

**Universidad Central “Marta Abreu” de Las Villas**

**Facultad de Ingeniería Eléctrica**

**Centro de Estudios de Electrónica y Tecnologías de la Información**



## **TRABAJO DE DIPLOMA**

**“Determinación de Fatiga Muscular en señales  
EMG de superficie para mejorar la clasificación de  
movimientos.”**

**Autor: Jesús Rolando Duarte Cubilla.**

**Tutor: MSc. Roberto Díaz Amador.**

**Santa Clara**

**2015**

**"Año 57 de la Revolución."**

**Universidad Central “Marta Abreu” de Las Villas**

**Facultad de Ingeniería Eléctrica**

**Centro de Estudios de Electrónica y Tecnologías de la Información**



## **TRABAJO DE DIPLOMA**

**“Determinación de Fatiga Muscular en señales  
EMG de superficie para mejorar la clasificación de  
movimientos.”**

**Autor: Jesús Duarte Cubilla.**

[jduarte@uclv.edu.cu](mailto:jduarte@uclv.edu.cu)

**Tutor: MSc. Roberto Díaz Amador.**

Asistente, CEETI, Ingeniería Eléctrica.

[ramador@uclv.edu.cu](mailto:ramador@uclv.edu.cu)

**Santa Clara**

**2015**

**“Año 57 de la Revolución.”**



Hago constar que el presente trabajo de diploma fue realizado en la Universidad Central “Marta Abreu” de Las Villas como parte de la culminación de estudios de la especialidad de Ingeniería en Biomédica, autorizando a que el mismo sea utilizado por la Institución, para los fines que estime conveniente, tanto de forma parcial como total y que además no podrá ser presentado en eventos, ni publicados sin autorización de la Universidad.

---

Firma del Autor

Los abajo firmantes certificamos que el presente trabajo ha sido realizado según acuerdo de la dirección de nuestro centro y el mismo cumple con los requisitos que debe tener un trabajo de esta envergadura referido a la temática señalada.

---

Firma del Tutor

---

Firma del Jefe de Departamento  
donde se defiende el trabajo

---

Firma del Responsable de  
Información Científico-Técnica

## PENSAMIENTO

*En la tierra hacen falta personas (...) que trabajen más y critiquen menos,  
que construyan más y destruyan menos, que prometan menos y resuelvan  
más, que esperen recibir menos y dar más, que digan mejor ahora que mañana.*

*Che*

## **DEDICATORIA**

A la memoria de mi padre: Andrés Francisco.

A la mejor madre del mundo: Noris.

A mi hermanito querido: Jose Daniel.

A mi familia y amigos.

## AGRADECIMIENTOS

Agradecer especialmente:

A mi madre por la confianza que ha depositado en mí y por estar siempre ahí cuando la he necesitado.

A mi padre que aunque no se encuentra físicamente siempre ha sido una fuente de inspiración para mí.

A mi tutor por su apoyo incondicional. Para ser sincero sin su ayuda hubiese sido imposible.

A mi hermano por preocuparse por mí en cada momento.

A todas aquellas personas que contribuyeron de una forma u otra con mi formación en todos estos años de estudio.

A todas aquellas personas que contribuyeron de una forma u otra con la realización de este trabajo.

A mi familia y amigos.

... .. Nada hubiese sido posible sin ustedes, llegue a todos mi eterna gratitud... ..

## **TAREA TÉCNICA**

- 1.Revisión bibliográfica sobre electromiografía y sobre fatiga muscular.
- 2.Estudio de las alternativas existentes en la cuantificación de fatiga muscular.
- 3.Implementación en Matlab de una alternativa elegida.
- 4.Evaluación de la efectividad de la alternativa elegida en la clasificación de movimientos.
- 5.Elaboración del informe final y presentación de los resultados.

---

Firma del Autor

---

Firma del Tutor

## RESUMEN

La electromiografía es una técnica para la evaluación y registro de la actividad eléctrica de los músculos en el proceso de contracción y debido a que el desarrollo tecnológico relacionado con el uso de señales de origen electrofisiológico ha estado en constante crecimiento por su gran utilidad, actualmente encuentra aplicaciones en numerosos campos, entre los que encontramos la ingeniería biomédica. Una de las principales aplicaciones de la señal electromiográfica en la actualidad lo constituye el desarrollo de prótesis inteligentes. Sin embargo existen factores que afectan el desempeño de algunas de estas aplicaciones a lo largo del tiempo, debido a factores que provocan variaciones en la señal electromiográfica, entre ellos la fatiga muscular. En este trabajo se desarrolla un estudio de las diversas alternativas de cuantificación de fatiga muscular en señales EMGs de superficie, y se desarrolla un clasificador binario de fatiga muscular basado en Máquinas de Vectores Soporte. Como evaluación de clasificador binario propuesto se desarrolla un clasificador de movimientos de la mano, en el cual se introduce como paso previo la clasificación de la fatiga muscular para luego realizar la clasificación del tipo de movimiento. Los resultados obtenidos demuestran que tener un clasificador de fatiga muscular previo a la clasificación del tipo de movimiento mejora el desempeño de la clasificación.

## TABLA DE CONTENIDOS

PENSAMIENTO .....	i
DEDICATORIA.....	ii
AGRADECIMIENTOS .....	iii
TAREA TÉCNICA .....	iv
RESUMEN .....	v
TABLA DE CONTENIDOS .....	vi
INTRODUCCIÓN.....	1
CAPÍTULO 1. REVISIÓN BIBLIOGRÁFICA.....	4
1.1 Electromiografía (EMG).....	4
1.1.1 Electroodos.....	5
1.1.1.1 Electroodos superficiales.....	6
1.1.2 Electromiografía superficial (SEMG).....	7
1.2 Fatiga muscular.....	7
1.2.1 Causas.....	8
1.2.2 Manifestaciones.....	8
1.3 Extracción de rasgos o características.....	9
1.3.1 Valor medio absoluto.....	9
1.3.2 Cruces por cero.....	10
1.3.3 Cambio de signo de la pendiente.....	10
1.3.4 Longitud de la forma de onda.....	10

1.4	Métodos de obtención de la fatiga muscular .....	10
1.4.1	Redes neuronales artificiales (RNA).....	11
1.4.2	Sistema difusos.....	11
1.4.3	Análisis discriminante lineal (ADL).....	12
1.4.4	Máquinas de vectores soporte (MVS).....	13
1.5	Conclusiones del capítulo.....	14
CAPÍTULO 2. MATERIALES Y MÉTODOS .....		15
2.1	Adquisición de la señal.....	15
2.2	Descripción de la base de datos.....	17
2.3	Diseño del experimento.....	18
2.4	Extracción de los rasgos a emplear.....	18
2.4.1	Valor medio absoluto .....	19
2.4.2	Cruces por cero.....	19
2.4.3	Cambios de signo de la pendiente .....	19
2.4.4	Longitud de la forma de onda .....	20
2.5	Esquema de clasificación propuesto.....	20
2.5.1	Clasificador basado en máquinas de vectores soporte (MVS) .....	21
2.5.2	Clasificador basado en análisis discriminante lineal (ADL) .....	21
2.6	Método de evaluación.....	22
2.6.1	Tasa de clasificación correcta (TCC).....	22
2.6.2	Tasa de error activa (TEA) .....	22
2.7	Conclusiones del capítulo. Estrategia propuesta.....	23
CAPÍTULO 3. RESULTADOS Y DISCUSIÓN .....		24
3.1	Análisis de la señal EMG con y sin fatiga.....	24

3.2	Tasa de clasificación correcta (TCC) .....	26
3.3	Tasa de error activa (TEA) .....	27
3.4	Conclusiones del capítulo .....	27
CONCLUSIONES Y RECOMENDACIONES.....		29
Conclusiones .....		29
Recomendaciones .....		30
REFERENCIAS BIBLIOGRÁFICAS .....		31
ANEXOS .....		35
1.1.	Anexo I “Programación en Matlab para la extracción de los rasgos: valor medio absoluto (mav), cruces por cero (zero_count), longitud de onda (len) y cambio de signo de la pendiente (turns).” .....	35

## INTRODUCCIÓN

La señal electromiográfica (EMG) de superficie encuentra un uso cada vez mayor en varias aplicaciones biomédicas, que van desde el control de dispositivos para juegos, determinación de niveles de actividad muscular en medicina deportiva, hasta el control de prótesis inteligentes de miembro superior para personas con amputaciones. En el caso del control de prótesis de miembro superior, existen varios factores que pueden afectar el desempeño de estos dispositivos, entre estos factores se encuentran: el cambio de impedancia en la piel debido al sudor, el corrimiento de los electrodos producto del corrimiento del *socket* y la aparición de fatiga en los músculos, debido a un esfuerzo excesivo para controlar el dispositivo. A este último aspecto se dedica este trabajo.

En la bibliografía especializada sobre el tema de prótesis de miembro superior, varios autores señalan a la fatiga muscular como una de las causas fundamentales de la aparición de errores en la clasificación de la intención de movimiento. Investigaciones llevadas a cabo muestran que efectivamente la presencia de fatiga muscular afecta el desempeño de las llamadas prótesis inteligentes. Es por ello que en este trabajo se parte como **hipótesis** de que conocer *a priori* el nivel de fatiga muscular puede ayudar a mejorar el desempeño de los sistemas de clasificación de la intención de movimiento en prótesis de miembro superior.

Desde los años 70 se han realizado investigaciones sobre la influencia de la fatiga muscular a partir de un análisis espectral de las señales antes y luego de ser afectadas. Todos estos trabajos muestran que a partir de un análisis espectral de la señal antes y posterior de influir la fatiga, se evidencia un corrimiento del espectro hacia las bajas frecuencias y una compresión del mismo.

Por supuesto que en la literatura especializada existe una gran cantidad de métodos que permiten la medición o clasificación de la fatiga muscular, por ello en este trabajo se tiene el siguiente **problema científico**:

1. ¿Se puede mejorar el desempeño de los sistemas de clasificación de la intención de movimiento en prótesis de miembro superior, a partir del conocimiento del nivel de fatiga muscular que los pueda estar afectando?
2. ¿Cuál o cuáles de las alternativas existentes para conocer la existencia o no de fatiga muscular puede ser útil a estos efectos teniendo en cuenta los requerimientos generales de estos tipos de sistemas?

Por la importancia y complejidad de estos aspectos el **Objetivo General** de este trabajo es obtener una alternativa que permita mejorar el desempeño de los sistemas de clasificación de la intención de movimiento en prótesis de miembro superior, cuando la señal electromiográfica se afecta por fatiga muscular.

Para dar cumplimiento a este objetivo se plantean los siguientes **Objetivos Específicos**:

1. Estudiar críticamente las diferentes alternativas existentes para cuantificar la fatiga muscular y cómo pueden utilizarse para mejorar el desempeño de los clasificadores de intención de movimiento.
2. Implementar en Matlab una de las alternativas estudiadas y ensamblarla a la solución actual de clasificación de la intención de movimiento.
3. Evaluar cómo mejora o no el uso de esta alternativa el desempeño en la clasificación de la intención de movimiento.

Los resultados que se alcanzan con este trabajo deben tener un **impacto** directo en las investigaciones que se llevan a cabo actualmente para mejorar el desempeño en la clasificación de la intención de movimiento y ser un paso hacia futuras soluciones o implementaciones.

### **Organización del informe**

El presente informe se encuentra dividido en Introducción, tres capítulos, Conclusiones, Recomendaciones, Referencias Bibliográficas y Anexos.

---

En el Capítulo 1 se discuten los principales aspectos teóricos y se comparan las diferentes alternativas utilizadas en la clasificación del nivel de fatiga muscular. En el Capítulo 2 se exponen los materiales y métodos empleados, se describe la base de datos utilizada, el diseño del experimento y se aborda la solución propuesta en este trabajo. El Capítulo 3 se dedica a presentar los resultados obtenidos en la investigación, discutir estos resultados y explicar las principales limitaciones. Finalmente se presentan las Conclusiones, Recomendaciones y las Referencias Bibliográficas.

## **CAPÍTULO 1. REVISIÓN BIBLIOGRÁFICA.**

*En este capítulo se hace referencia a algunos de los conceptos y generalidades sobre las señales electromiográficas, se analiza el fenómeno de la fatiga muscular, que constituye uno de los factores que la afectan a lo largo del tiempo y se abordan los algoritmos de estimación de fatiga muscular reportados en la literatura.*

### **1.1 Electromiografía.**

La electromiografía es un registro de la actividad eléctrica de los músculos, y por tanto constituye una extensión de la exploración física, además prueba la integridad del sistema motor [1,2]. De ahí que podamos afirmar que la señal electromiográfica es una señal electrofisiológica que mide las corrientes eléctricas generadas en los músculos durante su contracción [3].

Debido a que la señal presenta valores de amplitud muy pequeños, es susceptible solo de ser medida con un instrumento médico llamado electromiógrafo. La función de un electromiógrafo es detectar la diferencia de potencial eléctrico que activa las células musculares, cuando estas son activadas neuralmente o eléctricamente, de esa forma las señales pueden ser analizadas para detectar anomalías, el nivel de activación o analizar la biomecánica del movimiento [4].

Su detección se realiza por medio de electrodos intramusculares o superficiales [5]. La electromiografía de aguja se usa con el fin de estudiar la fisiología y patología de las unidades motrices, tales como la denervación, la reinervación y las miopatías, entre otras.

La electromiografía de superficie (SEMG, por sus siglas en inglés) es más adecuada para estudios en donde se pretende observar el comportamiento muscular global, los patrones de actividad temporal y la fatiga de un músculo o de un grupo muscular [6].

La amplitud de la señal de SEMG varía de 0 a 10 mV (pico a pico), dependiendo del músculo en el cual se realiza el estudio o de las condiciones del registro. La región útil de la señal, es decir, aquella cuya energía es mayor que el nivel de ruido eléctrico, se encuentra entre 0 y 500 Hz, con una región de energía dominante en el rango 50-150 Hz [7].

A continuación se muestra el espectro de frecuencias de varias señales electromiográficas (Fig.1.11).

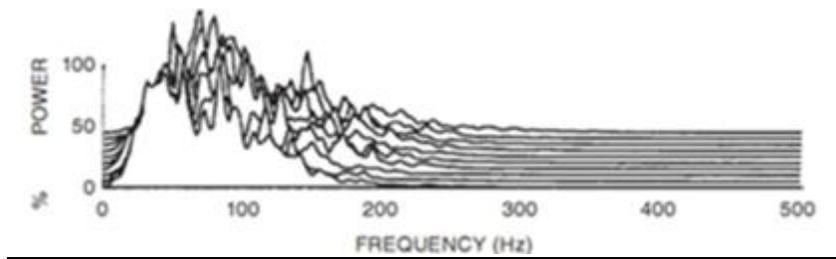


Fig. 1.1.1 Gráfica del espectro de frecuencia de varias señales electromiográficas.

### 1.1.1 Electrodo.

La forma de obtener información acerca de nuestro entorno y transferirla a algún dispositivo electrónico se realiza mediante un transductor, un transductor es capaz de transformar un tipo de energía de entrada a otro tipo de energía de salida. En el campo de la Ingeniería Biomédica los transductores utilizados son llamados electrodos; los electrodos hacen una transferencia iónica del tejido del cuerpo hacia un dispositivo electrónico, el cual se encarga de procesarla para posteriormente obtener información útil de la medición [8]. Para los registros de estas señales se suelen utilizar principalmente dos tipos de electrodos, los electrodos de superficie y los electrodos invasivos; los electrodos de superficie son colocados en la superficie de la piel y son capaces de tomar registros poblacionales de la actividad bioeléctrica [9]; mientras que los electrodos invasivos son

insertados en el tejido para tomar directamente la diferencia de potencial existente entre la membrana celular y la piel [9].

### 1.1.1.1 Electrodo superficial.

Los electrodos superficiales son colocados sobre la piel, estos electrodos son principalmente superficies de metal, sin embargo, debido al estar en contacto directo con la piel hay que tomar ciertas consideraciones[10]: la piel es un tejido conductor cuyo material intracelular y extracelular está compuesto de soluciones electrolíticas, en la cual la corriente es transportada por iones; mientras que el metal es un material altamente conductor, en el cual la corriente es transportada por electrones, en consecuencia, la interfaz electrodo piel es en sí muy ruidosa[10].

Existen varios tipos de electrodos de superficie, estos se dividen principalmente en dos grandes grupos: electrodos secos y electrodos húmedos [11]. Los electrodos húmedos son aquellos en los que entre la placa de metal y la piel se encuentra una sustancia electrolítica o gel conductor [9], esto se hace con el fin de minimizar el ruido intrínseco que se genera entre el contacto de la piel y el metal, este gel conductor mejora la conductividad y el flujo de la corriente.

Los materiales de los que se constituyen la mayoría de los electrodos de superficie son muy variables, entre ellos están la plata, el oro, acero inoxidable, platino entre otros.

En la Fig.2 se muestran ejemplos de electrodos superficiales:

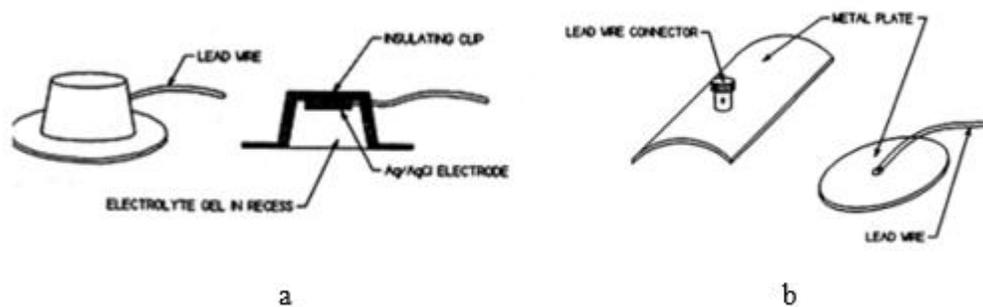


Fig. 1.1.2 Electrodo superficial: a) electrodo hueco, b) electrodo de placa de metal.

### **1.1.2 Electromiografía superficial.**

La electromiografía de superficie o SEMG [10] es una técnica que se basa en el uso de electrodos superficiales; estos electrodos son colocados directamente sobre la piel del músculo del cual se quiere obtener información. La SEMG tiene la peculiaridad de que los registros obtenidos mediante ella muestran actividad poblacional de las unidades motoras, esto es debido a que los electrodos, al estar en la superficie del músculo, no son capaces de captar la señal de una sola unidad motora, sino que por el contrario, captan la información de varias unidades motoras [9]. Es por esta razón que esta técnica no es muy utilizada para diagnósticos médicos muy precisos. Por otro lado el uso de los electrodos superficiales es mucho más adecuado para el estudio del comportamiento promedio de la actividad eléctrica de un músculo o grupo de músculos, lo cual es muy utilizado para detectar fatiga muscular y para monitoreo del rendimiento de deportistas; la SEMG es la técnica que se utiliza principalmente para el desarrollo de prótesis mioeléctricas, donde el uso de los electrodos de aguja no sería muy cómodo para el paciente.

### **1.2 Fatiga muscular.**

El término de fatiga muscular se puede definir como el conjunto de modificaciones fisiológicas, diferentes según el grado de esfuerzo y de entrenamiento del individuo, que conllevan a la disminución reversible de la capacidad del músculo para producir tensión o acortamiento (contracción muscular). La fatiga se manifiesta como una reducción en la capacidad de mantener un determinado nivel de fuerza en una contracción sostenida o como la incapacidad de alcanzar un nivel de fuerza inicial en contracciones intermitentes, y está acompañada por cambios en la actividad eléctrica muscular [12].

La fatiga muscular no se considera una causa de preocupación, a menos que la condición no se normalice después de un descanso suficiente.

La fatiga muscular tiene componentes centrales y periféricos. Los primeros se manifiestan como una incapacidad para realizar una actividad inducida por el desarrollo de esta. Los segundos se manifiestan como una incapacidad del músculo para producir un determinado nivel de fuerza [13].

### 1.2.1 Causas.

Las causas más comunes que provocan la aparición del fenómeno de fatiga muscular están relacionadas con cambios o modificaciones fisiológicas que ocurren en nuestro organismo cuando sobrepasamos el grado de esfuerzo que podemos soportar según el entrenamiento que presente nuestro cuerpo. Entre las modificaciones más comunes podemos encontrar [14] el aumento de la concentración de  $PO_4^{3-}$ , derivado de la desintegración de fosfocreatina, en el citoplasma. Se cree que esto reduce la fuerza creada por puentes, y contribuidor importante en la fatiga muscular. Otra de las causas es la declinación de ATP, en la unión de túbulos transversos y retículo sarcoplasmático, lo cual obstaculiza la acción de las bombas de  $Ca^{2+}$ . El ATP declina rápidamente en fibras de contracción rápida durante el ejercicio sin producir rigor; en cambio declina de manera medible en fibras de contracción lenta. También podemos mencionar entre las causas el agotamiento de glucógeno muscular. Este mecanismo no se comprende por completo, pero parece disminuir la liberación de  $Ca^{2+}$  desde el retículo sarcoplasmático. La disminución de la entrada de  $O_2$  al cuerpo, aumenta el ADP en el citoplasma, lo que causa disminución de la velocidad de acortamiento muscular, otros de los aspectos que ocurre durante la fatiga muscular.

### 1.2.2 Manifestaciones.

La fatiga puede evaluarse por medio de la señal de SEMG, siendo las variables más usadas su amplitud pico a pico y la media del valor rectificado, la media y la mediana de su espectro de frecuencias y la velocidad de conducción de las fibras musculares [15]. Inicialmente, la amplitud de la señal de SEMG aumenta, debido a que, como mecanismo de compensación de fatiga, los músculos intentan mantener la misma fuerza reclutando unidades motoras adicionales; pero cuando esto no es posible, la fuerza comienza a disminuir evidenciándose una reducción en la amplitud de la señal. Durante contracciones fatigantes, se presenta una reducción en la velocidad de conducción y, por lo tanto, de las frecuencias características de la señal; siendo la acumulación de ácido láctico una de sus causas [16]. Esta reducción en la velocidad de conducción resulta en una

compresión y un corrimiento del espectro de frecuencias hacia las bajas [17]. Así mismo, la frecuencia de activación de las unidades motoras, representada en la zona de bajas frecuencias del espectro del EMG, cambia como consecuencia del estado de fatiga .

### **1.3 Extracción de rasgos o características.**

Es el proceso de generar características que puedan ser usadas en el proceso de clasificación de los datos. En ocasiones viene precedido por un pre-procesado de la señal, necesario para corregir posibles deficiencias en los datos debido a errores del sensor, o bien para preparar los datos de cara a posteriores procesos en las etapas de extracción de características o clasificación.

Las características elementales están explícitamente presentes en los datos adquiridos y pueden ser pasados directamente a la etapa de clasificación. Las características de alto orden son derivadas de las elementales y son generadas por manipulaciones o transformaciones en los datos [18].

Se pueden considerar generalmente dos métodos para la extracción de características: aproximación paramétrica y no paramétrica. Dentro de la aproximación paramétrica se tienen modelos tales como AR (autorregresive model), MA (moving average) y ARMA. En la aproximación no paramétrica se consideran dos métodos: aproximación temporal y aproximación espectral, aunque también pueden ser considerados métodos de aproximación tiempo-frecuencia [19].

Precisamente algunas características referidas a la aproximación temporal tales como el valor medio absoluto, cruces por cero, cambio de signo de la pendiente y longitud de forma de onda, son empleadas en nuestra investigación.

#### **1.3.1 Valor medio absoluto.**

Constituye el valor medio tomado sobre un período de una magnitud alterna determinada. Es un valor estimado a partir de un promedio de valores de la señal en un número determinado de muestras en un segmento de esta.

### **1.3.2 Cruces por cero.**

Es una forma simple de medir la frecuencia de la señal, puede determinarse contando el número de veces que la forma de onda cruza por cero. Se requiere un umbral para reducir el número de cruces por cero inducidos por ruido, y se selecciona con respecto al voltaje de la señal [20].

Los cruces por cero indican el número de veces que una señal continua toma el valor de cero. Para las señales discretas, un cruce por cero ocurre cuando dos muestras consecutivas difieren de signo, o bien una muestra toma el valor de cero [21].

### **1.3.3 Cambio de signo de la pendiente.**

La pendiente, basándonos en términos matemáticos, constituye la inclinación de una recta de acuerdo a la horizontal en un eje cartesiano.

Provee otra forma de medir el contenido de frecuencia en la señal mediante el conteo del número de veces que la pendiente de la forma de onda cambia de signo. Igualmente requiere de un umbral para reducir los cambios de signo de pendiente inducidos por el ruido. [20]

En nuestro trabajo hacemos referencia a esta característica como el número de veces en que la señal EMG cambia su estado desde una pendiente creciente a una decreciente, o viceversa.

### **1.3.4 Longitud de la forma de onda.**

Es la distancia que hay entre el mismo punto de dos ondulaciones consecutivas, o la distancia entre dos crestas consecutivas [22].

Constituye otra característica importante que provee información acerca de la complejidad de la señal. El valor resultante da una medida de la amplitud de la forma de onda, su frecuencia y duración en un solo parámetro [20].

## **1.4 Métodos de obtención de la fatiga muscular.**

Los métodos de obtención de fatiga muscular que se abordarán en el trabajo son:

Redes neuronales artificiales (RNA).

Sistemas difusos.

Análisis discriminante lineal (ADL).

Máquinas de vectores soporte (MVS).

#### **1.4.1 Redes neuronales artificiales (RNA).**

Una Red Neuronal Artificial (RNA), también llamada red neural (RN) es un modelo de procesamiento de información inspirado en la forma biológica de redes neuronales que procesan la información [23]. Estas conexiones establecen una estructura jerárquica que tratando de emular la fisiología del cerebro busca nuevos modelos de procesamiento para solucionar problemas concretos del mundo real. Lo importante en el desarrollo de la técnica de las RNA es su útil comportamiento al aprender, reconocer y aplicar relaciones entre objetos y tramas de objetos propios del mundo real [24].

Las RNAs son sistemas adaptables en los que la estructura es variable dependiendo de la información interna y externa que fluye a través de la red en la fase de aprendizaje, y son capaces de modelar relaciones complejas. Las RNAs se utilizan en la clasificación, en particular para el reconocimiento de patrones, pero también en el procesamiento de datos (por ejemplo, el filtrado, la agrupación, la separación ciega de fuentes y compresión), así como para la robótica, y el análisis de regresión. Una de las ventajas de las RNA es su capacidad de encontrar un sentido a los datos complicados [24].

En reconocimiento de patrones, donde las tendencias son complejos y no pueden ser derivados por los seres humanos o modelos informáticos lineales, actúan como un experto en analizar el problema.

Existen cuatro aspectos que caracterizan una RNA: su topología, el mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y salida, y la forma de representación de estas informaciones, [25] [26].

#### **1.4.2 Sistema difusos.**

La lógica difusa, constituye una forma de lógica que es tolerante a los datos contradictorios, se utiliza en biomédica en el procesamiento de la señal y la clasificación, para superar problemas donde las señales son estocásticas y por lo tanto pueden ser contradictorias en la

naturaleza [27]. Los sistemas difusos pueden ser entrenados para identificar patrones que no son identificables por otros métodos.

Los sistemas difusos determinan operadores difusos, que pueden ser desconocidos, en conjuntos difusos, que requieren el uso de reglas "si-entonces" y se utilizan para modelar o clasificar problemas con variables y reglas que pueden ser analizadas por un usuario humano. Un clasificador difuso es un algoritmo donde se argumenta que el clasificador puede predecir la etiqueta de clase.

Kucheva argumentó que cualquier clasificador que utiliza la lógica difusa en su conjunto de entrenamiento puede ser considerado como un clasificador difuso [28].

Los sistemas difusos tiene un vector que contiene los valores de las características para una tarea específica, y el sistema ejecuta un algoritmo de entrenamiento a un conjunto de datos de entrenamiento. Una vez que el sistema está capacitado que puede aplicarse a objetos invisibles, hay varios modelos de clasificadores difusos, y el método más simple es un enfoque basado en normas que funciona como un sistema de reglas 'SI-ENTONCES ', donde la clase etiqueta es la parte consecuente de la regla. Si la parte consecuente de la regla contiene lingüística, valora la salida, la cual será una etiqueta suave con los valores de la función discriminante.

### **1.4.3 Análisis discriminante lineal (ADL).**

Análisis discriminante lineal (ADL) es una técnica aplicada en las estadísticas para el reconocimiento de patrones y aprendizaje automático, que encuentra una combinación lineal de características para la caracterización o la separación de dos o más clases. El resultado puede ser utilizado como un clasificador lineal o para la reducción de dimensionalidad en la clasificación posterior.

Este modelo está estrechamente relacionado con otras técnicas, por ejemplo, el análisis de regresión, el análisis de la varianza y el análisis de componentes principales, sin embargo, en ADL la varianza es categórica. ADL puede ejecutar fácilmente casos con frecuencias desiguales dentro de las clases, cuyo desempeño se examina en datos de pruebas producidas al azar [29].

En este método la relación entre la clase varianza a la varianza de clase dentro se maximiza en cualquier conjunto de datos, que asegura la separabilidad óptima. Hay dos enfoques diferentes para la transformación de conjuntos de datos y la clasificación de vectores de

prueba en el espacio transformado: la clase dependiente de transformación y de clase independiente de transformación [29, 30].

La clase dependiente transformación implica la maximización de la relación entre la clase varianza de clase dentro de varianza. El objetivo principal es la separabilidad de clase alta, que se obtiene mediante la maximización de esta proporción. Los conjuntos de datos se transforman de forma independiente por el uso de dos criterios de optimización.

La transformación de clase independiente maximiza la proporción de la varianza total dentro de la clase varianza. En este método, sólo un criterio de optimización se utiliza para transformar los conjuntos de datos, lo que significa que los puntos de datos se transforman independientemente de su identidad de clase. En este enfoque, cada clase se considera como una clase separada contra todas las demás clases. ADL es a menudo utilizado para la caracterización de dos clases. Aquí el conjunto de muestra se considera a ser un entrenamiento para establecer como encontrar un buen predictor de la segunda clase. La siguiente transformación lineal describe la clasificación:

$$y = w^t x + w_0, \quad 1.3.1$$

Donde  $w$  y  $w_0$  se determinan mediante la maximización de la relación entre la clase varianza para dentro de la clase varianza garantizar separabilidad máxima.

El LDA utiliza dos clases que son clasificadas a la vez:

$$X \in \begin{cases} \text{Class 1,} & \text{if } y > 0, \\ \text{Class 2,} & \text{if } y < 0. \end{cases} \quad 1.3.2$$

#### 1.4.4 Máquinas de vectores soporte (MVS).

Una Máquina de Vectores Soporte (MVS) es esencialmente un método de aprendizaje supervisado que puede ser utilizado en la clasificación y regresión. Al someterse a la formación, la MVS utiliza un algoritmo para desarrollar un modelo que prediga a qué categoría en el conjunto de entrenamiento pertenece. Las SVMs son una técnica útil de clasificación de datos [31,32].

A continuación se muestra una tabla con desempeños en trabajos anteriores de los algoritmos máquinas de vectores soporte y análisis discriminante lineal [33]:

<b>Clasificador</b>	<b>Desempeños (%)</b>
LDA	86,1; 93,5; 98; 97; 84,62; 89
Máquinas de Vectores Soporte	93,5; 79,4; 87,5

Tabla 1.4.1 Desempeños de los clasificadores máquinas de vectores soporte y análisis discriminante lineal.

### **1.5 Conclusiones del capítulo**

En este capítulo se presentaron los conceptos de electromiografía y fatiga muscular. Se realizó una descripción de las diferentes alternativas descritas en la literatura para la obtención de la fatiga muscular. De las alternativas descritas, teniendo en cuenta su facilidad de implementación, los resultados que muestran y el relativamente bajo costo computacional, características estas deseables a la hora de realizar los experimentos, las alternativas que se implementarán en este trabajo son la basada en máquinas de vectores soporte y análisis discriminante lineal.

## CAPÍTULO 2. MATERIALES Y MÉTODOS

*En este capítulo se explica el proceso de adquisición de la señal EMG y la conformación de la base de datos. Se explica el diseño del experimento. Se hace una breve descripción de los rasgos y clasificadores utilizados. Al final se expone la estrategia de clasificación propuesta.*

### 2.1 Adquisición de la señal.

La señal utilizada fue adquirida en el Instituto de Ingeniería Biomédica de la Universidad de New Brunswick. Se utiliza la señal electromiográfica del sistema fisiológico brazo-antebrazo. Para esto se utilizó un modelo típico de instrumentación constituido por sensores, encargados de la captación de la señal, amplificadores y filtros, en la etapa de acondicionamiento, convertor análogo digital con tarjeta de adquisición de datos y procesamiento, ver Figura 2.1.1, [15]. Luego de digitalizadas dichas señales, se conformó la base de datos.

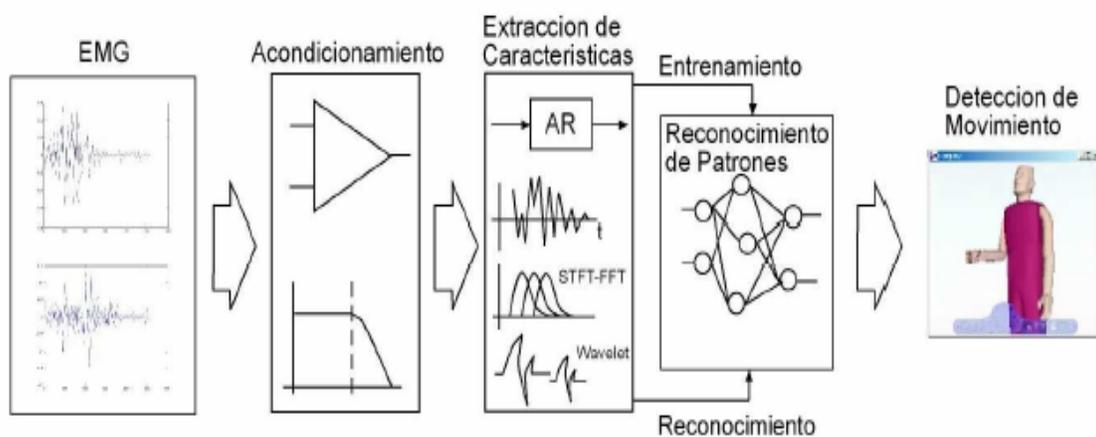


Fig. 2.1.1 Esquema general del proyecto.

Los filtros empleados en esta etapa son un Filtro Paso Alto de Butterworth de orden 3 y frecuencia de corte de 20 Hz y un Filtro Notch con un factor de calidad (Q) igual a 1, con aproximación de Butterworth de divididos en 3 secciones cada una de orden 2, para eliminar el ruido en los tres primeros armónicos impares de la línea de alimentación que es donde se concentra la mayor parte de la energía en las señales electromiográficas, sus respectivas funciones de transferencias y respuestas de magnitud se muestran a continuación:

Filtro Paso Alto de Butterworth:

$$H(z) = \frac{0,9391 - 2,8173 z^{-1} + 2,8173 z^{-2} - 0,9391 z^{-3}}{1 - 2,8744 z^{-1} + 2,7565 z^{-2} - 0,8819 z^{-3}} \quad 2.1.1$$

Filtro Notch con aproximación de Butterworth de divididos en 3 secciones:

$$H(z)_1 = \frac{0,9845 - 1,9344 z^{-1} + 0,9845 z^{-2}}{1 - 1,9344 z^{-1} + 0,9691 z^{-2}} \quad 2.1.2$$

$$H(z)_2 = \frac{0,9845 - 1,6627 z^{-1} + 0,9845 z^{-2}}{1 - 1,6627 z^{-1} + 0,9691 z^{-2}} \quad 2.1.3$$

$$H(z)_3 = \frac{0,9845 - 1,1575 z^{-1} + 0,9845 z^{-2}}{1 - 1,1575 z^{-1} + 0,9691 z^{-2}} \quad 2.1.4$$

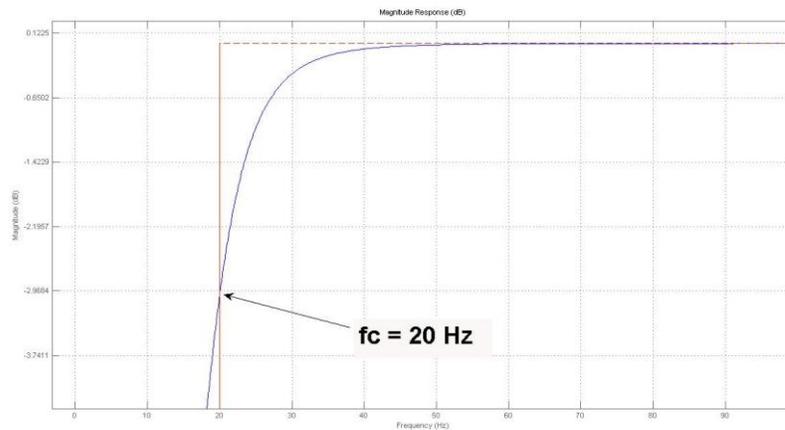


Fig.2.1.2. Respuesta de frecuencia en magnitud del Filtro Paso Alto de Butterworth.

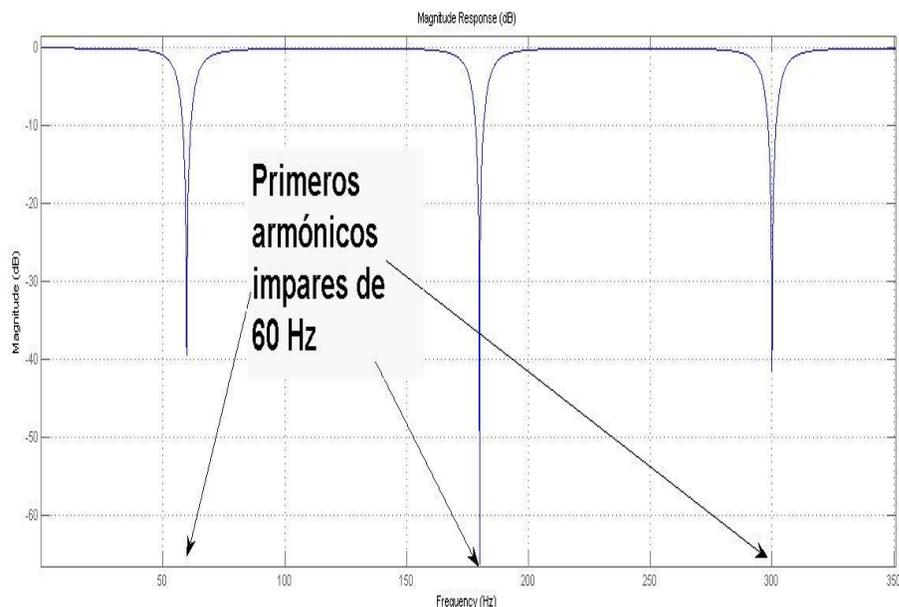


Fig.2.1.3. Respuesta de frecuencia en magnitud del Filtro Notch.

## 2.2 Descripción de la base de datos.

La Base de Datos fue conformada a partir de la adquisición de los mismos, en señales electromiográficas afectadas por la fatiga muscular, en 5 sujetos sanos de ambos sexos, con edades comprendidas entre los 24 y 36 años. Las señales fueron captadas con el empleo de 6 electrodos superficiales de Ag/AgCl, los cuales son revestidos con un gel que facilita el contacto entre el propio electrodo y la superficie de la piel, permitiendo que la corriente emitida por el músculo pase libremente a través de la juntura entre el gel electrolito y el electrodo. Estos fueron colocados equidistantemente alrededor del antebrazo, separados 5 cm del codo, para captar 6 canales de señales electromiográficas.

Se empleó el sistema comercial de adquisición Delsys para captar las señales electromiográficas, con una instrumentación semejante a la mostrada en la Figura 2.1.1. La frecuencia de muestreo empleada en cada señal es de 2 kHz con una resolución de 16 bits/muestra. En este experimento se graban 30 segundos de señal de cada una de las clases de movimientos en las que se basó el experimento: No movimiento, Flexión, Extensión, Supinación y Pronación de la muñeca, Puño cerrado y Agarre de pinzas, teniendo a su vez 6 repeticiones por clase.

### **2.3 Diseño del experimento.**

En el experimento cada uno de los sujetos realiza varias repeticiones de cada uno de los movimientos a evaluar, durante un tiempo que va incrementándose.

Primeramente se limpió con alcohol isopropílico la superficie de la piel para aumentar la calidad de la interfaz piel-electrodo. El experimento se realiza a una temperatura de 22°C, para evitar la sudoración y con ella el cambio de impedancia de la piel, y se emplea una banda elástica para ubicar los electrodos y evitar su corrimiento.

Así, se realizan 8 repeticiones de 3 segundos de duración de cada una de las contracciones, seguidamente se realizan 4 repeticiones de 10 segundos de duración para cada contracción y por último 4 repeticiones de 30 segundos cada una. En todos los casos el tiempo entre estas es de 2 segundos.

Este proceder debe ir incrementando los niveles de fatiga muscular progresivamente como usualmente ocurre en usuarios amputados en la realización de actividades de la vida cotidiana.

El experimento consiste en entrenar un clasificador a partir de datos del EMG del antebrazo del paciente sin fatiga y obtener los resultados de la clasificación independientemente de si tiene fatiga o no. En un segundo paso, se obtiene una clasificación del nivel de fatiga, de modo que se entrena un clasificador para un nivel bajo de fatiga y otro para un nivel alto de fatiga, y se obtienen los resultados de la clasificación de acuerdo al nivel de fatiga. De esta manera se pretende obtener un clasificador de fatiga muscular que permita el uso de una estrategia de clasificación basada en un clasificador seleccionable.

### **2.4 Extracción de los rasgos a emplear**

El proceso de extracción de los rasgos se enmarca en cuatro de estos específicamente: valor medio absoluto, cruces por cero, cambios de signo de la pendiente de la señal y la longitud de la forma de onda de esta, los cuales a partir de sus respectivas ecuaciones matemáticas, definidas en este capítulo, fueron implementados con el software Matlab en su versión 7.0.10. Los rasgos valor medio absoluto, cruces por cero y cambio de signo de la pendiente se utilizan para la clasificación en fatiga o no fatiga, mientras que los cuatro son

utilizados para la clasificación del tipo de movimiento.

### 2.4.1 Valor medio absoluto

Un estimado del valor medio absoluto de la señal  $x$  en el segmento  $i$  de  $N$  muestras está dado por la ecuación 2.3.1:

$$VMA = \frac{1}{N} \sum_{i=1}^N |X_i| \quad 2.4.1$$

, donde  $X_i$  son las muestras y  $N$  el número de muestras.

### 2.4.2 Cruces por cero

La cantidad de cruces por cero da una idea de la frecuencia de una señal. En este trabajo se calcula el número de cruces por cero según 2.3.2:

$$CPC = \sum_{i=1}^N \text{sgn}(-X_i * X_{i+1}); \text{sgn} = \begin{cases} 1, \wedge x > th \\ 0, \wedge \text{otros} \end{cases} \quad 2.4.2$$

, donde  $X_i$  son las muestras,  $N$  es la longitud de la señal y  $th$  un umbral que se define para evitar contar cruces por cero que surjan como consecuencia del ruido. En este caso el umbral ha sido el 5% del valor de la amplitud promedio de la señal.

### 2.4.3 Cambios de signo de la pendiente

Otra característica que puede dar idea sobre el contenido de frecuencia de una señal puede ser el número de veces que cambia de signo la pendiente de esta, es decir cuántas veces pasa de un estado creciente a decreciente, o viceversa. Es recomendable seleccionar un umbral  $th$  para reducir los cambios de signo de la pendiente inducidos por el ruido. El cambio de signo de la pendiente se calcula según 2.4.3:

$$CP = \sum_{i=1}^N \text{sgn}(X_{i+1} - X_i) * (X_{i+2} - X_{i+1}); \text{sgn} = \begin{cases} 1, \wedge x > th \\ 0, \wedge x < th \end{cases} \quad 2.4.3$$

, donde  $X_i$  son las muestras,  $N$  es la longitud de la señal y  $th$  umbral, igual al 5% del valor de la amplitud promedio de la señal.

#### 2.4.4 Longitud de la forma de onda

Una característica que se tiene en cuenta en este trabajo es la es la longitud de la forma de la onda calculada de acuerdo con la ecuación 2.4.4:

$$LO = \sum_{i=1}^N |\Delta X_i|; \Delta X_i = X_i - X_{i-1} \quad 2.4.4$$

, donde  $X_i$  : muestras y  $N$  es la longitud de la onda.

#### 2.5 Esquema de clasificación propuesto.

En este trabajo se utilizan tres clasificadores diferentes, uno basado en Máquinas de Vectores soporte, y dos basados en Análisis Discriminante Lineal. El primer clasificador se utiliza como clasificador binario para clasificar en Fatiga o No Fatiga. De acuerdo a la salida del Clasificador MVS se utilizará uno u otro de los clasificadores ADL. Los clasificadores ADL se utilizan propiamente para obtener el tipo de movimiento. La figura 2.5.1 muestra un esquema que ilustra mejor este proceso:

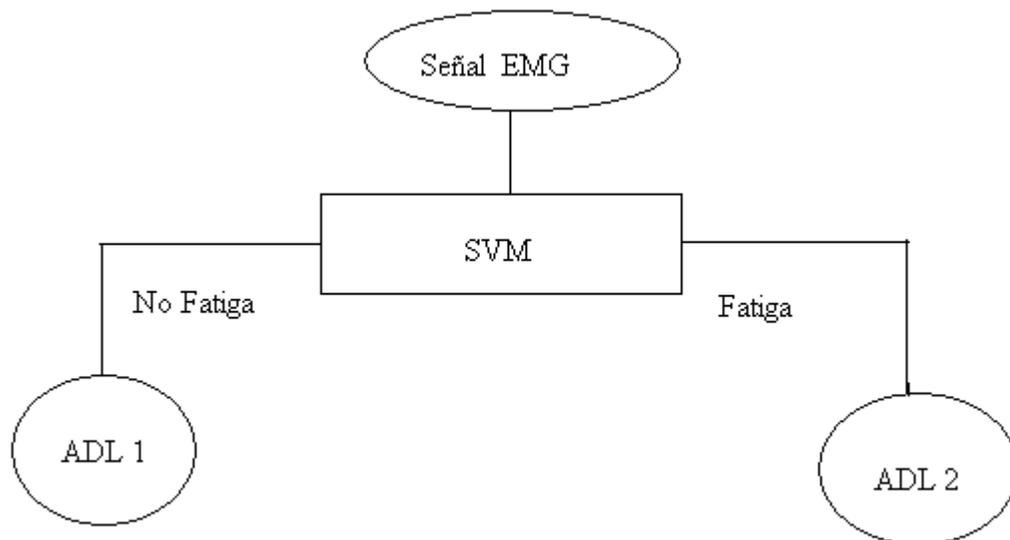


Fig.2.5.1. Esquema de clasificación propuesto.

### 2.5.1 Clasificador basado en máquinas de vectores soporte (MVS)

Las MVS son un método de clasificación que consiste en construir hiperplanos en un espacio multidimensional para separar los casos de diferentes clases. Para construir el hiperplano óptimo se emplea un algoritmo de entrenamiento iterativo, el cual se utiliza para minimizar una función de error. De acuerdo a la función de error existen dos tipos de vectores soporte para clasificación: tipo 1 (C-MVS) y tipo 2 (-MVS).

La clasificación tipo II es la variante SVM seleccionada para esta investigación a través de la cual se minimiza la función de error de la ecuación 2.5.1

$$e = 0.5\omega^T\omega - \nu\rho + \frac{1}{N}\sum_{i=1}^N \xi_i \quad 2.5.1$$

Sujeta a las restricciones de la ecuación 2.5.2:

$$y_i(\omega^T\Phi_{(x_i)} + b) \geq \rho - \xi_i, \xi_i \geq 0, i = 1, \dots, N \text{ y } \rho > 0 \quad 2.5.2$$

Donde  $\omega$  es el vector de coeficientes,  $b$  es el umbral calculado en la sección de entrenamiento a partir de un conjunto de datos de entrenamiento y  $\xi_i$  son los parámetros de los datos de entrada. El índice  $i$  indica el caso  $N$  de entrenamiento,  $y$  es la clase y  $x_i$  es la variable independiente. El núcleo (o kernel)  $\Phi$  es el usado para separar los datos de la variable independiente (de entrada) en características independientes.

Se pueden emplear como núcleos funciones polinómicas, funciones gaussianas de base radial o sigmoides. En esta investigación se emplea en concreto un núcleo polinomial de orden 3. Esta función del núcleo es la que utiliza como algoritmo el clasificador para separar los datos y crear el hiperplano entre ellos. Se evalúan los datos en los términos del polinomio y de acuerdo a su resultado se le asigna su clase de pertenencia.

### 2.5.2 Clasificador basado en análisis discriminante lineal (ADL)

El ADL es una técnica estadística que permite identificar las características que discriminan entre dos o más grupos y crea una función capaz de distinguir con la mayor precisión posible a los miembros de uno u otro grupo.

En este caso se emplea el ADL para diferenciar cada una de las clases de movimiento (mano abierta, puño cerrado, flexión de la muñeca, extensión de la muñeca, supinación del brazo, pronación del brazo y no movimiento), buscando la combinación lineal de las variables independientes que mejor permita discriminar a los grupos, según la ecuación (2.5.1): donde  $a$  es una constante y  $b1-bm$  son los coeficientes de la función.

$$D = a + b1*x1 + b2*x2 + \dots + bm*xm \quad 2.5.3$$

El principal parámetro a tener en cuenta en este clasificador es la probabilidad ‘*a priori*’ de las clases, que afecta la matriz de covarianza de las clases y la media de las clases. En este caso se ha considerado que todas las 8 clases son equiprobables. Teniendo esto en cuenta, la probabilidad *a priori* que se obtiene es  $p = 1/8 = 0.125$ .

## 2.6 Método de evaluación

El desempeño de los clasificadores será evaluado a partir de dos aspectos fundamentales: la Tasa de Clasificación Correcta y la Tasa de Error Activa.

### 2.6.1. Tasa de clasificación correcta. (TCC)

La tasa de Clasificación Correcta es el porcentaje que representa el número de decisiones correctas contra el número total de decisiones como se muestra en la ecuación 2.6.1

$$TCC = 100 \times \frac{\text{Número de Decisiones Correctas}}{\text{Total de Decisiones}} \quad 2.6.1$$

### 2.6.2. Tasa de error activa. (TEA)

La tasa de Error Activa es mucho más útil en el caso de la clasificación de movimientos, pues se refiere al número de decisiones incorrectas que involucran un movimiento contra el número total de decisiones que involucran un movimiento. (ecuación 2.6.2)

$$TEA = 100 \times \frac{\text{Número de Decisiones Activas Incorrectas}}{\text{Total de Decisiones Activas}} \quad 2.6.2$$

---

### **2.7 Conclusiones del capítulo. Estrategia propuesta.**

En este capítulo se presentó una descripción de los datos utilizados para los experimentos, describiendo su proceso de adquisición y conformación. Además se describe el diseño experimental. La estrategia de clasificación propuesta consiste en utilizar cuatro rasgos dominio temporales ampliamente descritos en la literatura, tres de ellos se utilizan para determinar, utilizando SVM, la presencia o no de fatiga muscular. Luego con los cuatro rasgos se determina el tipo de movimiento utilizando uno de los dos clasificadores ADL entrenados, uno en presencia de fatiga muscular y el otro en ausencia de fatiga muscular. De esta manera se obtiene una clasificación selectiva basada en una clasificación previa.

## CAPÍTULO 3. RESULTADOS Y DISCUSIÓN

*En este capítulo se hace un análisis de los resultados alcanzados en este trabajo. Se explica el porqué de la elección de los rasgos valor medio absoluto, cruces por cero y cambio de signo de la pendiente para determinar la presencia de fatiga. Se realiza una comparación de los resultados que se alcanzan cuando se introduce el clasificador de fatiga con los alcanzados sin introducirlo.*

### 3.1 Análisis de la señal EMG con y sin fatiga.

La figura 3.1.1 muestra la densidad espectral de potencia (DEP) de la señal correspondiente a uno de los sujetos del experimento para el movimiento de flexión de la muñeca. Con línea continua se muestra la señal cuando no hay signos de fatiga muscular, mientras que la señal con fatiga muscular se encuentra con línea discontinua.

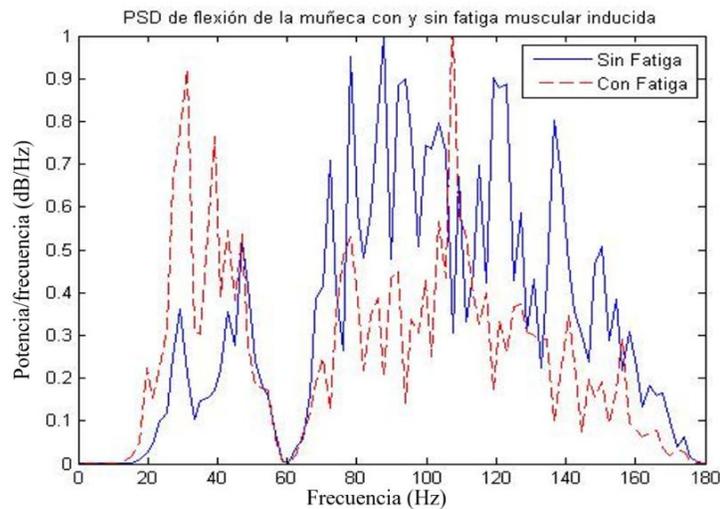


Fig.3.1.1. Densidad Espectral de Potencia en la señal de la clase 'Flexión de la muñeca' con y sin fatiga muscular.

Tal como sugiere la literatura, en presencia de fatiga muscular ocurre un corrimiento hacia las bajas frecuencias del espectro de la señal. Por lo que es de esperar que a partir de las características frecuenciales se pueda determinar la presencia de fatiga muscular. En este trabajo se ha tratado de no incorporar rasgos del dominio de la frecuencia, sino tratar de utilizar los rasgos dominio temporales que se necesitan calcular para clasificar los movimientos en la determinación de la fatiga.

La figura 3.1.2 muestra la evolución temporal de los cuatro rasgos bajo estudio. Se está suponiendo que el nivel de fatiga se está incrementando con el tiempo. Como se observa en la figura, solamente la longitud de la forma de onda no experimenta variaciones significativas a medida que aumenta la fatiga, ese es el motivo por el cual se han seleccionado los rasgos valor medio absoluto, cruces por cero y cambio de signo de la pendiente para la determinación de la fatiga. Desde el punto de vista de las ecuaciones descritas en el capítulo 2, se puede entender que la cantidad de cruces por cero y el cambio de signo de la pendiente están relacionados con la información frecuencial. El Valor Medio Absoluto si bien no tiene información frecuencial, pero si tiene información de amplitud y la amplitud de la señal disminuye cuando hay fatiga. En la figura 3.1.2 se ve que, contrario a lo esperado, los valores se reestablecen en algún punto donde si hay fatiga, esto se debe fundamentalmente al hecho de que cuando se percibe la fatiga se reclutan unidades motoras adicionales para tratar de mantener la contracción o el esfuerzo, lo que dura poco tiempo e incrementa el nivel de fatiga.

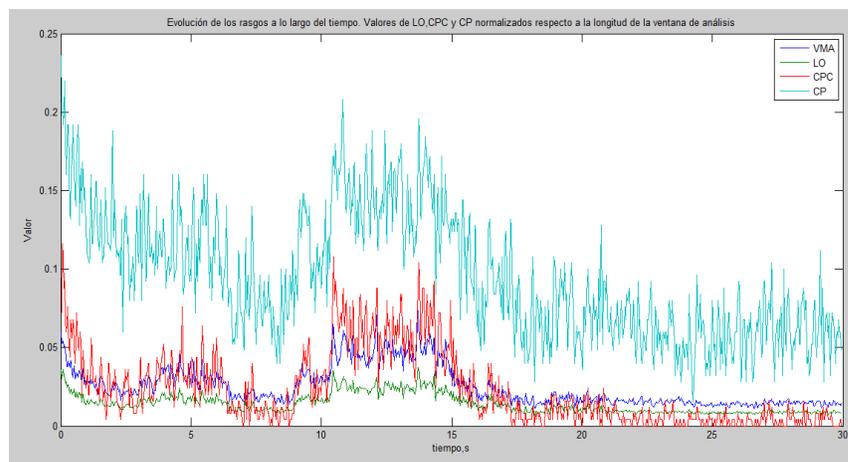


Fig. 3.1.2. Representación de los rasgos extraídos.

### 3.2 Tasa de Clasificación Correcta

La tabla 3.2.1 muestra la Tasa de Clasificación correcta por sujeto involucrado en el experimento. En la tabla los valores se expresan en porcentaje. La primera columna corresponde a la variante utilizada. Las variantes son ADL (cuando se utiliza solamente un clasificador ADL y el entrenamiento se realiza sin tener en cuenta el nivel de fatiga), MVS+ ADL1 (es la variante en la cual se utiliza el clasificador MVS para obtener el nivel de fatiga y luego ADL1 si el nivel de fatiga fue bajo), MVS+ADL2 (es la variante en la que se utiliza MVS para obtener el nivel de fatiga y luego ADL2 si el nivel de fatiga fue alto) y por último MVS + ADL (es el resultado completo de las dos variante anteriores). Esta última fila de la tabla es la que se quiere comparar con la primera.

$$X \in \begin{cases} \text{Class 1,} & \text{if } y > 0, \\ \text{Class 2,} & \text{if } y < 0. \end{cases} \quad 3.2.1$$

Variante	Sujeto 1	Sujeto 2	Sujeto 3	Sujeto 4	Sujeto 5
ADL	70,60	82,40	87,38	81,71	89,46
SVM + ADL1	72,36	83,32	88,20	83,11	89,40
SVM + ADL2	76,72	85,30	88,46	83,20	89,74
SVM + ADL	74,59	84,20	88,41	83,16	89,47

Tabla 3.2.1 Tasa de Clasificación Correcta (en %) de cada clasificador con respecto a cada sujeto del experimento.

De la tabla 3.2.1 se puede observar que para todos los sujetos se tiene una mejora en el desempeño del sistema final comparado con la variante de no utilizar una clasificación previa del nivel de fatiga. Esta mejora, es muy poco apreciable en el sujeto 5, donde el desempeño era de los mejores antes de introducir el clasificador de fatiga. También hay que señalar el hecho de que para un nivel alto de fatiga (SVM+ADL2) la mejora en el

desempeño es mayor que para un nivel bajo de fatiga. Esto se debe a que el entrenamiento del clasificador de referencia (ADL) se realiza en ausencia de fatiga.

### 3.3 Tasa de Error Activa

En la tabla 3.3.1 se muestra la Tasa de Error Activa, que es una medida más útil si se tiene en cuenta que en ella entran solamente aquellas decisiones que involucran un cambio de movimiento y por lo tanto que pueden conducir a errores perceptibles por el usuario. Se utiliza la misma simbología que en la Tabla del epígrafe anterior.

Variante	Sujeto 1	Sujeto 2	Sujeto 3	Sujeto 4	Sujeto 5
ADL	21,99	17,60	5,86	17,33	6,97
SVM + ADL1	19,06	16,23	5,05	16,11	7,00
SVM + ADL2	17,23	15,11	4,88	15,20	6,25
SVM + ADL(tot)	17,89	15,20	4,91	15,21	6,83

Tabla 3.3.1 Tasa de Error Activa.

Otra vez se observa cómo la cantidad de errores disminuye cuando se utiliza el clasificador SVM previo al clasificador ADL. En este caso también es notable el hecho de que es mejor el desempeño del clasificador SVM + ADL2, por el hecho de que el clasificador se entrena con datos que presentan fatiga muscular.

### 3.4 Conclusiones del capítulo

En este capítulo se han presentado los principales resultados de la investigación. Como principal limitación de este trabajo está el hecho de que no se contaba con una anotación *a priori* del nivel de fatiga, por lo que se ha supuesto su incremento con el incremento del tiempo de contracción. Este hecho ha provocado que los resultados se obtengan en relación a si mejora o no la clasificación final del tipo de movimiento al introducir el clasificador de fatiga, sin embargo no se pudo realizar algún experimento que evaluara exactamente el desempeño del clasificador de fatiga basado únicamente en su capacidad para clasificar la

---

fatiga. A pesar de esto, se ha demostrado que utilizar un clasificador de fatiga previo al clasificador de tipo de movimiento puede mejorar el desempeño de estos últimos.

## CONCLUSIONES Y RECOMENDACIONES

### Conclusiones

En este trabajo se han estudiado diferentes variantes para obtener una clasificación del nivel de fatiga muscular presente y se ha desarrollado un clasificador de fatiga muscular basado en Máquinas de Vectores Soporte. La realización de este trabajo permite llegar a las siguientes conclusiones:

1. De los clasificadores estudiados para obtener el nivel de fatiga muscular el que mejor desempeño ofrece para esta aplicación es el basado en Máquinas de Vectores Soporte.
2. Al incluir el clasificador de fatiga como paso previo al clasificador de movimientos se obtiene una mejora del desempeño de aproximadamente el 6 %.
3. Al incluir el clasificador de fatiga como paso previo al clasificador de movimientos se obtiene una reducción de la Tasa de Error Activa de un 2 %.

## Recomendaciones

Como principal limitación de este trabajo está el hecho de que no se contaba con una anotación *a priori* del nivel de fatiga, por lo que se ha supuesto su incremento con el incremento del tiempo de contracción. Por lo que se realizan las siguientes recomendaciones:

1. Realizar una bases de datos con anotaciones del nivel de fatiga para poder evaluar el desempeño del clasificador de fatiga.
2. Evaluar la posibilidad de aumentar la cantidad de clases del clasificador de fatiga, de manera que no sea un clasificador binario, esto deberá conducir a una mejora del desempeño final de los clasificadores de movimiento.
3. Evaluar la posibilidad de sustituir el clasificador de fatiga por un índice de fatiga, que pueda ser utilizado como dato adicional en la configuración del clasificador de movimiento.

## REFERENCIAS BIBLIOGRÁFICAS

- [1] Kimura J. *Electrodiagnosis in diseases of nerve and muscle*. Philadelphia: F.A. Davis Company; 1983.
- [2] Gutiérrez Rivas E, Jiménez MD, Pardo J, Romero M. *Manual de electromiografía clínica*. Barcelona: Prous Science; 2000.
- [3] M. B. I. Reaz, M. S. Hussain, and F. Mohd-Yasin. *Techniques of EMG signal analysis: detection, processing, classification and applications*. *Biological Procedures Online*, 2006.
- [4] Ferguson S.; Dunlop G. “Recognition from Myoelectric Signals”, *Procedures Australasian Conference Robotics and Automation*, 2002.
- [5] Farina, D.; Merletti, R. and Stegeman, D. *Biophysics of the generation of EMG signals*. En: Merletti, R. and Parker, P. *Electromyography: physiology, engineering and noninvasive applications*. USA. IEEE Press. Wiley-Interscience. (2004), p. 81-105.
- [6] Trontelj, J; Jabre, J. and Mihelin, M. *Needle and wire detection techniques*. En: Merletti, R. and Parker, P. *Electromyography: physiology, engineering and noninvasive applications*. USA. IEEE Press. Wiley-Interscience. (2004), p. 27-46.
- [7] Juliana M. Fernández, Rubén C. Acevedo, Carolina B. Tabernig. *Influencia de la fatiga muscular en la señal electromiográfica de músculos estimulados eléctricamente*. *Revista EIA*, ISSN 1794-1237 Número 7, p. 111-119. Junio 2007. Escuela de Ingeniería de Antioquia, Medellín (Colombia)
- [8] Neuman, M. R. “Biopotential Electrodes”. *The Biomedical Engineering Handbook: Second Edition*. Ed. Joseph D. Bronzino Boca Raton: CRC Press LLC, 2000.

- [9] Khandpur R.S. "Biomedical instrumentations. Technology and applications", MacGraw-Hill.
- [10] Merletti, Roberto "Electromyography - Physiology, Engineering, and Noninvasive Applications". Editado por: Merletti, Roberto; Parker, Philip © 2004 John Wiley & Sons.
- [11] Searle A. and L Kirkup "A direct comparison of wet, dry and isolating bioelectric recordings electrodes". Department of Applied Physics, university of technology, Sydney, Broadway, NSW, 2007, Australia.
- [12] Dimitrova, N. and Dimitrov, G. Interpretation of EMG changes with fatigue: facts, pitfalls, and fallacies. En: Journal of Electromyography and Kinesiology. Vol. 13, No. 1(2003), p. 13-36.
- [13] Nordlund, M.; Thorstensson, A. and Cresswel, A. Central and peripheral contributions to fatigue in relation to level of activation during repeated maximal voluntary isometric plantar flexions. En: Journal of Applied Physiology. Vol. 96, No. 1(2004), p. 218-225.
- [14] Gómez-Campos, R.; Cossio-Bolaños, M.A.; Brousett Minaya, M., Hochmuller-Fogaca, R.T. "Mecanismos implicados en la fatiga aguda", Revista Internacional de Medicina y Ciencias de la Actividad Física y el Deporte vol. 10 (40) pp. 537-555, 2010.
- [15] Thorsen, R; Spadone, R. and Ferrarin, M. A pilot study of myoelectrically controlled FES of upper extremity. En: IEEE Transactions on Neural Systems and Rehabilitation Engineering. Vol. 9, No. 2 (2001); p. 161-168.
- [16] Brody, L.; Pollock, M.; Roy, S.; De Luca, C. and Celli, B. pH induced effects on median frequency and conduction velocity of the myoelectric signal. En: Journal of Applied Physiology, Vol. 71, No. 5 (1991), p. 1878-1885.
- [17] Gannoni, M.; Camelia, F. and Farina, D. Conduction velocity of quiescent muscle fibers decreases during sustained contractions. En: Journal of Neurophysiology. 94, No. 1(2005), p. 387-394.
- [18] Du S., Vuskovic M. "Temporal vs. Spectral Approach to Feature Extraction from Prehensible EMG Signal", Department of Computer Science, San Diego State University, 2003.

- [19] Franco J., Suárez E. “Reconocimiento de patrones de movimiento del sistema fisiológico brazo-antebrazo, a partir de señales electromiográficas”, Universidad Tecnológica de Pereira, Colombia, 2004.
- [20] Alonso A., Sánchez H., Hurtado E., Steinz D., Liptak L. “Entrenador Mioeléctrico de Prótesis Para Amputados de Brazo y Mano”, Hospital Clínico Universitario, Universidad de Valladolid. *Mapfre Medicina*, vol. 13, pp. 1119, 2002.
- [21] Vega, M. “Detector de cruce por cero”, Instituto Tecnológico de Querétaro, México, 2009
- [22] French, A.P. “Vibrations and Waves”, Instituto de Tecnología de Massachusetts, Unites States, 2003.
- [23] Bishop, C. M. (1995). *Neural networks for pattern recognition*, Oxford University Press, New York, NY, USA.
- [24] Moran M.J., Shapiro H.N. “Fundamentals of Engineering Thermodynamics”. 2a edición, New York: John Wiley & Sons, cap. 6, pp. 187, 1992.
- [25] McCollum, P. “An Introduction to Back-Propagation Neural Networks”, the Newsletter of the Searle Robotics Society, 2009.
- [26] Daza S. “Redes neuronales artificiales. Fundamentos, modelos y aplicaciones.” Universidad Militar Nueva Granada, Facultad de Ingeniería Mecatrónica, Bogotá, Colombia, 2011.
- [27] Chan, F. H. Y., Yang, Y. S., Lam, F. K., Zhang, Y. T. & Parker, P. A. (2000). Fuzzy EMG classification for prosthesis control, *IEEE Transactions on Rehabilitation Engineering* 8(3): 305–311.
- [28] Kucheva, L. I., Whitaker, C. J., Shipp, C. A. & Duin, R. P. W. (2000). Is independence good for combining classifiers?, *Proc. of ICPR2000, 15th Int. Conference on Pattern Recognition*, Barcelona, Spain, Vol. 2, pp. 168–171.
- [29] Balakrishnama, S. & Ganapathiraju, A. (2010). Linear discriminant analysis –a brief tutorial, [http://www.music.mcgill.ca/~ich/classes/mumt611\\_07/classifiers/lda\\_theory.pdf](http://www.music.mcgill.ca/~ich/classes/mumt611_07/classifiers/lda_theory.pdf).
- [30] Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems, *Ann. Eugenics* 7: 179–188.

- 
- [31] Gunn, S. R. (1998). Support vector machines for classification and regression, Technical report, University of Southampton, Southampton, UK. URL: <http://eprints.ecs.soton.ac.uk/6459/>.
- [32] Hsu, C. W., Chang, C. C. & Lin, C. J. (2003). A practical guide to support vector classification, Technical report, National Taiwan University, Taipei, Taiwan. URL: <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>
- [33] Luis Emilio Supervia Jara (2014). Efectos de la fatiga muscular en clasificadores para el control de prótesis de miembro superior, Tesis de diploma, Universidad Central “Marta Abreu” de Las Villas, Santa Clara, Cuba.

## ANEXOS

### 1.4 Anexo I “Programación en Matlab para la extracción de los rasgos Valor Medio Absoluto (mav), Cruces por Cero (zero\_count), Longitud de onda (len) y Cambio de signo de la pendiente (turns).”

```
%%  
  
function feats = extractTDFeats (DataSet, frameLen)  
  
DEADZONE = 0.025;  
  
TURNTHRESH = 0.015;  
  
Nsig = size (DataSet, 2);  
  
feats = zeros (4, Nsig);  
  
frameLen = min (size (DataSet, 1), frameLen);  
  
try  
  
for SigNum = 1: Nsig  
  
clear mav turns zero_count len;  
  
zero_count = 0;  
  
len = 0;  
  
mav = 0;  
  
turns = 0;  
  
index = 1;  
  
range = index: index+frameLen-1;
```

---

```
mav = mean (abs (DataSet (range, SigNum)));

flag1 = 1;

flag2 = 1;

for i = 1: frameLen-2;

    idx = index + i;

    fst = DataSet (idx-1, SigNum);

    mid = DataSet (idx, SigNum);

    lst = DataSet (idx+1, SigNum);

    % Compute Zero Crossings

    if ((mid>=0 && fst>=0) || (mid<=0 && fst<=0))

        flag1 = flag2;

        else if ((mid<DEADZONE) && (mid>-DEADZONE) && (fst<DEADZONE) && (fst>-
        DEADZONE))

            flag1 = flag2;

        else

            flag1 = (-1)*flag2;

        end

        if (flag1~=flag2);

            zero_count = zero_count + 1;

            flag1 = flag2;

        end

        % Compute Turns (Slope Changes)

        if ((mid>fst & mid>lst) | (mid<fst & mid<lst))

            % turns threshold of 15mV (i.e. 3uV noise)

            if (abs (mid-fst)>TURNTHRESH) | (abs (mid-lst)>TURNTHRESH)
```

---

```
turns=turns+1;
end
end
% Compute Waveform Length
len = len + abs (fst-mid);
end
% Scale the feats to normalize for frameLen
len = len/frameLen;
turns = turns/frameLen;
zero_count = zero_count/frameLen;
feats (:, SigNum) = [mav len zero_count turns]';
end
catch A
A.message
```