %, y no tiene sentido ocupar espacio con unos modelos que ya están automáticamente descartados bajo estas condiciones.

Como puede verse en las tablas, aunque los HMM parezcan obtener una media conjunta buena, lo consiguen a costa de sobreestimar la parte de movimiento, de modo que hay un exceso de falsos positivos que producen una gran cantidad de fallos en el descanso. También podrá observarse que los SVM y LDA obtienen resultados muy similares. Obtiene una media total prácticamente igual, pero cada modelo identifica mejor un estado que el otro: en LDA hay mayor cantidad

Delay	LDA		SVM		HMM	
	Rest	Attempt	Rest	Attempt	Rest	Attempt
0	64.69	77.43	67.13	74.92	46.41	93.19
0.125	65.48	78.50	72.14	70.73	59.46	89.86
0.25	66.22	79.14	71.48	72.25	65.48	88.25

Cuadro 6: Comparación en porcentaje de aciertos para diferentes retardos (en segundos) - Arm Healthy Cortex Healthy - Todos los canales

Delay	LDA		SVM		HMM		HMM (*)	
	Rest	Attempt	Rest	Attempt	Rest	Attempt	Rest	Attempt
0	60.03	69.57	60.52	68.23	38.99	90.25	40.69	85.84
0.125	60.77	70.59	67.74	61.52	53.39	86.75	58.77	85.91
0.25	61.18	70.54	67.40	63.82	58.51	85.66	63.58	89.37

Cuadro 7: Comparación en porcentaje de aciertos para diferentes retardos (en segundos) - Arm Impaired Cortex Healthy - Modelos con todos los canales, excepto la segunda columna de HMM (indicado con asterisco) debido a la mejora de clasificación con un único canal.

de aciertos para el movimiento y en SVM lo hay para el reposo. En conjunto estos últimos podría considerarse que son sensiblemente más precisos.

5. Conclusiones

En este proyecto se ha realizado un estudio de diversos modelos de inteligencia artificial para detectar el movimiento, o su intención, en pacientes que han sufrido un infarto cerebral a partir de la señal capturada a través de un electroencefalograma. Esta señal había sido capturada con anterioridad por otros miembros de la Universidad de Zaragoza, por lo que todos los análisis se hicieron en diferido.

Nos hemos centrado en cuatro modelos estadísticos que nos han parecido de especial interés y que se pueden dividir en dos categorías. La primera, con métodos que podemos denominar *estáticos*, clasifica cada instante de la señal de forma independiente del resto, no guardando en su estructura ningún tipo de información temporal. De ella hemos seleccionado el *Linear Discriminant Analysis* y las *Support Vector Machines*, por ser las más representativas y las que más literatura presentan en el campo de la clasificación de ondas capturadas por EEG. La segunda categoría, y que es la que supone una novedad en este campo con escasos estudios al respecto, son los modelos dinámicos, en los que una observación se clasificará de modo distinto en función del resto de observaciones a su alrededor, siendo dependientes del tiempo. Quizás el modelo más representativo de esta categoría sea el *Hidden Markov Model* al que hemos acompañado de otro más novedoso denominado *Conditional Random Field*.

Nos hemos enfrentado a este problema desde dos escenarios bien distintos. Por un lado hemos querido comprobar la eficiencia de estos modelos matemáticos para discriminar el movimiento del reposo directamente sobre la señal completa. Aquí únicamente tendremos en consideración el porcentaje de aciertos obtenido en la clasificación. El segundo escenario va un paso más lejos, como pensamos que es nuestro deber como investigadores, y pretende buscar aplicaciones prácticas más allá de la simple competición entre modelos estadísticos. Con la intención de que se pueda utilizar en un hipotético caso de rehabilitación como asistencia a un terapeuta informándole de la participación del paciente, se simulará una gradual adquisición de datos como ocurriría en una situación real con estas señales que teníamos ya capturadas. Esto es necesario porque, como se ha indicado, los modelos dinámicos utilizan todas las observaciones disponibles a la hora de realizar la clasificación, de forma que una misma observación x_i se etiquetaría como un estado distinto en función de si disponemos de $x_{1:i}$ o $x_{1:i+j}$ observaciones.

En el primer subobjetivo, disponiendo de toda la señal, los modelos dinámicos son claramente la opción más eficiente, obteniendo unos porcentajes de clasificación muy superiores a los modelos estáticos. Esto resultaba predecible teniendo en cuenta que estos modelos utilizan, por un lado, más información a la hora de asignar la probabilidad de pertenencia a una clase para una cierta observación y, por otro, realizan el etiquetado final de forma que se maximice la probabilidad de la secuencia completa. En particular los CRF consiguen mejores resultados que los HMM.

Para el segundo subobjetivo, la clasificación por puntos de trayectoria, los modelos dinámicos pierden todo su potencial y encontramos mejores resultados en los modelos estáticos, ambos en condiciones muy similares. Esto es así porque se ha primado la rapidez con la que se obtenían las etiquetas clasificadas al tener en cuenta que en una situación real un terapeuta necesitaría una información lo más actualizada posible y por encima de los 250 milisegundos se ha considerado excesivo. En este retraso no se tiene en cuenta la ejecución en sí del algoritmo de clasificación, ya que una vez entrenado es despreciable, sino la cantidad de observaciones requeridas para obtener una clasificación apropiada. Se ha comprobado que los modelos dinámicos necesitan un margen de más de un segundo para obtener porcentajes de aciertos que puedan mejorar a los modelos estáticos.

Pese a lo eficientes que demuestran ser los HMM y CRF utilizando la señal completa, no se ha logrado un comportamiento atractivo con ellos a la hora de utilizarlos en tiempo real, quizás por contar con unos datos muy escasos para explotar estos modelos secuenciales. A pesar de todo, éste no es un campo que deba dejarse de investigar. En este trabajo se ha asumido que los CRF deben seguir una estructura lineal similar a los HMM; sin embargo esta es una decisión totalmente arbitraria ya que son unos modelos que permiten, en potencia, infinitad de combinaciones en cuanto a la estructura del grafo que los define.

Esto permitiría, por ejemplo, utilizar distintas funciones para tratar cada canal, otorgándoles más peso a unos que a otros o diferentes comportamientos.

También podrían extraerse las características sólo de los vecinos anteriores, en lugar de utilizar también los posteriores como en el modelo analizado, reduciendo a cero los posibles retardos; distinta cantidad por delante que por detrás, profundizar en la utilización de las *function-features* gaussianas, etc.

Como decimos, los resultados de este trabajo no deben detener la investigación en modelos de aprendizaje automático para datos secuenciales en tiempo real, ni siquiera HMM o CRF. La última década ha sido especialmente prolífica en el desarrollo de estos modelos y desde aquí animamos a otros investigadores a que analicen su utilidad en el campo de la clasificación de señales obtenidas por EEG.

Algunos modelos alternativos de *machine learning* para secuencias de datos que podríamos citar son: Hidden Markov SVM and LabelSequence Ada-Boost (Altun & Hofmann, 2003), Cycling Dependency Networks (Toutanova et al., 2003), Max-margin Markov Networks (Taskar et al., 2003), Conditional Markov Models (Ratnaparkhi, 1996), Maximum-entropy Markov Models (McCallum et al., 2000), Discriminatively trained HMM (Collins, 2002), Stacked Sequential Learning (Cohen, 2004), Constraint Satisfaction INference (Canisius et al., 2006).

Referencias

- [1] D. L. Vail, M. M. Veloso, and J. D. Lafferty, "Conditional random fields for activity recognition," in *Proceedings of the 6th international joint conference on Autonomous agents and multiagent systems*, ser. AAMAS '07. New York, NY, USA: ACM, 2007, pp. 235:1–235:8. [Online]. Available: <http://doi.acm.org/10.1145/1329125.1329409>
- [2] F. Lotte, M. Congedo, A. Lecuyer, and F. Lamarche, "Topical review a review of classification algorithms for eeg-based brain-computer interfaces," 2007.
- [3] R. A. Fisher, "The use of multiple measurements in taxonomic problems," *Annals of Eugenics*, vol. 7, no. 7, pp. 179–188, 1936.
- [4] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, pp. 273–297, 1995, 10.1007/BF00994018. [Online]. Available: <http://dx.doi.org/10.1007/BF00994018>
- [5] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," in *Proceedings of the 5th Annual Workshop on Computational Learning Theory (COLT'92)*, D. Haussler, Ed. Pittsburgh, PA, USA: ACM Press, July 1992, pp. 144–152. [Online]. Available: <http://doi.acm.org/10.1145/130385.130401>
- [6] V. Vapnik and A. Lerner, "Pattern recognition using generalized portrait method," *Automation and Remote Control*, vol. 24, 1963.
- [7] M. A. Aizerman, E. M. Braverman, and L. I. Rozoner, "Theoretical foundations of the potential function method in pattern recognition learning," *Automation and Remote Control*, vol. 25, pp. 821–837, 1964.
- [8] J. Antelis, L. Montesano, A. Murguialday, N. Birbaumer, and J. Minguez, "Continuous decoding of intention to move from contralateral hemisphere brain oscillations in severely affected chronic stroke patients," in *34th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS)*, 2012.
- [9] C.-C. Chang and C.-J. Lin, "LIBSVM: A library for support vector machines," *ACM Transactions on Intelligent Systems and Technology*, vol. 2, pp. 27:1–27:27, 2011, software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [10] L. R. Rabiner, "A tutorial on hidden markov models and selected applications in speech recognition," in *Proceedings of the IEEE*, 1989, pp. 257–286.
- [11] A. J. Viterbi, "Error bounds for convolutional codes and an asymptotically optimum decoding algorithm," *IEEE Transactions on Information Theory*, vol. IT-13, no. 2, pp. 260–269, April 1967.
- [12] *Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data*, ser. ICML '01. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2001. [Online]. Available: <http://dl.acm.org/citation.cfm?id=645530.655813>

- [13] C. Sutton and A. McCallum, “An introduction to conditional random fields,” 2010, cite arxiv:1011.4088Comment: 90 pages. [Online]. Available: <http://arxiv.org/abs/1011.4088>
- [14] H. B, “An on-line transformation of eeg scalp potentials into orthogonal source derivations,” *Electroencephalogr Clin Neurophysiol*, vol. 5, pp. 526–30, 1975.
- [15] C. Tallon-Baudry, O. Bertrand, C. Delpuech, and J. Permier, “Oscillatory gamma-band (30-70 Hz) activity induced by a visual search task in humans.” *J Neurosci*, vol. 17, no. 2, pp. 722–734, Jan. 1997.
- [16] B. Graimann and G. Pfurtscheller, “Quantification and visualization of event-related changes in oscillatory brain activity in the time frequency domain,” *Progress in Brain Research*, vol. 169, no. 159, pp. 79–97, 2006.
- [17] D. J. McFarland and J. R. Wolpaw, “Trained modulation of sensorimotor rhythms can affect reaction time,” *Clinical Neurophysiology*, vol. 5, p. 155, 2011. [Online]. Available: <http://dx.doi.org/10.1016/j.clinph.2011.02.016>
- [18] G. Pfurtscheller and C. Neuper, “Future prospects of ERD/ERS in the context of brain-computer interface (BCI) developments,” in *Event-Related Dynamics of Brain Oscillations*, ser. Progress in Brain Research, C. Neuper and W. Klimesch, Eds. Elsevier, 2006, vol. 159, pp. 433–437.

Anexos

A. Captura y procesamiento de la señal

La señal con la que se trabaja en este estudio ha sido capturada por el Grupo de Robótica de la Universidad de Zaragoza siguiendo el protocolo que se detalla a continuación. Nos facilitaron los datos ya procesados y en formato adecuado para su lectura en Matlab mediante ficheros *.mat*. Aquí se destaca la información más relevante del protocolo de experimentación, la extracción de datos y el procesado previo de la señal, pero para información más detallada consúltese [8].

A.1. Sujetos

La obtención de datos para este análisis se realizó sobre pacientes con hemiplejia producida por haber sufrido un infarto cerebral. El infarto cerebral es un accidente cerebro-vascular causado por la falta de sangre (isquemia) —y en consecuencia de oxígeno— que, dependiendo de la severidad, puede dañar permanentemente un hemisferio cerebral produciendo la parálisis de la mitad del cuerpo controlada por él mismo. Así pues, nuestros sujetos tienen una corteza cerebral sana y otra dañado, al mismo tiempo que tienen las extremidades de un lado del cuerpo paralizadas.

Concretamente fueron cuatro varones de edades entre 55 y 65 años con apoplejía isquémica (dos en el hemisferio derecho y dos en el izquierdo) los que participaron en este estudio. Todos los pacientes sufrieron el infarto al menos dos años antes de los experimentos. Los pacientes eran incapaces de utilizar la extremidad superior para ninguna actividad cotidiana, sin movilidad en los dedos del lado con paresia (*having no residual finger extension on the paretic side*). Todos los pacientes eran capaces de completar las tareas con el lado sano.

Se realizaron dos experimentos equivalentes, uno en el que el paciente ejecutaba las acciones con el brazo sano, y otro en el que intentaba realizarlas con el brazo dañado. En ambos experimentos se grabaron al mismo tiempo las ondas generadas por cada córtex cerebral. Una vez finalizados, se extrajo la señal de ambos experimentos separando en cada paciente las cuatro combinaciones posibles (Brazo Sano—Córtex Sano, Brazo Sano—Córtex Dañado, Brazo Dañado—Córtex Sano, Brazo Dañado—Córtex Dañado). Será a partir de estos cuatro conjuntos de datos sobre los que se analizarán los diferentes modelos de clasificación.

A.2. Protocolo de experimentación

El protocolo experimental ha sido aprobado por el comité ético de la Facultad de Medicina de la Universidad de Tübingen, y se obtuvo consentimiento escrito de cada paciente.

Los pacientes se sentaban en una silla enfrente de una pantalla de ordenador con los dos antebrazos descansando cómodamente en su regazo.

La tarea consistía en mover el brazo sano, o intentar mover el incapacitado, desde la posición inicial a un punto elegido por el sujeto entre los presentados en una pantalla mediante círculos coloreados y volver a la posición inicial (véase la figura 13).

El experimento comprende dos condiciones diferentes: la condición uno representa el movimiento del brazo sano, mientras que la condición dos se refiere al intento de movimiento del brazo incapacitado.

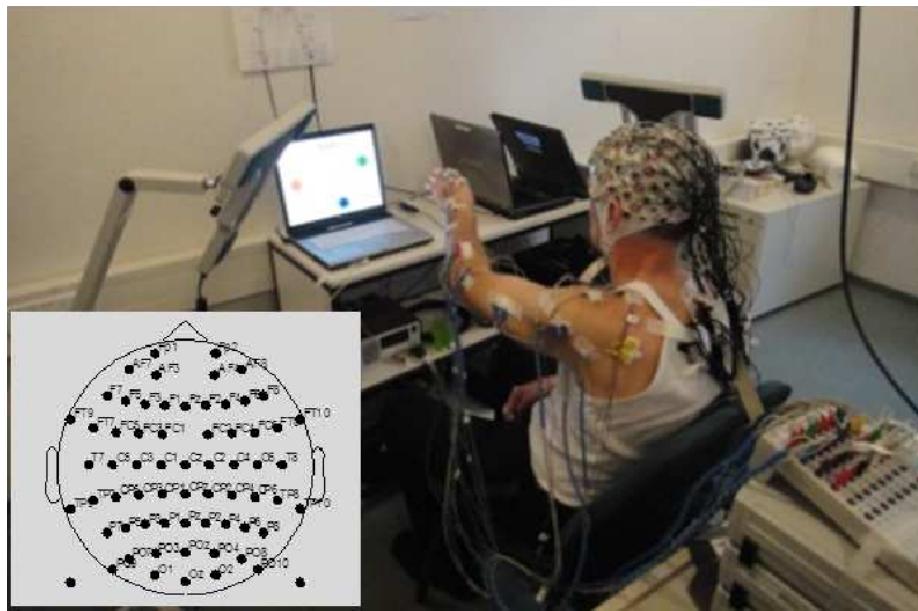


Figura 13: Sujeto en mitad de experimento. Se pueden apreciar los detectores EEG (en la cabeza) y EMG (en el brazo). Abajo a la izquierda, diagrama de la posición de los electrodos en el cráneo del sujeto.

Los usuarios fueron guiados por señales visuales y sonoras. La primera señal indicaba a los usuarios relajar el cuerpo y adoptar la posición inicial durante tres segundos. La segunda señal marcaba el inicio del movimiento del brazo sano y el intento de movimiento del brazo incapacitado. Después de tres segundos, la tercera señal indicaba relajarse adoptando la posición inicial, parpadeando y descansando durante otros tres segundos. Durante la fase de movimiento, entre la segunda y tercera señales), se solicitaba a los sujetos evitar parpadear

o compensar el movimiento con el torso u otras partes del cuerpo; lo cual era controlado visualmente por el terapeuta y luego, tras los experimentos, mediante inspección visual de los datos EMG.

El experimento se ejecutó en cuatro bloques de seis minutos cada uno. Cuarenta ensayos se grabaron en cada bloque, resultando un total de 160 ensayos (80 para cada condición). Después de cada bloque el paciente podía descansar tanto como fuera necesario para evitar la fatiga.

A.3. Proceso de grabación

La actividad EEG fue grabada a través de 64 electrodos activos ordenados de acuerdo al sistema internacional 10/10 utilizando un sistema *actiCAP* (de Brain Products GmbH, Alemania), con masa en AFz y referenciado al lóbulo de la oreja izquierda.

Dieciséis electrodos bipolares *Ag/AgCl* (ocho en cada brazo) de Myotronics-Noromed (Tuwila, WA, USA) se emplearon para la adquisición de datos EMG en la superficie y situados en los músculos involucrados en el movimiento: 1) extensor ulnar del carpo (extensor carpi ulnaris); 2) extensor digitorum; 3) en el flexor radial del carpo (flexor carpi radialis), palmar menor (plamaris longus), flexor carpi ulnaris (flexión); 4) en la cabeza externa del bíceps (flexion); 5) la cabeza externa del tríceps; 6) lado frontal del deltoides; 7) lado lateral del deltoides; y 8) lado posterior del del deltoides sobre el músculo redondo menor (*teres minor*) y el músculo intraespínoso. Los datos EEG y EMG se grabaron a una tasa de sampleo de 2500 Hz sin filtrado.

A.4. Procesado previo del EEG y del EMG

Cada ensayo de EEG y EMG tiene una duración de nueve segundos, con la referencia de tiempo tomada desde los segundos -3 a 6 con respecto a la aparición de la segunda señal (inicio del movimiento), por lo que éste comienza en el instante cero. Para cada ensayo el comienzo del movimiento se determinó utilizando las señales del EMG. Para cada sujeto, la señal EMG con mayor amplitud y actividad más consistente (una baja amplitud en el periodo de relajación y alta amplitud mantenida durante el periodo de movimiento) durante todos los ensayos fue seleccionada por inspección visual. En cada ensayo, a la señal del canal EMG elegido se le aplicó un filtrado paso-alto con una frecuencia de corte de 10 Hz, y posteriormente se le aplicó la transformada de Hilbert para obtener el comienzo del movimiento. Finalmente, todos los ensayos EEG y EMG fueron recortados entre los segundos -3 y 3 en relación al comienzo del movimiento basado en el EMG.

A las señales EEG se les aplicó un filtro paso-banda entre 0.5 y 60 Hz usando un filtro desplazado a la fase cero y resampleado a 160 Hz. Para eliminar los efectos de la conducción del volumen, se aplicó un filtrado espacial Laplaciano

([14]) con la intención de obtener señales EEG libres de artefactos.

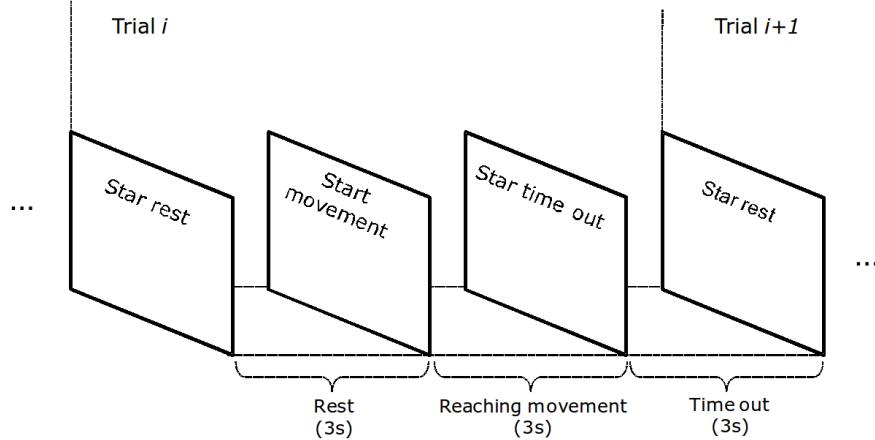


Figura 14: Esquema donde se aprecia la secuencia de estados rest (descanso) y reaching movement (movimiento).

A.5. Tareas relacionadas con la modulación en potencia

La evolución temporal de la potencia espectral en diferentes bandas de frecuencia de la actividad EEG libre de artefactos se calculó con un análisis de frecuencia temporal usando las ondículas complejas de Morlet (complex Morlet's wavelet) [15]. La representación en la frecuencia temporal (TFR) se calculó para todos los ensayos en cada condición de 2 a 40 Hz con una resolución de frecuencia de 1 Hz. Posteriormente, la relevancia estadística del porcentaje de incremento/disminución de la potencia espectral en relación al punto de referencia en el intervalo de -3 a 0 segundos se calculó con un análisis de remuestreo ([16]) con un nivel de significancia de $\alpha = 0,01$.

A.6. Selección de características

Los canales localizados en el córtex motor sano y y los *frequency bins* en las franjas (α y β) que muestran una desincronización significativa en la ventana temporal de 0 a 3 segundos fueron identificados individualmente por inspección visual en cada sujeto.

La potencia espectral de estas parejas de canal-frecuencia se calculó usando un modelo autoregresivo de orden 16^o [17] sobre una ventana de tamaño δ_w para la actividad EEG, obteniendo las características x_t en el tiempo t para la detección de intención de movimiento. Las características basadas en la potencia espectral de los canales en el córtex motor y en las franjas relacionados con la zona motor han sido usados en otros trabajos para la detección de movimientos ejecutados o imaginados de diferentes partes de las extremidades [18]. Sin embargo, en esta investigación se utilizan simplemente los canales del córtex motor

opuesto a la zona lesionada para decodificar ambas condiciones (movimientos del lado sano e intentos de mover el lado paralizado).

B. Planificación

Este proyecto estuvo desarrollándose a tiempo completo de febrero a junio. Durante este tiempo se realizó la mayor parte del trabajo, desde la documentación a la ejecución y pruebas con todos los modelos.

- Documentación sobre EEG y clasificación de estas señales.
- Documentación sobre el caso particular de pacientes con hemiplejia y los experimentos de lectura del EEG.
- Documentación de modelos de clasificación estáticos (LDA y SVM).
- Aprendizaje del uso de las librerías para modelos estáticos.
- Primeros contactos replicando experimentos realizados sobre sujetos sanos.
- Implementación de código para tratar adecuadamente nuestros conjuntos de datos para entrenar y testear los modelos estáticos con las librerías.
- Ejecuciones probando el comportamiento de los modelos con diferentes parámetros.
- Documentación de modelos de clasificación dinámicos (HMM y CRF).
- Aprendizaje del uso de las librerías para modelos dinámicos.
- Implementación de código para tratar adecuadamente nuestros conjuntos de datos para entrenar y testear los modelos dinámicos con las librerías.
- Ejecuciones probando el comportamiento de los modelos con diferentes parámetros.
- Implementación de baterías de pruebas para todos los modelos y código para automatizar los entrenamientos y obtener información de salida consistente entre todos los modelos.

A partir de entonces, y con el grueso del trabajo realizado, el presente investigador se incorporó a jornada completa a trabajar en una empresa privada. Así, desde julio hasta noviembre, primero se dedicó a entrenar los diferentes modelos con los parámetros que se habían considerado de mayor importancia en el estudio previo. Una vez obtenidos, siguió un proceso de evaluación y estudio de los mismos para, finalmente, terminar realizando la presente memoria que resume y engloba todo el trabajo realizado en este proyecto.

C. Resultados completos por modelo

En este apartado vamos a mostrar los resultados detallados obtenidos en todos los modelos mediante la media de aciertos de los seis sujetos estudiados.

El formato de todas las tablas va a ser el mismo para todos los tres primeros modelos. La primera columna representa cómo se seleccionan los datos según se describió en la sección 2.2: puntos es que se toma una muestra individual cada vez, ventanas es que se considera toda la ventana entre dos puntos haciendo la media, y solapadas es similar al anterior pero permitiendo solapamiento de ventanas.

La segunda columna llamada *delay*, indica la distancia entre cada lectura que se toma según el tipo y es, por tanto, el retraso en segundos con el que se puede clasificar una muestra ya leída. Esto también se ha explicado detalladamente en la sección 2.2 y como sabemos es un criterio básico a la hora de estimar la eficacia de un clasificador, puesto que necesitamos conocer la etiqueta de los estados cuanto antes. Las tres siguientes columnas son la media obtenida en cada estado por separado y la media total. Obsérvese que esta última media no es la media aritmética de las anteriores, puesto que cada estado tiene distinto tamaño.

Como se describe en 3.4.2 los CRF en cadena permiten incluir la información de los nodos vecinos para realizar la clasificación. En la librería que utilizamos a este parámetro se le denomina *tamaño de ventana* y hace referencia al número de nodos vecinos en ambas direcciones que se utilizarán. Para no liarnos con el sistema de segmentación de la señal, le llamaremos *wSize*. Entonces aquí el *delay* dependerá de cuántos vecinos utilizamos por delante, que coincide con *wSize*, y a qué intervalo hemos decidido tomar estos puntos. De ese modo, $delay = wsize * intervalo$.

Por este motivo los CRF necesitan un formato de tabla distinto a los anteriores, en el que se muestran las tres variables de la última fórmula en las tres primeras columnas. Se han realizado combinaciones entre el número de vecinos (de 5 a 30) y los intervalos de muestreo de la señal (desde utilizar toda la señal a intervalos de 0.25 segundos), quedando diferentes delays de ± 1.25 , ± 0.9375 y ± 0.625 , etc. segundos. Puesto que algunas combinaciones distintas de *intervalo* y *wsize* pueden dar lugar a un mismo *delay*, estos se han agrupado, pues a fin de cuentas utilizan *grosso modo* un subconjunto similar de observaciones (y esto se hace evidente cuando se observa que todos los modelos con mismo *delay* comparten un porcentaje de aciertos similar).

C.1. LDA

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	58.02	73.33	66.76
Puntos	0.03125	58.05	73.38	66.76
Puntos	0.0625	58.14	73.32	66.72
Puntos	0.125	58.21	73.42	66.70
Puntos	0.1875	58.25	73.48	66.65
Puntos	0.25	58.04	73.76	66.61
Puntos	0.5	58.37	74.37	67.10
Ventanas	0.03125	58.02	73.53	66.88
Ventanas	0.0625	58.13	73.58	66.96
Ventanas	0.125	58.09	73.89	67.12
Ventanas	0.1875	58.15	74.28	67.37
Ventanas	0.25	58.31	74.51	67.56
Ventanas	0.5	59.73	75.34	69.10
V. Solapadas	0.03125	58.13	73.63	66.95
V. Solapadas	0.0625	58.09	73.91	67.05
V. Solapadas	0.125	58.26	74.28	67.25
V. Solapadas	0.1875	58.45	74.63	67.44
V. Solapadas	0.25	58.40	74.81	67.42
V. Solapadas	0.5	62.23	75.75	69.74

Cuadro 8: LDA - Arm Healthy Cortex Healthy - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	64.69	77.43	71.96
Puntos	0.03125	64.76	77.40	71.94
Puntos	0.0625	64.68	77.53	71.94
Puntos	0.125	64.75	77.47	71.85
Puntos	0.1875	64.47	77.65	71.74
Puntos	0.25	64.64	77.10	71.43
Puntos	0.5	64.45	77.01	71.30
Ventanas	0.03125	64.77	77.62	72.11
Ventanas	0.0625	65.06	77.79	72.33
Ventanas	0.125	65.26	77.88	72.47
Ventanas	0.1875	65.41	78.69	73.00
Ventanas	0.25	65.94	78.42	73.07
Ventanas	0.5	66.61	79.75	74.50
V. Solapadas	0.03125	65.10	77.79	72.32
V. Solapadas	0.0625	65.24	77.98	72.45
V. Solapadas	0.125	65.48	78.50	72.78
V. Solapadas	0.1875	65.90	78.69	73.00
V. Solapadas	0.25	66.22	79.14	73.33
V. Solapadas	0.5	67.23	80.62	74.67

Cuadro 9: LDA - Arm Healthy Cortex Healthy - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	54.75	65.11	60.66
Puntos	0.03125	54.82	65.02	60.62
Puntos	0.0625	55.04	64.96	60.64
Puntos	0.125	55.13	64.84	60.55
Puntos	0.1875	54.51	65.28	60.45
Puntos	0.25	55.79	64.72	60.66
Puntos	0.5	55.87	65.20	60.96
Ventanas	0.03125	54.85	65.13	60.72
Ventanas	0.0625	54.80	65.47	60.90
Ventanas	0.125	54.84	65.38	60.86
Ventanas	0.1875	55.12	65.84	61.25
Ventanas	0.25	55.30	65.64	61.21
Ventanas	0.5	55.41	68.12	63.04
V. Solapadas	0.03125	54.75	65.42	60.82
V. Solapadas	0.0625	54.73	65.47	60.82
V. Solapadas	0.125	54.84	65.67	60.92
V. Solapadas	0.1875	54.73	65.98	60.98
V. Solapadas	0.25	54.30	66.42	60.96
V. Solapadas	0.5	57.60	67.16	62.91

Cuadro 10: *LDA - Arm Impaired Cortex Healthy - Mejor canal*

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	60.03	69.57	65.47
Puntos	0.03125	60.07	69.65	65.51
Puntos	0.0625	60.16	69.76	65.58
Puntos	0.125	60.24	69.59	65.46
Puntos	0.1875	60.54	69.27	65.35
Puntos	0.25	60.16	69.65	65.34
Puntos	0.5	60.12	69.23	65.09
Ventanas	0.03125	60.04	69.74	65.58
Ventanas	0.0625	60.13	69.89	65.71
Ventanas	0.125	60.34	70.33	66.05
Ventanas	0.1875	60.45	70.42	66.15
Ventanas	0.25	60.74	70.62	66.38
Ventanas	0.5	60.52	71.07	66.85
V. Solapadas	0.03125	60.28	69.94	65.77
V. Solapadas	0.0625	60.48	70.31	66.05
V. Solapadas	0.125	60.77	70.59	66.28
V. Solapadas	0.1875	61.25	70.61	66.45
V. Solapadas	0.25	61.18	70.54	66.33
V. Solapadas	0.5	61.19	71.00	66.64

Cuadro 11: *LDA - Arm Impaired Cortex Healthy - Todos los mejores canales*

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	56.00	57.19	56.68
Puntos	0.03125	56.07	57.13	56.67
Puntos	0.0625	55.84	57.00	56.49
Puntos	0.125	55.81	57.23	56.60
Puntos	0.1875	55.65	57.01	56.40
Puntos	0.21875	55.98	57.72	56.92
Puntos	0.25	55.81	56.42	56.14
Puntos	0.5	56.12	56.63	56.40
Ventanas	0.03125	56.02	57.26	56.73
Ventanas	0.0625	56.12	57.45	56.88
Ventanas	0.125	56.20	57.65	57.03
Ventanas	0.1875	56.18	57.66	57.03
Ventanas	0.21875	55.87	57.83	56.98
Ventanas	0.25	56.11	57.91	57.14
Ventanas	0.5	56.25	58.61	57.66
V. Solapadas	0	56.00	57.21	56.69
V. Solapadas	0.03125	56.17	57.40	56.87
V. Solapadas	0.0625	56.25	57.57	57.00
V. Solapadas	0.125	56.40	57.56	57.05
V. Solapadas	0.1875	56.45	57.86	57.23
V. Solapadas	0.21875	56.56	57.95	57.32
V. Solapadas	0.25	56.78	57.57	57.21
V. Solapadas	0.5	57.65	58.41	58.07

Cuadro 12: LDA - Arm Healthy Cortex Injured - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	56.58	65.45	61.64
Puntos	0.03125	56.71	65.59	61.76
Puntos	0.0625	56.36	65.72	61.65
Puntos	0.125	56.86	65.49	61.68
Puntos	0.1875	56.73	65.80	61.73
Puntos	0.21875	56.40	65.62	61.39
Puntos	0.25	56.81	64.93	61.24
Puntos	0.5	57.33	66.25	62.19
Ventanas	0.03125	56.56	65.54	61.69
Ventanas	0.0625	56.49	65.85	61.84
Ventanas	0.125	56.67	66.03	62.02
Ventanas	0.1875	56.47	66.19	62.03
Ventanas	0.21875	56.79	66.28	62.15
Ventanas	0.25	56.85	66.26	62.23
Ventanas	0.5	57.34	67.50	63.43
V. Solapadas	0	56.53	65.41	61.60
V. Solapadas	0.03125	56.54	65.71	61.76
V. Solapadas	0.0625	56.74	65.86	61.91
V. Solapadas	0.125	56.78	65.82	61.85
V. Solapadas	0.1875	57.34	65.91	62.10
V. Solapadas	0.21875	57.58	66.28	62.32
V. Solapadas	0.25	57.38	66.38	62.33
V. Solapadas	0.5	59.21	67.50	63.81

Cuadro 13: LDA - Arm Healthy Cortex Injured - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	52.62	62.77	58.42
Puntos	0.03125	52.62	62.93	58.48
Puntos	0.0625	52.80	62.91	58.51
Puntos	0.125	52.91	62.58	58.31
Puntos	0.1875	52.41	63.03	58.27
Puntos	0.21875	52.68	63.42	58.50
Puntos	0.25	52.79	62.37	58.02
Puntos	0.5	53.33	63.50	58.88
Ventanas	0.03125	52.67	63.05	58.60
Ventanas	0.0625	52.69	63.15	58.67
Ventanas	0.125	52.78	63.14	58.70
Ventanas	0.1875	52.22	63.33	58.57
Ventanas	0.21875	52.70	64.21	59.21
Ventanas	0.25	52.93	63.36	58.89
Ventanas	0.5	53.17	63.57	59.41
V. Solapadas	0	52.65	62.88	58.49
V. Solapadas	0.03125	52.71	63.25	58.71
V. Solapadas	0.0625	52.54	63.55	58.78
V. Solapadas	0.125	52.33	63.97	58.86
V. Solapadas	0.1875	52.29	64.26	58.94
V. Solapadas	0.21875	52.06	64.20	58.68
V. Solapadas	0.25	52.89	64.65	59.36
V. Solapadas	0.5	54.32	64.75	60.11

Cuadro 14: LDA - Arm Impaired Cortex Injured - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	57.20	63.26	60.66
Puntos	0.03125	57.24	63.40	60.74
Puntos	0.0625	57.47	63.22	60.72
Puntos	0.125	57.46	62.98	60.54
Puntos	0.1875	56.74	63.68	60.57
Puntos	0.21875	57.59	64.02	61.07
Puntos	0.25	56.75	62.43	59.84
Puntos	0.5	58.08	62.91	60.71
Ventanas	0.03125	57.21	63.43	60.77
Ventanas	0.0625	57.01	63.52	60.73
Ventanas	0.125	56.93	63.64	60.76
Ventanas	0.1875	57.20	64.47	61.36
Ventanas	0.21875	56.91	64.47	61.18
Ventanas	0.25	57.17	63.97	61.06
Ventanas	0.5	57.50	64.86	61.91
V. Solapadas	0	57.19	63.29	60.67
V. Solapadas	0.03125	57.03	63.54	60.73
V. Solapadas	0.0625	57.25	63.72	60.92
V. Solapadas	0.125	57.07	64.22	61.08
V. Solapadas	0.1875	57.50	64.40	61.33
V. Solapadas	0.21875	57.75	64.61	61.49
V. Solapadas	0.25	58.10	64.50	61.62
V. Solapadas	0.5	59.06	64.83	62.26

Cuadro 15: LDA - Arm Impaired Cortex Injured - Todos los mejores canales

C.2. SVM

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0.0625	47.25	82.38	67.09
Puntos	0.125	47.99	81.93	66.93
Puntos	0.1875	50.08	80.18	66.68
Puntos	0.25	50.43	80.65	66.92
Ventanas	0.03125	46.96	82.97	67.54
Ventanas	0.0625	47.39	82.82	67.63
Ventanas	0.125	47.31	82.96	67.68
Ventanas	0.1875	47.84	83.00	67.93
Ventanas	0.25	48.70	82.81	68.19
V. Solapadas	0.03125	48.08	82.37	67.59
V. Solapadas	0.0625	48.83	81.96	67.59
V. Solapadas	0.125	50.78	81.04	67.75
V. Solapadas	0.1875	52.70	79.54	67.61
V. Solapadas	0.25	54.88	78.69	67.97

Cuadro 16: SVM - Arm Healthy Cortex Healthy - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0.0625	58.40	81.26	71.31
Puntos	0.125	59.46	81.58	71.81
Puntos	0.1875	59.56	81.49	71.66
Puntos	0.25	60.39	81.12	71.70
Ventanas	0.03125	58.20	80.58	70.99
Ventanas	0.0625	58.47	81.54	71.65
Ventanas	0.125	58.88	82.45	72.35
Ventanas	0.1875	59.27	82.33	72.44
Ventanas	0.25	60.34	82.74	73.14
V. Solapadas	0.03125	59.10	79.96	70.97
V. Solapadas	0.0625	60.22	80.66	71.80
V. Solapadas	0.125	61.62	81.10	72.55
V. Solapadas	0.1875	63.15	80.98	73.06
V. Solapadas	0.25	64.30	80.54	73.23

Cuadro 17: SVM - Arm Healthy Cortex Healthy - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0.0625	34.73	83.26	62.13
Puntos	0.125	35.09	82.91	61.78
Puntos	0.1875	36.07	82.18	61.51
Puntos	0.25	37.64	80.79	61.18
Ventanas	0.03125	34.57	83.76	62.68
Ventanas	0.0625	34.78	84.01	62.91
Ventanas	0.125	35.03	83.84	62.92
Ventanas	0.1875	34.87	84.28	63.11
Ventanas	0.25	34.51	85.00	63.36
V. Solapadas	0.03125	35.61	83.09	62.62
V. Solapadas	0.0625	36.65	82.93	62.86
V. Solapadas	0.125	38.59	82.25	63.08
V. Solapadas	0.1875	39.27	82.12	61.00

Cuadro 18: SVM - Arm Impaired Cortex Healthy - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0.03125	48.49	78.58	65.58
Puntos	0.0625	48.70	79.55	66.12
Puntos	0.125	49.30	80.06	66.47
Puntos	0.1875	49.95	78.98	65.96
Puntos	0.25	50.77	79.14	66.25
Ventanas	0.03125	48.60	78.47	65.66
Ventanas	0.0625	47.93	79.92	66.21
Ventanas	0.125	47.59	80.98	66.67
Ventanas	0.1875	47.10	81.60	66.81
Ventanas	0.25	47.43	82.41	67.42
V. Solapadas	0.03125	49.60	77.89	65.69
V. Solapadas	0.0625	49.42	78.98	66.16
V. Solapadas	0.125	50.18	79.57	66.67
V. Solapadas	0.1875	51.85	78.83	66.84
V. Solapadas	0.25	53.07	78.31	66.95

Cuadro 19: SVM - Arm Impaired Cortex Healthy - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0.03125	26.72	84.40	59.48
Puntos	0.0625	27.43	84.14	59.46
Puntos	0.125	28.83	83.08	59.11
Puntos	0.1875	32.03	81.31	59.22
Puntos	0.21875	36.47	77.54	58.72
Puntos	0.25	31.39	81.42	58.68
Puntos	0.5	34.95	79.86	59.45
Ventanas	0.0625	24.61	85.86	59.61
Ventanas	0.125	24.30	86.38	59.77
Ventanas	0.1875	23.59	86.65	59.62
Ventanas	0.21875	26.77	84.82	59.58
Ventanas	0.25	24.07	86.11	59.52
Ventanas	0.5	18.54	91.38	62.25
V. Solapadas	0.0625	27.42	84.22	59.58
V. Solapadas	0.125	29.57	82.78	59.42
V. Solapadas	0.1875	33.15	80.43	59.42
V. Solapadas	0.21875	38.52	76.56	59.27
V. Solapadas	0.25	36.57	77.82	59.26
V. Solapadas	0.5	37.08	78.20	59.93

Cuadro 20: SVM - Arm Healthy Cortex Injured - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0.03125	37.91	81.67	62.77
Puntos	0.0625	38.46	81.77	62.92
Puntos	0.125	39.66	80.96	62.71
Puntos	0.1875	41.61	80.53	63.08
Puntos	0.21875	45.39	76.81	62.41
Puntos	0.25	41.31	79.58	62.18
Puntos	0.5	44.95	78.02	62.99
Ventanas	0.0625	38.20	81.91	63.17
Ventanas	0.125	38.42	82.38	63.54
Ventanas	0.1875	38.57	82.85	63.87
Ventanas	0.21875	41.62	81.50	64.16
Ventanas	0.25	39.18	82.50	63.93
Ventanas	0.5	33.75	88.36	66.52
V. Solapadas	0.0625	40.25	80.66	63.13
V. Solapadas	0.125	41.99	79.87	63.24
V. Solapadas	0.1875	44.25	78.79	63.44
V. Solapadas	0.21875	47.70	77.13	63.75
V. Solapadas	0.25	45.74	77.99	63.47
V. Solapadas	0.5	46.40	78.37	64.16

Cuadro 21: SVM - Arm Healthy Cortex Injured - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0.0625	30.70	83.47	60.50
Puntos	0.125	32.23	82.68	60.39
Puntos	0.1875	33.34	81.14	59.71
Puntos	0.21875	37.61	78.14	59.56
Puntos	0.25	34.70	82.03	60.52
Puntos	0.5	33.95	82.84	60.62
Ventanas	0.0625	30.56	84.51	61.39
Ventanas	0.125	30.69	84.53	61.45
Ventanas	0.1875	31.07	84.72	61.73
Ventanas	0.21875	32.29	83.79	61.40
Ventanas	0.25	30.94	84.25	61.40
Ventanas	0.5	26.61	88.05	63.47
V. Solapadas	0.0625	31.81	83.64	61.16
V. Solapadas	0.125	33.94	82.53	61.20
V. Solapadas	0.1875	36.63	81.09	61.33
V. Solapadas	0.21875	40.52	79.49	61.78
V. Solapadas	0.25	38.93	80.49	61.79
V. Solapadas	0.5	38.33	81.91	62.54

Cuadro 22: SVM - Arm Impaired Cortex Injured - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0.0625	41.36	78.77	62.49
Puntos	0.125	42.05	78.82	62.57
Puntos	0.1875	42.08	78.08	61.94
Puntos	0.21875	47.02	74.56	61.94
Puntos	0.25	42.97	77.93	62.04
Puntos	0.5	43.00	80.34	63.37
Ventanas	0.0625	41.23	79.07	62.85
Ventanas	0.125	41.16	80.02	63.37
Ventanas	0.1875	41.19	80.82	63.83
Ventanas	0.21875	43.08	79.93	63.91
Ventanas	0.25	41.27	80.52	63.70
Ventanas	0.5	36.19	85.45	65.75
V. Solapadas	0.0625	42.86	77.77	62.63
V. Solapadas	0.125	44.42	77.78	63.13
V. Solapadas	0.1875	45.81	77.02	63.15
V. Solapadas	0.21875	48.95	75.62	63.50
V. Solapadas	0.25	47.77	76.32	63.47
V. Solapadas	0.5	47.81	78.08	64.62

Cuadro 23: SVM - Arm Impaired Cortex Injured - Todos los mejores canales

SVM train a 0.75 y test variado

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	61.39	70.74	66.72
Puntos	0.03125	61.48	70.73	66.73
Puntos	0.0625	61.32	70.87	66.72
Puntos	0.125	61.40	70.70	66.59
Puntos	0.25	60.50	71.35	66.42
Ventanas	0.03125	51.37	79.40	67.39
Ventanas	0.0625	51.31	79.68	67.52
Ventanas	0.125	51.19	80.04	67.67
Ventanas	0.25	51.13	80.15	67.71
V. Solapadas	0.03125	64.06	67.63	66.09
V. Solapadas	0.0625	64.24	68.08	66.42
V. Solapadas	0.125	64.32	68.83	66.85
V. Solapadas	0.25	64.35	69.26	67.05

Cuadro 24: SVM (train 0.75 - test variado) - Arm Healthy Cortex Healthy - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	67.13	74.92	71.58
Puntos	0.03125	67.00	74.97	71.53
Puntos	0.0625	67.00	75.06	71.55
Puntos	0.125	66.98	75.00	71.46
Puntos	0.25	66.31	74.30	70.67
Ventanas	0.03125	62.13	79.08	71.82
Ventanas	0.0625	62.09	79.52	72.05
Ventanas	0.125	62.32	80.05	72.45
Ventanas	0.25	62.19	80.95	72.91
V. Solapadas	0.03125	72.31	68.58	70.19
V. Solapadas	0.0625	72.31	69.13	70.51
V. Solapadas	0.125	72.14	70.73	71.35
V. Solapadas	0.25	71.48	72.25	71.90

Cuadro 25: SVM (train 0.75 - test variado) - Arm Healthy Cortex Healthy - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	55.94	63.02	59.98
Puntos	0.03125	55.80	63.00	59.89
Puntos	0.0625	55.54	63.29	59.92
Puntos	0.125	55.17	63.57	59.86
Puntos	0.25	56.08	62.46	59.56
Ventanas	0.03125	37.45	81.16	62.43
Ventanas	0.0625	37.41	81.64	62.68
Ventanas	0.125	37.32	82.07	62.89
Ventanas	0.25	37.63	82.20	63.10
V. Solapadas	0.03125	59.48	61.78	60.79
V. Solapadas	0.0625	58.52	60.67	59.74
V. Solapadas	0.125	58.35	61.82	60.29
V. Solapadas	0.25	58.35	62.78	60.79

Cuadro 26: SVM (*train 0.75 - test variado*) - Arm Impaired Cortex Healthy - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	60.52	68.23	64.92
Puntos	0.03125	60.46	68.31	64.92
Puntos	0.0625	60.54	68.59	65.09
Puntos	0.125	60.52	69.01	65.26
Puntos	0.25	60.72	68.42	64.92
Ventanas	0.03125	50.26	77.64	65.91
Ventanas	0.0625	49.79	78.20	66.02
Ventanas	0.125	49.82	78.88	66.42
Ventanas	0.25	49.30	79.58	66.60
V. Solapadas	0.03125	68.45	59.29	63.24
V. Solapadas	0.0625	68.24	60.26	63.72
V. Solapadas	0.125	67.74	61.52	64.25
V. Solapadas	0.25	67.40	63.82	65.43

Cuadro 27: SVM (*train 0.75 - test variado*) - Arm Impaired Cortex Healthy - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Punto	0.03125:	54.18	60.25	57.63
Punto	0.0625:	53.96	60.25	57.51
Punto	0.125:	53.82	60.18	57.37
Punto	0.25:	53.27	60.22	57.06
Punto	0.5:	55.00	60.69	58.10
Ventana	0.03125:	30.50	81.48	59.63
Ventana	0.0625:	30.43	81.67	59.71
Ventana	0.125:	30.52	82.08	59.98
Ventana	0.25:	29.58	82.27	59.69
Ventana	0.5:	30.88	83.68	62.56
V. Solapada	0.03125:	55.36	59.58	57.76
V. Solapada	0.0625:	55.71	59.81	58.03
V. Solapada	0.125:	55.87	60.16	58.28
V. Solapada	0.25:	56.25	60.66	58.67
V. Solapada	0.5:	57.44	60.25	59.00

Cuadro 28: SVM (train 0.75 - test variado) - Arm Healthy Cortex Injured - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Punto	0.03125:	54.88	66.27	61.35
Punto	0.0625:	54.75	66.34	61.30
Punto	0.125:	54.49	66.23	61.04
Punto	0.25:	54.18	65.92	60.58
Punto	0.5:	55.83	66.38	61.59
Ventana	0.03125:	42.40	78.87	63.24
Ventana	0.0625:	42.40	79.27	63.46
Ventana	0.125:	42.43	79.66	63.70
Ventana	0.25:	43.03	80.38	64.37
Ventana	0.5:	44.68	81.45	66.75
V. Solapada	0.03125:	61.91	59.13	60.33
V. Solapada	0.0625:	61.86	59.82	60.71
V. Solapada	0.125:	61.77	60.37	60.98
V. Solapada	0.25:	61.22	61.34	61.29
V. Solapada	0.5:	63.17	62.29	62.68

Cuadro 29: SVM (train 0.75 - test variado) - Arm Healthy Cortex Injured - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Punto	0.03125:	53.92	61.86	58.43
Punto	0.0625:	53.69	61.76	58.25
Punto	0.125:	53.46	61.66	58.04
Punto	0.25:	53.43	61.33	57.74
Punto	0.5:	54.12	61.59	58.20
Ventana	0.03125:	34.02	81.69	61.26
Ventana	0.0625:	34.17	82.03	61.52
Ventana	0.125:	34.16	82.43	61.75
Ventana	0.25:	33.84	83.21	62.05
Ventana	0.5:	33.85	83.57	63.68
V. Solapada	0.03125:	55.48	60.73	58.46
V. Solapada	0.0625:	55.46	61.32	58.78
V. Solapada	0.125:	55.57	61.99	59.17
V. Solapada	0.25:	55.34	62.72	59.40
V. Solapada	0.5:	57.03	62.79	60.23

Cuadro 30: SVM (train 0.75 - test variado) - Arm Impaired Cortex Injured - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Punto	0.03125:	55.99	65.86	61.60
Punto	0.0625:	55.97	65.73	61.48
Punto	0.125:	56.01	65.92	61.55
Punto	0.25:	55.83	65.74	61.24
Punto	0.5:	56.50	65.83	61.59
Ventana	0.03125:	41.34	79.37	63.07
Ventana	0.0625:	41.20	79.56	63.12
Ventana	0.125:	41.16	79.90	63.30
Ventana	0.25:	41.20	80.59	63.71
Ventana	0.5:	42.86	80.76	65.60
V. Solapada	0.03125:	57.71	65.04	61.88
V. Solapada	0.0625:	57.91	65.41	62.16
V. Solapada	0.125:	58.04	65.82	62.40
V. Solapada	0.25:	59.39	66.02	63.04
V. Solapada	0.5:	61.82	67.70	65.09

Cuadro 31: SVM (train 0.75 - test variado) - Arm Impaired Cortex Injured - Todos los mejores canales

C.3. HMM

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	39.25	94.03	70.51
Puntos	0.03125	46.81	92.62	72.83
Puntos	0.0625	51.56	91.87	74.32
Puntos	0.125	56.19	91.37	75.82
Puntos	0.1875	60.09	91.56	77.45
Puntos	0.25	61.70	91.47	77.94
Puntos	0.5	66.58	92.46	80.70
Ventanas	0.03125	46.53	92.66	72.89
Ventanas	0.0625	51.23	91.87	74.45
Ventanas	0.125	56.56	91.15	76.32
Ventanas	0.1875	59.93	90.93	77.64
Ventanas	0.25	61.71	91.00	78.45
Ventanas	0.5	67.96	91.84	82.29
V. Solapadas	0.03125	46.23	92.68	72.65
V. Solapadas	0.0625	51.00	91.84	74.12
V. Solapadas	0.125	56.26	91.09	75.80
V. Solapadas	0.1875	59.67	90.77	76.95
V. Solapadas	0.25	61.75	90.77	77.71
V. Solapadas	0.5	69.16	91.20	81.41

Cuadro 32: HMM - Arm Healthy Cortex Healthy - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	46.41	93.19	73.11
Puntos	0.03125	51.84	91.76	74.52
Puntos	0.0625	54.94	91.10	75.36
Puntos	0.125	58.50	90.23	76.21
Puntos	0.1875	60.32	90.13	76.76
Puntos	0.25	62.68	90.01	77.59
Puntos	0.5	67.04	90.27	79.71
Ventanas	0.03125	51.56	91.76	74.53
Ventanas	0.0625	54.72	91.09	75.50
Ventanas	0.125	58.62	90.26	76.70
Ventanas	0.1875	61.09	89.76	77.47
Ventanas	0.25	62.91	89.27	77.97
Ventanas	0.5	69.94	89.40	81.62
V. Solapadas	0.03125	51.63	91.75	74.45
V. Solapadas	0.0625	55.05	91.05	75.43
V. Solapadas	0.125	59.46	89.86	76.51
V. Solapadas	0.1875	62.76	89.00	77.33
V. Solapadas	0.25	65.48	88.25	78.01
V. Solapadas	0.5	73.02	86.83	80.69

Cuadro 33: HMM - Arm Healthy Cortex Healthy - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	40.69	85.84	66.46
Puntos	0.03125	49.54	84.26	69.26
Puntos	0.0625	54.36	84.36	71.30
Puntos	0.125	59.26	85.84	74.09
Puntos	0.1875	61.42	89.50	76.91
Puntos	0.25	63.62	89.63	77.81
Puntos	0.5	68.20	91.21	80.75
Ventanas	0.03125	49.19	84.35	69.28
Ventanas	0.0625	53.96	84.58	71.46
Ventanas	0.125	58.77	85.91	74.28
Ventanas	0.1875	61.73	87.83	76.65
Ventanas	0.25	63.58	89.37	78.32
Ventanas	0.5	67.65	91.84	82.16
V. Solapadas	0.03125	48.99	84.32	69.09
V. Solapadas	0.0625	53.83	84.44	71.16
V. Solapadas	0.125	58.33	86.51	74.14
V. Solapadas	0.1875	61.44	88.41	76.42
V. Solapadas	0.25	63.07	89.43	77.57
V. Solapadas	0.5	69.06	89.95	80.67

Cuadro 34: HMM - Arm Impaired Cortex Healthy - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	38.99	90.25	68.24
Puntos	0.03125	45.03	88.38	69.65
Puntos	0.0625	48.27	87.57	70.46
Puntos	0.125	53.45	86.36	71.82
Puntos	0.1875	55.65	86.40	72.62
Puntos	0.25	57.50	85.65	72.85
Puntos	0.5	61.95	87.43	75.85
Ventanas	0.03125	44.73	88.54	69.76
Ventanas	0.0625	48.39	87.50	70.74
Ventanas	0.125	52.66	86.73	72.13
Ventanas	0.1875	55.57	86.11	73.02
Ventanas	0.25	57.33	86.02	73.73
Ventanas	0.5	62.39	87.29	77.33
V. Solapadas	0.03125	44.82	88.62	69.74
V. Solapadas	0.0625	48.63	87.61	70.71
V. Solapadas	0.125	53.39	86.75	72.10
V. Solapadas	0.1875	56.52	86.26	73.04
V. Solapadas	0.25	58.51	85.66	73.44
V. Solapadas	0.5	66.45	85.16	76.85

Cuadro 35: HMM - Arm Impaired Cortex Healthy - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	46.63	76.50	63.68
Puntos	0.03125	56.90	73.79	66.49
Puntos	0.0625	62.29	72.52	68.07
Puntos	0.125	66.67	73.32	70.38
Puntos	0.1875	70.44	73.20	71.96
Puntos	0.21875	71.68	73.95	72.91
Puntos	0.25	72.12	74.68	73.52
Puntos	0.5	75.66	79.65	77.84
Ventanas	0.03125	56.73	73.69	66.42
Ventanas	0.0625	61.82	72.70	68.04
Ventanas	0.125	66.92	72.66	70.20
Ventanas	0.1875	69.82	73.12	71.71
Ventanas	0.21875	71.35	73.28	72.44
Ventanas	0.25	71.87	74.18	73.19
Ventanas	0.5	76.25	79.30	78.08
V. Solapadas	0	46.66	76.48	63.68
V. Solapadas	0.03125	56.45	73.71	66.27
V. Solapadas	0.0625	61.75	72.54	67.86
V. Solapadas	0.125	67.14	71.99	69.86
V. Solapadas	0.1875	70.64	72.37	71.60
V. Solapadas	0.21875	72.22	72.41	72.32
V. Solapadas	0.25	72.75	72.76	72.76
V. Solapadas	0.5	77.13	77.08	77.10

Cuadro 36: HMM - Arm Healthy Cortex Injured - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	48.50	81.12	67.12
Puntos	0.03125	56.31	78.46	68.89
Puntos	0.0625	60.87	76.94	69.94
Puntos	0.125	65.83	75.74	71.36
Puntos	0.1875	68.76	74.92	72.16
Puntos	0.21875	69.50	75.40	72.69
Puntos	0.25	70.60	75.13	73.07
Puntos	0.5	74.37	77.98	76.34
Ventanas	0.03125	56.20	78.61	69.01
Ventanas	0.0625	60.55	77.32	70.13
Ventanas	0.125	65.65	76.30	71.74
Ventanas	0.1875	68.55	76.13	72.88
Ventanas	0.21875	69.93	75.72	73.20
Ventanas	0.25	70.90	76.11	73.87
Ventanas	0.5	74.58	79.34	77.43
V. Solapadas	0	48.46	81.15	67.12
V. Solapadas	0.03125	56.03	78.53	68.83
V. Solapadas	0.0625	60.56	77.11	69.93
V. Solapadas	0.125	65.98	75.75	71.46
V. Solapadas	0.1875	69.09	75.27	72.53
V. Solapadas	0.21875	70.70	74.51	72.78
V. Solapadas	0.25	71.36	74.84	73.28
V. Solapadas	0.5	76.87	76.20	76.50

Cuadro 37: HMM - Arm Healthy Cortex Injured - Todos los mejores canales

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	44.64	76.69	62.93
Puntos	0.03125	53.01	73.53	64.66
Puntos	0.0625	57.43	72.76	66.08
Puntos	0.125	62.07	72.44	67.86
Puntos	0.1875	64.75	73.05	69.33
Puntos	0.21875	65.56	75.08	70.72
Puntos	0.25	66.68	75.32	71.40
Puntos	0.5	70.95	83.57	77.84
Ventanas	0.03125	52.80	73.71	64.75
Ventanas	0.0625	57.32	72.98	66.27
Ventanas	0.125	62.29	73.49	68.69
Ventanas	0.1875	65.08	75.22	70.87
Ventanas	0.21875	65.95	75.83	71.53
Ventanas	0.25	66.92	77.01	72.68
Ventanas	0.5	71.04	86.84	80.52
V. Solapadas	0	44.53	76.68	62.88
V. Solapadas	0.03125	52.61	73.85	64.70
V. Solapadas	0.0625	56.82	73.07	66.02
V. Solapadas	0.125	61.94	73.36	68.35
V. Solapadas	0.1875	65.10	74.45	70.30
V. Solapadas	0.21875	66.39	75.08	71.13
V. Solapadas	0.25	67.22	75.96	72.03
V. Solapadas	0.5	71.40	81.87	77.22

Cuadro 38: HMM - Arm Impaired Cortex Injured - Mejor canal

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	41.74	81.93	64.68
Puntos	0.03125	49.50	78.79	66.14
Puntos	0.0625	53.75	77.27	67.03
Puntos	0.125	58.94	76.00	68.46
Puntos	0.1875	61.85	75.63	69.46
Puntos	0.21875	61.40	76.12	69.37
Puntos	0.25	63.43	76.56	70.59
Puntos	0.5	68.50	80.97	75.30
Ventanas	0.03125	49.49	78.61	66.13
Ventanas	0.0625	53.98	77.13	67.20
Ventanas	0.125	58.85	76.51	68.94
Ventanas	0.1875	61.78	76.80	70.37
Ventanas	0.21875	62.95	77.16	70.98
Ventanas	0.25	64.09	77.30	71.64
Ventanas	0.5	70.15	82.98	77.85
V. Solapadas	0	41.65	81.95	64.66
V. Solapadas	0.03125	49.35	78.63	66.01
V. Solapadas	0.0625	53.81	76.99	66.93
V. Solapadas	0.125	58.88	75.94	68.45
V. Solapadas	0.1875	62.13	75.97	69.82
V. Solapadas	0.21875	63.27	75.26	69.81
V. Solapadas	0.25	64.83	75.43	70.66
V. Solapadas	0.5	70.98	77.79	74.76

Cuadro 39: HMM - Arm Impaired Cortex Injured - Todos los mejores canales

HMM - Completo - Viterbi

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	56.10	88.19	74.41
Puntos	0.03125	55.81	87.89	74.03
Puntos	0.0625	54.84	87.80	73.45
Puntos	0.125	55.36	87.41	73.25
Puntos	0.1875	55.41	87.60	73.17
Puntos	0.25	55.04	87.48	72.73
Puntos	0.5	57.25	89.89	75.05
Ventanas	0.03125	56.46	87.66	74.29
Ventanas	0.0625	56.63	87.31	74.16
Ventanas	0.125	56.25	87.66	74.20
Ventanas	0.1875	56.45	87.57	74.24
Ventanas	0.25	56.08	87.89	74.26
Ventanas	0.5	58.80	90.06	77.56
V. Solapadas	0.03125	56.31	87.13	73.84
V. Solapadas	0.0625	56.50	86.79	73.65
V. Solapadas	0.125	56.23	86.73	73.34
V. Solapadas	0.1875	56.21	86.52	73.05
V. Solapadas	0.25	56.34	87.04	73.22
V. Solapadas	0.5	58.12	88.12	74.79

Cuadro 40: HMM - Arm Healthy Cortex Healthy - Mejor canal - Viterbi

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	66.26	86.28	77.69
Puntos	0.03125	66.31	86.44	77.75
Puntos	0.0625	66.51	85.85	77.43
Puntos	0.125	66.90	86.00	77.56
Puntos	0.1875	66.87	86.60	77.75
Puntos	0.25	67.64	86.52	77.94
Puntos	0.5	70.08	86.77	79.18
Ventanas	0.03125	66.44	86.30	77.79
Ventanas	0.0625	66.69	85.95	77.70
Ventanas	0.125	66.72	86.52	78.04
Ventanas	0.1875	67.25	86.17	78.06
Ventanas	0.25	67.56	86.49	78.38
Ventanas	0.5	72.23	86.07	80.54
V. Solapadas	0.03125	66.55	86.05	77.65
V. Solapadas	0.0625	67.07	85.86	77.71
V. Solapadas	0.125	67.37	85.83	77.72
V. Solapadas	0.1875	69.07	85.29	78.08
V. Solapadas	0.25	69.35	84.43	77.64
V. Solapadas	0.5	72.18	82.87	78.12

Cuadro 41: HMM - Arm Healthy Cortex Healthy - Todos los mejores canales - Viterbi

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	60.34	77.38	70.06
Puntos	0.03125	59.87	76.01	69.04
Puntos	0.0625	60.07	74.83	68.40
Puntos	0.125	59.64	73.81	67.55
Puntos	0.1875	56.66	74.68	66.60
Puntos	0.25	57.43	76.37	67.76
Puntos	0.5	56.20	81.52	70.01
Ventanas	0.03125	59.60	75.77	68.84
Ventanas	0.0625	59.61	74.96	68.38
Ventanas	0.125	59.94	74.35	68.17
Ventanas	0.1875	57.22	75.57	67.70
Ventanas	0.25	56.45	77.10	68.25
Ventanas	0.5	55.36	85.62	73.52
V. Solapadas	0.03125	59.50	75.51	68.61
V. Solapadas	0.0625	60.12	73.66	67.79
V. Solapadas	0.125	58.37	73.92	67.09
V. Solapadas	0.1875	57.82	74.37	67.02
V. Solapadas	0.25	57.54	75.83	67.60
V. Solapadas	0.5	54.16	85.87	71.78

Cuadro 42: HMM - Arm Impaired Cortex Healthy - Mejor canal - Viterbi

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	59.21	81.93	72.18
Puntos	0.03125	60.93	82.03	72.92
Puntos	0.0625	60.94	82.01	72.84
Puntos	0.125	62.99	81.80	73.49
Puntos	0.1875	62.01	81.66	72.85
Puntos	0.25	63.81	80.22	72.76
Puntos	0.5	66.00	82.25	74.86
Ventanas	0.03125	61.13	81.23	72.62
Ventanas	0.0625	61.57	81.21	72.79
Ventanas	0.125	61.75	81.58	73.09
Ventanas	0.1875	62.25	81.47	73.23
Ventanas	0.25	63.17	81.99	73.92
Ventanas	0.5	65.78	83.64	76.50
V. Solapadas	0.03125	61.49	81.35	72.79
V. Solapadas	0.0625	62.33	81.71	73.31
V. Solapadas	0.125	62.81	80.99	73.01
V. Solapadas	0.1875	62.91	81.84	73.43
V. Solapadas	0.25	63.98	81.25	73.47
V. Solapadas	0.5	68.69	81.62	75.87

Cuadro 43: HMM - Arm Impaired Cortex Healthy - Todos los mejores canales - *Viterbi*

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	62.14	68.52	65.78
Puntos	0.03125	61.89	67.54	65.10
Puntos	0.0625	62.57	64.92	63.90
Puntos	0.125	61.23	65.81	63.79
Puntos	0.1875	61.37	64.02	62.83
Puntos	0.21875	61.59	63.17	62.44
Puntos	0.25	60.41	64.49	62.64
Puntos	0.5	58.66	71.07	65.43
Ventanas	0.03125	62.21	67.36	65.15
Ventanas	0.0625	62.31	66.06	64.45
Ventanas	0.125	61.37	66.31	64.19
Ventanas	0.1875	60.05	67.26	64.17
Ventanas	0.21875	60.22	66.85	63.97
Ventanas	0.25	60.23	67.67	64.48
Ventanas	0.5	59.16	74.44	68.33
V. Solapadas	0	62.05	68.52	65.74
V. Solapadas	0.03125	62.09	67.56	65.20
V. Solapadas	0.0625	62.33	66.21	64.53
V. Solapadas	0.125	61.82	65.45	63.86
V. Solapadas	0.1875	61.44	65.37	63.62
V. Solapadas	0.21875	62.14	63.71	63.00
V. Solapadas	0.25	61.13	65.81	63.70
V. Solapadas	0.5	60.72	69.58	65.64

Cuadro 44: HMM - Arm Healthy Cortex Injured - Mejor canal - Viterbi

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	67.59	70.95	69.51
Puntos	0.03125	67.68	70.18	69.10
Puntos	0.0625	68.29	69.30	68.86
Puntos	0.125	68.03	69.20	68.68
Puntos	0.1875	68.79	68.88	68.84
Puntos	0.21875	66.85	70.38	68.76
Puntos	0.25	68.47	67.56	67.98
Puntos	0.5	68.33	70.65	69.60
Ventanas	0.03125	67.60	70.57	69.30
Ventanas	0.0625	67.74	70.19	69.14
Ventanas	0.125	67.41	69.43	68.57
Ventanas	0.1875	67.70	69.44	68.69
Ventanas	0.21875	68.54	70.44	69.61
Ventanas	0.25	67.56	70.32	69.14
Ventanas	0.5	69.06	74.86	72.54
V. Solapadas	0	67.50	70.72	69.34
V. Solapadas	0.03125	68.09	69.65	68.97
V. Solapadas	0.0625	68.20	68.88	68.58
V. Solapadas	0.125	67.89	69.24	68.65
V. Solapadas	0.1875	67.50	69.19	68.44
V. Solapadas	0.21875	67.41	70.08	68.87
V. Solapadas	0.25	67.59	69.75	68.78
V. Solapadas	0.5	68.54	70.75	69.76

Cuadro 45: HMM - Arm Healthy Cortex Injured- Todos los mejores canales - Viterbi

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	57.87	68.26	63.80
Puntos	0.03125	57.89	66.82	62.96
Puntos	0.0625	58.50	66.03	62.75
Puntos	0.125	57.88	65.29	62.02
Puntos	0.1875	57.19	64.94	61.47
Puntos	0.21875	58.42	62.94	60.87
Puntos	0.25	59.37	63.05	61.38
Puntos	0.5	58.70	68.40	63.99
Ventanas	0.03125	57.58	67.09	63.01
Ventanas	0.0625	57.82	65.55	62.24
Ventanas	0.125	58.54	64.40	61.88
Ventanas	0.1875	58.97	63.77	61.71
Ventanas	0.21875	58.91	63.01	61.23
Ventanas	0.25	58.98	63.94	61.81
Ventanas	0.5	57.34	76.49	68.83
V. Solapadas	0	57.82	68.26	63.78
V. Solapadas	0.03125	57.08	67.18	62.83
V. Solapadas	0.0625	58.28	65.18	62.19
V. Solapadas	0.125	58.31	63.68	61.32
V. Solapadas	0.1875	58.55	63.86	61.50
V. Solapadas	0.21875	58.54	64.20	61.62
V. Solapadas	0.25	58.31	64.60	61.77
V. Solapadas	0.5	58.54	71.87	65.94

Cuadro 46: HMM - Arm Impaired Cortex Injured - Mejor canal - Viterbi

Tipo	Delay	Reposo	Movimiento	Media ambos
Puntos	0	61.06	72.24	67.44
Puntos	0.03125	60.20	71.13	66.41
Puntos	0.0625	60.15	70.29	65.88
Puntos	0.125	61.05	69.19	65.59
Puntos	0.1875	61.53	70.57	66.52
Puntos	0.21875	60.96	70.35	66.05
Puntos	0.25	62.22	70.13	66.54
Puntos	0.5	64.66	72.43	68.90
Ventanas	0.03125	59.88	71.52	66.53
Ventanas	0.0625	59.72	70.71	66.00
Ventanas	0.125	60.13	70.18	65.87
Ventanas	0.1875	61.37	70.02	66.31
Ventanas	0.21875	61.35	70.92	66.76
Ventanas	0.25	61.64	70.38	66.63
Ventanas	0.5	62.91	76.04	70.79
V. Solapadas	0	61.01	72.05	67.32
V. Solapadas	0.03125	59.98	71.05	66.28
V. Solapadas	0.0625	60.31	70.25	65.94
V. Solapadas	0.125	60.86	70.14	66.07
V. Solapadas	0.1875	61.44	70.00	66.19
V. Solapadas	0.21875	61.77	69.89	66.20
V. Solapadas	0.25	62.10	71.02	67.01
V. Solapadas	0.5	63.43	74.37	69.51

Cuadro 47: HMM - Arm Impaired Cortex Injured- Todos los mejores canales - Viterbi

C.4. CRF

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	69.70	97.72	85.27
	20	0.0625	70.97	97.50	85.95
	5	0.25	68.10	97.58	84.18
	0.9375		62.53	97.26	82.14
0.9375	10	0.09375	62.60	97.76	82.34
	15	0.0625	62.85	97.52	82.43
	30	0.03125	62.14	96.51	81.66
	0.625		51.80	98.08	77.88
0.625	10	0.0625	51.58	98.13	77.87
	20	0.03125	53.50	97.57	78.54
	5	0.125	50.33	98.53	77.23
	0.3125		29.37	99.06	68.84
0.3125	10	0.03125	30.63	98.92	69.42
	5	0.0625	28.12	99.19	68.25
	5	0.03125	16.66	99.65	63.80
	0.125	20	0	20.55	65.40
0.0625	10	0	10.96	99.61	61.56

Cuadro 48: CRF - Arm Healthy Cortex Healthy - Mejor canal

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	64.87	91.42	79.66
	20	0.0625	65.46	91.02	79.72
	5	0.25	60.54	92.51	78.59
	0.9375		68.60	90.74	80.68
0.9375	10	0.09375	55.98	92.28	76.49
	15	0.0625	59.95	91.11	77.45
	30	0.03125	56.23	92.30	76.60
	0.625		51.76	93.43	75.43
0.625	10	0.0625	50.39	93.66	74.80
	20	0.03125	50.91	93.23	74.81
	5	0.125	44.90	94.00	72.79
	0.3125		55.37	93.76	76.80
0.3125	10	0.03125	35.24	95.49	69.36
	5	0.0625	35.66	94.68	69.19
	0.15625	5	34.82	96.30	69.54
	0.0625	10	24.68	97.13	65.83
0.0625	10	0	20.92	96.70	64.17

Cuadro 49: CRF - Arm Healthy Cortex Healthy - Todos los mejores canales

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	78.40	94.98	87.71
	20	0.0625	69.48	97.77	85.27
	40	0.03125	86.53	92.67	90.00
	5	0.25	69.60	95.76	84.46
			88.00	93.73	91.12
0.9375	10	0.09375	54.22	97.43	78.25
	15	0.0625	64.05	97.62	82.90
	30	0.03125	48.421	97.44	73.50
			59.20	97.13	80.75
0.625	10	0.0625	44.37	98.79	75.52
	20	0.03125	49.89	98.30	77.23
	5	0.125	46.64	98.48	76.09
			37.95	99.09	72.03
0.3125	10	0.03125	22.69	99.74	66.33
	5	0.0625	21.73	99.81	66.09
			23.65	99.66	66.57
0.15625	5	0.03125	12.32	99.88	62.06
0.125	20	0	12.41	99.59	62.17
0.0625	0	0.0625	4.818650	99.91	58.80
	10	0	2.719595	100.00	57.65
			6.917705	99.82	59.94

Cuadro 50: CRF - Arm Impaired Cortex Healthy - Mejor canal

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	64.25	90.52	78.97
	20	0.0625	66.19	89.03	78.94
	40	0.03125	63.93	89.95	78.62
	5	0.25	58.35	93.27	78.19
			68.52	89.84	80.15
0.9375	10	0.09375	56.36	91.58	76.26
	15	0.0625	59.98	90.41	77.06
	30	0.03125	54.80	91.36	75.45
			54.31	92.96	76.27
0.625	10	0.0625	46.41	93.14	72.76
	20	0.03125	47.33	92.57	72.88
	5	0.125	43.03	94.09	72.03
			48.88	92.76	73.37
0.3125	10	0.03125	38.27	93.59	69.61
	5	0.0625	37.11	93.75	69.28
			39.44	93.44	69.93
0.15625	5	0.03125	25.50	95.91	65.50
0.0625	10	0	20.47	96.03	63.60

Cuadro 51: CRF - Arm Impaired Cortex Healthy - Todos los mejores canales

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	5	0.25	58.25	97.36	79.58
	10	0.125	57.65	97.58	79.94
0.9375	10	0.09375	44.59	98.39	74.79
0.625	10	0.0625	30.67	98.89	69.19
	5	0.125	31.80	99.17	69.40
0.3125	5	0.0625	15.81	99.76	63.22

Cuadro 52: CRF - ArmHealthy CortexInjured - Mejor canal

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	61.74	90.67	77.89
	5	0.25	64.04	92.17	79.38
0.9375	10	0.09375	51.72	93.89	75.39
0.625	5	0.125	40.37	96.84	71.88
	10	0.0625	38.33	95.97	70.88
0.3125	5	0.0625	21.58	98.78	65.17

Cuadro 53: CRF - ArmHealthy CortexInjured - Todos los mejores canales

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	56.61	97.33	79.34
	5	0.25	57.66	97.69	79.49
0.9375	10	0.09375	46.60	98.41	75.69
	15	0.0625	48.41	97.45	76.11
0.625	5	0.125	33.21	99.14	70.01
0.3125	5	0.0625	16.64	99.63	63.50

Cuadro 54: CRF - ArmImpaired CortexInjured 1Ch CRF

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	61.25	90.27	77.45
	5	0.25	64.58	91.97	79.52
0.9375	10	0.09375	55.33	92.22	76.04
	15	0.0625	44.33	94.82	72.84
0.625	10	0.0625	43.80	96.06	72.97
	5	0.125	24.52	98.93	66.54

Cuadro 55: CRF - ArmImpaired CortexInjured - Todos los mejores canales

CRF - Completo - Viterbi

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	70.02	98.09	85.68
	20	0.0625	70.97	97.50	85.95
	5	0.25	68.10	97.58	84.18
0.9375	10	0.09375	62.60	97.76	82.34
	15	0.0625	62.85	97.52	82.43
	30	0.03125	62.14	96.51	81.66
0.625	10	0.0625	51.58	98.13	77.87
	20	0.03125	53.50	97.57	78.54
	5	0.125	50.33	98.53	77.23
0.3125	10	0.03125	30.63	98.92	69.42
	5	0.0625	28.12	99.19	68.25
0.15625	5	0.03125	16.66	99.65	63.80
0.125	20	0	20.55	99.13	65.40
0.0625	10	0	10.96	99.61	61.56

Cuadro 56: CRF - Arm Healthy Cortex Healthy - Mejor canal - Viterbi

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	65.46	91.02	79.72
	20	0.0625	60.54	92.51	78.59
	5	0.25	68.60	90.74	80.68
0.9375	10	0.09375	59.95	91.11	77.45
	15	0.0625	56.23	92.30	76.60
	30	0.03125	51.76	93.43	75.43
0.625	10	0.0625	50.91	93.23	74.81
	20	0.03125	44.90	94.00	72.79
	5	0.125	55.37	93.76	76.80
0.3125	10	0.03125	35.66	94.68	69.19
	5	0.0625	34.82	96.30	69.54
0.15625	5	0.03125	24.68	97.13	65.83
0.0625	10	0	20.92	96.70	64.17

Cuadro 57: CRF - Arm Healthy Cortex Healthy - Todos los mejores canales - Viterbi

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	69.48	97.77	85.27
	20	0.0625	86.53	92.67	90.00
	40	0.03125	69.60	95.76	84.46
	5	0.25	88.00	93.73	91.12
0.9375	10	0.09375	64.05	97.62	82.90
	15	0.0625	84.42	92.73	89.11
	30	0.03125	59.20	97.13	80.75
0.625	10	0.0625	49.89	98.30	77.23
	20	0.03125	46.64	98.48	76.09
	5	0.125	37.33	99.10	71.81
0.3125	10	0.03125	21.73	99.81	66.09
	5	0.0625	23.65	99.66	66.57
0.15625	5	0.03125	12.32	99.88	62.06
0.125	20	0	12.41	99.59	62.17
0.0625	10	0	6.917705	99.82	59.94

Cuadro 58: CRF - Arm Impaired Cortex Healthy - Mejor canal - Viterbi

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	66.19	89.03	78.94
	20	0.0625	63.93	89.95	78.62
	40	0.03125	58.35	93.27	78.19
	5	0.25	68.52	89.84	80.15
0.9375	10	0.09375	59.98	90.41	77.06
	15	0.0625	54.80	91.36	75.45
	30	0.03125	54.31	92.96	76.27
0.625	10	0.0625	47.33	92.57	72.88
	20	0.03125	43.03	94.09	72.03
	5	0.125	48.88	92.76	73.37
0.3125	10	0.03125	37.11	93.75	69.28
	5	0.0625	39.44	93.44	69.93
0.15625	5	0.03125	25.50	95.91	65.50
0.0625	10	0	20.47	96.03	63.60

Cuadro 59: CRF - Arm Impaired Cortex Healthy - Todos los mejores canales - Viterbi

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	88.09	92.91	90.78
	5	0.25	89.31	92.77	91.20
0.9375	10	0.09375	87.69	93.00	90.67
0.625	10	0.0625	86.56	92.61	89.98
	5	0.125	87.39	92.77	90.39
0.3125	5	0.0625	87.42	94.14	91.22

Cuadro 60: CRF - ArmHealthy CortexInjured - Mejor canal - Viterbi

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	5	0.25	83.31	87.30	85.49
	10	0.125	81.41	86.52	84.26
0.9375	10	0.09375	80.80	86.82	84.18
0.625	5	0.125	81.80	87.21	84.82
	10	0.0625	80.83	86.90	84.26
0.3125	5	0.0625	82.38	88.30	85.72

Cuadro 61: CRF - ArmHealthy CortexInjured - Todos los mejores canales - Viterbi

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	87.10	92.03	89.85
	5	0.25	88.64	92.46	90.72
0.9375	10	0.09375	87.23	92.18	90.01
0.625	5	0.125	86.94	93.59	90.65

Cuadro 62: CRF - ArmlImpaired CortexInjured - Mejor canal - Viterbi

Delay	winSize	intervalo	Reposo	Movimiento	Media ambos
1.25	10	0.125	80.10	85.99	83.39
	5	0.25	82.35	86.57	84.65
0.9375	10	0.09375	79.85	86.06	83.34
0.625	5	0.125	81.38	87.58	84.84
	10	0.0625	78.75	86.36	83.04

Cuadro 63: CRF - ArmlImpaired CortexInjured - Todos los mejores canales - Viterbi