



INSTITUTO POLITÉCNICO NACIONAL

CENTRO DE INVESTIGACIÓN EN COMPUTACIÓN

**Clasificación de señales electromiográficas mediante
algoritmos de cómputo no convencional**

TESIS

QUE PARA OBTENER EL GRADO DE
Maestría en Ciencias de la Computación

PRESENTA:

Ing. José Roberto Caro Vásquez

DIRECTORES

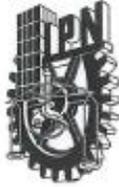
Dr. Cornelio Yáñez Márquez

Dr. Jorge Isaac Chairez Oria



Centro de Investigación
en Computación
Instituto Politécnico Nacional

CIUDAD DE MÉXICO, ENERO 2017



INSTITUTO POLITÉCNICO NACIONAL SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

ACTA DE REVISIÓN DE TESIS

En la Ciudad de México siendo las 15:00 horas del día 15 del mes de diciembre de 2016 se reunieron los miembros de la Comisión Revisora de la Tesis, designada por el Colegio de Profesores de Estudios de Posgrado e Investigación del:

Centro de Investigación en Computación

para examinar la tesis titulada:

“Clasificación de señales electromiográficas mediante algoritmos de cómputo no convencional”

Presentada por el alumno:

CARO

Apellido paterno

VÁSQUEZ

Apellido materno

JOSÉ ROBERTO

Nombre(s)

Con registro:

A	1	5	0	1	7	7
---	---	---	---	---	---	---

aspirante de: **MAESTRÍA EN CIENCIAS DE LA COMPUTACIÓN**

Después de intercambiar opiniones los miembros de la Comisión manifestaron **APROBAR LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA

Directores de Tesis



Dr. Cornelio Yáñez Márquez



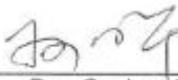
Dr. Jorge Isaac Chairez Oria



Dr. Oleksiy Pogrebnyak



Dr. Marco Antonio Moreno Ibarra



Dra. Guohua Sun



Dr. Amadeo José Argüelles Cruz

PRESIDENTE DEL COLEGIO DE PROFESORES



Dr. Marco Antonio Ramírez Salinas



INSTITUTO POLITÉCNICO NACIONAL
CENTRO DE INVESTIGACIÓN
EN COMPUTACIÓN
DIRECCIÓN



INSTITUTO POLITÉCNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

CARTA CESIÓN DE DERECHOS

En la Ciudad de México el día 16 del mes diciembre del año 2016, el que suscribe José Roberto Caro Vásquez alumno del Programa de Maestría en ciencias de la Computación con número de registro A150177, adscrito al Centro de Investigación en Computación, manifiesta que es autor (a) intelectual del presente trabajo de Tesis bajo la dirección del Dr. Cornelio Yáñez Márquez y el Dr. Jorge Isaac Chairez Oria y cede los derechos del trabajo titulado Clasificación de señales electromiográficas mediante algoritmos de cómputo no convencional, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección rcaro4253@gmail.com. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.



José Roberto Caro Vásquez.

Resumen

En el presente trabajo de tesis se presenta una metodología de clasificación de patrones aplicada a señales electromiográficas de miembro superior, cuya función es identificar la posición de un miembro en su estado actual.

Como parte de esta metodología, se muestran técnicas de extracción de características aplicadas a señales biológicas. Las técnicas mencionadas son capaces de cambiar la naturaleza de los datos con el fin de optimizar la clasificación, mediante un algoritmo de reconocimiento de patrones utilizado en el estado del arte y algoritmos no convencionales.

Se incluyen técnicas de preprocesamiento, las cuales permiten que la metodología propuesta sea capaz de trabajar de manera recurrente; esto permite el sistema sea capaz de reconocer señales o muestras de una señal.

Además, se incluye un estudio experimental del desempeño de la metodología propuesta haciendo uso de un banco de datos de señales recuperadas a través de electrodos superficiales.

En dichos experimentos se muestra que la metodología propuesta es capaz de reconocer de manera competitiva el comportamiento de un miembro superior mediante la respuesta de una señal electromiográfica recuperada con electrodos.

Abstract

In this thesis, a methodology for pattern classification applied to upper limb electromyographic signals is presented, whose purpose is to identify the current position of a limb.

This methodology includes feature extraction techniques for biological signals. Such techniques are able to modify the data nature in order to optimize classification, by means of a pattern recognition algorithm taken from the state of the art, as well as unconventional algorithms.

Pre-processing techniques are also part of the proposed methodology, enabling it to operate concurrently. This in turn allows the proposed system to recognize signals or signal samples.

The current thesis includes also an experimental study of the proposed methodology when applied to a data set of superficial electrode signals.

In such experiments, the proposed methodology is shown to competitively recognize the behavior of an upper limb, by means of an electromyographic signal acquired through superficial electrodes.

Contenido

Resumen.....	iv
Abstract	v
Contenido	vi
Lista de Figuras.....	viii
Lista de Tablas.....	x
Capítulo 1. Introducción	1
1.1 Antecedentes	1
1.2 Justificación.....	3
1.3 Objetivo general	3
1.4 Objetivos específicos.....	3
1.5 Organización del documento.....	4
Capítulo 2. Marco teórico y estado del arte	5
2.1 Marco teórico	5
2.1.1 Potencial de acción.....	5
2.1.2 Unidad motora y contracción muscular.....	7
2.1.3 Electrodo	9
2.1.4 Electromiografía.....	9
2.1.5 Procesamiento de señales biológicas.....	10
2.1.6 Extracción de características	13
2.1.7 Clasificación de patrones	15
2.1.8 Máquinas de soporte vectorial.....	16
2.2 Estado del arte	19
Capítulo 3. Metodología propuesta.	22
3.1 Recolección y adecuación de señales electromiográficas	22
3.2 Preprocesamiento de las señales electromiográficas	24
3.3 Clasificación mediante variable temporal: Desarrollo del algoritmo de clasificación para señales electromiográficas por el método máquinas de soporte vectorial recurrentes	28
3.3.1 Fase de entrenamiento	28
3.3.2 Fase de clasificación.....	30
3.3.3 Desarrollo de ensamble homogéneo por máquinas de soporte vectorial recurrentes (algoritmo multiclase)	30

3.4	Filtrado no lineal.	32
Capítulo 4. Resultados.		33
4.1	Preprocesamiento de las señales electromiográficas	33
4.2	Clasificación binaria de señales electromiográficas con uso del algoritmo de clasificación máquinas de soporte vectorial recurrentes	39
4.3	Clasificación de señales electromiográficas con uso del algoritmo máquinas de soporte vectorial recurrentes multiclase.....	46
4.4	Clasificación con filtrado no lineal.	49
4.5	Validación del modelo haciendo uso de la matriz de confusión con la técnica de validación hold out.	51
4.6	Desempeño y parámetros de preprocesamiento	53
4.7	Comparación con modelos del estado del arte.	55
Capítulo 5. Conclusiones y trabajo a futuro		56
5.1	Conclusiones.	56
5.2	Trabajo a futuro.....	57
Bibliografía		58

Lista de Figuras.

Figura 1 Fases del potencial de acción.....	6
Figura 2 Filamentos de miosina y actina en contracción muscular.....	8
Figura 3 Esquema de recuperación de señal biológica.....	11
Figura 4 Hiperplano óptimo y vectores de soporte	16
Figura 5 Función Kernel	19
Figura 6 Metodología propuesta.	22
Figura 7 Etiquetas de las señales de electromiografía (16).....	24
Figura 8 Representación del ensamble homogéneo que conforma el algoritmo completo.....	31
Figura 9 Señal electromiográfica de miembro superior recuperada del antebrazo.	34
Figura 10 Preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 1$ y $T = 250$	34
Figura 11 Preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 1$ y $T = 500$	35
Figura 12 Preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 1$ y $T = 1000$	35
Figura 13 Preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 10$ y $T = 1000$	36
Figura 14 Preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 100$ y $T = 1000$	37
Figura 15 Preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 1000$ y $T = 1000$	37
Figura 16 Distribución de datos de señales electromiográficas sin preprocesamiento.	38
Figura 17 Distribución de datos de señales electromiográficas con preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral.	38
Figura 18 Conjuntos de señales de entrenamiento de la clase HC.....	39
Figura 19 Conjuntos de señales de entrenamiento de la clase T.....	40
Figura 20 Matriz V generada por el entrenamiento de las señales de las figuras 17 y 18.....	40
Figura 21 Caracterización del problema de clasificación para las clases HC y T.....	41
Figura 22 Señal desconocida de la clase HC.....	42
Figura 23 Señal desconocida de la clase T.....	42
Figura 24 Clasificación de las señales HC y T con señales desconocidas	43
Figura 25 Caracterización del problema de clasificación para las clases HC y RL.	44
Figura 26 Clasificación de las señales HC y RL con señales desconocida	44
Figura 27 Caracterización del problema de clasificación para las clases IMR y T.....	45
Figura 28 Clasificación de las señales HC y RL con señales desconocida	45
Figura 29 Modelos binarios para resubstitution error.	46
Figura 30 Modelos binarios para un patrón desconocido.....	47
Figura 31 Resultado de clasificación con resubstitution error	48
Figura 32 Resultado de clasificación para un patrón que no pertenece al conjunto de entrenamiento	48
Figura 33 Salida del modelo máquina de soporte vectorial recurrente multiclase.....	49
Figura 34 Salida del modelo máquina de soporte vectorial recurrente multiclase con filtro no lineal $K=10$	50

Figura 35 Salida del modelo máquina de soporte vectorial recurrente multiclase con filtro no lineal K=50.....	50
Figura 36 Salida del modelo máquina de soporte vectorial recurrente multiclase con filtro no lineal K=10.....	51
Figura 37 Desempeño para distintos tamaños de ventana.....	53
Figura 38 Desempeño para distintos tamaños de factor de desplazamiento	54

Lista de Tablas.

Tabla 1 Características de señales biológicas.....	12
Tabla 2 Matriz de confusión para el modelo sin filtro con resubstitution error	51
Tabla 3 Matriz de confusión para el modelo sin filtro con hold-out.....	52
Tabla 4 Matriz de confusión para el modelo con filtro de tamaño k=50 con resubstitution error	52
Tabla 5 Matriz de confusión para el modelo con filtro de tamaño k=50 con hold-out	52
Tabla 6 Matriz de confusión para el modelo con filtro de tamaño k=100 con resubstitution error.....	52
Tabla 7 Matriz de confusión para el modelo con filtro de tamaño k=100 con hold-out	53
Tabla 8 Comparación de desempeño de los algoritmos con resubstitution error	55
Tabla 9 Comparación de desempeño de los algoritmos con hold-out.....	55

Capítulo 1. Introducción

1.1 Antecedentes

Muchas de las tareas que nos exige la vida cotidiana, como sujetar objetos, escribir ya sea en teclado o a mano, manejar un auto, entre otras, son posibles gracias a la cantidad de grados de libertad que poseemos en los miembros superiores; sin embargo, cada año miles de personas pierden esa libertad de movimiento principalmente por 3 causas: accidentes, guerras y enfermedades (especialmente la diabetes). En la actualidad se registran alrededor de 30 millones de amputaciones en el mundo, y el desarrollo de tecnologías de prótesis es crucial para mejorar la calidad de vida de estas personas (1).

El creciente desarrollo tecnológico en las últimas décadas en las áreas de la computación, el diseño mecánico y el procesamiento digital de señales, entre otras disciplinas, ha generado una evolución de los dispositivos protésicos de manera asintótica a la funcionalidad de un miembro superior biológico (1) (2).

Estos dispositivos pueden clasificarse por su funcionalidad como pasivos y activos.

Las prótesis pasivas son aquellas diseñadas mecánicamente para generar movimientos mediante la actividad física de algún otro miembro. Estas prótesis son incapaces de realizar las tareas necesarias para cumplir las exigencias de la vida cotidiana, ya que no poseen la capacidad de controlar una cantidad grande de grados de libertad; por lo tanto, su diseño se limita a tareas básicas.

Las prótesis activas son aquellas accionadas por dispositivos electrónicos capaces de imitar los movimientos de un miembro biológico. Sin embargo, el funcionamiento actual de las prótesis activas presenta algunas deficiencias relacionadas principalmente con sus estrategias de control (1).

La metodología de control más utilizada en prótesis activas es el control basado en electromiografía superficial, la cual consiste en colocar electrodos en los miembros residuales para recuperar la actividad eléctrica producida por la contracción y relajación de

la fibra muscular que conforma los músculos esqueléticos. El registro de esta actividad eléctrica es conocido como señal electromiográfica. (3) (4) (5).

Esta metodología se ha estado apoyando en técnicas de procesamiento digital de señales y algoritmos de reconocimiento de patrones durante las dos décadas más recientes, siendo la tarea de clasificación de patrones la más utilizada en el estado del arte. (6) (7).

En la actualidad, grupos de investigación alrededor del mundo se encuentran trabajando en la aplicación de estos algoritmos para clasificar señales electromiográficas (8) (9) (10) (12). Por citar sólo algunos ejemplos, podemos mencionar que Xing *et al* hacen uso de máquinas de soporte vectorial para la clasificación de las señales electromiográficas (18), mientras que Yousefi *et al* mencionan sus aplicaciones con redes neuronales artificiales con el mismo propósito (14). Por otro lado, la extracción de características de señales, cuya función es extraer información de las señales electromiográficas, es un problema abierto debido a la gran cantidad de posibles técnicas de procesamiento de señales que pueden ser usadas para esta aplicación (15) (16) (17). Este hecho queda evidenciado en los trabajos de Phinyomark *et al*, quienes enfatizan el uso del área bajo la curva de las señales, la media absoluta, la varianza, el valor efectivo de la señal, y doce características más extraídas de cada una de las señales (11); en cambio, Gokgoz *et al* prefieren utilizar únicamente la transformada wavelet (13).

En este contexto, vale la pena enfatizar un hecho relevante que da pie a la propuesta del presente trabajo de tesis: los estudios realizados hasta el momento hacen uso de algoritmos de propósito general que **no consideran la naturaleza temporal de una señal**.

1.2 Justificación

Los trabajos de investigación del estado del arte en el tema que nos ocupa hacen uso de metodologías diseñadas para clasificar patrones de naturaleza estática; esto sugiere utilizar metodologías que consideren una muestra de una señal y sus anteriores, para realizar la clasificación de las señales, lo cual redundaría positivamente en la calidad de las metodologías dedicadas a clasificar señales electromiográficas.

1.3 Objetivo general

Desarrollar, implementar y validar algoritmos de clasificación para señales electromiográficas que consideren su naturaleza temporal.

1.4 Objetivos específicos.

- 1- Desarrollar un algoritmo recurrente de clasificación de señales electromiográficas basado en máquinas de soporte vectorial.
- 2- Desarrollar un ensamble homogéneo por máquinas de soporte vectorial recurrentes para la clasificación de señales electromiográficas.
- 3- Comparar las metodologías desarrolladas con algoritmos utilizados en el estado del arte.

1.5 Organización del documento

El resto del documento de tesis está organizado de la siguiente manera: en el capítulo 2 se presenta el marco teórico, el cual abarca desde la fisiología del sistema nervioso del ser humano hasta los modelos de procesamiento de señales, clasificación de patrones y una pequeña introducción a las máquinas de soporte vectorial, se presenta también el estado del arte mostrando los trabajos más relevantes publicados en años recientes en revistas JCR, afines al presente trabajo de tesis.

En la metodología propuesta, materia del capítulo 3, se muestra el banco de datos con el cual se realizan los experimentos, el modelo con memoria temporal propuesto como solución a la problemática para los casos de clasificación biclase y multiclase y, por último, una sección de filtrado no lineal aplicado a la clasificación de señales electromiográficas.

Los resultados experimentales y las discusiones correspondientes se muestran en el capítulo 4, mientras que en el capítulo 5 se presentan las conclusiones y el trabajo a futuro derivados de este trabajo. Finalmente, se anexan las referencias bibliográficas.

Capítulo 2. Marco teórico y estado del arte

2.1 Marco teórico

La tarea de reconocer señales de electromiografía y controlar una prótesis de miembro superior con el uso de estas señales tiene detrás un fuerte fundamento teórico, el cual ha sido creado a través de los siglos que le ha llevado al ser humano aprender los hechos relacionados con la naturaleza del cuerpo humano y la funcionalidad de sus componentes.

La tecnología usada en la actualidad para reconocer información del cuerpo humano y señales de control de los actuadores, contienen un principio de funcionamiento desarrollado a partir de investigaciones en las áreas de la fisiología, la química y la conductividad de potenciales biológicos. Estos fundamentos se extienden desde el mismo comportamiento de una célula del cuerpo humano, hasta el comportamiento del tejido muscular.

2.1.1 Potencial de acción

El contenido de esta sección está fuertemente basado en (3). La totalidad de las células del cuerpo humano son capaces de generar un potencial electroquímico de membrana, y algunas de ellas, como las células nerviosas y musculares, son capaces de generar potenciales capaces de propagarse. Este fenómeno es conocido como potencial de acción.

Todas las células del cuerpo contienen una potente bomba que transporta iones de sodio al exterior de la célula y iones de potasio al interior, con una relación de tres iones de sodio por cada ion de potasio; esto significa que una membrana es permeable a los iones de potasio, pero no a iones de sodio, lo cual genera un potencial de adentro hacia afuera de la membrana. En ocasiones, este potencial provoca que los iones de potasio escapen de la membrana generando electropositividad en el exterior de la membrana.

El potencial de membrana generado por la electropositividad, que se extiende rápidamente por el largo de una membrana de la fibra nerviosa, es precisamente el potencial de acción. Este potencial de acción consta de tres fases, como se describe a continuación y se ilustra en la Figura 1:

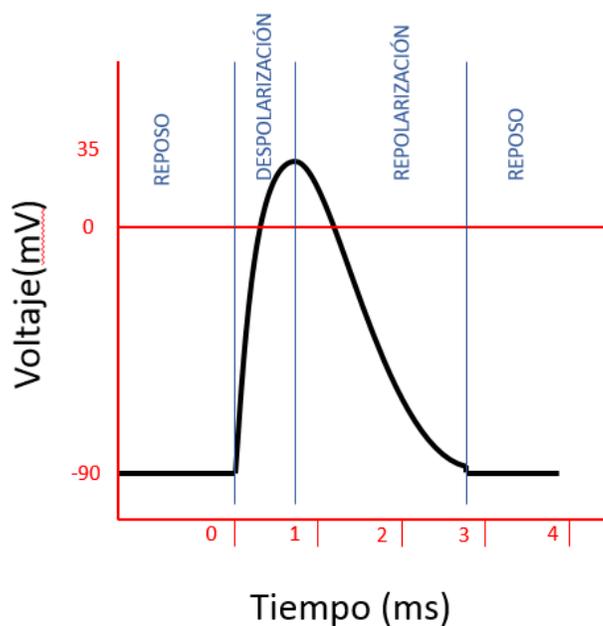


Figura 1 Fases del potencial de acción

Fase de reposo:

Esta fase corresponde al potencial de membrana antes de que se genere un potencial de acción. También es conocida como fase de polarización, y, aquí, el potencial de membrana tiene un valor de aproximadamente -90mv

Fase de despolarización.

En esta fase, la membrana se hace repentinamente permeable a iones de sodio, lo cual permite que estos iones entren y se difundan hacia el interior del axón. Este fenómeno causa que la diferencia de potencial entre el interior y exterior de la membrana sea nula, y en ocasiones la carga interior de la membrana supera al exterior; a este suceso se le llama sobreexcitación.

Fase de repolarización

En esta última fase, la célula regresa a su estado natural y su bomba de potasio empieza a funcionar de manera normal, por lo que los iones de potasio corren hacia el interior de la membrana, logrando así regularizar el potencial de -90mv .

Dado que la cantidad de iones de potasio y sodio en la célula tiene una naturaleza variable, el potencial de acción es generado cuando se registra una falta de iones de potasio para la alimentación de la bomba de la célula, y esto hace que el valor de voltaje en la membrana sea de valores que oscilan cerca de -90 mv ; pero si la célula no tiene la cantidad de iones de potasio necesaria para satisfacer a la membrana, su voltaje aumenta. Una vez que este voltaje llega a un umbral normalmente establecido de -65 mv , se genera la estimulación del potencial de acción.

El potencial de acción se puede producir en cualquier punto de la membrana, pero es importante hacer notar que se propaga a través de toda la membrana; esto causa que el ciclo de potencial de acción se repita a lo largo de toda la membrana, y, una vez alcanzada la fase de despolarización, la carga negativa genera una corriente en toda la fibra. A esta corriente se le denomina impulso nervioso.

Cuando este potencial se extiende a través de la fibra muscular, se dice que el impulso es un impulso muscular; el sistema que genera el impulso nervioso es mejor conocido como unidad motora.

2.1.2 Unidad motora y contracción muscular.

Se le denomina unidad motora al conjunto conformado por las neuronas que generan un impulso nervioso, que a su vez estimula fibras musculares que provocan la contracción y relajación de los músculos (8) (3).

Un músculo contiene fibras musculares que están formadas por miles de miofibrillas, que a su vez están formadas por filamentos de actina y miosina y rellenas de un líquido llamado sarcoplasma. El sarcoplasma contiene un retículo que envuelve como una red a la miofibrilla (9).

Los filamentos de actina y miosina son grandes moléculas proteicas traslapadas entre sí y separadas por un complejo de troponina y tropomiosina, haciendo por ello imposible una interacción entre los filamentos y a su vez controlando la contracción de un músculo, como se ilustra en la Figura 2.

Para lograr la contracción y relajación de un músculo, es preciso que ocurra la siguiente sucesión de eventos: (8) (3)

1. Un potencial se propaga desde una neurona hasta una fibra muscular.
2. El potencial de acción es transmitido a la fibra muscular y se propaga a lo largo de su membrana.
3. La despolarización del potencial de acción genera una corriente eléctrica que fluye a través de la fibra muscular, la cual provoca que el retículo sarcoplasmático libere una fuerte cantidad de calcio.
4. El calcio reacciona con el complejo troponina-tropomiosina, permitiendo la unión de los filamentos de actina y miosina y generando así la contracción muscular.
5. La membrana bombea el calcio de nuevo al retículo, provocando la relajación del músculo.

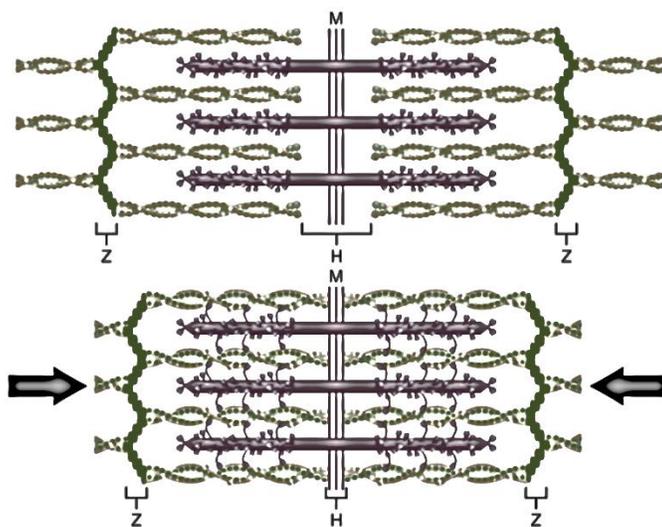


Figura 2 Filamentos de miosina y actina en contracción muscular

Debido al potencial de acción y a la propagación de éste a través de las membranas y las fibras musculares, el cuerpo humano es capaz de generar una corriente eléctrica, la cual genera un voltaje comúnmente de muy baja amplitud; esta información bioeléctrica puede ser recuperada mediante un electrodo.

2.1.3 Electrodo

Un electrodo es un transductor que se encarga de convertir la corriente iónica en corriente eléctrica usando un medio no metálico; en el tema que nos ocupa, el electrodo se encarga de recuperar el potencial de acción y convertirlo en una señal eléctrica que se puede medir y procesar.

Esto es posible ya que el tejido de la piel cumple con propiedades similares a la de una sustancia electrolítica, la cual en su composición contiene iones libres provocando que se comporte como un conductor (10).

Al sumergir un electrodo de metal en una sustancia electrolítica, el electrodo se convierte en un catión y la sustancia electrolítica en un anión, generando así un flujo de electrones entre el metal y la solución electrolítica. Gracias a este proceso, es posible que el electrodo detecte la actividad eléctrica del tejido muscular.

El registro de la actividad eléctrica generada por las fibras musculares mediante el uso de electrodos es conocido como electromiografía.

2.1.4 Electromiografía

La electromiografía es el proceso mediante el cual se recuperan las señales provocadas por el potencial de acción en los tejidos musculares; esta técnica se divide principalmente en dos tipos: electromiografía de aguja y electromiografía superficial (11).

La electromiografía de aguja es un proceso invasivo en el cual un electrodo con forma de aguja atraviesa la membrana de una unidad motora, obteniendo su actividad eléctrica a niveles muy precisos.

La electromiografía superficial es un proceso en el cual un electrodo se coloca sobre la superficie de la piel, recolectando información de la suma de unidades motoras dentro de un área determinada por la superficie de contacto entre el electrodo y la piel (12).

Las primeras contribuciones en esta área comenzaron en 1780 por el fisiólogo y físico italiano Luigi Galvani y su famoso experimento de la rana y la electricidad animal, haciendo pasar corriente por la extremidad de una rana y generando así espasmos musculares. El primer registro real de corrientes eléctricas que circulan por nuestro cuerpo fue hecho por Marey en 1890, quien además introdujo el término electromiografía (24).

En los años 1900, el estudio de esta técnica se extendió. En 1912, Piper diseñó un prototipo de electromiógrafo basado en un galvanómetro, y en 1924 Gasser y Erlanger hicieron un estudio similar con osciloscopios; sin embargo, hasta 1960 se generaron los primeros registros haciendo uso de electrodos superficiales, por John Basmajian (13) (14).

En aplicaciones prácticas, este tipo de registros no son de mucha utilidad sin un procesamiento adecuado de las señales electromiográficas, para lo cual se utilizan técnicas de procesamiento de señales.

2.1.5 Procesamiento de señales biológicas.

Las señales biológicas contienen información muy útil para la comprensión de patologías complejas y comportamientos del cuerpo; sin embargo, esta información no se encuentra disponible en la señal recibida de los electrodos directamente, porque la señal recuperada de los electrodos suele ser poco entendible y con bastantes componentes de ruido aditivo provocados por los electrodos y el ambiente. Por esta razón, es requerido un procesamiento previo para extraer la información relevante de la señal, y para ello se utilizan métodos de amplificación de filtrado y métodos suavizadores de señales, entre otros (15) (16).

Con el progreso de la tecnología digital, se hace más conveniente el análisis y procesamiento de señales biológicas (o bioseñales) en formato digital, como se ilustra en la Figura 3. Para digitalizar una señal es necesario convertir la señal a una forma numérica con un convertidor analógico digital.

El esquema de recuperación de una bioseñal es el siguiente:

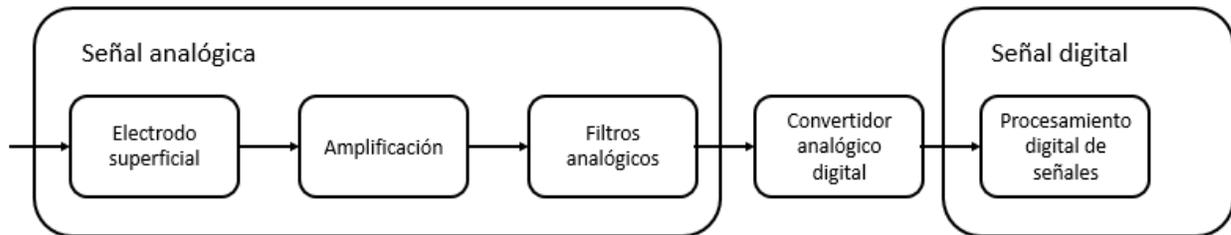


Figura 3 Esquema de recuperación de señal biológica

Cada uno de estos bloques se configura de acuerdo con la señal que se desea obtener. La Tabla 1 muestra las bandas de frecuencia, la amplitud de los datos y el método de adquisición para cada uno de los tipos de señales biológicas o bioseñales (12).

Tabla 1 Características de señales biológicas

clasificación	Adquisición	Rango de frecuencias (Hz)	Niveles de voltaje
Potencial de acción	Microelectrodos	100-2000	10 μ V-100mV
Electoneurograma (ENG)	Electrodos de aguja	100-1000	5 μ V-10mV
Electroretinograma (ERG)	Microelectrodos	0.2-200	0.5 μ V-1mV
Electro-oculograma (EOG)	Electrodos superficiales	100	10 μ V-5mV
Electroencefalograma (EEG)	Electrodos superficiales	0.5-100	2-100 μ V
Potenciales evocados (EP)	Electrodos superficiales		0.1-20 μ V
Visual (VEP)		1-300	1-20 μ V
Somatesensorial (SEP)		2-3000	
Auditivas (AEP)		100-3000	0.5-10 μ V
electrocortigrama	Electrodos de aguja	100-5000	
Electromiografía de fibra individual (SFEMG)	Electrodos de aguja	500-10000	1-10 μ V
Potencial de acción de unidad motora (MUAP)	Electrodos de aguja	5-10000	100 μ V-2mV
Electromiografía superficial (SEMG)	Electrodos superficiales	2-500	50 μ V-5mV
Electrocardiografía (ECG)	Electrodos superficiales	0.5-100	1-10mV

El procesamiento digital de una señal da como resultado información relevante para una aplicación dada; a esta información se le conoce comúnmente como característica de la señal.

2.1.6 Extracción de características

La habilidad de entender e interpretar la información que contienen las señales biológicas es muy importante en muchas de las aplicaciones del procesamiento digital de señales y reconocimiento de patrones (11) (29). Entre las aplicaciones más fuertes en el análisis de señales biomédicas se encuentra el estudio de complejo QRS de señales de electrocardiografía (23). Las técnicas de extracción de características de una señal nos permiten definir en valores numéricos las formas, comportamiento y niveles, entre otros datos, con los cuales es posible representar una señal o un segmento de ella en un intervalo de tiempo determinado (27) (30); algunas de estas técnicas más destacadas se presentan a continuación

El área bajo la curva

$$SI = \sum_{t=1}^N |x(t)|$$

donde t es el número de muestra de la señal y N es el tamaño de la señal. Esta característica es una de las más usadas en el estado del arte para clasificar señales biológicas y representa el área bajo la curva o la integral de un segmento de la señal.

El promedio del valor absoluto

$$MAV = \frac{1}{N} \sum_{t=1}^N |x(t)|$$

MAV por sus siglas del inglés mean absolute value. Esta característica nos da el valor promedio..

Área bajo la curva del valor cuadrado

$$SSI = \sum_{t=1}^N x(t)^2$$

Un indicador cuadrático.

Varianza

$$VAR = \frac{1}{N-1} \sum_{t=1}^N x(t)^2$$

Esta característica es muy utilizada en el área de la estadística, ya que es muy conocida como medida de dispersión de una muestra de datos.

Valor RMS o valor efectivo.

$$RMS = \sqrt{\frac{1}{N} \sum_{t=1}^N x(t)^2}$$

Una característica muy representativa en el área de análisis de circuitos.

Porcentaje de pulsos.

$$MYOP = \frac{1}{N} \sum_{t=1}^N f[x(t)]$$

$$f(a) = \begin{cases} 1 & \text{if } a > \text{umbral} \\ 0 & \text{en otro caso} \end{cases}$$

Indica el porcentaje de la señal que pasó un umbral determinado.

Cada una de las características presentadas anteriormente tiene una característica equivalente con diferencias de muestras. Estas son: WL, el tamaño de onda; DAMV, la diferencia del promedio del valor absoluto; M2, el cuadro de la suma de la diferencia; DVAR, el valor de la varianza en diferencia DASDV; el valor RMS en diferencia y por último la amplitud de Willison, que es un equivalente en diferencias al MYOP.

$$WL = \sum_{t=1}^N |x(t+1) - x(t)|$$

$$DAMV = \frac{1}{N} \sum_{t=1}^N |x(t+1) - x(t)|$$

$$M2 = \sum_{t=1}^N [x(t+1) - x(t)]^2$$

$$DVAR = \frac{1}{N-1} \sum_{t=1}^N [x(t+1) - x(t)]^2$$

$$DASDV = \sqrt{\frac{1}{N} \sum_{t=1}^N [x(t+1) - x(t)]^2}$$

$$WAMP = \frac{1}{N} \sum_{t=1}^N f[x(t+1) - x(t)]$$

Las características de una señal biológica son utilizadas mayormente para reconocer información importante sobre variables biológicas. Las señales médicas, en particular, son usadas principalmente para reconocer enfermedades con ayuda de un especialista.

Las características de una señal son también utilizadas como patrones, los cuales pueden alimentar un software de reconocimiento de patrones para reconocer variables de la naturaleza.

2.1.7 Clasificación de patrones

La tarea de reconocer las variables de la naturaleza, tales como el sonido, las imágenes y la presencia de objetos, es una tarea que se ejecuta de manera natural e inconsciente dentro de nuestro cerebro (31) (32). Esta tarea nos permite percibir nuestro entorno y es de vital importancia a la hora de tomar decisiones (33) (34). La relevancia de esto ha inspirado a un grupo considerable de científicos a implementar sistemas inteligentes de reconocimiento de patrones (35) (36).

Una de las tareas más importantes del reconocimiento de patrones es la tarea de clasificación, la cual consiste en etiquetar patrones con clases dependiendo de la similitud entre características de patrones conocidos por un sistema inteligente (37) (38).

Entre los algoritmos de clasificación de patrones más usados en el estado del arte se encuentran los algoritmos de redes neuronales, los algoritmos basados en métricas, los algoritmos probabilísticos, las máquinas de soporte vectorial y las memorias asociativas, entre otros (39-43).

Un problema de reconocimiento de patrones para el caso particular de señales biológicas reside en la extracción y selección de características, y esto se debe a que es imposible representar en su totalidad un fenómeno físico en una computadora digital. Por ello, se hace uso de técnicas de procesamiento digital de señales que representan de manera parcial información de una señal generando un vector de datos con una o más características; ese vector de datos es llamado patrón (44) (45).

2.1.8 Máquinas de soporte vectorial

El algoritmo utilizado por las máquinas de soporte vectorial funciona como un clasificador biclase que minimiza simultáneamente el error empírico de clasificación y maximiza algunas métricas involucradas; como tal, este algoritmo está fuertemente basado en la teoría de aprendizaje estadístico desarrollada por Vapnik, Chervonenkins *et al*, que dio lugar a la implementación de las máquinas de soporte vectorial durante las décadas de los noventa en los laboratorios Bell de AT&T (46-48).

El problema básico que ataca este modelo es encontrar el hiperplano que separe dos clases de manera óptima; y para ello se utiliza el concepto de vectores de soporte, que son aquellos puntos que se encuentran más cercanos al hiperplano óptimo (49) (50), como se ilustra en la Figura 4.

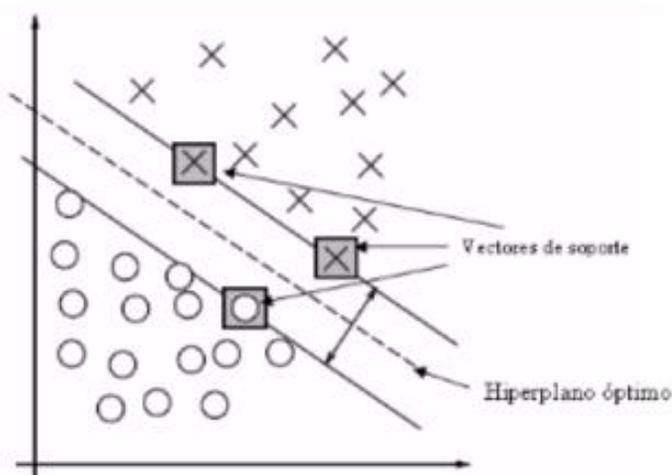


Figura 4 Hiperplano óptimo y vectores de soporte

El conjunto de entrenamiento de una máquina de soporte vectorial se puede definir como X que contiene vectores x_i asociado con su correspondiente clase, $x_i \in R^d$, $y_i = \pm 1$. La ecuación del hiperplano se puede representar de la siguiente manera:

$$\langle w, x \rangle + b = 0$$

donde:

w es el vector de parámetros que conforman el hiperplano y b es el bias.

La operación $\langle w, x \rangle$ se refiere al producto punto entre los elementos de un vector y los parámetros w , por lo que $w \in R^d$ y b es real.

El hiperplano óptimo está definido de la siguiente manera:

$$y_i \langle w, x_i \rangle + b \geq 1$$

donde w y b son aquellos que minimizan $\|w\|$ para todos los datos del conjunto de entrenamiento.

Esto mismo puede ser expresado así:

$$\min f(w) = \frac{1}{2} \|w\|^2 = \frac{1}{2} \langle w, w \rangle$$

Mediante el uso de la teoría de la optimización, este problema puede ser abordado con la siguiente serie de pasos:

1. Se construye el problema de optimización sin restricciones haciendo uso de la función Lagrangiana.

$$L(w, b, \alpha) = \frac{1}{2} \langle w, w \rangle - \sum_{i=1}^n \alpha_i [y_i (\langle w, x_i \rangle + b) - 1]$$

donde $\alpha_i \geq 0$ corresponde a los multiplicadores de Lagrange.

2. El segundo paso consiste en aplicar las condiciones KKT (Karush Khun Tucker), las cuales nos permiten expresar los parámetros w, b en términos de los multiplicadores de Lagrange

$$w^* = \sum_{i=1}^n \alpha_i y_i x_i$$

Y se establece que

$$\sum_{i=1}^n \alpha_i y_i = 0$$

Teniendo en cuenta esto, se puede construir la función Lagrangiana sólo en función de los multiplicadores de Lagrange

$$L(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle$$

Una vez definida la función Lagrangiana, se puede replantear el problema de optimización original

$$\max L(\alpha) \rightarrow \min f(w)$$

De igual manera que el problema anterior, la solución de este problema se da a partir de la teoría de la optimización y la solución a este α^* nos permitirá obtener la solución para w^* .

Considerando que los patrones de entrenamiento son los vectores soportes que están definidos como $SV \subseteq X$, $x_i \in SV$ ssi $y_i \langle w, x_i \rangle + b = 1$, se puede encontrar solución para el valor de b^* a partir de la siguiente ecuación:

$$y_i \langle w^*, x_i \rangle + b^* = 1.$$

De esta manera encontramos los valores w^* y b^* que generan el hiperplano óptimo.

Una vez conocidos los parámetros de caracterización del problema, consideremos $z \notin X$. La máquina de soporte vectorial lo clasifica de la siguiente manera:

$$Clase(z) = \text{signo}(\langle w^*, z \rangle + b^*)$$

donde:

w^* y b^* son los parámetros el hiperplano optimo después del entrenamiento y la función signo se define así:

$$\text{signo}(x) = \begin{cases} 1 & \text{si } x > 0 \\ 0 & \text{si } x = 0 \\ -1 & \text{si } x < 0 \end{cases}$$

Existe el caso del problema que no es linealmente separable; en éste se utiliza una transformación de datos por medio de una función llamada función kernel, la cual se encarga de llevar los patrones a un espacio de dimensión mayor donde el problema sea linealmente separable. Un ejemplo de ello se muestra en la Figura 5 (17) (18).

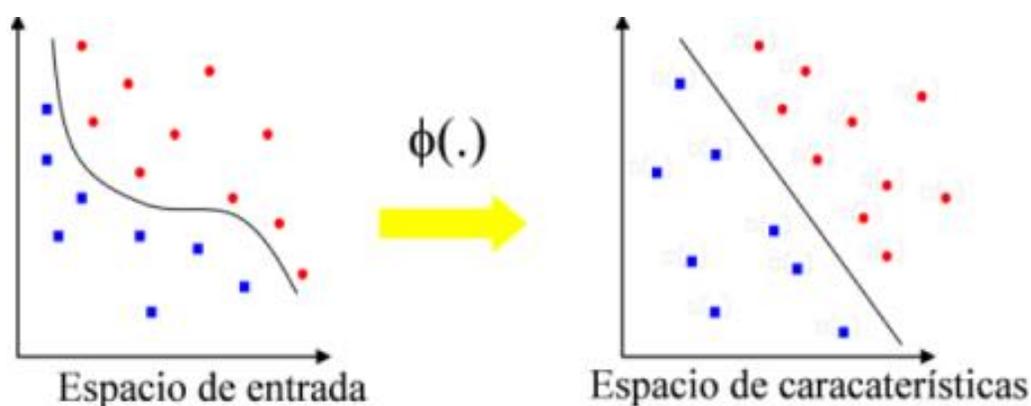


Figura 5 Función Kernel

2.2 Estado del arte

Existe una cantidad significativa de trabajos relacionados con la clasificación y procesamiento de señales de electromiografía, y algunos de los más recientes y relevantes en el estado del arte son mostrados a continuación:

El primer trabajo presentado es (53), que lleva por nombre “Towards an EMG Controlled Prosthesis Hand Using a 3D Electromagnetic Positioning System”, desarrollado por Y Su *et al.* Los autores proponen un método para usar las señales electromiográficas generadas por los músculos del antebrazo, las cuales son recuperadas mediante electromiografía superficial durante el movimiento del miembro superior y controlan una prótesis de mano usada por una persona amputada. A la par, se hace uso de un sistema de posicionamiento 3D vía sensores electromagnéticos.

Las señales recuperadas son preprocesadas mediante análisis de frecuencia y tiempo, y son utilizadas en un algoritmo de reconocimiento de patrones basado en niveles de tensión para identificar los movimientos.

El artículo (8), “Towards a High-Stability EMG Recognition System for Prosthesis Control: a One-Class Classification Based Non-Target EMG Pattern Filtering Scheme”, desarrollado por Yi Hung *et al.*, se enfoca en proponer una solución al problema de estabilidad en una prótesis controlada por señales de electromiografía; para ello, se propone un algoritmo de clasificación de señales electromiográficas basado en clasificadores uniclase que se presentan en un esquema de filtro no lineal con preprocesamiento y basado en máquinas de soporte vectorial.

Este algoritmo utiliza para sus pruebas preprocesamiento de la señal de electromiografía mediante histograma de la señal y parametrización de modelo auto regresivo.

En el trabajo (9) de Panagiotis *et al.*, denominado “An EMG-Based Robot Control Scheme Robust to Time-Varying EMG Signal Feature”, las señales de electromiografía recuperadas por los autores son usadas para generar una interface entre un cuerpo humano y un robot antropomórfico de 4 grados de libertad capaz de tener movimientos en el espacio. Esta interface es construida utilizando el análisis de componentes principales como procesamiento de la señal y algoritmos de enfoque probabilístico.

En el trabajo realizado por Kevin Xing *et al*, que se describe en el artículo (18) “A real time EMG pattern recognition method for virtual myoelectric hand control”, los autores desarrollan un sistema de clasificación de señales que trabaja en tiempo real y que controla una prótesis multifuncional de miembro superior. Este sistema utiliza la herramienta de transformada wavelet como característica principal de la señal de electromiografía, la cual proporciona información de la frecuencia y la amplitud de la señal; además, propone un algoritmo de selección de características recursivo, y finalmente la clasificación de la señal se hace mediante el algoritmo de máquinas de soporte vectorial.

En el artículo (13), “Comparision of decision tree algorithms for EMG signal classification using DWT”, se presenta una comparación entre algoritmos de machine learning, principalmente para el entrenamiento de árboles de decisión, con objeto de encontrar una herramienta efectiva para la clasificación de señales electromiográficas. Este trabajo realizado por Gokgoz presenta además el desarrollo de una interface que clasifica haciendo uso de análisis de componentes principales multiescala y transformadas wavelets como preprocesamiento de la señal y utilizando los algoritmos de árboles de clasificación CART, C4.5 y Random Forest.

La eficiencia de los algoritmos se compara haciendo uso de las técnicas de curvas ROC y el método de validación de “K fold cross validation”.

El autor del artículo (11), “Feature extraction of the first difference of EMG time series for EMG patter recognition”, Angkoon Phinyomark, presenta la utilidad de diferenciar las distintas técnicas de extracción de características de una señal de electromiografía durante sus estados de reposo y de actividad; también utiliza pruebas de estado estacionario de la señal para probar sus propiedades, y además demuestra que las características de señales transformadas funcionan mejor que características tomadas de la señal cruda para seis diferentes algoritmos de clasificación de patrones, incluyendo análisis de discriminación cuadrático.

Capítulo 3. Metodología propuesta.

En este capítulo se presenta de manera detallada la metodología propuesta, la cual se esquematiza en la siguiente figura:

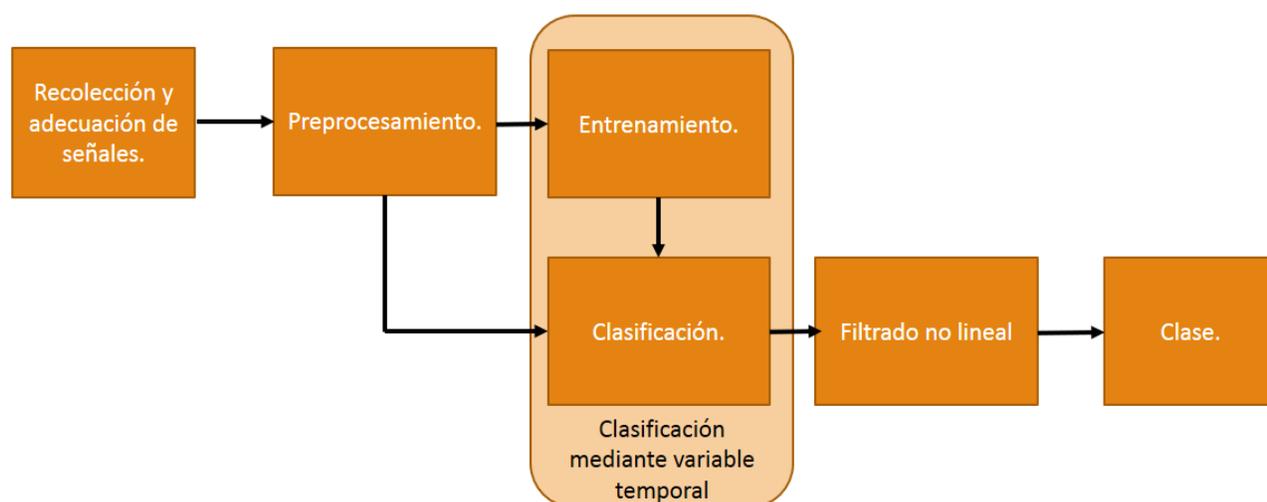


Figura 6 Metodología propuesta.

A continuación, cada una de las secciones de la metodología será explicada en detalle.

3.1 Recolección y adecuación de señales electromiográficas

Las pruebas y validación del modelo propuesto en este documento se hacen mediante un banco de datos de señales reales recuperadas por Rami N. Khusaba, Sarath Kodagoda, Dikai Liu y Gamini Dissanayake (16), quienes son miembros del grupo de investigación de la universidad tecnológica de Sidney. Estas señales se recuperaron mediante la técnica que se muestra en la Figura 3.

Electrodos

Las señales de electromiografía fueron recuperadas mediante electromiografía superficial alrededor del antebrazo del paciente con electrodos (DE 2.x series EMG sensors) y procesado por el sistema (Bagnoli desktop EMG system from Delsys Inc).

Amplificación

La señal fue amplificada con una ganancia de 1000 haciendo uso del dispositivo (National Instruments, BNC-2090).

Filtrado analógico.

Esta señal es procesada por un filtro pasabandas de frecuencias de corte de 20Hz – 450 Hz y un filtro rechazabandas de 50 Hz. Con la ayuda del dispositivo (National Instruments, BNC-2090).

Convertidor analógico-digital.

La señal fue digitalizada con un procesador analógico digital de 12 bits a una frecuencia de muestreo de 4000 Hz con el dispositivo (National Instruments, BNC-2090).

Los datos se conforman de pruebas de 5s. tomadas a 8 personas diferentes: 6 hombres y 2 mujeres con miembros totalmente sanos (sin ningún desorden muscular).

Durante este experimento fueron recolectadas señales correspondientes a 15 diferentes posiciones del miembro, las cuales corresponden a las clases, y se describen a continuación:

1. Thumb (T).
2. Index (I).
3. Middle (M)
4. Ring (R)
5. Little (L)
6. Thumb-Index (T-I)
7. Thumb-Middle (T-M)
8. Thumb-Ring (T-R)
9. Thumb-Little (T-L)
10. Index-Middle (I-M)
11. Middle-Ring (M-R)
12. Ring-Little (R-L)
13. Index-Middle-Ring (I-M-R)
14. Middle-Ring-Little (M-R-L)
15. Hand close (HC)

Se han tomado señales de cada una de las posiciones 3 veces a cada persona por un periodo de tiempo de 5 segundos.

En la Figura 6 se muestra gráficamente la posición correspondiente a cada etiqueta.

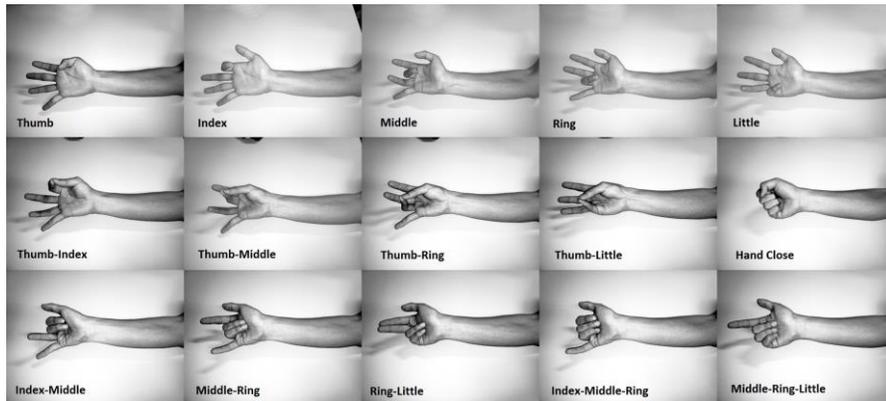


Figura 7 Etiquetas de las señales de electromiografía (19)

Para completar nuestro esquema de recuperación de señales biológicas es necesario agregar la etapa de procesamiento digital de señales, la cual se explica de manera detallada en la siguiente sección.

3.2 Preprocesamiento de las señales electromiográficas

El preprocesamiento digital de la señal de electromiografía se hace mediante segmentos construidos a partir de ventanas de tiempo móviles con la integral de la señal de electromiografía.

La operación de ventana es conocida como la operación que extrae un segmento de tiempo finito de una señal (20). Definiremos la ventana de la siguiente forma:

$$h[n] = \begin{cases} 1 & \text{si } n \in [0, T] \\ 0 & \text{otro caso} \end{cases}$$

donde T se refiere a las primeras muestras de la señal.

El segmento de la señal mediante la operación se ventana se construye mediante la siguiente operación:

$$\forall n \ s[n] = x[n] \cdot h[n]$$

siendo $x[n]$ la señal de electromiografía y $s[n]$ el segmento.

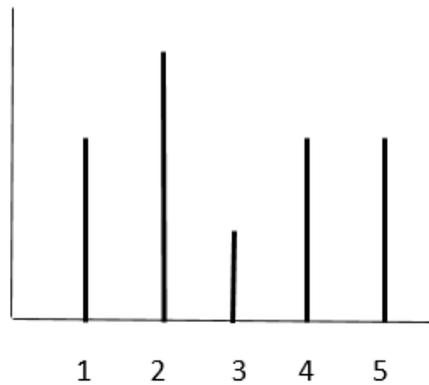
Una vez definida la ventana, continuaremos con el concepto de ventana de tiempo móvil.

El conjunto de segmentos de ventana móvil son aquellos segmentos construidos a partir de ventanas de tiempo, las cuales se encuentran separadas por una diferencia entre muestras Δn , de manera tal que construyen un segmento de la señal de manera recurrente. Cada elemento de este conjunto se define de la siguiente manera:

$$\forall n \ s_i[n] = x[(\Delta n \cdot i) + n] \cdot h[n]$$

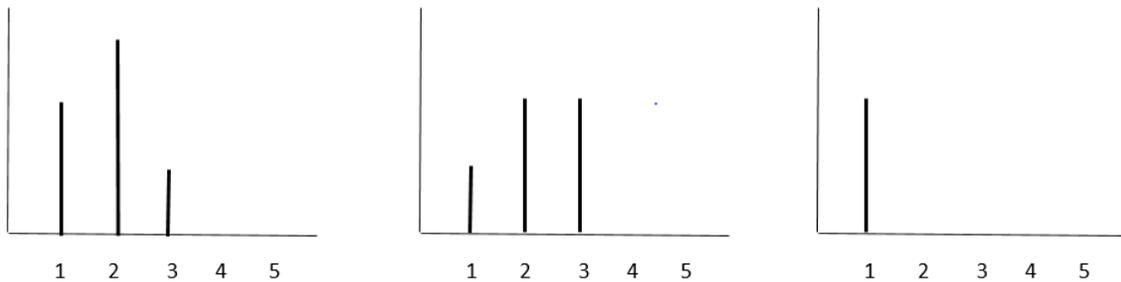
A continuación, se presentan algunos ejemplos y particularidades:

Se tiene la siguiente señal $x[n]$:



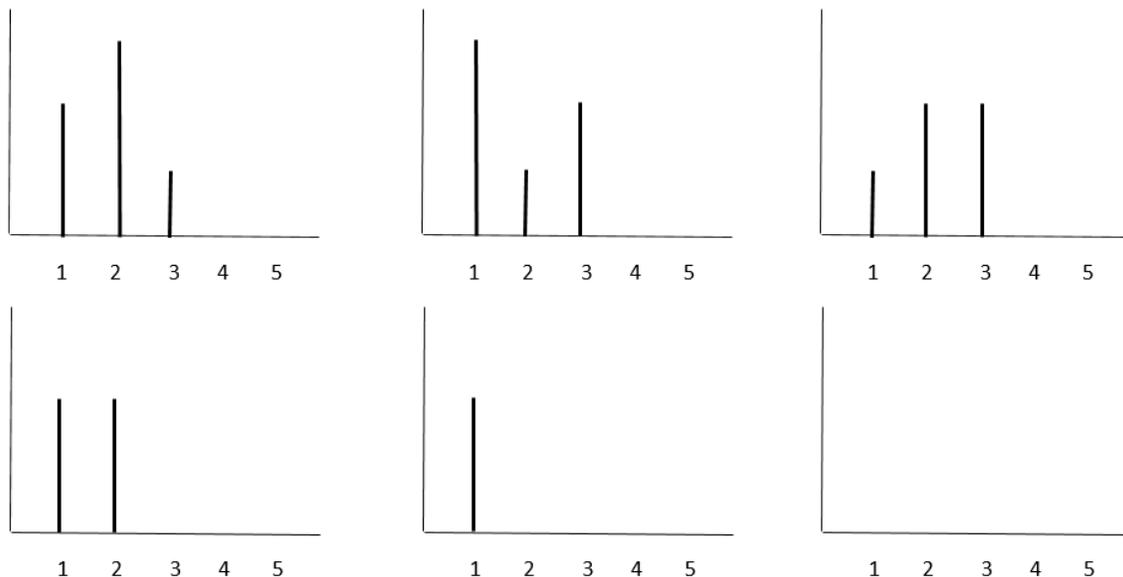
Se aplica el proceso de ventana móvil para los siguientes casos:

Caso para $T = 3$ y $\Delta n = 2$



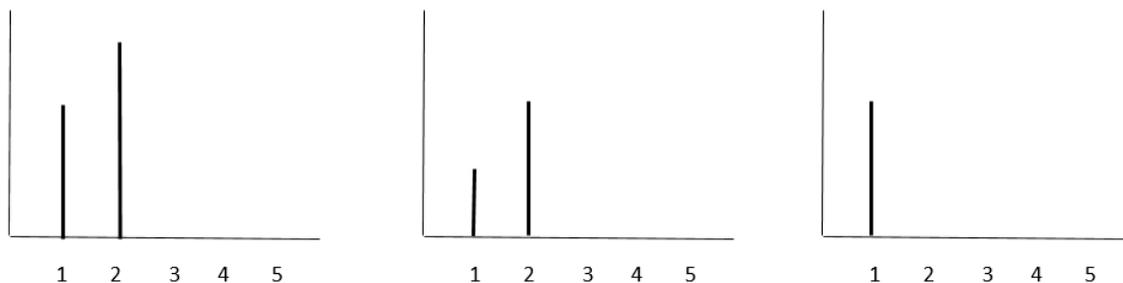
En el ejemplo se puede apreciar el corrimiento de la señal por cada uno de los segmentos y el tamaño de ventana que se le está aplicando. Para este caso en particular, el último elemento del segmento i es el primero elemento del segmento $i - 1$

Caso para $T = 3$ y $\Delta n = 1$



En la figura se puede apreciar el movimiento de ventana por cada muestra de la señal.

Caso para $T = 2$ y $\Delta n = 2$



En el caso donde $\Delta n = T$, se presenta el fenómeno donde ninguna muestra se repite en ninguna de las ventanas. A este se le conoce como ventana de tiempo estática.

Conociendo el concepto de ventana móvil, es posible el preprocesamiento basado en segmentos construidos a partir de ventanas móviles con la integral de la señal:

Una vez que conocemos los i segmentos generados a partir del proceso de ventana de tiempo móvil, se genera una nueva señal que se conforma de una muestra por cada segmento de ventana móvil de la señal original haciendo uso de la extracción de características. Para este caso en particular se presenta el método con la integral de la señal.

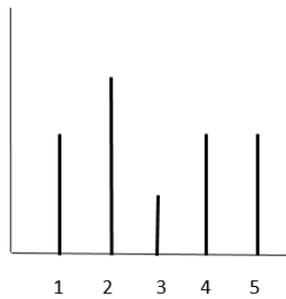
Como se ha mencionado anteriormente, el área bajo la curva de una señal de electromiografía es una de las características más usadas en el estado del arte para tareas de clasificación de señales; esta característica usa como parámetros una señal o un segmento de una señal y nos entrega una representación de ese segmento en un valor real.

Para este caso en particular se hará uso de los segmentos generados por la ventana móvil, los cuales serán utilizados para generar la señal preprocesada. Esta operación se representa de la siguiente manera:

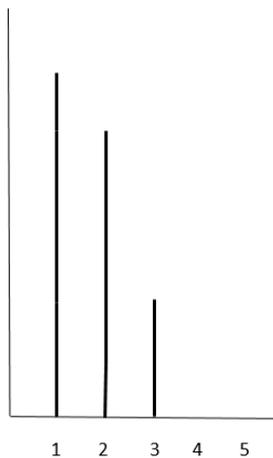
$$x_p[i] = \sum_{n=1}^T |s_i[n]|$$

De igual manera se presenta un ejemplo gráfico del proceso:

Para una señal $x[n]$:



El resultado de preprocesamiento con los parámetros $T = 3$ y $\Delta n = 2$



Con el preprocesamiento debido, la señal está lista para convertirse en entrada de un software de reconocimiento de patrones.

3.3 Clasificación mediante variable temporal: Desarrollo del algoritmo de clasificación para señales electromiográficas por el método máquinas de soporte vectorial recurrentes

La fundamentación teórica de este modelo está basada fuertemente en el problema de optimización de la máquina de soporte vectorial. Se ha elegido trabajar con base en este modelo gracias a las claras ventajas que presenta contra algoritmos clásicos como el algoritmo de backpropagation, las cuales se mencionan a continuación: es un sistema bastante robusto a la generalización, a grado tal, que aun sin función kernel nos arrojará siempre un hiperplano óptimo sin necesidad de que el sistema sea linealmente separable, a diferencia de lo que ocurre en la red neuronal; esto, porque la red neuronal necesita un número dado de neuronas en la capa oculta para garantizar un entrenamiento convergente, a fin de lograr transformaciones a cualquier dimensión. Otra ventaja evidente es que el algoritmo de búsqueda contiene sólo un mínimo global, lo que marca una diferencia notable con el algoritmo de entrenamiento de una red neuronal, el cual puede detenerse en mínimos locales, no garantizando por ello la solución óptima. En cuanto a su fase de clasificación, el algoritmo se resume a una simple suma de productos, ofreciendo así un resultado correcto a partir de operaciones simples.

La aportación de la optimización se da partir de la siguiente función:

$$hp(X)$$

la cual tiene como entrada el conjunto X que contiene vectores x_i asociados con su correspondiente clase y_i , $x_i \in R^d$, $y_i = \pm 1$, restringiendo el algoritmo únicamente para problemas biclase. A la salida de la función se obtiene un vector que está formado por la concatenación de w^* y b^* .

Como todo algoritmo de clasificación de patrones este algoritmo cuenta con 2 fases: entrenamiento y clasificación.

3.3.1 Fase de entrenamiento

La primera fase del algoritmo consiste en encontrar la matriz V a partir de señales de 2 diferentes clases, y esto se hace de la siguiente manera:

Consideramos los conjuntos de señales $S1$ y $S2$, los cuales son 2 señales de diferentes clases, a partir de las cuales se creará el conjunto de entrenamiento por la siguiente serie de pasos:

Paso 1: se generan patrones a partir de la señal con el preprocesamiento de segmentos construidos a partir de ventanas de tiempo móviles con la integral de la señal de

electromiografía para cada una de las señales; para este caso siendo un problema de clasificación binario.

$$\forall n \ s1_i[n] = S1[(\Delta n \cdot i) + n] \cdot h[n]$$

$$\forall n \ s2_i[n] = S2[(\Delta n \cdot i) + n] \cdot h[n]$$

$$\forall i \ x_{s1}[i] = \sum_{n=1}^T |s1_i[n]|$$

$$\forall i \ x_{s2}[i] = \sum_{n=1}^T |s2_i[n]|$$

Paso 2: se genera el conjunto de entrenamiento formado por asociaciones de la máquina de soporte vectorial recurrente a partir de los patrones construidos anteriormente:

$$\forall i \ X^i = (x_{s1}[i], 1) \quad i = 1, 2, 3 \dots, c - 2, c - 1, c$$

$$\forall j \ X^j = (x_{s2}[j], -1) \quad j = c + 1, c + 2, \dots, 2c - 2, 2c - 1, 2c$$

donde c es la cardinalidad de x_{s1} o x_{s2} lo cual restringe el modelo a $|x_{s1}| = |x_{s2}|$

Paso 3: se genera la matriz V a partir del conjunto X y la función hp

$$\forall i \ V^i = hp(X^i) \quad i = 1, 2, 3 \dots, c - 2, c - 1, c$$

donde c en esta ocasion es la cardinalidad de X

Con estos 3 pasos concluye la fase de aprendizaje.

Nótese que a pesar de usar el algoritmo de optimización de la máquina de soporte vectorial, la complejidad del algoritmo de nuestra propuesta es mucho menor que el del algoritmo de las SVM.

Lo anterior se cumple, ya que al momento de clasificar se hace uso solo de las muestras de las señales en ese instante de tiempo, por lo que las entradas del algoritmo de optimización son como máximo el número de muestras de ese instante.

3.3.2 Fase de clasificación.

La fase de clasificación consiste en determinar la clase del algoritmo para el caso de clasificación binaria 1 o -1. Siendo \hat{x} una muestra de una señal podemos determinar su clase con la siguiente operación:

$$H\left(\sum_{i=1}^c [X^i \cdot \hat{x}]\right)$$

La cual es una función compuesta de la función de producto punto, la sumatoria y la función $H(x)$ siendo esta una variante de la función de heaviside definida de la siguiente manera:

$$\forall x \in \mathbb{R} \quad H(x) = \begin{cases} -1 & \text{si } x < \theta \\ 1 & \text{si } x \geq \theta \end{cases}$$

donde θ es un umbral.

3.3.3 Desarrollo de ensamble homogéneo por máquinas de soporte vectorial recurrentes (algoritmo multiclase)

Al igual que en el algoritmo anterior, éste se divide en 2 fases: la fase de entrenamiento y la fase de clasificación; la primera se divide en 4 pasos:

Paso 1: se tiene un conjunto de entrenamiento X , el cual contiene n clases, se separa el conjunto de entrenamiento en 2 clases clase P y clase N . Para el primer caso hacemos $P = S \in X \wedge S$ es de la clase 1 y $N = X - S$, por lo tanto, tenemos un conjunto de entrenamiento nuevo conformado por N y P el cual nombraremos $X(1)$.

Paso 2: se entrena el modelo biclase con el conjunto conformado por N y P .

Paso 3: se normaliza el modelo agregando un valor de "offset", el cual se calcula de la siguiente forma:

$$mp = \sum_{\forall a \in X \wedge a \in P} \sum_{i=1}^n (X^i \cdot a) \quad mn = \sum_{\forall b \in X \wedge b \in N} \sum_{i=1}^n (X^i \cdot b)$$

$$Offset = \frac{\frac{mp}{|P|} + \frac{mn}{|N|}}{2}$$

Paso 4: se repiten el paso 1,2 y 3 para las clases de la 2 hasta la n , logrando así obtener n modelos biclases entrenados a partir del conjunto X .

Fase de clasificación

Siendo \hat{x} una muestra de una señal, podemos determinar su clase con la siguiente secuencia de pasos:

Paso 1: se calcula el siguiente valor para cada uno de los clasificadores entrenados y los guardamos en el vector de resultados.

$$\forall j \quad R[j] = \sum_{i=1}^c [X^i(j) \cdot \hat{x}] + offset \quad j = 1,2,3, \dots, n-1, n$$

Paso 2: la clase se determina por la asociación del máximo valor.

$$Clase = k \mid R[k] = \bigvee_{j=1}^n R[j]$$

De esta manera es posible determinar el valor de la clase mediante un ensamble de clasificadores homogéneo. La Figura 7 muestra el esquema general de clasificación.

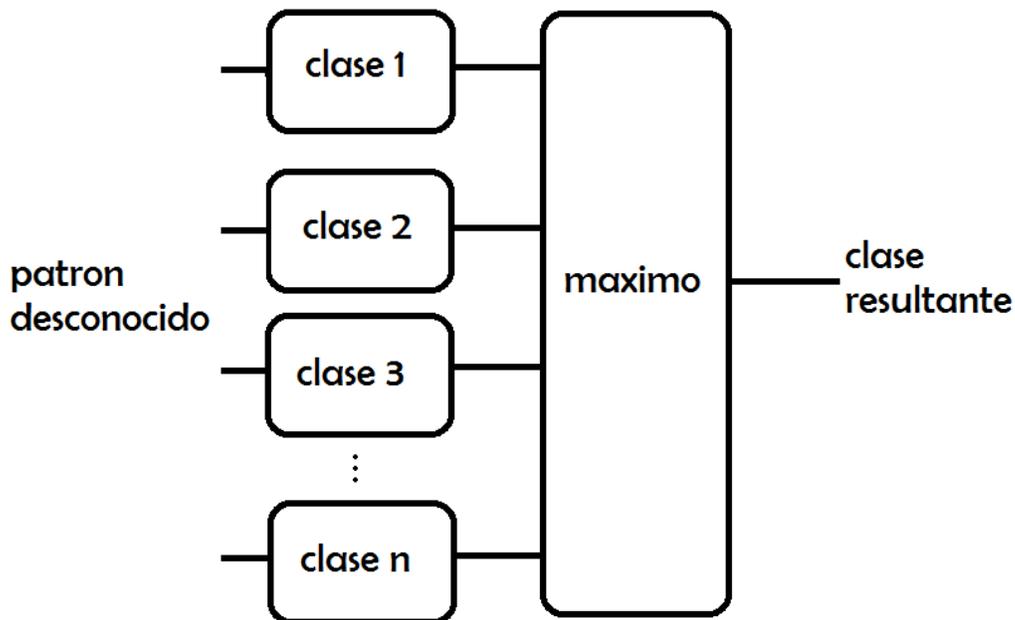


Figura 8 Representación del ensamble homogéneo que conforma el algoritmo completo

3.4 Filtrado no lineal.

Siendo la aplicación directa de esta metodología una señal electromiográfica, es natural que la entrada de nuestro sistema trabaje con señales, esto a su vez nos genera como respuesta una señal a la salida. Es preciso mencionar que no se tiene un desempeño del 100% para todas las señales, por lo cual es conveniente aplicar un filtro no lineal a la salida del sistema.

Este nos permitirá tener una ganancia en el desempeño sacrificando tiempo de respuesta, se hará uso de un filtro mediana para esta aplicación, el cual se describe a continuación: consideramos $x[n]$ la señal resultante del algoritmo de ensamble homogéneo por máquinas de soporte vectorial recurrentes, el filtrado se define de la siguiente manera:

$$y[i] = \mathbf{mediana}(x[i - k], x[i - k + 1], \dots, x[i])$$

siendo k el tamaño de ventana de memoria del filtro no lineal.

Una vez definido el filtro como la etapa final de la metodología propuesta, esta puede ser aplicada a señales electromiográficas.

Capítulo 4. Resultados.

En este capítulo se presentan algunas pruebas experimentales, al aplicar la metodología propuesta en las señales electromiográficas descritas en el capítulo anterior. Se exhiben los resultados obtenidos mediante el modelo de validación *hold-out*; además, se valida el modelo mediante una matriz de confusión, la cual es útil para reflejar el comportamiento del algoritmo en el proceso de caracterización para las señales de electromiografía. Como parte importante del capítulo, se discuten los resultados de manera detallada.

4.1 Preprocesamiento de las señales electromiográficas

En esta primera sección se presentan 3 experimentos que ilustran el comportamiento de una señal de electromiografía para casos particulares del preprocesamiento, mediante **segmentos** construidos a partir de ventanas de tiempo móviles de la integral.

Experimento 1

Este experimento consiste en aplicar el preprocesamiento a la señal de la siguiente figura, fijando el parámetro $\Delta n = 1$ y variando los valores del tamaño de ventana T .

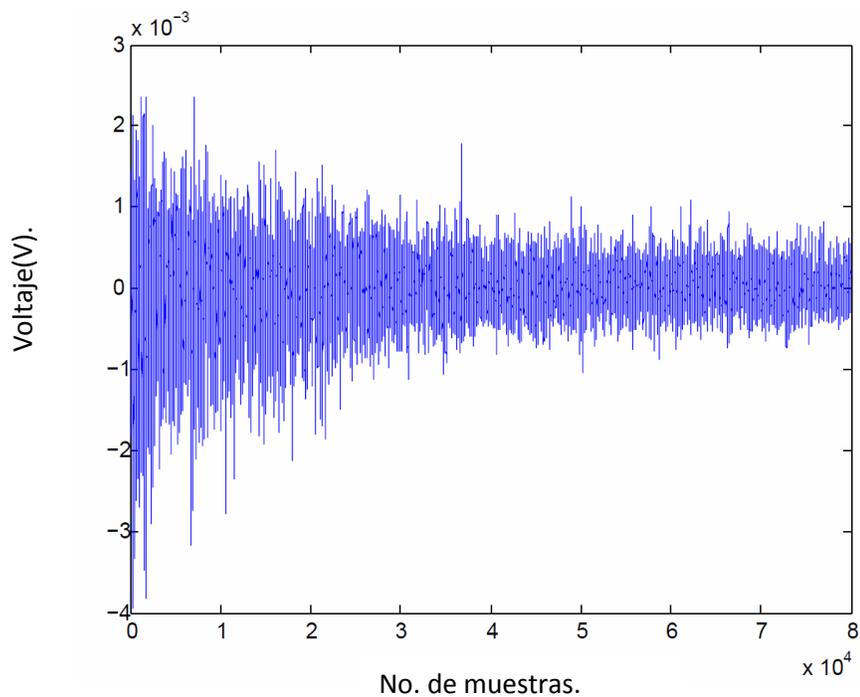


Figura 9 Señal electromiográfica de miembro superior recuperada del antebrazo.

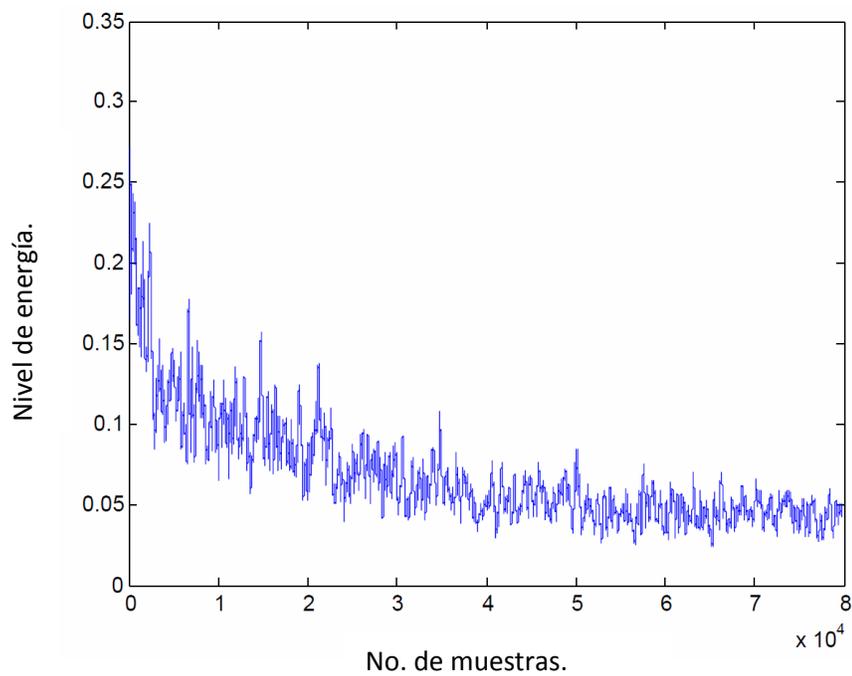


Figura 10 Preprocesamiento mediante segmentos construidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 1$ y $T = 250$

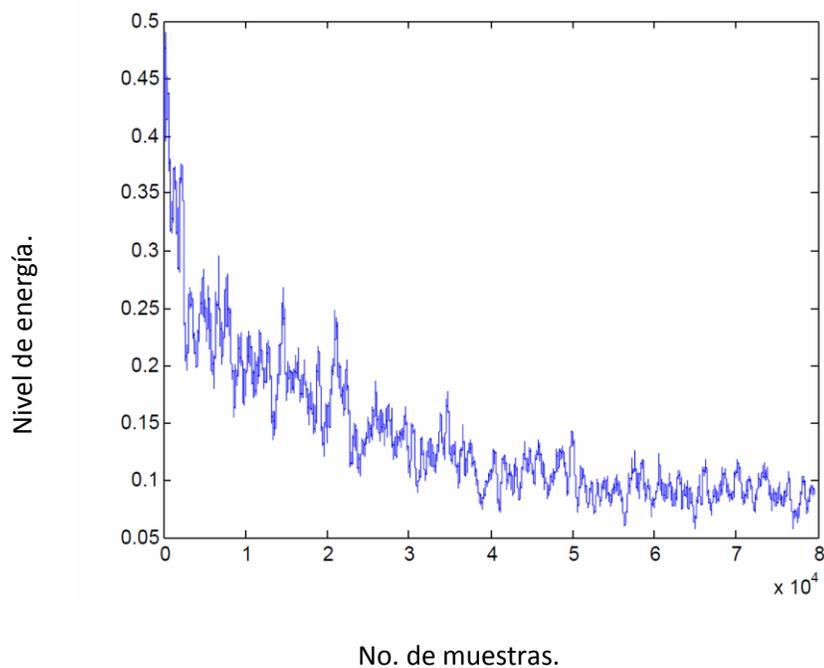


Figura 11 Preprocesamiento mediante segmentos construidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 1$ y $T = 500$

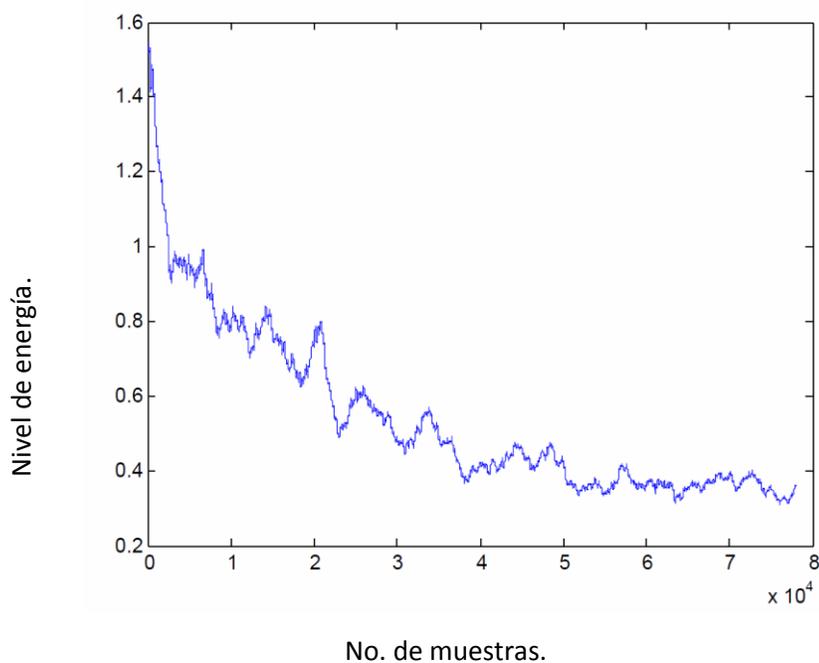


Figura 12 Preprocesamiento mediante segmentos construidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 1$ y $T = 1000$

Se puede apreciar en las figuras que al aumentar el tamaño de ventana también aumenta la energía de la señal por segmento generado. También se puede apreciar que a mayor tamaño de la ventana se obtiene una señal menos ruidosa.

Experimento 2

Este experimento consiste en aplicar el preprocesamiento a la señal de la siguiente figura fijando el parámetro $T = 1000$ y variando la variable de desplazamiento Δn

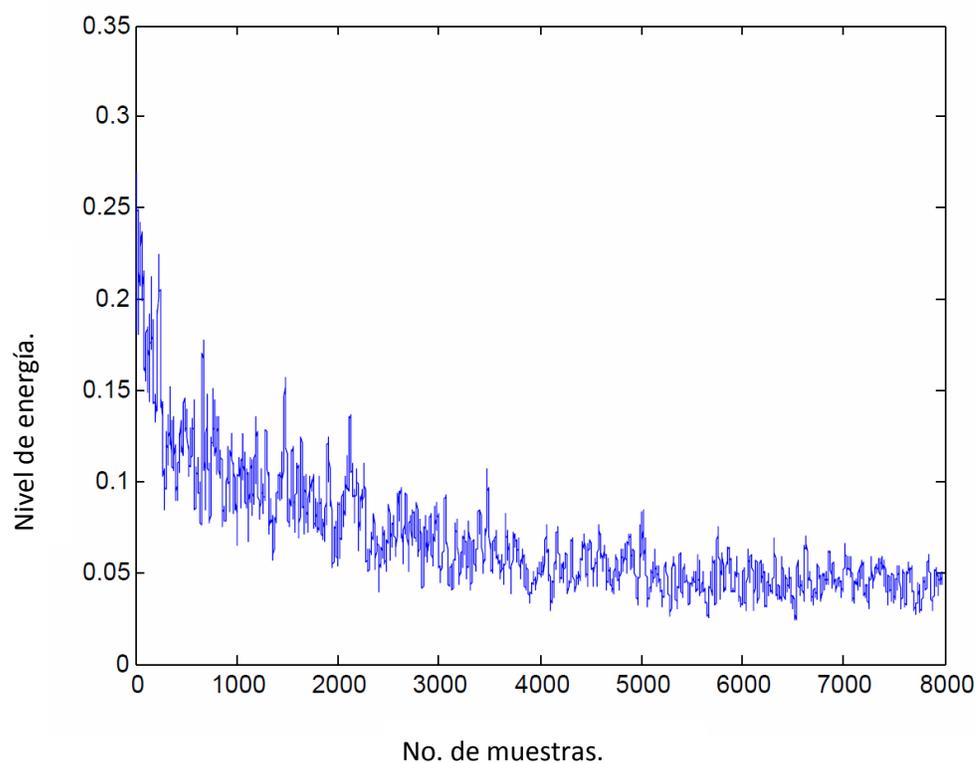


Figura 13 Preprocesamiento mediante segmentos construidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 10$ y $T = 1000$

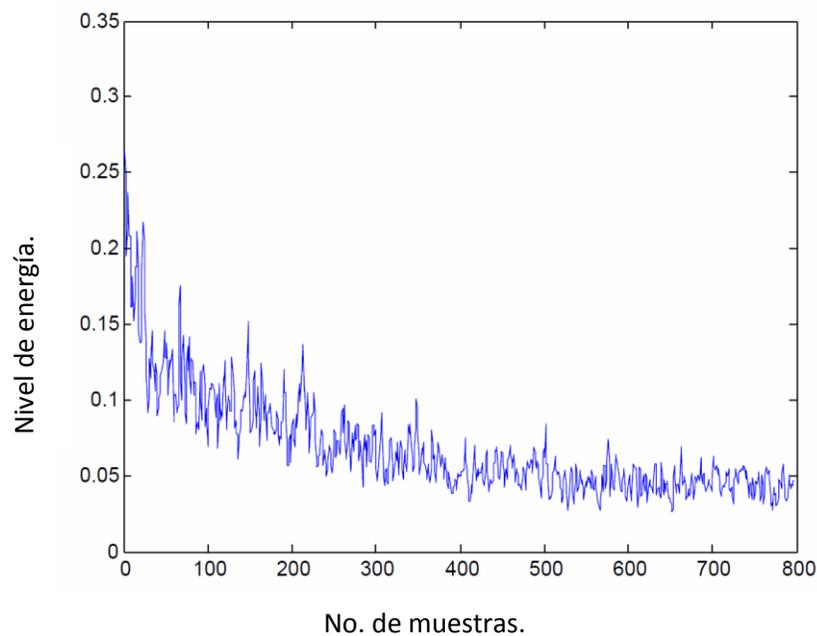


Figura 14 Preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 100$ y $T = 1000$

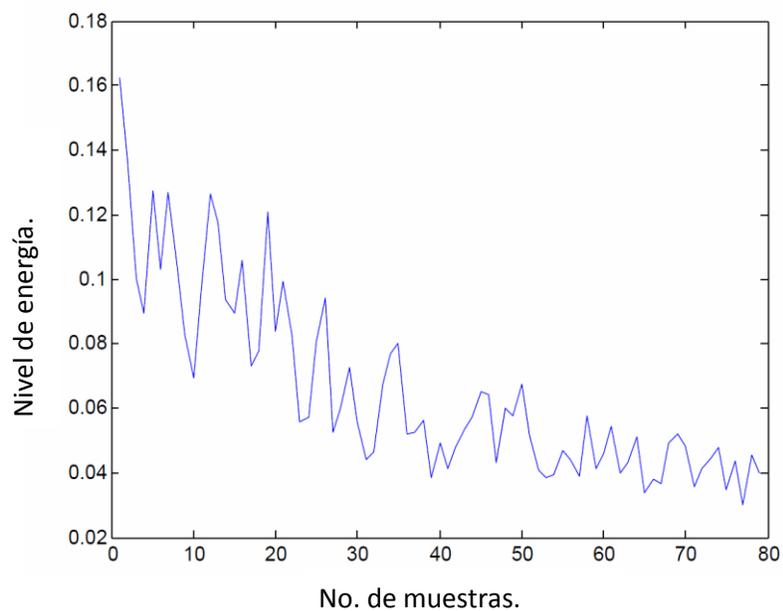


Figura 15 Preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal con parámetros $\Delta n = 1000$ y $T = 1000$

Se puede apreciar en las imágenes que a un mayor desplazamiento podremos tener un menor número de muestras para la señal preprocesada. A diferencia del experimento previo donde se variaba el tamaño de ventana, los valores de energía se corresponden entre sí.

Experimento 3

Este experimento consiste en visualizar los datos con y sin procesamiento con un conjunto de datos conformado por 2 señales para 5 diferentes movimientos; este experimento se hace con ayuda del software weka (21)

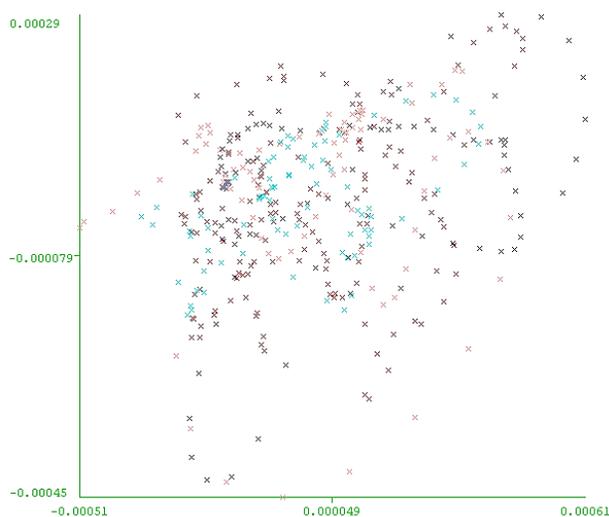


Figura 16 Distribución de datos de señales electromiográficas sin preprocesamiento.

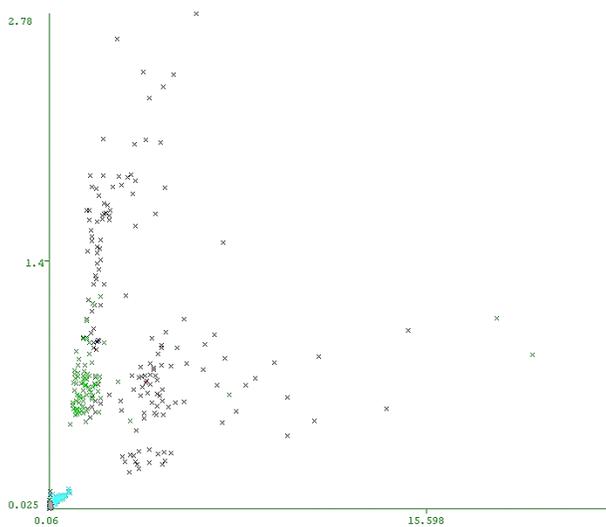


Figura 17 Distribución de datos de señales electromiográficas con preprocesamiento mediante segmentos construidos a partir de ventanas de tiempo móviles con la integral.

Se puede apreciar en las figuras anteriores cómo el preprocesamiento mediante segmentos contruidos a partir de ventanas de tiempo móviles con la integral de la señal, genera una separación en la distribución de las señales, facilitando la tarea de clasificación.

4.2 Clasificación binaria de señales electromiográficas con uso del algoritmo de clasificación máquinas de soporte vectorial recurrentes

En esta sección se muestra el modelo máquinas de soporte vectorial recurrentes y cómo se comporta al aplicarlo en señales electromiográficas.

Experimento 1

El primer experimento consiste en encontrar la matriz V generada por los conjuntos de señales generados por las clases HC-T.

Los conjuntos de señales que se utilizaron para entrenar el modelo con las clases HC y T fueron los siguientes:

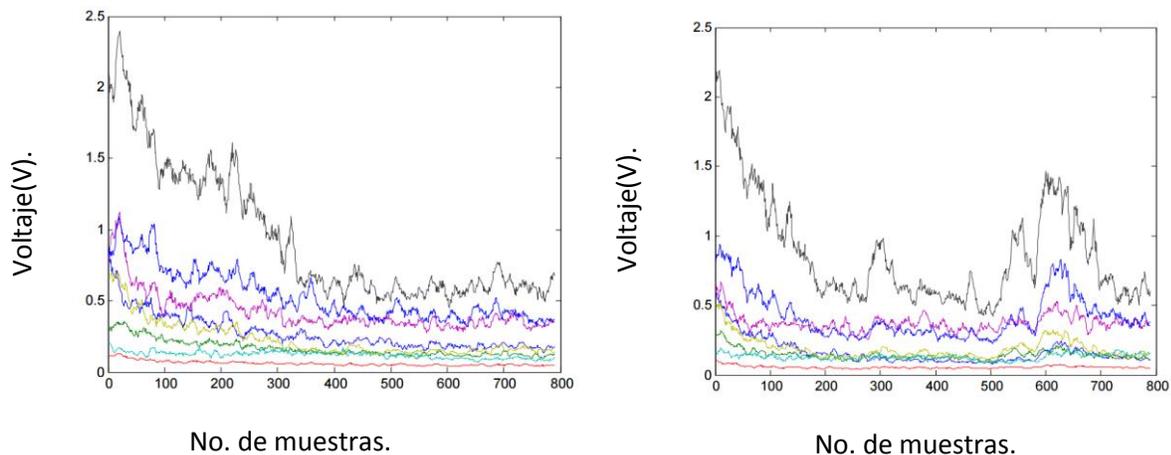


Figura 18 Conjuntos de señales de entrenamiento de la clase HC.

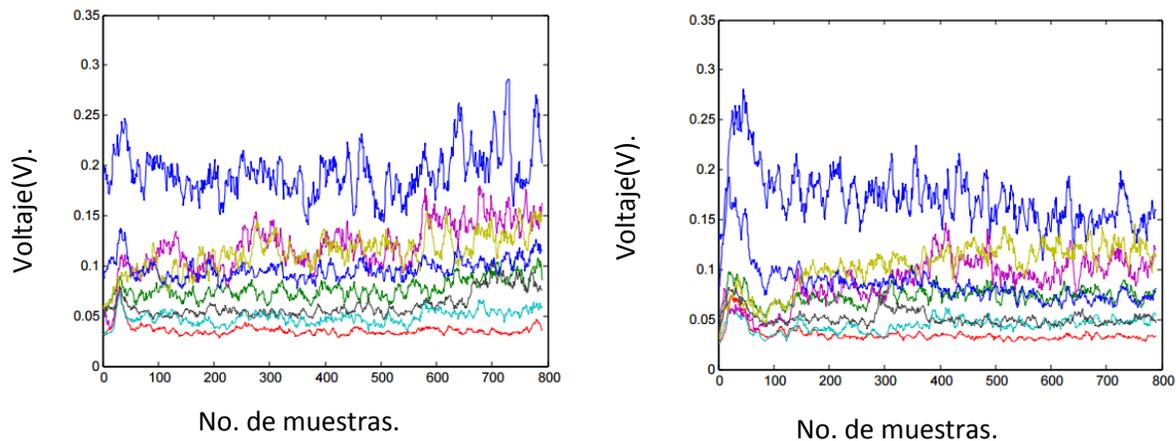


Figura 19 Conjuntos de señales de entrenamiento de la clase T.

Como resultado del entrenamiento, la matriz V se ve reflejada de la siguiente manera:

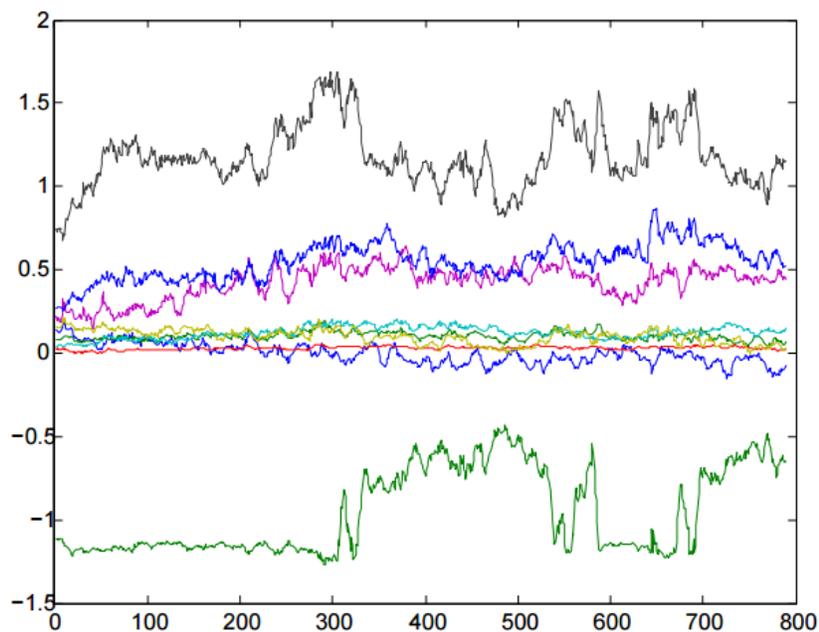


Figura 20 Matriz V generada por el entrenamiento de las señales de las figuras 17 y 18.

Esta matriz representa el ajuste de los parámetros que generan el hiperplano a través del tiempo.

Experimento 2

Este experimento consiste en mostrar los resultados del *resubstitution error* para visualizar la caracterización de la señal.

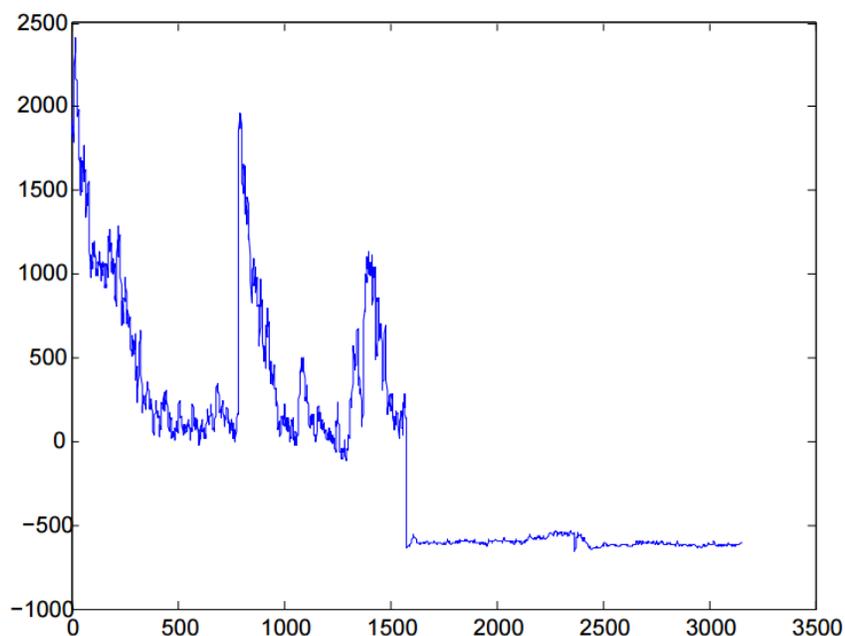


Figura 21 Caracterización del problema de clasificación para las clases HC y T.

Se puede apreciar en la figura que, mientras el sistema tiene como entrada una de la clase HC, la salida mantiene un nivel mayor a -100.

También se puede observar en la figura que es evidente la clasificación correcta en todos los casos para el *resubstitution error*.

Experimento 3

Este experimento muestra los resultados obtenidos al clasificar haciendo uso de señales ajenas a las señales de entrenamiento del sistema; estas señales son las siguientes:

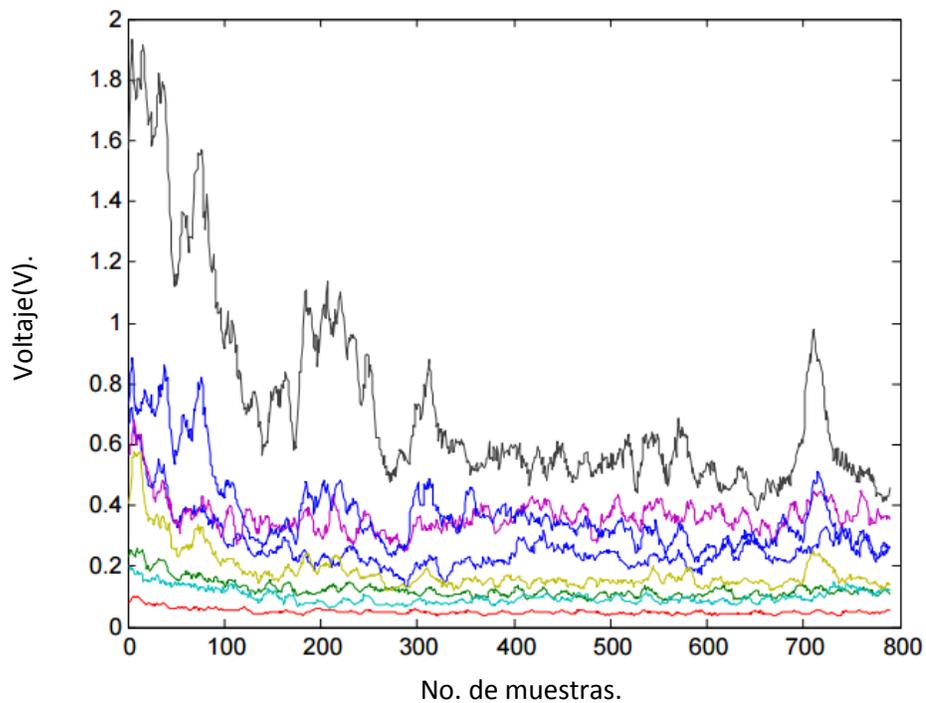


Figura 22 Señal desconocida de la clase HC

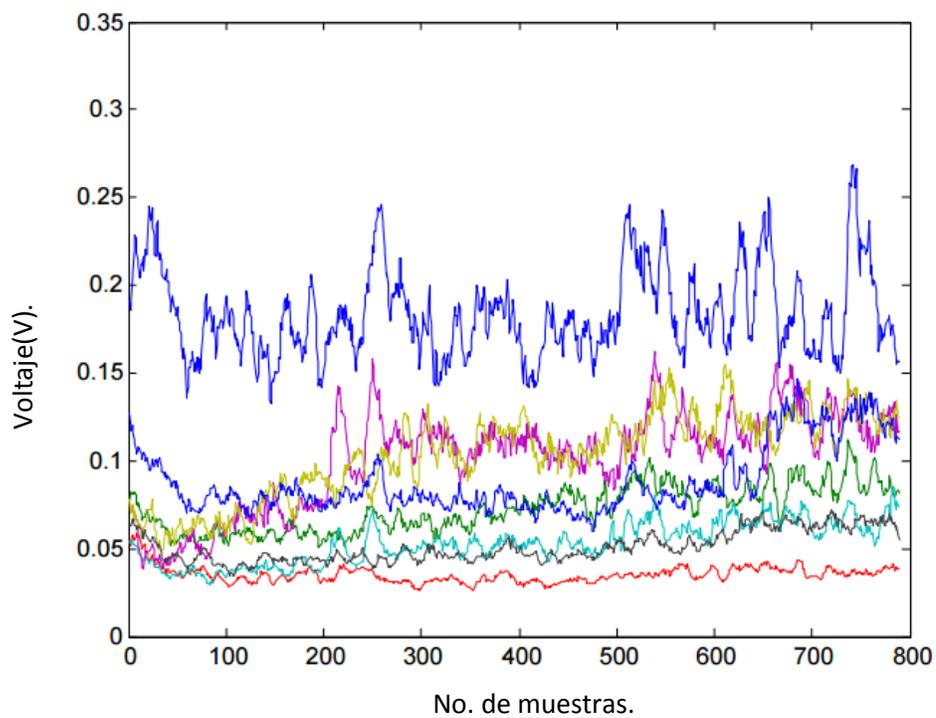


Figura 23 Señal desconocida de la clase T

El resultado de la clasificación es el siguiente:

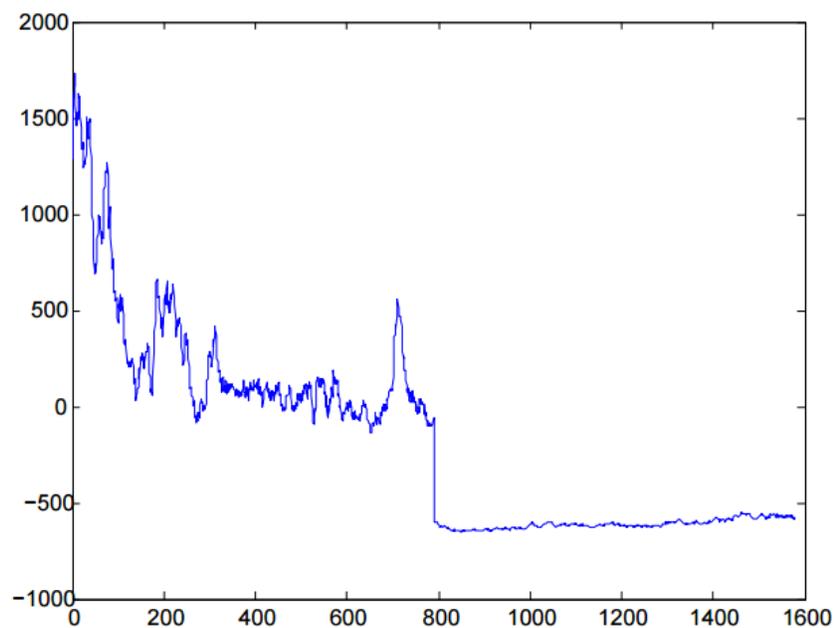


Figura 24 Clasificación de las señales HC y T con señales desconocidas

Se puede observar en la figura que los resultados obtenidos de la clasificación son similares a los resultados obtenidos con *resubstitution error*: para ambos casos se ha obtenido una clasificación correcta.

Experimento 4

Se repiten los experimentos de 1 al 3 para las clasificaciones entre las clases HC-RL y las clases IMR-T y se observan los resultados.

HC-RL

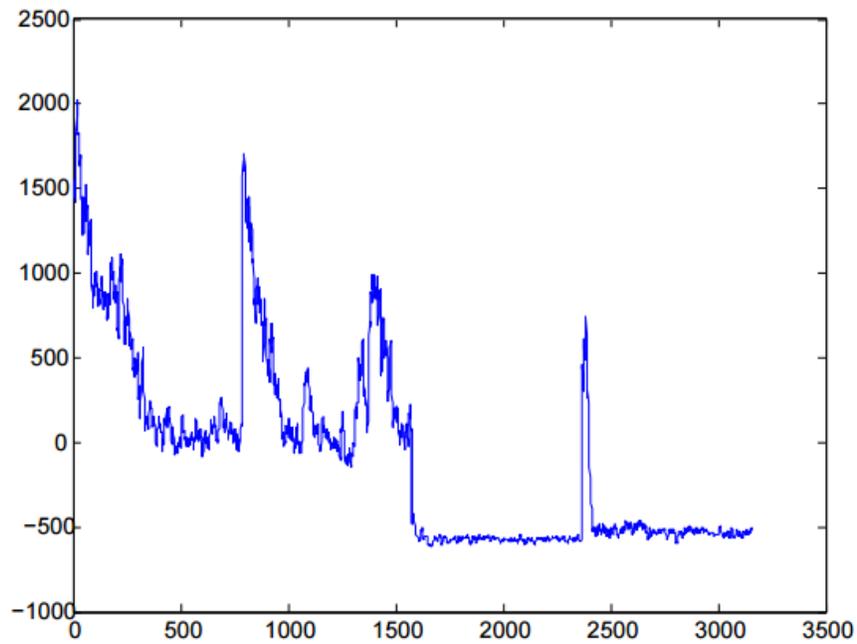


Figura 25 Caracterización del problema de clasificación para las clases HC y RL.

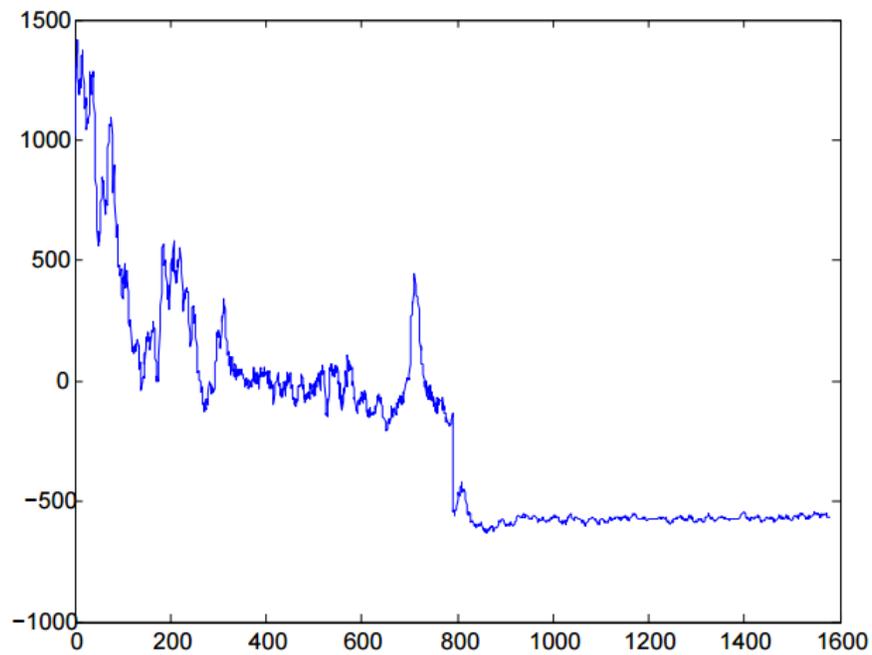


Figura 26 Clasificación de las señales HC y RL con señales desconocida

IMR-T

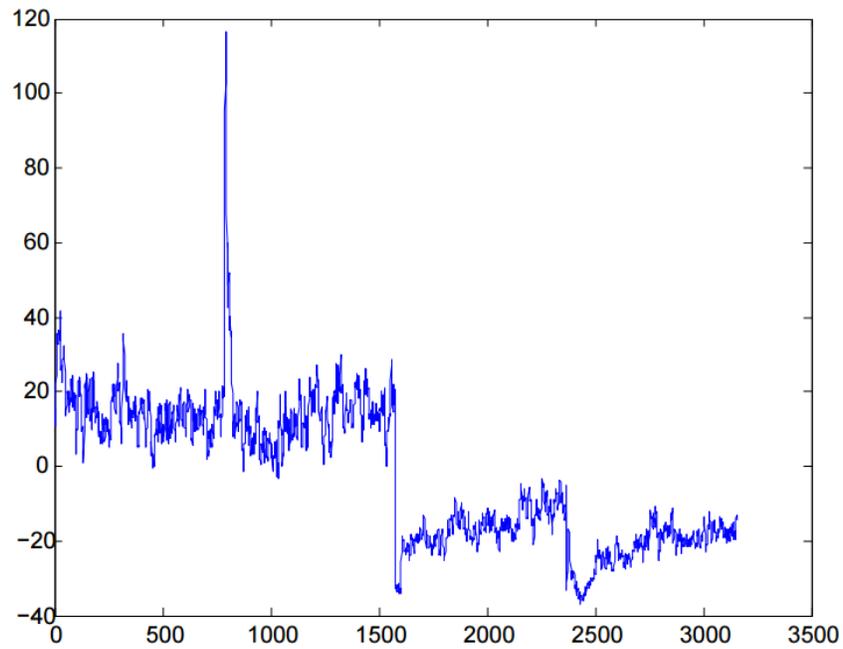


Figura 27 Caracterización del problema de clasificación para las clases IMR y T.

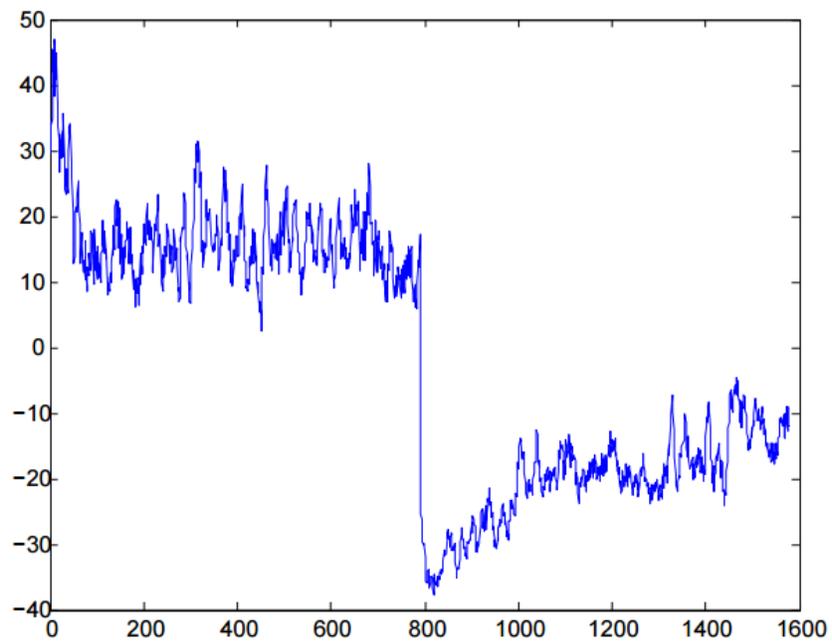


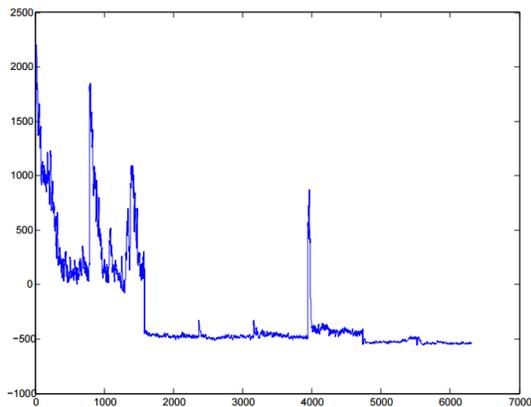
Figura 28 Clasificación de las señales HC y RL con señales desconocida

4.3 Clasificación de señales electromiográficas con uso del algoritmo máquinas de soporte vectorial recurrentes multiclase

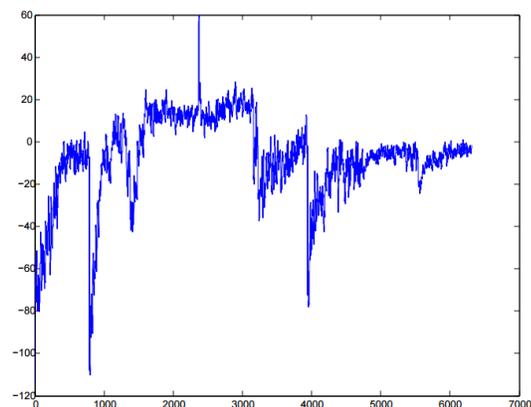
En esta sección se presenta las pruebas al modelo completo entrenado con las señales de las clases HC, RL, IRM y T.

EXPERIMENTO 1

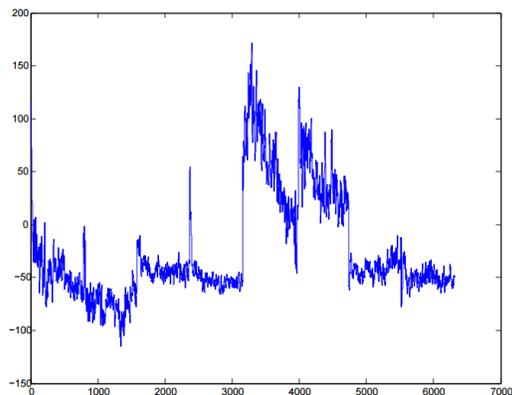
Como se mencionó anteriormente, este algoritmo consiste en entrenar varios algoritmos de manera independiente; por ello, el primer experimento consiste en recuperar el comportamiento de cada uno de los algoritmos para una secuencia de recuperación de la clase 1, 2, 3 y 4 respectivamente:



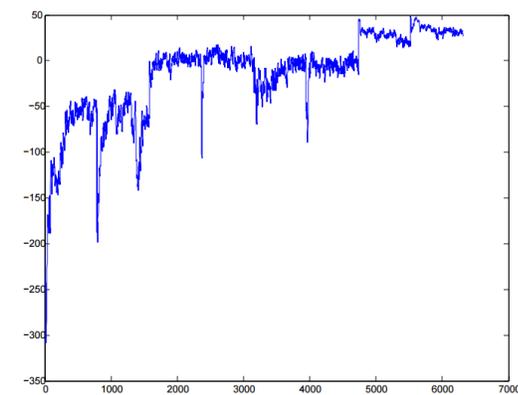
a) Modelo entrenado con la clase 1



b) Modelo entrenado con la clase 2



c) Modelo entrenado con la clase 3

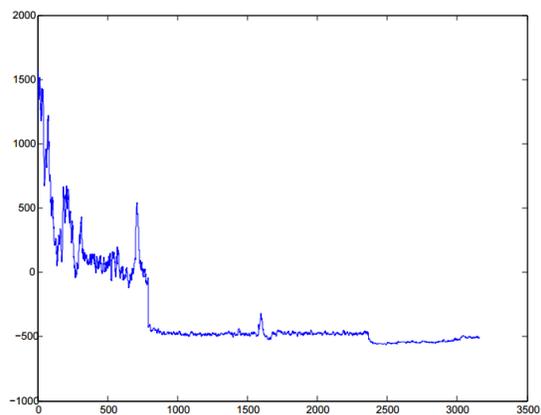


d) Modelo entrenado con la clase 4

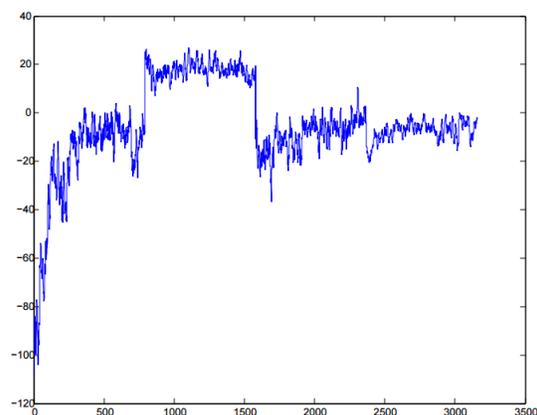
Figura 29 Modelos binarios para resubstitution error.

Como se puede apreciar en la figura, cada una de los clasificadores tiene un valor mayor para datos de su correspondiente clase.

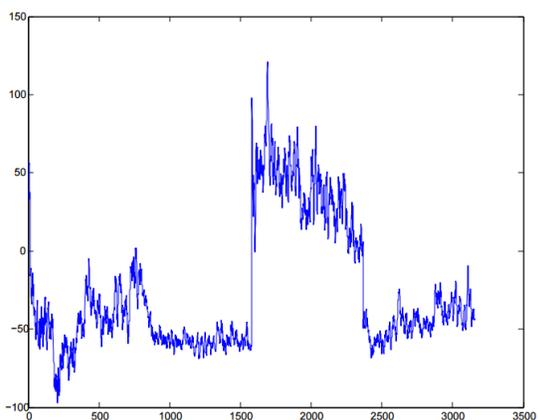
Se repite el experimento usando señales que no pertenecen al conjunto de entrenamiento.



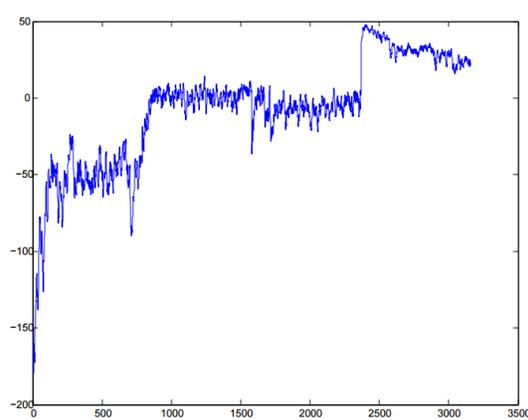
a) Modelo entrenado con la clase 1



b) Modelo entrenado con la clase 2



c) Modelo entrenado con la clase 3



d) Modelo entrenado con la clase 4

Figura 30 Modelos binarios para un patrón desconocido.

EXPERIMENTO 2

Como continuación al experimento anterior, se presentan los resultados de la clasificación para ambos casos.

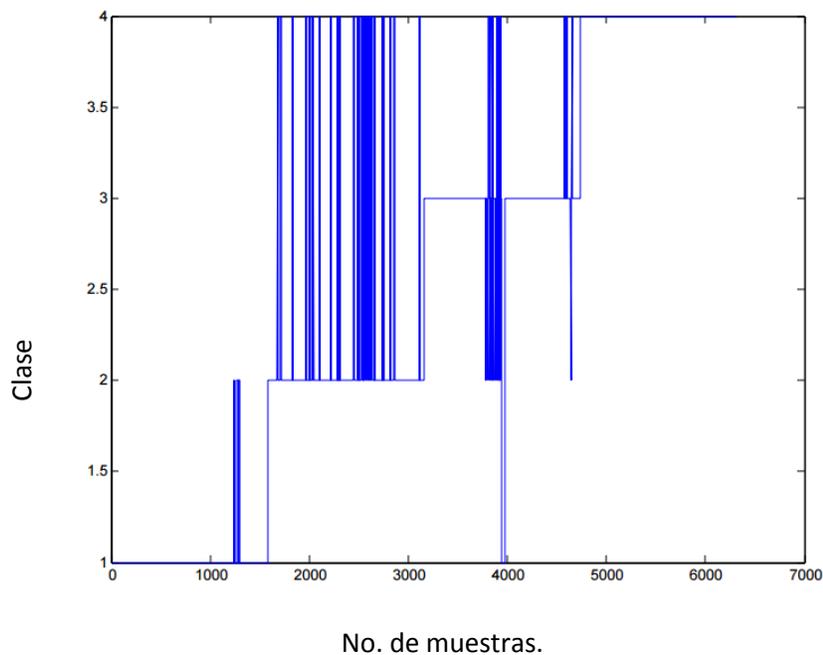


Figura 31 Resultado de clasificación con resubstitution error

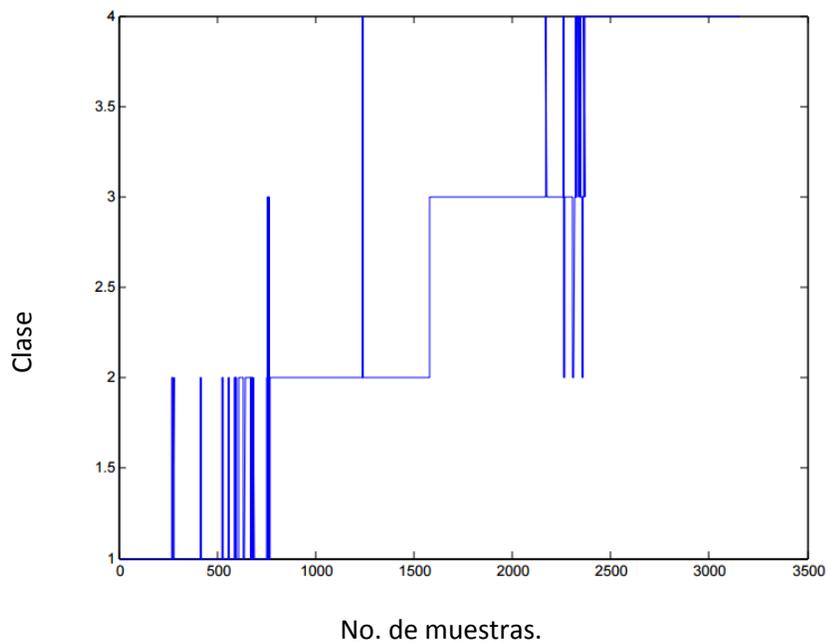


Figura 32 Resultado de clasificación para un patrón que no pertenece al conjunto de entrenamiento

4.4 Clasificación con filtrado no lineal.

Como se puede ver en la figura anterior el modelo no asegura una clasificación correcta el 100% del tiempo; esto puede cambiar al aplicar un filtro no lineal, sacrificando tiempo de respuesta del sistema.

EXPERIMENTO 1

Se muestra a continuación el resultado de aplicar filtro no lineal para diferentes tamaños de ventana en la señal recuperada del sistema de clasificación multiclase.

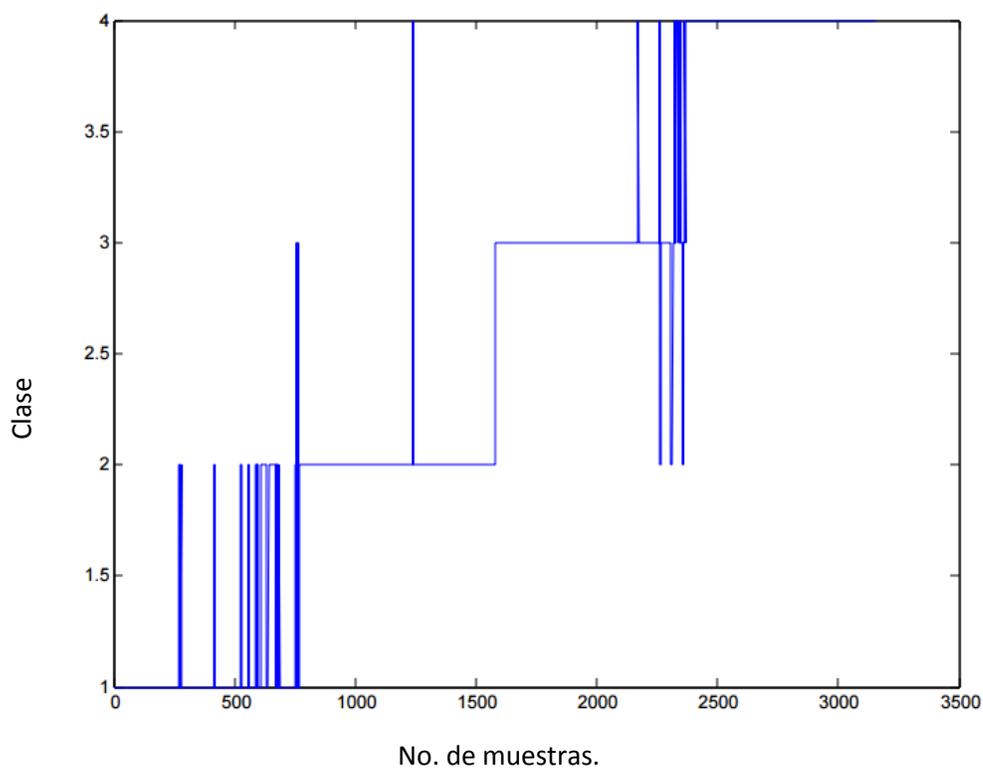


Figura 33 Salida del modelo máquina de soporte vectorial recurrente multiclase

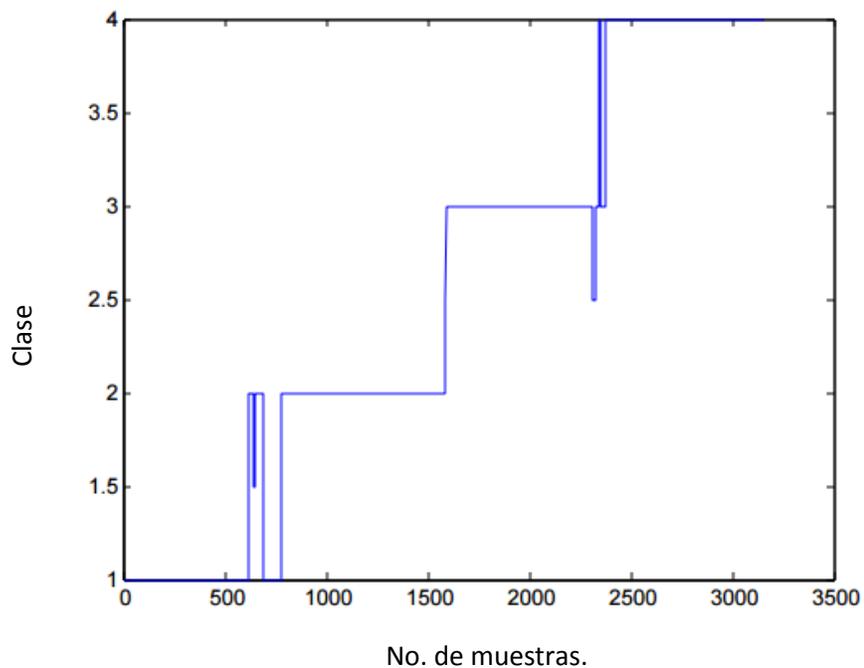


Figura 34 Salida del modelo máquina de soporte vectorial recurrente multiclase con filtro no lineal $K=10$

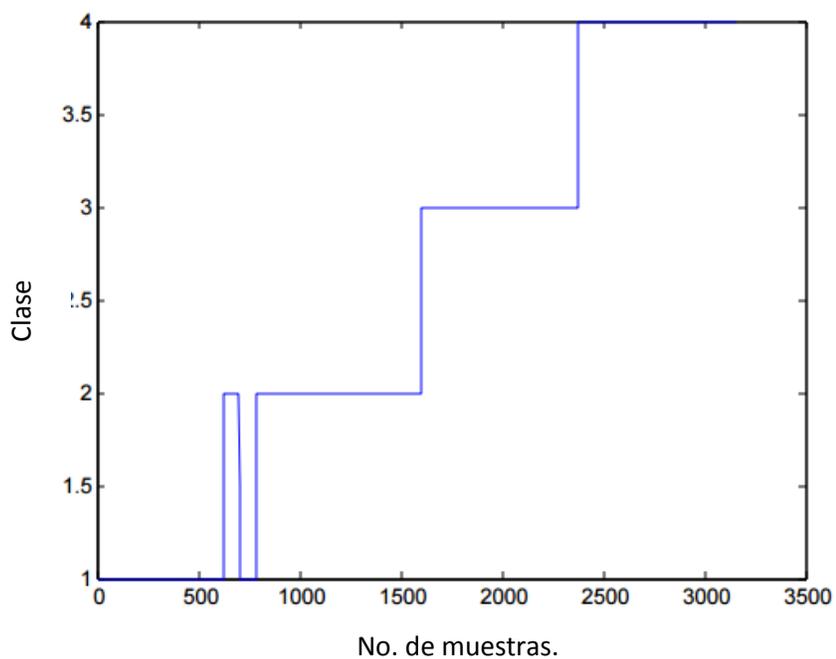


Figura 35 Salida del modelo máquina de soporte vectorial recurrente multiclase con filtro no lineal $K=50$

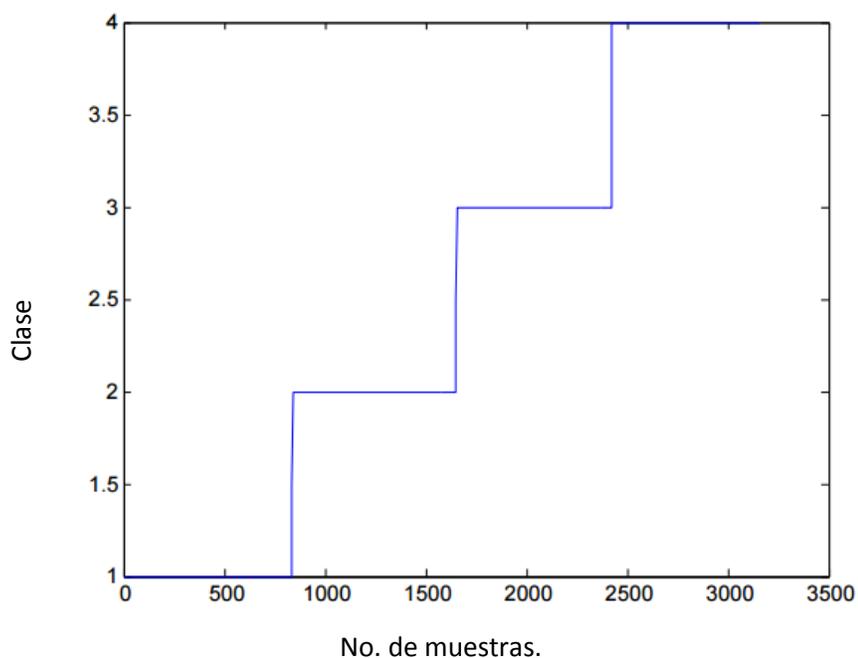


Figura 36 Salida del modelo máquina de soporte vectorial recurrente multiclase con filtro no lineal $K=10$

4.5 Validación del modelo haciendo uso de la matriz de confusión con la técnica de validación *hold out*.

A continuación, se presenta la validación al modelo completo entrenado con las señales de las clases HC, RL, IRM y T haciendo uso de la técnica de validación *hold-out* para diferentes sin filtro no lineal.

Tabla 2 Matriz de confusión para el modelo sin filtro con resubstitution error

	HC	IMR	RL	T
HC	1543	35	0	0
IMR	0	1452	0	126
RL	33	34	1484	27
T	0	0	0	1578

Tabla 3 Matriz de confusión para el modelo sin filtro con hold-out

	HC	IMR	RL	T
HC	680	106	3	0
IMR	0	788	0	1
RL	0	16	754	19
T	0	0	0	789

Una vez más se presenta la validación del modelo, esta vez filtrado mediante filtro mediana con tamaño $k=50$ y entrenado con las señales de las clases HC, RL, IRM y T, haciendo uso y la técnica de validación *hold-out*.

Tabla 4 Matriz de confusión para el modelo con filtro de tamaño $k=50$ con resubstitution error

	HC	IMR	RL	T
HC	1546	32	0	0
IMR	24	1504	6	44
RL	32	34	1512	0
T	0	0	0	1578

Tabla 5 Matriz de confusión para el modelo con filtro de tamaño $k=50$ con hold-out

	HC	IMR	RL	T
HC	712	77	0	0
IMR	0	789	0	0
RL	0	24	765	0
T	0	0	0	789

Se puede apreciar en las matrices que con un filtro de tamaño $k=50$ se mejora el desempeño del algoritmo; sin embargo, para este problema no logra un desempeño del 100% de clasificación.

De manera similar se presenta la validación del modelo, esta vez con un filtro mediana con tamaño $k=100$ y entrenado con las señales de las clases HC, RL, IRM y T haciendo uso y la técnica de validación *hold-out*.

Tabla 6 Matriz de confusión para el modelo con filtro de tamaño $k= 100$ con resubstitution error

	HC	IMR	RL	T
HC	1578	0	0	0
IMR	0	1578	0	0
RL	0	0	1578	0
T	0	0	0	1578

Tabla 7 Matriz de confusión para el modelo con filtro de tamaño $k=100$ con hold-out

	HC	IMR	RL	T
HC	789	0	0	0
IMR	0	789	0	0
RL	0	0	789	0
T	0	0	0	789

Nótese que para esta última validación el modelo ha alcanzado un desempeño del 100%. Esto nos indica que para este problema de clasificación es necesario un filtro no lineal de tamaño $k = 100$, a fin de conseguir una clasificación correcta.

4.6 Desempeño y parámetros de preprocesamiento

En esta sección se muestra cómo afecta al desempeño la variación de los parámetros; tamaño de ventana (T) y factor de desplazamiento Δn

Para este experimento se evalúa el modelo sin filtro y se aprecia el desempeño de clasificación para las clases HC, RL, IRM y T con un coeficiente de desplazamiento $\Delta n = 80$, haciendo uso del algoritmo máquinas de soporte vectorial recurrentes.

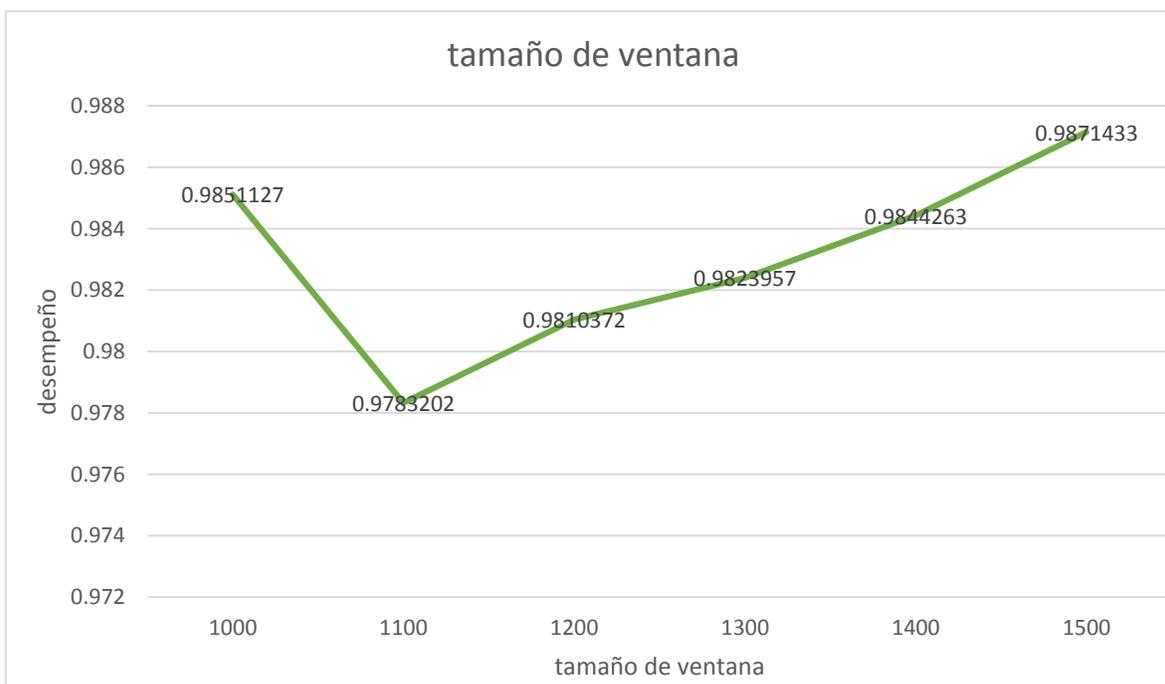


Figura 37 Desempeño para distintos tamaños de ventana

Se puede apreciar en la gráfica que el desempeño no varía de manera considerable. Sin embargo, el optimizar esta característica podría significar un mayor desempeño o un menor tiempo de respuesta del sistema.

La siguiente prueba consiste en repetir el experimento anterior, variar el factor de desplazamiento para un tamaño de ventana de $T=2000$ y observar el comportamiento del desempeño de clasificación.

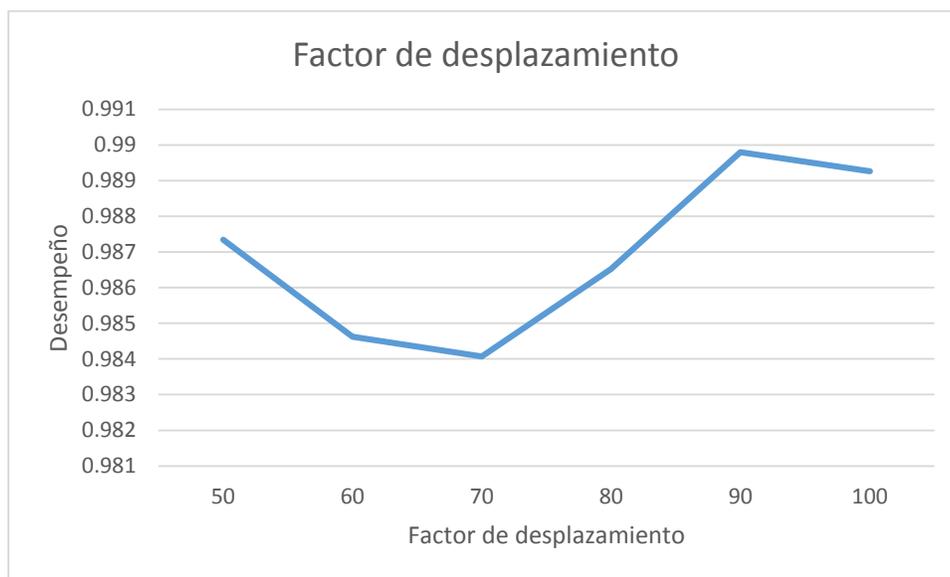


Figura 38 Desempeño para distintos tamaños de factor de desplazamiento

Al igual como ocurre al variar el tamaño de ventana, se da un fenómeno parecido al variar el factor de desplazamiento: el desempeño definitivamente es afectado por estos dos componentes del preprocesamiento.

No obstante, lo anteriormente expresado, es pertinente hacer notar que el problema de elegir los 2 valores óptimos para la tarea de clasificación se convierte en un problema de optimización muy complejo.

Este complejo problema de optimización podría ser resultado con el uso de técnicas avanzadas de optimización, con metaheurísticas o con algoritmos evolutivos.

4.7 Comparación con modelos del estado del arte.

En la esta sección se presenta el desempeño de clasificación logrado por los algoritmos más populares en el estado del arte comparado con el algoritmo que se presenta en este trabajo de tesis para el problema de clasificación de las señales correspondientes a las clases HC, RL, IRM, T e I, haciendo uso de *resubstitution error* y *hold-out*.

Tabla 8 Comparación de desempeño de los algoritmos con *resubstitution error*

Algoritmo de clasificación	<i>Resubstitution error</i> (%)
NaiveBayes	2.51
RSVM (sin filtro)	1.53
RSVM (filtro con k=50)	0.91
SVM	0.59
RNA (BackPropagation)	0.31
Árbol de decisión J48	0.06
KNN(1NN)	0
RSVM (filtro con k=100)	0

Tabla 9 Comparación de desempeño de los algoritmos con *hold-out*

Algoritmo de clasificación	Desempeño <i>hold-out</i> (%)
NaiveBayes	93.53
RSVM (sin filtro)	97.00
Árbol de decisión J48	97.51
RNA (BackPropagation)	97.84
SVM	98.75
RSVM (filtro con k=50)	98.97
KNN	99.36
RSVM (filtro con k=100)	100

Un escrutinio de las Tablas 8 y 9 nos permite apreciar que el modelo propuesto en este trabajo de tesis, cuando se usa sin filtro, arroja resultados no aceptables, que lo hacen quedar en desventaja en el proceso de comparación de resultados con otros modelos del estado del arte. Sin embargo, se observa que el uso del filtro no lineal le añade poder discriminatorio al modelo propuesto, de modo tal que aumenta ostensiblemente su desempeño, tanto en señales de aprendizaje (Tabla 8) como de prueba (Tabla 9).

Es notable que en las señales de entrenamiento la propuesta iguala en desempeño al 1NN con 0% de error, resultado es imposible de mejorar. Al aplicar el algoritmo propuesto a señales de prueba, es competitivo, dado que un tamaño de filtro de k=50 fue suficiente para vencer a los algoritmos del estado del arte, con excepción del kNN; aún así, el algoritmo propuesto supera al kNN cuando se aplica un filtro de tamaño k=100.

Capítulo 5. Conclusiones y trabajo a futuro

Este capítulo consta de dos secciones: conclusiones y trabajo a futuro. En la sección 5.1 se presentan las conclusiones que se extraen a partir de los resultados generados en las pruebas donde se aplicó el modelo propuesto máquinas de soporte vectorial recurrentes, en señales electromiográficas con preprocesamiento mediante ventanas móviles con integral de la señal.

En la sección 5.2, por su parte, se proponen algunas acciones de trabajo a futuro, las cuales podrían servir como punto de partida para aquellos interesados en el tema, quienes podrían tomar como punto de partida las ideas aquí expuestas.

5.1 Conclusiones.

Se ha desarrollado un algoritmo de clasificación de señales temporales, el cual toma como base matemática el algoritmo de optimización del hiperplano de las máquinas de soporte vectorial clásicas, pero que trabaja de manera recurrente. Este nuevo algoritmo muestra ser competente para el banco de datos de señales electromiográficas recolectadas de un miembro superior.

Se ha desarrollado una metodología de clasificación de señales electromiográficas, la cual es capaz de funcionar en el modo “muestra a muestra”, generando así un sistema de control ideal para aplicar a prótesis inteligentes.

Se propone un preprocesamiento de ventana móvil, el cual permite realizar desplazamientos en la integral de la señal, generado así patrones que conservan su secuencia temporal, lo cual nos permite hacer uso de estos patrones para aplicar el algoritmo de máquinas de soporte vectorial recurrentes.

El uso de ensambles homogéneos de algoritmos que funcionan para problemas biclase nos permite generar modelos que pueden funcionar para más de una clase. Es preciso subraya que, no obstante que el uso de los ensambles mejora el desempeño de clasificación, en el proceso de implementación de los ensambles se debe sacrificar complejidad computacional, ya que hay que entrenar un conjunto de varios modelos en paralelo para lograr obtener un buen resultado en la clasificación.

5.2 Trabajo a futuro.

Muchas actividades pueden realizarse a partir de este trabajo de tesis; algunas de las más destacables se mencionan a continuación:

- 1.- Modificar la normalización de los clasificadores individuales por clase para el ensamble homogéneo, con el fin de mejorar el desempeño del algoritmo.
- 2.- Generar un modelo completo que nos permita utilizar funciones kernel. Es razonable suponer que el uso de las funciones kernel ayudará en la mejoría del desempeño del modelo.
- 3.- Generar un nuevo algoritmo de selección de características capaz de elegir entre las mejores señales del conjunto, haciendo uso de la matriz V .
- 4.- Generar un algoritmo que prediga la variable tiempo mediante el algoritmo de clasificación maquinas soporte vectorial recurrentes.
- 5.- Probar el algoritmo para diferentes señales biológicas ajenas a las que se usaron en este trabajo.
- 6.- Hacer uso de técnicas avanzadas de optimización, de metaheurísticas o de algoritmos evolutivos, con miras a optimizar las variables correspondientes al preprocesamiento de la señal.

Bibliografía

1. *Review of Control Strategies for Lower Limb Protheses.* **César Ferreira, Luis Paulo Rels, Cristina Santos.** 2016, *Advances in Intelligence Systems and Computing*, pp. 209-220.
2. *Robust Control of Semi-active Ankle Prosthesis Driven by Electromyographic and Electropneumatic Signals.* **Hugo Serrano, Alberto Luviano, Isaac Chairez.** 2015, *IFMBE Proceedings* 49, pp. 277-280.
3. **Arthur C. Guyton, John E. Hall.** *Tratado de fisiología médica.* Barcelona, España : ELSEVIER, 2011.
4. *Spectral properties of surface electromyogram signal and change in muscle conduction velocity during isometric muscle contraction.* **Sridhar Poosapadi Arjunan, Dinesh Kant Kumar, Katherine Wheeler, Hirokazu Shimada.** 2015, *Signal, Image and Video Processing*, pp. 261-266.
5. *Real-Time Motor Unit Identification From High-Density Surface EMG.* **Vojko Glaser, Aleš Holobar, Damjan Zazula.** 2013, *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING*, pp. 949-958.
6. *Is Accurate Mapping of EMG Signals on Kinematics Needed for Precise Online Myoelectric Control?* **Ning Jiang, Ivan Vujaklija, Hubertus Rehbaum, Bernhard Graimann, Dario Farina.** 2014, *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING*, pp. 549-558.
7. *Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use.* **Englehart, E. Scheme and K.** 2011, *J. Rehabil. Res. Develop.*, vol. 48, no. 6, p. 643.
8. *Towards a High-Stability EMG Recognition System for Prosthesis Control: a One-Class Classification Based Non-Target EMG Pattern Filtering Scheme .* **Yi Hung Liu, Han Pang Huang.** Texas USA : *IEEE International Conference on Systems, Man, and Cybernetics*, 2009.
9. *An EMG-Based Robot Control Scheme Robust to Time-Varying EMG Signal Features.* **Panagiotis K. Artemiadis, Kostas J. Kyriakopoulos.** 2010, *IEEE TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE*, pp. 582-588.

-
10. *Continuous estimation of finger joint angles under different static wrist motions from surface EMG signals.* **Lizhi Pan, Dingguo Zhang, Jianwei Liu, Xinjun Sheng, Xiangyang Zhu.** 2014, *Biomedical Signal Processing and Control*, pp. 265-271.
 11. *Feature extraction of the first difference of EMG time series for EMG pattern recognition.* **Angkoon Phinyomark, Franck Quaine, Sylvie Charbonnier, Christine Serviere, Franck Tarpin-Bernard, Yann Laurillau.** 2014, *Computer Methods and Programs in Biomedicine*, pp. 247-256.
 12. *Control of Upper Limb Prostheses: Terminology and Proportional Myoelectric Control.* **Anders Fougner, Øyvind Stavadahl, Peter J. Kyberd, Yves G. Losier, Philip A. Parker.** 2012, *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING*, pp. 663-677.
 13. *Comparison of decision tree algorithms for EMG signal classification using DWT.* **Ercan Gokgoz, Abdulhamit Subasi.** 2015, *Biomedical Signal Processing and Control* 18, pp. 138-144.
 14. *Characterizing EMG data using machine-learning tools.* **Jamileh Yousefi, Andrew Hamilton-wright.** 2014, *Computers in Biology and Medicine* 51, pp. 1-13.
 15. *Active SVM-based relevance feed-back using multiple classifiers ensemble and features reweighting.* **Xiang-Yang Wang, Bei-Bei Zhang, Hong-Ying Yang.** 2013, *Engineering Applications of Artificial Intelligence* 26, pp. 368-381.
 16. *Electromyogram (EMG) Feature Reduction Using Mutual Components Analysis for Multifunction Prosthetic Fingers Control.* **Rami N. Khushaba, Sarath Kodagoda.** 2012, *ICARCV*
 17. *Multifunction Control of Prostheses Using the Myoelectric Signal.* **K. Englehart, B. Huggins, and P. Parker.** 2000, Boca Raton, FL: CRC Press.
 18. *A real-time EMG pattern recognition method for virtual myoelectric hand control.* **Kevin Xing, Peipei Yang, Jian Huang, Yongji Wang, Quanmin Zhu.** 2014, *Neurocomputing*, pp. 345-355.
 19. **Richard, Drake L.** *Anatomia para estudiantes.* s.l. : ELSEVIER, 2015.
 20. *Crystal structure of the calcium pump of sarcoplasmic reticulum at 2.6 Å resolution.* **Toyoshima C, Nakasako M, Nomura H, Ogawa H.** 2000, *Nature* 405, pp. 647-655.
 21. **Kutz, Myer.** *Standard Handbook of Biomedical Engineering & Design.* s.l. : McGrawHill, 2002.

-
22. **Jeffery R. Cram, Eleanor Criswell.** *Cram's Introduction to Surface Electromyography.* Mississauga Canada. : Jones & Bartlett Learning, 2011.
23. **Bronzino, Joseph D.** *The Biomedical Engineering Handbook : Medical Devices and Systems.* Boca Raton : Taylor and Francis Group, 2006.
24. *LA RANA DE GALVANI: ANUNCIO DE UNA NUEVA ERA**. **Gallone, P.** 1986, Electrochimica Acta, pp. 1485–1490.
25. *The discovery of bioelectricity and current electricity The Galvani-Volta controversy.* **Geddes, L. A., Hoff, H. E.** 1971, Spectrum IEE, pp. 38-46.
26. *Estimating the prevalence of limb loss in the united states:2005 to 2050.* **K. Ziegler-Graham, E. J. MacKenzie, P. L. Ephraim, T. G. Trivison, and R. Brookmeyer.** 2008, Arch. Phys. Med. Rehabil.,vol 89 no.3, pp. 422-429.
27. **Mizrahi, Joseph.** *Advances in Applied Electromyography.* s.l. : Intech, 2011.
28. **Alan V. Oppenheim, Ronald W. Schaffer, Jhon R.** *BuckDiscrete-Time Signal Processing.* Upper Saddle River, New Jersey : Prentice-Hall, Inc, 1999.
29. *Evaluation of the forearm emg signal.* **Boostani, R. and Moradi, M. H.** 2003, Physiological Measurement, pp. 309–319.
30. **Roberto Merletti, Philip Parker.** *Electromiography :Physiology, Engeenering, and Noninvasive Applications.* Hoboken, New Jersey. : JOHN WILEY & SONS,IEEE PRESS, 2004.
31. **Duda R. O., Hart P. E., Stork D. G.** *Pattern classification.* USA : John Wiley y Sons, 2001.
32. **Sánchez-Garfias, F.A., Díaz de León, J.L. Yáñez Márquez, C.** *Reconocimiento automático de patrones: Conceptos basicos.* Centro de investigación en computación, IPN, México. : IT 79, Serie Verde, 2003.
33. **Marqués de Sá, J.P.** *Patter Recognition, concepts, Methods and applications.* Germany : Springer, 2001.
34. **Ian H. Witten, Eibe Frank, Mark A.** *Data Mining Practical Machine Learning Tools and Techniques.* Burlington, MA 01803, USA : Elsevier Inc., 2011.
35. **Schuermann, J.** *Pattern Classification: A Unified View of Statistical and Neural Approaches.* s.l. : Wiley&Sons, 1996.

-
36. **Kulikowski, Sholom Weiss and Casimir.** *Computer Systems That Learn.* s.l. : Morgan Kaufmann., 1991.
37. *Nearest Pattern Classification.* **Cover, T.M., Hart, P.E.** 1967, IEEE Trans. on Information Theory, vol. IT-13, no. 1 , pp. 21-27.
38. **Díaz-de-León, J.L., Yáñez-Márquez, G., Sánchez-Garfias, F.A.** *Reconocimiento de patrones: Enfoque probabilístico-estadístico.* s.l. : IT 83, Serie Verde, Centro de Investigación en Computación, IPN, México , 2003.
39. *A logical calculus of the ideas immanent in nervous activity.* **McCulloch, W., Pitts, W.** 1943, Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133.
40. *The Perceptron: A probabilistic model for information storage and organization in the brain.* **Rosenblatt, F.** 1958, Psychological Review, vol. 65, pp. 386-408.
41. *Learning internal representation by Backpropagating errors.* **Rumelhart, D.E., Hinton, G. E., Williams, and R.J.** 1986, Nature, pp. 533–536.
42. *Support Vector Network.* **Cortes C., Vapnik V.** 1995, Machine Learning 20, pp. 273-297.
43. *Using Alpha-beta Associative Memories to Learn and Recall RGB Images.* **Yáñez Márquez C., Cruz Meza M.E., Sánchez Garfias F.A., López Yáñez I.,**2007,Advances in Neural Networks, vol.4493,p.828-833.
44. **Dimitris G. Manolakis, Vinay K. Ingle, Stephen M. Kogon.** *Statistical and Adaptive Signal Processing.* Norwood : ARTECH HOUSE INC., 2005.
45. **Won Y. Yang, Tae G. Chang, Ik H. Song, Yong S. Cho, Jun Heo, Won G. Jeon, Jeong W. Lee, Jae K. Kim.** *Signals and Systems with Matlab.* Berlin : Springer, 2009.
46. *Pattern recognition using generalized pertrait method.* **Vapnik, Lerner.** 1963, Automation and Remote Control, p. 24.
47. *A note on one class of Perceptrons.* **Vapnik, Chervonenkins.** 1964, Automation and Remote Control , p. 25.
48. *A training algorithm for optimal margin classifier.* **Boser, B.E., Guyon, I.M., Vapnik, V.N.** 1992, ACM Press , pp. 144-152.

-
49. *Support Vector Regression Machine*. **Drucker, H., Burgues, C., Kaufman, L., Smola, A., Vapnik, V.** 1997, *Advances in Neural Information Processing Systems 9*, MA, MIT PRESS, pp. 155-161.
50. **Hastie, T., Tibshirani, R., and J. Friedman.** *The Elements of Statistical Learning*. New York : Springer, 2008.
51. *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. **Christianini, N., J. Shawe-Taylor.** 2000, Cambridge University Press.
52. *A Tutorial on Support Vector Machines for Pattern Recognition*. **Burges, C. J. C.** 1998, *Knowledge Discovery and Data Mining*, p. 2.
53. *Towards an EMG Controlled Prosthetic Hand Using a 3D Electromagnetic Positioning System*. **Y Su, A Wolczowski, M H Fisher, G D Bell, D Burn, R Gao.** 2005, *Instrument and Measurement Technology Conference* , pp. 261-266.
54. *The WEKA Data Mining Software: An Update*. **Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, and Ian H. Witten.** 2009, *SIGKDD Explorations*.