



Facultad de Ingeniería Eléctrica

Centro de Estudios de Electrónica y Tecnología de la Información

TRABAJO DE DIPLOMA

Efectos de la fatiga muscular en rasgos dominio- temporales para el control de prótesis de miembro superior

Autor: Yusniel Echemendía Cepeda

Tutor: MSc. Ing. Roberto Díaz Amador

Santa Clara

2014

"Año 56 de la Revolución"



Facultad de Ingeniería Eléctrica

Centro de Estudios de Electrónica y Tecnología de la Información

TRABAJO DE DIPLOMA

Efectos de la fatiga muscular en rasgos dominio- temporales para el control de prótesis de miembro superior

Autor: Yusniel Echemendía Cepeda

E-mail: yechemendia@uclv.edu.cu

Tutor: MSc. Ing. Roberto Díaz Amador

E-mail: rdamador@uclv.edu.cu

Santa Clara

2014

"Año 56 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 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 Autor

Firma del Jefe de Departamento
donde se defiende el trabajo

Firma del Responsable de
Información Científico-Técnica

PENSAMIENTO

“Quien conoce a los demás posee inteligencia; quien se conoce a sí mismo posee clarividencia. Quien vence a los demás posee fuerza, quien se vence a sí mismo es fuerte.”

Lao Zi

DEDICATORIA

A la madre que todos quisieran, Irma.

A mi familia y amigos.

AGRADECIMIENTOS

A mi madre, la mejor del mundo; por estar, por la consistencia, por ser mi fuerza, por el impulso, por haberme traído a este mundo, por mostrarme que sí podías.

A mis abuelos; por haber hecho posible mi travesía por la universidad, por respaldarme en cada locura, en cada momento, por la compañía, por los dulces, por el cariño.

A mi hermano; por no dejarme caer, por confiar, por quererme hecho ingeniero, por esas dos criaturas que iluminan nuestras vidas.

A mi tutor; por la constancia, por el esfuerzo, por creer siempre que yo sí podía llegar al final.

A todos los profesores de la carrera, por haber contribuido a graduar de ingeniero a un bailarín eternamente frustrado.

A Wendelín; por guiarme, por quitarme la venda, por abrirme los ojos, por enseñarme de lo bueno y de lo malo, por estar siempre, por el amor sin límites.

A Luis; por ser mi hermano, mi mamá, mi papá y mi confidente en buenos y malos tiempos, por pelearme tanto para que llegara hasta aquí, por las tertulias de café y cigarros, por ser como eres. Tu fuerza y decisión son mi ejemplo. Estoy orgulloso de ti.

A Regla; por ser la niña más linda del mundo, por acompañarme en la tristeza, por entenderme, por llegar en el momento adecuado aunque yo creía que no, por el cariño, por la ternura, por esos huequitos preciosos en tu Rostro de Rebusillos.

A mi papá; por ti comencé a crecerme ante las dificultades, por ti recibí el doble de lo que me tocaba, por ti igualmente, estoy parado frente a tantas personas recibiendo un título de ingeniero.

A mis guarrillos y soquetes de Sancti Spíritus:

Nosley: Por ser mi otro hermano, por vivir la vida como la vives, por la objetividad. Cuando sea grande quiero ser como tú.

Diana: Por conocerme tanto que ni yo mismo me explico, por solo mirarme y saber lo que pienso, por ser mi flaca y yo tu negro.

Rey: Gracias por regresar, por permitirme tenerte otra vez entre los míos, todo grupo debe tener un desnivel, te tocó por enano.

Lisbet: Gracias por existir, por apoyarme en todo aunque ello conllevara a un jalón de orejas, por ser mi Pepe Grillo.

Gladys: ¿Qué haría un mono sin una mona? Gracias por ser mi par; como en las pelis, todo grupo de amigos que se respete debe tener un par de negros, y más si son lindos como nosotros.

Yander: Si estás presente, es que el huevo te dejó venir; además, era claro que no podías dejar de estar en un momento tan importante para mí, como últimamente se ha hecho costumbre. Gracias por todo; gracias a ti el grupo se respeta más, por somos 3 (los negros).

Isaura: sin tu forma de mirar, de recorrer este mundo, sin aprender de ti, no hubiese sido posible. Gracias por ser mi compañera de ataques.

Y a los que se han sumado: Daily, Adolfo Eriberto (Papote), Marco, Yaritza, Roger, Claudia, Yileisy; no por ser los más nuevos son los menos importantes, cada uno me ha dejado ver que son de los buenos, que llegaron para quedarse. A todos, gracias por las borracheras, por los Café Teatro, incluyendo el tubo, por los llaneros solitarios, por dormir juntos, por los consejos, por las charlas de madrugada, por las coreografías, por confiar, por creer, por los secretos, por los abrazos, por ser los míos. Y recuerden: “La amistad es una semilla que brota en cualquier lugar.”

A mi familia del U3: Yisly, Tuté, Adri, Ernesto, Leduán, Aramis, Lismey, Bárbara; por acogerme en tiempos difíciles, por alimentarme en tiempos de apagón, por compartir conmigo incluso hasta su baño.

A Alina; por los buenos tiempos que pasamos juntos, por aquel gran grupo de “Doña flor y sus tres maridos.” Por los tantos Caneyes, Bosques y hasta etcéteras.

A Eduardo, por estar, por evaluarme, por permitirme contar con él desde primer año sin temor a nada, por integrar las filas de los mejores bailarines de Eléctrica.

A mis compañeros de cuarto: Luis, Yainet, el Peque, Joisel, Damarys; por el estudio, por el cuero, por las risas, por los pleitos, por tratar de hacer algo semejante a un hogar en un pedacito de 2 por 2.

A mi grupo de Biomédica, el mejor grupo de la carrera, por algo será.

A Luis Enrique y Héctor; por sacarme del bache en varios momentos, por hundirme en otros. Que suerte que llegaron cuando ya estaba en quinto, porque si no, a lo mejor estuviera en cuarto.

A esa gran familia que me ha enseñado tanto, a mi combo de 5 de Diciembre.

Muchos somos los que hemos llegado al teatro universitario algún día, embullado por un amigo o conocido, para ver qué es lo que hace la compañía de la universidad, y si nos gusta, pues enfrentarnos al supuesto ogro que tienen como coreógrafo. Muchos somos los que nos hemos puesto nerviosos cuando nos han encerrado en un camerino, a dar palmadas, ejecutar algunos pasos o bailar con los mejores que hemos visto en escena, para ver si nos quedamos o no. Pero cuando ha llegado el momento en que nos dicen -pasaste-, comienzan a surgir de pronto el sentido de pertenencia, la responsabilidad, el cariño, el amor, el respeto, la consagración, la amistad, y por supuesto, el queso, que nos hacen depender cada tarde de esas tres horas de ensayo, de la coreografía nueva, del diseño corporal, del chucho y la jarana, incluso hasta de uno u otro grito que se pueda escapar. Y comenzamos a tener la necesidad de bailar, y bailar, y bailar, y empezamos a enamorarnos perdidamente de ese tabloncillo que nos va a exigir tanto, pero que a su vez, nos va a recompensar con más. Por eso cuando me gradúe y tenga que irme, cuando termine para siempre mi andar por esta casa de altos estudios, recordaré con afán a los que están, a los que se fueron, a los que pasaron, a los bailarines en los que confío para subir a un escenario, darlo todo con entrega y sacrificio, y acabar desechos en menudos pedazos con la satisfacción más grande del mundo: el reconocimiento y el aplauso de nuestro público, el de la universidad.

Quiero agradecer a Gerardo, por haber tenido la grandiosa idea de crear esta familia, por ser la bestia coreográfica; a Karell, por acogerme cuando fui un novato, por enseñarme lo que sabía, por convertirte en mi espejo y mi ejemplo de queso; a You, por todo, sencillamente por todo, ah, y por ser la patrona de los machos; a Daimé, por los consejos, por gran amiga; a la vieja, por peleona; a Mariannis, por el olor a tuti fruti; a Lizandra, por ser la bailarina que es, por el baile del tambor; a Rafa, por perfeccionista; a Jose, por el contratiempo; a René y Sarmiento, por cachuapos, a Isis, por ser mi pareja, por “Aquí el que baila gana”; a Merly la mona, por ser lo más grande, por la sonrisa bestial, por las habaneras; a Yander, por buen bailarín, por continuar siéndolo; a Merly la Blanca, por la supergeta; a Rosario, por las locuras, por ser mi “socio”; a Maikel, Alejandro y Ariel, por francotiradores; a Eduardo, por decidirse aunque fuese a última hora; a Julio, por ser de Camagüey; a Galindo por el pre arranque; a Any, por aburrir al público junto conmigo; a Clara, por la gran reina que fuiste; a Yaser y Merly, por ser los pitinejos, por ser los míos; a Luis Emilio, por llegar en buena hora, por las banderas del panamá, las mejores; a Laira, por ser mi niña; a Regla, por deslumbrar el escenario con tu hermosura; a Yoandy, por cederme el paso; a Daily, por cumplidora, por llevar siempre puestas las nalgas de ensayo; a Arianna, por excitarse en el baile, por los pezones; a Geisy, por ser la florera más linda de Sancti Spíritus; a Angel, por los 80 Gigas.

Por favor, nunca dejen morir esa pasión que los llena cuando bailan, cuando ríen, cuando lloran al final de un espectáculo; nunca olviden que el 5 de Diciembre es lo más que recordarán de su estancia en la universidad, los viajes, las fiestas, los ensayos, las presentaciones; luchen, esfuércense, denlo todo, por mantener es nombre por todo lo alto, por dar otros auge, otros uepa, y sobre todo, por seguir manteniendo los pies sobre el viento. Los quiero.

TAREA TÉCNICA

1. Revisión bibliográfica sobre prótesis de miembro superior y sobre la fatiga muscular.
2. Identificación y programación de algoritmos de extracción de rasgos de los más utilizados en la determinación de la intensidad de movimiento.
3. Evaluación del desempeño de cada uno de los subconjuntos de rasgos en presencia de fatiga muscular.
4. Comparación del desempeño de los subconjuntos de rasgos.
5. Elaboración del informe final y presentación de los resultados.

Firma del Autor

Firma del Tutor

RESUMEN

La señal que se produce en los músculos cuando estos se contraen constituye la señal electromiográfica, cuya aplicación fundamental en los últimos tiempos, es en el control de prótesis. A su vez, existen factores que a lo largo plazo afectan el desempeño de estas prótesis, entre ellos, la fatiga muscular. Sin embargo, no se ha hecho un estudio que permita evaluar, de manera conjunta, cuál de las técnicas de extracción de rasgos, desarrolladas hasta el momento, es más robusta ante los cambios que puedan producir estos factores. Este trabajo permitió determinar la influencia de la fatiga muscular en la señal electromiográfica y evaluar las técnicas de extracción de rasgos, así como el conjunto de rasgos adecuados, para el entrenamiento de un clasificador de intención de movimiento.

Los resultados alcanzados muestran la distorsión que ocurre en los subconjuntos de rasgos conformados, luego de ser inducida la fatiga muscular; lo que provocó un ascenso de error de clasificación mediante el Análisis Discriminante Lineal. Según los aspectos analizados, los subconjuntos Fs8 y Fs2 resultaron de mejor y peor desempeño, y el Fs10 el de menor variabilidad entre sujetos, con un índice de sensibilidad de 97,20%; pero mediante un análisis estadístico, se concluyó que no existen diferencias significativas entre los subconjuntos conformados, por lo se hace necesario la búsqueda de otras soluciones.

TABLA DE CONTENIDOS

PENSAMIENTO	i
DEDICATORIA	ii
AGRADECIMIENTOS	iii
TAREA TÉCNICA.....	vii
RESUMEN	viii
INTRODUCCIÓN.....	1
CAPÍTULO 1. REVISIÓN BIBLIOGRÁFICA.....	6
1.1. Electromiografía.....	6
1.1.1. Medición de la señal EMG.	7
1.1.2. Adquisición de las señales EMG.....	7
1.1.3. Electrodo de adquisición.....	8
1.2. Factores que afectan la señal EMG.	8
1.2.1. Fatiga muscular.	9
1.3. Extracción de rasgos.....	9
1.3.1. Valor medio absoluto (<i>MAV</i>).....	11
1.3.2. Cruces por cero (<i>ZC</i>).	11
1.3.3. Cambio de signo de pendiente (<i>NT</i>).	11

1.3.4.	Longitud de la forma de onda (<i>WL</i>).....	11
1.3.5.	Varianza (<i>VAR</i>).....	11
1.3.6.	Promedio de los cambios de amplitud (<i>MAC</i>).....	11
1.3.7.	Coefficientes autorregresivos (<i>AR</i>).....	12
1.3.8.	Amplitud de Wilson (<i>WAMP</i>).....	12
1.3.9.	Valor medio del pulso mioeléctrico (<i>MYOP</i>).....	12
1.4.	Métodos de selección de rasgos.....	13
1.4.1.	Best Subset.....	13
1.4.2.	Análisis de Componentes Principales.....	13
1.5.	Clasificadores de patrones electromiográficos.....	14
1.5.1.	Análisis Discriminante Lineal.....	15
1.6.	Conclusiones parciales del capítulo.....	16
CAPÍTULO 2. MATERIALES Y MÉTODOS.....		17
2.1.	Base de Datos.....	19
2.2.	Rasgos extraídos.....	19
2.2.1	Valor medio absoluto.....	20
2.2.2	Cruces por cero.....	20
2.2.3.	Cambio de signo de la pendiente.....	21
2.2.4.	Longitud de la forma de onda.....	21
2.2.5.	Varianza.....	22
2.2.6.	Promedio de los cambios de amplitud.....	22
2.2.7.	Coefficientes autorregresivos.....	22
2.2.8.	Amplitud de Wilson.....	24
2.2.9.	Valor medio del pulso mioeléctrico.....	24

2.3.	Técnicas de selección de rasgos a utilizar.	24
2.3.1.	Best Subset.	24
2.4.	Análisis Discriminante Lineal.	25
2.5.	Análisis Estadístico.	25
2.6.	Conclusiones parciales del capítulo.	26
CAPÍTULO 3. RESULTADOS Y DISCUSIÓN		27
3.1.	Obtención de subconjuntos de rasgos.	27
3.2.	Clasificación.	28
3.2.1.	Clasificación aportada por los rasgos individuales.	28
3.2.2.	Error de clasificación por subconjunto.	29
3.2.3.	Error de clasificación por clases.	32
3.2.3.1.	Índice de sensibilidad.	33
3.2.4.	Clasificación por tramas.	34
3.2.4.1.	Error total.	34
3.2.4.2.	Error Activo.	36
3.3.	Análisis estadístico.	37
3.4.	Conclusiones parciales del capítulo.	37
CONCLUSIONES Y RECOMENDACIONES		39
	Conclusiones	39
	Recomendaciones	40
REFERENCIAS BIBLIOGRÁFICAS		41
ANEXOS		46
Anexo I	“Programación en Matlab para la extracción de los rasgos.”	46
Anexo II	“Programación en Matlab para la clasificación de los subconjuntos de rasgos.”	49

Anexo III “Programación en Matlab para la Prueba de Wilcoxon.”.....	54
Anexo IV “Clasificación de subconjuntos de rasgos con Análisis Discriminante Lineal. Sujeto 1.”	54
Anexo V “Clasificación de subconjuntos de rasgos con Análisis Discriminante Lineal. Sujeto 2.”	55
Anexo VI “Clasificación de subconjuntos de rasgos con Análisis Discriminante Lineal. Sujeto 3.”	55
Anexo VII “Clasificación de subconjuntos de rasgos con Análisis Discriminante Lineal. Sujeto 4.”	56
Anexo VIII “Clasificación de subconjuntos de rasgos con Análisis Discriminante Lineal. Sujeto 5.”	56
Anexo IX “Clasificación de las clases con Análisis Discriminante Lineal”.	57

INTRODUCCIÓN

En los últimos años han cobrado gran importancia los trabajos encaminados a la realización de interfaces hombre-máquina, diseñadas especialmente para ayudar a personas con discapacidad o para la ejecución de tareas sin contacto directo del operario [1].

En el caso de discapacidades asociadas a la pérdida de miembros superiores, estas interfaces se han desarrollado desde la sustitución del miembro afectado por una prótesis cosmética, hasta soluciones más funcionales que permiten restablecer parcialmente las funciones perdidas. Estas soluciones han evolucionado desde las puramente mecánicas que permiten realizar algunos movimientos, casi siempre repetitivos, hasta lo que se ha llamado prótesis inteligente, que permite que el dispositivo “aprenda” y sea relativamente fácil para ser gobernado por el usuario. Una de las formas para conseguir ese objetivo es la captación de señales electromiográficas (EMG) provenientes de los músculos que están asociados cualitativamente con el tipo de movimiento producido [2], lo cual está asociado a un músculo por movimiento, pero ha evolucionado hasta el uso de técnicas de reconocimiento de patrones que permiten el uso de señales captadas en conjunto por un número de sensores, usualmente entre 4 y 8.

La señal mioeléctrica es la que se produce en los músculos cuando éstos se contraen debido al intercambio de iones a través de las membranas de las fibras musculares. Dicha señal se adquiere de los músculos con electrodos de superficie y guarda relación directa con su nivel de contracción [3]. La técnica para la evaluación y registro de esta actividad eléctrica es conocida como electromiografía.

La señal EMG se ha aplicado en la diagnosis de enfermedades como la esclerosis, la neuropatía motora, o la distrofia muscular. Es útil también, a la hora de estudiar el

movimiento y la coordinación del cuerpo humano, sus mecanismos para realizar tareas complejas, así como para el control de prótesis mioeléctrica.

Una prótesis es una extensión artificial cuyo objetivo es sustituir una parte del cuerpo que haya sido perdida por una amputación o que no exista a causa de agenesia, cumpliendo las mismas funciones que la parte faltante, como las extremidades inferiores o superiores. Una prótesis mioeléctrica es un sistema accionado por servomotores que se gobierna a partir de señales EMG, bien sean intramusculares, capturadas mediante agujas superficiales, o recogidas en el muñón del paciente mediante electrodos [4].

Precisamente las amputaciones, han provocado un aumento extensivo de las prótesis mioeléctricas, ya sean en formas y funcionamientos. Estas pueden ser causadas de forma congénita, debido a algún tumor, enfermedades tales como la diabetes o algún tipo de trauma, ya sean accidentes o guerras. En países capitalistas y altamente desarrollados, que además tienen una elevada densidad de población, como en Estados Unidos, se reportan más de 50 mil amputaciones por año debido a estas causas, de las cuales aproximadamente el 25% son de miembro superior. De las 350 mil personas que presentan amputaciones en este país, cerca del 30% son de pérdida total del brazo, y de ellas, el 60% son personas entre los 21 y 64 años de edad, es decir, edad con plenas condiciones físicas para trabajar. De ahí la necesidad del desarrollo de las prótesis mioeléctricas como sustitución y solución a dicha problemática [5].

La agilidad para el control de una prótesis mioeléctrica ha progresado en cierta medida en comparación con décadas anteriores. El número de personas con amputación de mano que aceptan y se adecúan a este tipo de prótesis es cada vez mayor. El uso de señales EMG para el monitoreo de prótesis de extremidad superior, constituye una importante opción clínica, que ofrece a una persona con amputación, la autonomía de control por medio de músculos residuales, y la rehabilitación para un mejor desempeño en su campo laboral y social.

Las prótesis de miembro superior comenzaron siendo poco desarrolladas, ya que se implementaban en dos músculos solamente, con el empleo de un electrodo en cada uno de ellos. Se les denominaba músculos antagonicos porque para captar la señal por uno de los electrodos, el otro debía dejar de funcionar. Surgen entonces como solución a este problema las prótesis mioeléctricas multicanales [6].

Las prótesis movidas por motores eléctricos son de las primeras conocidas de este tipo utilizan la señal EMG como señal de control. Desde 1975 comienzan a desarrollarse trabajos en este sentido a partir del reconocimiento de características, continuados en 1983 con la aplicación de técnicas de correlación. En 1995 se obtuvieron índices del 85% de éxito en el departamento de Neuro-Ingeniería de la NASA, con la utilización de coeficientes espectrales. Mientras que en 1999 fueron desarrolladas técnicas de reconocimiento de patrones EMG por medio de redes neuronales y modelos ocultos de Markov [6].

También surgieron técnicas de caracterización de señales EMG basadas en modelamiento paramétrico, wavelets, de reconocimiento con redes neuronales, y métodos estadísticos en el año 2002. En el 2003, se realizaron investigaciones que perseguían el entrenamiento de prótesis, la predicción de fatiga muscular y la optimización de diseños de los algoritmos de reconocimiento de patrones en tiempo real [7]. En este sentido, se destacaron los implementados por Bernard S.Hudgins y Kevin Englehart, realizando aproximación temporal, modelamiento paramétrico, y empleando aproximación espectral.

Actualmente los trabajos de investigación en esta área están dirigidos a encontrar los algoritmos de procesamiento, caracterización, extracción y clasificación de patrones de dichas señales, que permitan el análisis y la determinación del tipo de movimiento, con porcentajes de acierto entre 80% y el 97% dependiendo del número de electrodos y del número de movimientos detectados [1].

Durante el desarrollo de prótesis de miembro superior controlados por señales EMG, varios factores de la vida diaria pueden afectar, a largo plazo, su validez clínica y desempeño. Existen soluciones a dichas afectaciones, orientadas fundamentalmente al desarrollo de electrodos implantables, técnica que resulta invasiva y de alto costo. Por tanto, es evidente que se lleve a cabo con mucha fuerza la búsqueda de soluciones que permitan mejorar el desempeño de las prótesis superficiales, principalmente diferentes grupos de investigación, fundamentalmente en Norteamérica y Europa.

El desarrollo de sistemas adaptativos que se adecúen a los cambios que ocurren en la señal EMG, es una de las soluciones que pudieran surgir en este sentido. Sin embargo, no se ha hecho un estudio que permita evaluar, de manera conjunta, cuál de las técnicas de

extracción de características, desarrolladas hasta el momento, es más robusta ante estos cambios.

Realizar esta investigación permitirá evaluar las técnicas ya existentes ante un problema no resuelto todavía, de donde pudieran surgir nuevas soluciones con un impacto social inmediato en la población de amputados de nuestro país, con un costo menor al que significaría el desarrollo de nuevas técnicas.

Definición del problema de investigación

¿Afecta la fatiga muscular causada por movimientos sostenidos, el desempeño a largo plazo de los sistemas de clasificación automática de movimientos?

¿Todos los rasgos que se han utilizado en sistemas de clasificación automática se comportan de la misma manera?

Objetivo General

Como **Objetivo General** se pretende evaluar el comportamiento de diferentes técnicas de extracción de rasgos de la señal EMG ante la presencia de cambios en sus patrones que afectan la viabilidad clínica de las prótesis de miembro superior a lo largo del tiempo.

Objetivos Específicos

- Identificar los factores reportados en la literatura que afectan el desempeño a largo plazo de las prótesis de miembro superior controladas por EMG.
- Desarrollar experimentos de clasificación utilizando diferentes subconjuntos de rasgos, empleando un clasificador basado en Análisis Discriminante Lineal.
- Evaluar el desempeño de los rasgos y combinaciones de ellos utilizados en la clasificación automática de la intención de movimiento ante cambios en la señal EMG causados por fatiga muscular.

Organización del Informe

El presente informe se encuentra dividido en Introducción, 3 Capítulos, Referencias Bibliográficas y Anexos.

En la Introducción se hace referencia a los antecedentes del tema en cuestión, así como a la importancia y novedad del trabajo, además de los objetivos trazados para la conformación del mismo. El Capítulo 1 se muestra una búsqueda teórica necesaria para la comprensión

del resto del informe. En el Capítulo 2 se exponen los materiales y métodos que permitieron la realización práctica del experimento, y en el Capítulo 3 los resultados a los que se arribó en la investigación. Por último se encuentran las Referencias Bibliográficas utilizadas en la búsqueda de información y los Anexos del trabajo.

CAPÍTULO 1. REVISIÓN BIBLIOGRÁFICA

Con el avance tecnológico, cada vez se logra mejorar la construcción de sistemas de prótesis como extensiones de algún miembro del cuerpo humano con características esenciales como: flexibilidad, estética cosmética, peso ligero y multifuncionalidad. Igualmente, la ciencia y la ingeniería han realizado grandes avances en el área de procesamiento digital de señales biomédicas como las señales electromiográficas (EMG) y sus aplicaciones en el control de dispositivos activos como las prótesis mioeléctricas [8], de ahí su importancia.

1.1. Electromiografía

La técnica utilizada para la evaluación y registro de la actividad eléctrica producida por los músculos esqueléticos es conocida como electromiografía. Estas señales son generadas por el intercambio de iones a través de las membranas de las fibras musculares debido a una contracción muscular. La técnica de electromiografía se desarrolla utilizando un instrumento médico llamado electromiógrafo, que produce un registro llamado electromiograma. Un electromiógrafo detecta el potencial de acción que activa las células musculares. Cuando éstas son activadas neural o eléctricamente, las señales pueden ser analizadas para detectar anomalías y el nivel de activación, o analizar la biomecánica del movimiento de un humano o un animal [9].

Existen dos métodos para utilizar el EMG, intramuscular y superficial. Para el EMG intramuscular, se usa una aguja electrodo que se inserta a través de la piel hasta que entre al tejido muscular. Mientras se va insertando, provee una información valiosa en cuanto a la actividad muscular como al nervio que inerva ese músculo. El problema fundamental de esta técnica es que es demasiado invasiva.

1.1.1. Medición de la señal EMG.

Las señales electromiográficas (EMG) pueden ser medidas utilizando elementos conductivos o electrodos sobre la superficie de la piel, o de manera invasiva sobre el músculo utilizando agujas. Sin embargo, la electromiografía de superficie es el método más común de medida puesto que es no invasiva y puede ser realizada con un mínimo de riesgo sobre el paciente.

La amplitud de las señales electromiográficas varía desde los μV hasta un bajo rango de mV (menor de 10 mV). La medición y representación de este tipo de señales depende de las propiedades de los electrodos y su interacción con la piel, el diseño del amplificador y la conversión y subsecuente almacenamiento de la señal de formato análogo a digital [10].

La calidad de la señal electromiográfica medida es usualmente descrita por la relación entre la señal EMG medida y las contribuciones de ruido indeseadas por el ambiente. La meta es maximizar la amplitud de la señal mientras se minimiza el ruido. Asumiendo que el diseño del amplificador y el proceso de conversión A/D están por encima de los estándares aceptables, la relación entre la señal y el ruido está determinada casi exclusivamente por los electrodos, y más específicamente, por las propiedades del electrodo y el contacto con la piel.

1.1.2. Adquisición de las señales EMG.

Las señales EMG son esencialmente un patrón unidimensional, por lo que cualquier técnica de procesamiento de señales para extracción de características y reconocimiento de patrones se puede aplicar a este tipo de señales. La información extraída de las señales EMG, es seleccionada de tal manera que se minimice el error en el control de los sistemas de prótesis mioeléctrica. La necesidad de una rápida respuesta de la prótesis limita la longitud de las muestras de la señal sobre las cuales se extraen las características. La tendencia en el control de prótesis a partir de señales EMG obedece a que se constituye en la técnica más sencilla de implementar por su facilidad en la recolección sin intromisión directa sobre el organismo del usuario, remoción de electrodos y equipo para efectos de mantenimiento y/o calibración y su reutilización de una persona a otra [11].

En la electromiografía, el reconocimiento de patrones promete grandes avances de destreza para el control de prótesis de extremidad superior. La labor de poder elegir

entre un grupo de contracciones musculares para el control mioeléctrico está influenciado por la interfaz de EMG y los métodos de reconocimiento de patrones.

1.1.3. Electrodo de adquisición.

La posición de los electrodos es muy importante en la recolección de registros EMGS con propósitos de control mioeléctrico. Por ello, se recomienda la asistencia de personal médico especializado, quienes pueden identificar con mayor precisión las regiones musculares con mayor compromiso en la ejecución de los movimientos de interés. Ha sido demostrado que unas regiones son mejores que otras para la ubicación de los electrodos. Sin embargo, es usual el empleo de sockets con electrodos equiespaciados.

EL electrodo del compuesto Ag-AgCl, es el más usual de los electrodos superficiales para recepción de señales [12], y con el gel electrolito empleado entre la superficie del electrodo y la piel del paciente, son capaces de recoger cientos o miles de potenciales de acción de cada una de las unidades motoras, y cuya amplitud de la señal recogida es mucho mayor que la señal del electrodo de aguja.

Estos electrodos se pueden ubicar en dependencia de la señal que se quiera obtener. La generalización de dichas posiciones no es recomendable para todos los pacientes, así que el procedimiento de identificación de las regiones musculares debe realizarse particularmente con cada paciente.

1.2. Factores que afectan la señal EMG.

La amplitud y las propiedades de las señales electromiográficas tanto en el dominio del tiempo como de la frecuencia dependen de factores como [13]:

- El tiempo y la intensidad de la contracción muscular.
- La distancia entre el electrodo y la zona de actividad muscular.
- Las propiedades de la piel (por ejemplo, el espesor de la piel y el tejido adiposo).
- Las propiedades del electrodo y el amplificador.
- La calidad del contacto entre la piel y el electrodo.

Estos factores en conjunto, determinados como fatiga muscular, mala interacción de la interfaz piel-electrodo, variaciones en la impedancia de la piel, así como un mal ajuste

de los electrodos provocando su corrimiento, son la causa primaria y fundamental del mal desempeño de las prótesis controladas por señales EMG a lo largo del tiempo.

1.2.1. Fatiga muscular.

Este término está definido como la disminución reversible, inducida por ejercicio físico, de la capacidad del músculo para generar fuerza, y con ello, impulsos eléctricos. Esta condición puede presentarse como consecuencia auto-inducida o por motivos genéticos. El límite tras el cual se somete a una fatiga muscular varía de persona a persona. Según sea el tipo de ejercicio efectuado, será la fatiga muscular causada.

Entre los factores que pueden causar fatiga muscular se encuentran:

- 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 es un contribuidor importante en la fatiga muscular.
- La declinación de ATP, en la unión de túbulos transversos y retículo sarcoplasmático, que obstaculiza la acción de las bombas de Ca^{2+} . El ATP declina rápidamente en fibras de contracción rápida durante el ejercicio sin producir rigor.
- Agotamiento de glucógeno muscular. Este mecanismo no se comprende por completo, pero parece disminuir la liberación de Ca^{2+} desde el retículo sarcoplasmático.
- Disminución de la entrada de O_2 al cuerpo. Esto puede ser causado por anemia y otro tipo de enfermedades, que provocan insuficiente entrada de oxígeno a las células sanguíneas, y a su vez la falta de células sanguíneas portadoras de oxígeno [14].
- Producción por el propio cuerpo humano de ácido láctico, el cual se cree causa debilidad al músculo, y por tanto, fatiga.
- Funcionamiento anormal de la glándula tiroides, es decir, reducción en la producción de la hormona tiroxina, ocasionando hipertiroidismo.

1.3. Extracción de rasgos.

La extracción de rasgos es un paso importante en el proceso de reconocimiento de patrones. En el caso de las señales EMG, un patrón está representado por una señal $x(t)$ en el dominio del tiempo, como la que se muestra en la Figura 1.




Fig.1. Señal EMG típica durante una contracción muscular.

Normalmente las señales en el tiempo son de duración limitada y se encuentran muestreadas y convertidas en formato digital. En tales situaciones es más apropiado representar un patrón como una secuencia de tiempo finita $x[1], x[2], \dots, x[n]$. El presentar esta secuencia directamente al clasificador es algo impráctico debido al gran número de entradas y a la aleatoriedad de la señal. Por lo tanto, la secuencia $x(n)$ debe ser reducida a un vector $x = (x_1, x_2, \dots, x_d)$, con $d \ll n$, llamado vector de características, el cual caracteriza la señal y permite que el clasificador presente un entrenamiento estable, y se logre una clasificación con un buen porcentaje de acierto [15].




Fig. 2. Etapas de procesamiento de señales EMG para el reconocimiento de patrones.

Se pueden considerar generalmente dos métodos para la extracción de características o rasgos: aproximación paramétrica y no paramétrica. Dentro de la aproximación paramétrica se tienen modelos tales como AR (AutorregresiveModel), MA (movingaverage) y ARMA. En la aproximación no paramétrica se consideran generalmente dos métodos: aproximación temporal y aproximación espectral, aunque también pueden ser considerados métodos de aproximación tiempo-frecuencia [2].

En este trabajo se utilizan rasgos en el dominio del tiempo, denominados TD en lo sucesivo, coeficientes de Autorregresión (AR) y coeficientes wavelets (WC).

1.3.1. Valor medio absoluto (MAV).

Estima el valor medio absoluto sobre cada segmento i de N muestras de la señal. Posibilita estimar el comportamiento promedio de la señal a lo largo del tiempo.

1.3.2. Cruces por cero (ZC).

Indican una medida del 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. Puede ser una forma simple de calcular la frecuencia de una señal, si se cuentan las veces en que la onda pasa por el valor cero [16].

1.3.3. Cambio de signo de pendiente (NT).

Se denomina pendiente, apelando a las ciencias aplicadas y a las matemáticas, a la inclinación de un elemento ideal, natural o constructivo con respecto a la horizontal.

El cambio de pendiente puede dar una idea de cómo varía la señal con el transcurso del tiempo, y de forma sencilla, expresar la frecuencia de la señal en dependencia del número de cambios de signos de la misma.

1.3.4. Longitud de la forma de onda (WL).

Es el período espacial de la misma, es decir, la distancia que hay de pulso a pulso. Normalmente se consideran dos puntos consecutivos que poseen la misma fase: dos máximos, dos mínimos, dos cruces por cero (en el mismo sentido) [17].

1.3.5. Varianza (VAR).

La varianza de una variable aleatoria es una medida de dispersión definida como la esperanza del cuadrado de la desviación de dicha variable con respecto a su media [18].

Este rasgo indica cuán alejada está la señal obtenida de su media original, su comportamiento con el paso del tiempo, y su posible distorsión.

1.3.6. Promedio de los cambios de amplitud (MAC).

Se define como el valor medio de las diferencias entre dos muestras consecutivas, dando una medida de la ocurrencia de cambios bruscos en la señal [19].

1.3.7. Coeficientes autorregresivos (*AR*).

También conocidos como *Modelo autorregresivo de media móvil*, estos coeficientes se aplican a series temporales de datos. Dada una serie temporal de datos x_t el modelo ARMA es una herramienta para entender y predecir valores y comportamientos futuros.

Este modelo está formado por dos partes: la de media móvil, y la otra parte autorregresiva, que será la que determinará dichos coeficientes empleados para el entrenamiento y comparación con otro grupo de rasgos.

El modelado paramétrico autorregresivo permite modelar series de tiempo. En este caso los coeficientes forman el conjunto de características requeridas. Graupe y Cline [2], fueron los primeros en clasificar señales EMG, utilizando coeficientes AR como características para clasificación a partir de un solo canal. Sin embargo, este parámetro tiene el inconveniente de suponer la condición de estacionareidad en la señal, lo cual no se cumple para las señales EMG.

1.3.8. Amplitud de Wilson (*WAMP*).

La amplitud de Wilson es una medida que se define como la cantidad de veces en que el cambio de la amplitud de la señal excede un determinado umbral. Es un indicador de la actividad de la unidad motora y por tanto una métrica de contracción muscular [20].

1.3.9. Valor medio del pulso mioeléctrico (*MYOP*).

Realizar mediciones directamente sobre la unidad motora es poco usual, e imposible en EMG de superficie, por lo que es generalmente en lugar de medir el aporte individual de cada una, realizar una medición promedio, donde el aporte de las unidades motoras próximas al punto de medición tendrá mayor importancia que el de las alejadas debido a que tienen una mayor amplitud. El valor medio del pulso mioeléctrico es una medida de la energía promedio del conjunto de unidades motoras que intervienen en el movimiento [19].

Es válido aclarar que todos los rasgos empleados han sido tratados con anterioridad en la literatura, pero en escasas ocasiones de forma individual, como es el caso de los rasgos *MAV*, *WL*, *WAMP* y *AR* en [21], donde han presentado buenos índices de clasificación individual. Estos rasgos han sido referenciados en investigaciones donde se tratan y procesan formando parte de conjuntos o agrupaciones de ellos.

1.4. Métodos de selección de rasgos.

Existen etapas fundamentales durante el reconocimiento de patrones para su posterior procesamiento digital. Una etapa de extracción de rasgos se utiliza para aumentar la densidad de información de las señales EMG. Idealmente, la información de la discriminación durante la contracción debe mantenerse, mientras que la información irrelevante es descartada. Muchos métodos de extracción de rasgos EMG han sido investigados, incluyendo en el dominio del tiempo (TD) [22,23], las características autorregresivas (AR) y cepstrales [24,25,26]. Métodos de tiempo-frecuencia se han investigado para representar eficazmente patrones EMG transitorias resultantes de contracciones dinámicas [27,28]. En comparaciones de los conjuntos de características realizadas con anterioridad, se ha demostrado que, por diferentes que sean los patrones EMG, una característica concatenada de TD / AR (TDAR), establece una superioridad a todos los demás [26,27].

Si el conjunto de características de la selección de rasgos ocupa un espacio de alta dimensión, puede ser beneficioso para reducir la dimensionalidad del espacio de características, seleccionar uno o varios subconjuntos de ellas, o una combinación estratégica de funciones, como el promedio [28], el análisis de componentes principales [29,30], el análisis de componentes independientes [31], o la proyección no lineal [32].

1.4.1. Best Subset.

Esta técnica, encaminada a la reducción de la dimensionalidad de los datos, es empleada en el presente trabajo de diploma. Realiza una verificación del desempeño de los rasgos, y a su vez, conforma varios subconjuntos evaluando su correspondencia con la clase a la que pertenecen, a través de la clasificación al azar de los mismos. Posteriormente cada subconjunto es evaluado por su error aparente; y al final del procesamiento, se conservan solo los mejores subconjuntos.

1.4.2. Análisis de Componentes Principales.

El Análisis de Componentes Principales (PCA, por sus siglas en inglés) busca reducir el número de variables de una señal, transformando el conjunto original de variables correlacionadas, que tienen información en común, en un conjunto de variables totalmente independientes, que no tienen repetición o redundancia entre ellas, es decir, en una señal simplificada, conservando en el conjunto reducido la información contenida en cada una de las características del conjunto original. La técnica de componentes principales es debida a Hotelling (1933), aunque sus orígenes se

encuentran en los ajustes ortogonales por mínimos cuadrados introducidos por K. Pearson (1901). Su utilidad es doble:

- Permite representar óptimamente en un espacio de dimensión pequeña, observaciones de un espacio general p -dimensional. En este sentido, el Análisis de Componentes principales es el primer paso para identificar las posibles variables latentes, o no observadas que generan los datos.
- Permite transformar las variables originales generalmente correlacionadas, en nuevas variables no correlacionadas, facilitando la interpretación de los datos [33].

Parte de la señal en forma de matriz, $N_1 \times N_2$, realizando un mapeo lineal y seleccionando el número adecuado de componentes principales retenidos, hasta obtener una matriz simplificada, $N_1 \times N_3$, conformada por dichos componentes. Los nuevos componentes principales van a constituir una combinación lineal de los datos originales, y además, serán independientes entre sí. Este es un procedimiento automático que no requiere de la intervención humana para la selección de las características finales. Esta técnica de selección de características busca conformar el mejor subconjunto de características a partir de la selección de los mejores patrones del conjunto original.

El análisis PCA es uno de los métodos más efectivos en aplicaciones de reconocimiento de patrones y ampliamente utilizado con señales EMG [12,34,35,36]. Su inconveniente es que parte de la información contenida en el conjunto original se pierde definitivamente por el descarte de algunas de sus características, además requiere de la intervención humana para el proceso de selección o descarte.

1.5. Clasificadores de patrones electromiográficos.

Una vez realizada la extracción de características de la señal, y reducida la información redundante de los patrones, así como conformados los subconjuntos de rasgos a través de las técnicas de selección mencionadas con anterioridad, es necesario verificar el comportamiento de los mismos con el transcurso del tiempo. Para ello pueden emplearse varias técnicas de clasificación de patrones, parte complementaria e importante en el diseño de un sistema de prótesis completo, incrementando la precisión en el control del mismo [8,37].

La clasificación trata de asignar las diferentes partes del vector de características a grupos o clases, basándose en las características extraídas. En esta etapa se usa lo que se

conoce como aprendizaje automático, cuyo objetivo es desarrollar técnicas que permitan a las computadoras aprender.

Al igual que los investigadores pueden llegar a tener un conjunto extensivo de características, lo mismo se puede decir de los clasificadores. Posiblemente toda forma de estadística y aprendizaje de clasificación haya sido investigada ya para uso de control mioeléctrico.

Las opciones más populares de clasificadores, basadas en las ventajas de acuerdo al rendimiento de clasificación, incluyen el análisis discriminante lineal (LDA) [38], las máquinas de soporte vectorial [39,40], y los modelos de Markov [41,42].

1.5.1. Análisis Discriminante Lineal.

Un análisis discriminante lineal logra usar las características de un objeto para identificar a qué clase o grupo pertenece el mismo, tomando una decisión de clasificación basada en el valor de una combinación lineal de sus características. Las características de un objeto son típicamente presentadas en un vector llamado vector de características.

El LDA (como también se le conoce), utiliza hiperplanos para separar los datos en representación de las distintas clases. El hiperplano de separación se obtiene mediante la búsqueda de la proyección que maximiza la distancia entre las medias de las dos clases y minimiza la varianza entre clases. Para resolver el problema N (clases, $N > 2$), se utilizan varios hiperplanos [3].

Es costumbre utilizar este tipo de clasificadores en situaciones donde la velocidad de la clasificación es importante, ya que a menudo es el clasificador más rápido, especialmente cuando el vector de características reales es disperso. Además, los clasificadores lineales tienen un buen funcionamiento cuando el número de dimensiones del vector de características es grande, como en la clasificación de documentos, donde típicamente cada elemento es el número de apariciones de una palabra en el documento. En tal caso el clasificador debe estar bien regularizado.

El análisis discriminante lineal puede manejar fácilmente el caso en el que las frecuencias dentro de la clase no son iguales. Este método maximiza la relación de la varianza entre clase a la varianza dentro de clase, garantizando de este modo separabilidad máxima. Existen dos métodos para transformar los conjuntos de datos y

clasificar los vectores de prueba en el espacio transformado: a) transformación de clase dependiente, que maximiza la proporción de varianza entre clases dentro de varianza clase y b) la transformación de clase independiente, que maximiza la relación de la varianza total de la varianza dentro de la clase y cada clase se considera como una clase separada en contra de todas las demás [43].

El clasificador discriminante lineal ofrece una gran ventaja: su simplicidad de aplicación (específicamente incorporado en un procesador) y la facilidad de formación, entrenamiento y estrategia estadística a la hora de la clasificación de un conjunto de patrones.

1.6. Conclusiones parciales del capítulo.

Luego de la revisión bibliográfica realizada en este capítulo, encaminada a la búsqueda de antecedentes en el tema, se concluyó de que uno de los factores principales para la adquisición de señales electromiográficas, es la selección de los electrodos, el número a utilizar y su ubicación. Además; que la fatiga muscular es uno de los factores que afectan el funcionamiento y desempeño de las prótesis mioeléctricas; así como que existen rasgos temporales no paramétricos capaces de describir el comportamiento de las señales EMG.

CAPÍTULO 2. MATERIALES Y MÉTODOS

Todos los enfoques del reconocimiento de patrones electromiográficos tienen etapas fundamentales de procesamiento, encaminadas a eliminar interferencias no deseadas, y artefactos, debido a movimientos del electrodo de captura, así como aumentar la densidad de información de la propia señal, y descartar elementos irrelevantes.

Adquisición y pre-procesamiento.

La primera parte del proyecto consiste en la adquisición de la señal electromiográfica del sistema fisiológico brazo-antebrazo, para realizar su procesamiento digital en una PC. El modelo utilizado, es un modelo típico de instrumentación, conformado por sensores destinados a captar la señal; un amplificador diferencial de alta ganancia, debido a que la amplitud típica de las señales EMG es de aproximadamente 0,6 mV, evitando así distorsiones de la información contenida en la señal [6], y filtros. Además, un conversor análogo digital con una tarjeta de adquisición de datos y procesamiento para la detección de la señal característica de cada movimiento. Fig. 2.1.




Fig. 2.a) Esquema general de investigación.

Una vez amplificada la señal, se debe considerar la eliminación de las componentes de ruido de alta frecuencia por lo que se implementó un filtro Paso Alto de Butterworth de orden 3, y con una frecuencia de corte de 20 Hz, ya que a partir de esta frecuencia se encuentran las frecuencias útiles para nuestro trabajo.

Filtro Paso Alto de Butterworth, orden 3:

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

Además, se eliminó la componente típica de ruido de 60 Hz, y los armónicos impares consecutivos, es decir, las componentes de 180 Hz y la de 360 Hz, que es donde se concentra la mayor parte de la energía en las señales electromiográficas. Para ello se utilizó un filtro tipo “Notch”, de Butterworth, con Q=1, y su implementación consistió en tres filtros, o secciones de orden 2 cada una.

Filtro “Notch”, de Butterworth, tres secciones:

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

$$H(z)_2 = \frac{0,9845 - 1,6627z^{-1} + 0,9845z^{-2}}{1 - 1,6627z^{-1} + 0,9691z^{-2}} \quad (3)$$

$$H(z)_3 = \frac{0,9845 - 1,1575z^{-1} + 0,9845z^{-2}}{1 - 1,1575z^{-1} + 0,9691z^{-2}} \quad (4)$$

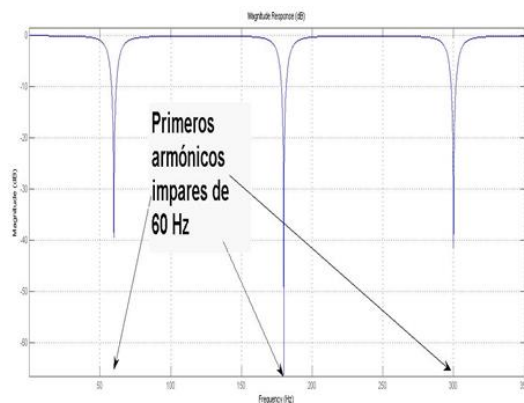


Fig. 2.b) Respuesta de frecuencia del Filtro Notch de Butterworth, Q=1.




Fig. 2.c) Respuesta de frecuencia del Filtro Paso Alto de Butterworth, orden 3.

Posición y número de electrodos.

Para la adquisición de las señales electromiográficas que conforman la Base de Datos a analizar, se utilizaron 6 electrodos del compuesto plata-cloruro de plata (Ag-AgCl), los cuales se revistieron 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. Esto introduce menos ruido eléctrico en la medida [7].

Fueron ubicados de forma equidistante alrededor del antebrazo, separados a 2 pulgadas del codo del paciente, siendo posible la recepción de una señal de un mismo movimiento por ubicaciones diferentes. Se utilizó para el desarrollo de la investigación un Sistema de adquisición comercial de la firma Delsys.

2.1. Base de Datos.

La Base de Datos fue conformada mediante la adquisición de señales electromiográficas a partir de 5 individuos discapacitados sanos de ambos sexos, con edades entre 24 y 36 años, los cuales realizaron 8 movimientos distintos (flexión/extensión de la muñeca, pronación/supinación de la muñeca, agarre fuerte/agarre de pinza, mano abierta y no movimiento).

Con el objetivo de inducir un nivel de fatiga muscular comparable al sufrido por pacientes con prótesis de miembro superior, cada uno de los movimientos se repitió 8 veces durante 3 segundos, 4 veces durante 10 segundos y 4 veces durante 30 segundos, dando en todos los casos un tiempo entre contracción de 2 segundos, lo cual fue incrementado los niveles de fatiga muscular en los pacientes.

2.2. Rasgos extraídos.

La extracción de rasgos es un paso importante en el reconocimiento de patrones. A partir de esta Base de Datos, para la investigación desarrollada, se extrajeron rasgos del dominio del tiempo, los cuales, posibilitaron establecer, como se muestra en otros apéndices, una comparación de los mismos.

2.2.1 Valor medio absoluto.

Este rasgo es un promedio absoluto de la señal de muestras en un segmento i determinado. Es una de las características basadas en estadísticos temporales, y está dada por la ecuación 5:

$$MAV = \frac{1}{N} \sum_{i=1}^N |X_i| \quad (5)$$

, donde X_i es la muestra y N es el tamaño total de la cantidad de muestras.

La implementación de esta ecuación para extraer los rasgos, fue hecha mediante la ayuda del software matemático Matlab.

2.2.2 Cruces por cero.

Para obtener el número de veces que la señal pasa por cero, fue necesario determinar un umbral th , lo cual permitió reducir los cruces por cero debido a la presencia de ruido en la señal por diversos factores. Este rasgo se puede calcular a través de la ecuación 6.

$$ZC = \sum_{i=1}^N \text{sgn}(-X_i * X_{i+1}) \quad \text{sgn} = \begin{cases} 1, X > th \\ 0, otros \end{cases} \quad (6)$$

, donde X_i es la muestra, N es el tamaño total de la cantidad de muestras, y th es el valor umbral, igual al 5% del valor de la amplitud promedio de la señal.

Se pudo evidenciar que para dos muestras consecutivas X_i y X_{i+1} , se incrementa el conteo de cruces por cero si:

$$X_k > 0 \text{ y } X_{k+1} < 0$$

y

$$X_k < 0 \text{ y } X_{k+1} > 0$$

ó

$$|X_k - X_{k+1}| \geq th$$

2.2.3. Cambio de signo de la pendiente.

A partir de la ecuación 7, se calcularon los rasgos de cambio de pendiente, importante en la predicción del contenido frecuencial de la señal EMG. Se seleccionó un umbral th para reducir los efectos del ruido.

$$NT = \sum_{i=1}^N \text{sgn}((X_{i+1} - X_i)(X_{i+2} - X_{i+1})) \quad \text{sgn} = \begin{cases} 1, X > th \\ 0, \text{otros} \end{cases} \quad (7)$$

, donde X_i es la muestra, N es el tamaño total de la cantidad de muestras, y th es el valor umbral, igual al 5% del valor de la amplitud promedio de la señal.

Se verificó además el incremento del cambio de pendiente, dadas tres muestras consecutivas X_{i-1} , X_i , X_{i+1} , si:

$$X_i > X_{i-1} \text{ y } X_i > X_{i+1}$$

ó

$$X_i < X_{i-1} \text{ y } X_i > X_{i+1}$$

y

$$|X_i - X_{k-1}| \geq th \text{ ó } |X_i - X_{i+1}| \geq th$$

2.2.4. Longitud de la forma de onda.

Para tener una idea de la amplitud, la frecuencia y la duración de la forma de onda de la señal, se calculó este rasgo mediante la ecuación 8, a partir de dos muestras consecutivas X_i y X_{i-1} .

$$WAVE = \sum_{i=1}^N |\Delta X_i| \quad \Delta X_i = X_i - X_{i-1} \quad (8)$$

donde X_i es la muestra y N es el tamaño total de la cantidad de muestras.

2.2.5. Varianza.

El cálculo de esta medida de dispersión en el dominio del tiempo, a partir de la ecuación 9, hizo visible la variabilidad de la señal en el transcurso del tiempo así como su comportamiento.

$$VAR = \frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2 \quad (9)$$

, donde X_i es la muestra y N es el tamaño total de la cantidad de muestras.

2.2.6. Promedio de los cambios de amplitud.

La ecuación 10 que define este rasgo, destaca variaciones bruscas en la señal, así como pendientes de la misma.

$$MAC = \frac{1}{N} \sum_{i=1}^N |X_{i+1} + X_i| \quad (10)$$

, donde X_i es la muestra y N es el tamaño total de la cantidad de muestras.

2.2.7. Coeficientes autorregresivos.

Basándose en que el espectro de la señal EMG cambia con el estado de la contracción muscular, son utilizados en varios trabajos los coeficientes autorregresivos como un rasgo para la clasificación de intención de movimiento. Por tanto, se toman estos datos como series temporales, y se emplea este rasgo con el fin de poder predecir valores y posteriores comportamientos de la señal.

$$X(n) = \sum_{i=1}^P a_i X_{n-1} + e_n \quad (11)$$

El Modelo AR está definido como la combinación lineal de las muestras anteriores más un factor de error; donde $X(n)$ es la señal EMG, a_i son los coeficientes autorregresivos del modelo, P denota el orden del modelo y e_n un término de error [2].

Este modelo también puede definirse por:

$$A(z) = 1 + \sum_{i=1}^P a_{i+1} z^{-1} \quad (12)$$

, donde $A(z)$ tiene los coeficientes normalizados del modelo.

El ser la señal EMG no estacionaria, consistía una limitación para nuestra investigación, sin embargo, basándonos en el planteamiento de Graup en 1978 [2], esta condición se suaviza si se escogen tramas de la señal de corta duración. Por lo que uno de los principales detalles de este modelo en nuestro trabajo fue el empleo de una ventana de 250 ms. El orden del modelo es otro de los parámetros a tener en cuenta, para lo cual se realizaron pruebas de ensayo de error, y se determinó el mejor resultado para un orden $P=4$.

En nuestra investigación se utilizó el método de modelo autorregresivo de Yule-Walker, el cual es también llamado método de la autocorrelación para encontrar un modelo autorregresivo (AR) de orden P de la señal de entrada x , minimizando por el método de mínimos cuadrados el error de predicción. La formulación conduce a las ecuaciones de Yule-Walker que se solucionan utilizando la recursión de Levinson-Durbin. Los coeficientes normalizados del modelo $A(z)$ se encuentran multiplicando potencias descendentes de z [2].

Este modelo puede definirse como:

$$H(z) = \frac{\sqrt{e}}{A(z)} = \frac{\sqrt{e}}{1 + a_2 z^{-1} + a_3 z^{-2} + \dots + a_{p+1} z^{-p}} \quad (13)$$

, donde e es un estimado de la varianza de la señal de entrada [2].

Si bien este modelo presenta como limitación el ser sensible a la amplitud de la señal, nuestro trabajo no se vió afectado por la misma, debido a que la amplitud de la señal EMG está en el orden de los μV .

Gracias al Modelo autorregresivo, se determinaron estos coeficientes, formando el conjunto de características requeridas, los cuales se emplearon para el entrenamiento de clasificación y comparación con otros grupos de rasgos.

2.2.8. Amplitud de Wilson.

Este rasgo, medida de la magnitud de la contracción muscular, se calculó mediante la ecuación 11.

$$WAMP = \sum_{i=1}^N f(|X_i - X_{i-1}|) \quad f(x) = \begin{cases} 1, & X > th \\ 0, & \text{otros} \end{cases} \quad (14)$$

, donde X_i es la muestra, N es el tamaño total de la cantidad de muestras, y th es el valor umbral, igual al 5% del valor de la amplitud promedio de la señal.

2.2.9. Valor medio del pulso mioeléctrico.

Esta medida, al ser un indicador promedio de la contribución de las unidades motoras que intervienen en el movimiento, y por tanto, en la contracción muscular, destaca el aporte de estas cuando rebasan un umbral determinado para que se produzca contracción. Para realizar su cómputo Se implementó la ecuación 12 en el Software Matlab.

$$MYOP = \frac{1}{N} \sum_{i=1}^N f(X_i) \quad f(x_i) = \begin{cases} 1, & |X_i| > th \\ 0, & |X_i| < th \end{cases} \quad (15)$$

, donde X_i es la muestra, N es el tamaño total de la cantidad de muestras, y th es el valor umbral, igual al 5% del valor de la amplitud promedio de la señal.

2.3. Técnicas de selección de rasgos a utilizar.

Para esta investigación se aplicaron varias técnicas de selección de rasgos con el objetivo de comprobar si existe distorsión o no de los mismos a lo largo del tiempo.

Todas las ecuaciones utilizadas para la extracción de rasgos de este capítulo, se implementaron en un programa del Software Matlab, el cual se muestra en el Anexo 1.

2.3.1. Best Subset.

Una vez extraídos los rasgos pertenecientes a cada paciente, con su correspondiente clase, se realizó la técnica de Best Subset, debido a que no todos los subconjuntos se comportan de la misma forma ante el transcurso del tiempo.

Al aplicar esta técnica, se realizó una verificación del desempeño de los rasgos, haciendo una selección de los mismos evitando su repetitividad. La forma de combinar los rasgos en este tipo de aplicaciones es compleja, en este caso, solamente las combinaciones desde 3 hasta 6 rasgos (como la mayoría de la bibliografía lo referencia, aunque el preferido es 4 rasgos por canal); y al realizar esta combinación con un total de 9 rasgos calculados se obtuvieron un número de combinaciones de 79128. Al mismo tiempo que se conformaron varios subconjuntos de rasgos, siendo evaluados luego en correspondencia con su respectiva clase. Posteriormente al procesamiento, solo se conservan los mejores subconjuntos.

Por esto en nuestro trabajo se seleccionaron las mejores combinaciones de variables (usualmente aparece un rasgo de un canal determinado pero no sus homólogos de los otros canales) y se le agregaron sus homólogos. De esta manera se construyen los subconjuntos desde FS2 hasta FS8. Los subconjuntos FS1, FS9 y FS10 se agregan de manera manual con propósitos de comparación.

2.4. Análisis Discriminante Lineal.

El Análisis Discriminante Lineal, al tener gran simplicidad de aplicación, entrenamiento y estrategia estadística, fue el utilizado en la investigación para evaluar el comportamiento de los subconjuntos de rasgos determinados. La clasificación en el proyecto se desarrolló de forma tal que se pudiera demostrar la degradación de los mismos, y con ellos, de la señal electromiográfica, con el paso del tiempo.

Para la implementación de este clasificador, uno de los parámetros más importantes a tener en cuenta es la probabilidad “a priori” de las clases de movimientos, la cual va a afectar la matriz de covarianza de las clases y la media de las mismas. En el caso en cuestión, consideramos una equiprobabilidad de las clases, con $p=1/8=0.125$. Ver Anexo 2.

2.5. Análisis Estadístico.

Puesto que de los datos obtenidos, no se puede asumir que se ajusten a una distribución conocida, se realiza la Prueba de Wilcoxon, o también conocida como Prueba de Mann-Whitney-Wilcoxon. Esta es una prueba no paramétrica que se usa para comprobar la heterogeneidad de dos muestras ordinales [44].

En el presente caso, la Prueba de Wilcoxon estuvo encaminada a demostrar si existe o no diferencias significativas entre los subconjuntos de rasgos que mostraron mejor y peor clasificación, teniendo como planteamiento de partida o hipótesis nula: “Las observaciones de ambos grupos son independientes.” Ver Anexo 3.

2.6. Conclusiones parciales del capítulo.

En este capítulo se detallan los materiales y métodos utilizados en la realización de este trabajo. Se describe la extracción de 9 rasgos característicos de las señales electromiográficas por cada uno de los 6 canales, con los cuales, empleando las técnicas de selección de rasgos Best Subset y Análisis de Componentes Principales, se conformaron 10 subconjuntos de rasgos. Se describe la utilización del clasificador Análisis Discriminante Lineal, y la realización de la prueba de Wilcoxon para determinar la significancia estadística del resultado.

CAPÍTULO 3. RESULTADOS Y DISCUSIÓN

Este capítulo aborda los resultados obtenidos en el proyecto de investigación, como la obtención de subconjuntos de rasgos, su posterior análisis y clasificación. Esto permitió evaluar el desempeño de cada subconjunto con el paso del tiempo. Las figuras y tablas de los resultados obtenidos apoyan los argumentos.

3.1. Obtención de subconjuntos de rasgos.

Para la selección de los rasgos se conformó una base de casos con información conjunta de todos los sujetos involucrados en el experimento. Mediante la aplicación de las técnicas de selección de rasgos, se conformaron varios subconjuntos de rasgos, combinando las familias de los de mayor varianza explicada en la base de casos combinada. Esto arrojó como resultado 7 subconjuntos nombrados desde el Fs2 hasta Fs8. Se incluyeron además, para comparación, 3 subconjuntos: Fs1 (*MVA, WL, ZC, NT*) debido a que constituye el subconjunto tomado como línea base en la mayoría de los trabajos; el Fs9 (*AR*, orden 4) para contar con los coeficientes autorregresivos de manera separada; y el Fs10, que incluye a todos los rasgos calculados por la obvia necesidad de comparar el desempeño de todos los subconjuntos juntos sin que sea realizable por cuestiones de costo computacional. Los subconjuntos conformados quedan expuestos en la Tabla 3.1.

Tabla 3.1 Subconjuntos de rasgos conformados a partir de las técnicas de selección de rasgos.

Fs	Rasgos conformantes	Rasgos por canales
Fs1	MAV, WL, ZC, NT	4
Fs2	WL, ZC, WAMP	3
Fs3	MAV, ZC, NT, WAMP	4
Fs4	MAV, WL, ZC, WAMP	4
Fs5	WL, ZC WAMP, VAR	4
Fs6	WL, ZC, NT, WAMP	4
Fs7	MAV, WL, ZC, NT, WAMP	5
Fs8	MAV, WL, ZC, NT, WAMP, AR	9
Fs9	AR	4
Fs10	MAV, WL, ZC, NT, WAMP, VAR, MAC, AR, MYOP	12

3.2. Clasificación.

Errores de clasificación de cada subconjunto o clases, así como el índice de sensibilidad de cada subconjunto, son parámetros determinados para dar cumplimiento a dicha demostración.

3.2.1. Clasificación aportada por los rasgos individuales.

Se realizó un análisis de cada uno de los rasgos de manera individual, donde el porcentaje de clasificación correcta, se muestra en la Fig. 3.2.1.




Fig. 3.2.1. Aporte de cada rasgo individual.

Haciendo un análisis de la gráfica que se muestra en la Fig. 3.2.1, se concluye que hay rasgos como WL (longitud de la forma de onda), WAMP (amplitud de Wilson), MAC (promedio del cambio de amplitud) y AR (coeficientes autorregresivos), que aportan más del 97% a la clasificación. Es decir, que pudieran ser rasgos que definen con mayor exactitud el comportamiento de las clases bajo estudio.

Sin embargo, no sucede lo mismo con los rasgos CS (cambio de signo de la pendiente), MYOP (valor medio del pulso mioeléctrico) y ZC (cruces por cero), debido a que su aporte es menor que el 85%. Esto indica que no son rasgos idóneos para el entrenamiento de un clasificador de prótesis mioeléctricas.

Hay que tener en cuenta que se utilizó el mismo subconjunto de casos para entrenar el modelo que para evaluarlo, por lo que se obtienen buenos desempeños de los rasgos individuales, y por tanto, altas tasas de clasificación.

3.2.2. Error de clasificación por subconjunto.

Cumpliendo con uno de los objetivos principales del proyecto, para verificar el comportamiento de los subconjuntos conformados, se implementó un clasificador basado en Análisis Discriminante Lineal. Los resultados de esta primera clasificación,

se muestran en la Tabla 3.2.2, donde queda expuesto el error de clasificación promedio por cada paciente estudiado.

Tabla 3.2.2 Error de clasificación por subconjunto en cada sujeto.

	Fs1	Fs2	Fs3	Fs4	Fs5	Fs6	Fs7	Fs8	Fs9	Fs10
1	2.2	2.28	2.349	2.326	2.257	2.234	2.257	1.974	2.141	2.28
2	3.287	3.692	3.437	3.542	3.241	3.484	3.003	3.31	2.72	3.229
3	0.278	0.544	0.104	0.347	0.428	0.417	0.278	0.266	0.289	0.674
4	2.129	2.986	3.044	2.963	3.044	2.5	2.546	1.783	2.454	2.396
5	0.718	0.879	0.833	0.891	0.891	0.879	0.787	0.822	0.741	1.053
Total Error	1.72	2.08	1.95	2.01	1.97	1.90	1.77	1.63	1.67	1.93
Clasif. Correcta	98.28	97.92	98.05	97.99	98.03	98.10	98.23	98.37	98.33	98.07

De la tabla anterior, se puede constatar la influencia de la fatiga muscular en la clasificación de la señal, ejerciendo en ella un nivel de deterioro perceptible. En la última fila de la tabla se exponen las tasas de clasificación correcta de cada subconjunto, de donde es apreciable que, en el caso del subconjunto Fs9 (Coeficientes autorregresivos), se corresponde con el porcentaje de clasificación correcta individual por rasgo. Es evidente también, en comparación con la clasificación individual, como el subconjunto Fs8, agrupa los rasgos de mejor desempeño individual, exceptuando uno solamente, el rasgo “cruces por cero”.

Además, no todos los pacientes tuvieron el mismo grado de degradación en los subconjuntos extraídos, ver Anexos 4, 5, 6, 7, 8. En cuanto al porcentaje global de clasificación de cada subconjunto, es perceptible en la Fig. 3.2.2 a).

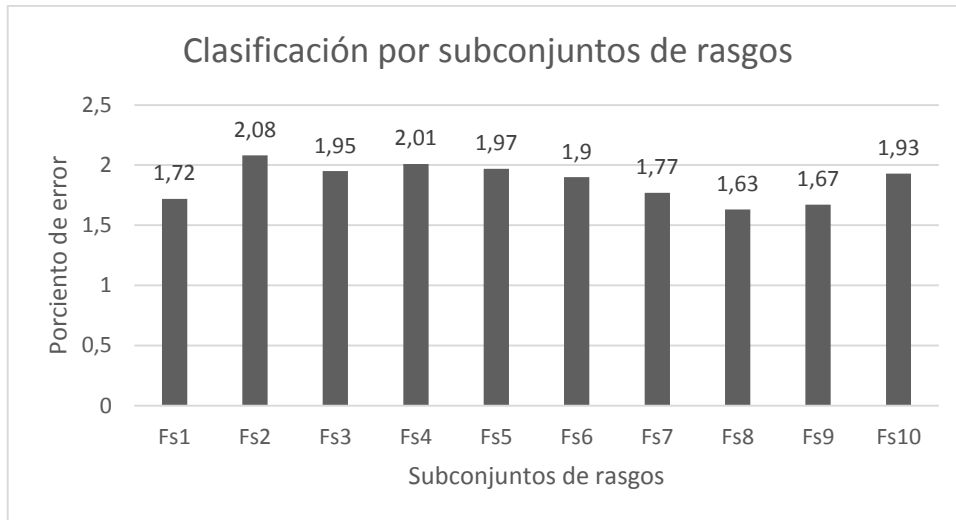


Fig.3.2.2 a) Porciento global de clasificación.

La gráfica anterior, muestra que el subconjunto con menor error de clasificación es el Fs8; y por tanto, el menos afectado a largo plazo debido a la fatiga muscular inducida en el experimento. Durante la clasificación a cada paciente, este subconjunto se mantuvo entre los cuatro de mejor desempeño, conjuntamente con el Fs9, Fs1 y Fs7.

La clasificación más afectada por la fatiga muscular, resultó ser la del subconjunto Fs2, mientras el Fs4, Fs5 y Fs3, también mostraron deterioro en dicho proceso.

Una idea aproximada de este gráfico a lo largo del tiempo durante los 30 segundos de la duración de los movimientos, divididos en tramas de 3 segundos, se apreciar en la Fig. 3.2.2 b).

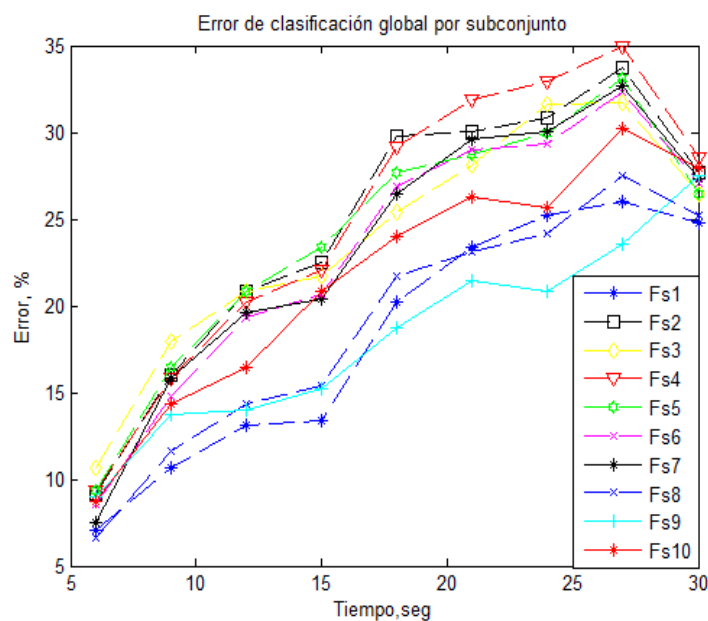


Fig. 3.2.2 b) Error de clasificación con respecto al tiempo.

3.2.3. Error de clasificación por clases.

El comportamiento de cada clase por sujeto estudiado, puede ser un resultado que aporte al experimento una idea de qué movimiento se afecta más debido a la fatiga muscular, partiendo de las clasificaciones de cada subconjunto.

A partir de estos, se verifica la distorsión en la señal de cada movimiento desarrollado, evidenciándose entonces su afectación debido a la fatiga muscular. La Tabla 3.2.3 muestra los resultados obtenidos.

Tabla 3.2.3 Error de clasificación por clase en cada paciente.

	C1	C2	C3	C4	C5	C6	C7	C8
1	0,657	0,343	5,898	0,037	0	0,222	0,704	2,229
2	0,028	4,37	7,482	9,907	0	0,009	2,815	0,787
3	0,176	0,389	1,482	0,306	0,37	0,046	0,371	0,046
4	0,556	4,879	3,389	1,454	1,398	0,37	0,722	7,093
5	0,352	0,009	0	0,037	0,028	0,185	6,12	0,056
Total	0,354	1,998	3,65	2,348	0,359	0,166	2,146	2,042

De la tabla anterior, se evidencia que no todas los movimientos se afectan de igual forma por la fatiga muscular inducida durante el experimento. La Fig. 3.2.3 muestra la media de clasificación para cada clase de movimiento.

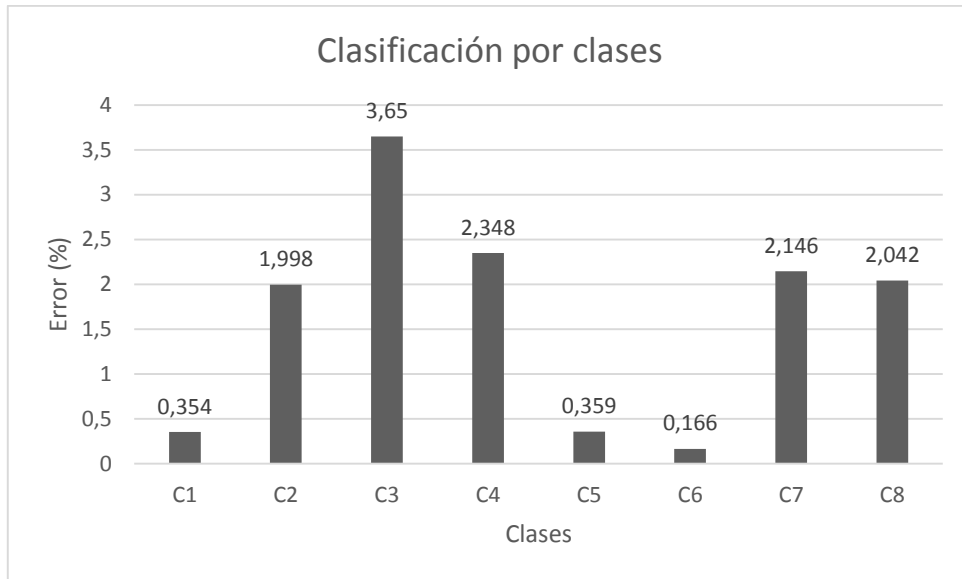


Fig. 3.2.3 Promedio de clasificación por clase

Como se puede comprender, la clase menos afectada ante el paso del tiempo, debido a la fatiga muscular por sostener un movimiento durante 30 segundos, es la clase 6 o “puño cerrado”, con un 0,178% de error aproximadamente. Conjuntamente a ella, las clases 5 y 1, son las dos de mejor comportamiento.

Además, se pudo constatar que no todas las clases en cada uno de los sujetos participantes en el experimento, se ve afectada de igual manera, ver Anexo 9.

3.2.3.1. Índice de sensibilidad.

A partir de las clasificaciones anteriores, se obtuvo como resultado de este experimento el índice de sensibilidad de cada subconjunto. Este índice no es más que el análisis del comportamiento de cada variable por sujeto participante en el experimento, y matemáticamente, es la razón entre la media y la varianza elevada a un coeficiente igual a $\alpha/2$, del porcentaje de clasificación correcta. La ecuación que nos permitió determinar dicho índice:

$$I = \frac{\frac{1}{N} \sum_{i=1}^N CA_i}{\left[\frac{1}{N-1} \sum_{i=1}^N \left(CA_i - \frac{1}{N} \sum_{i=1}^N CA_i \right)^2 \right]^{\alpha/2}} \quad (16)$$

Teniendo los valores de media y varianza, se calculó el índice de estabilidad para cada uno de ellos, mostrados en la Tabla 3.2.3.1.

Tabla 3.2.3.1 Índice de sensibilidad por subconjunto.

	Fs1	Fs2	Fs3	Fs4	Fs5	Fs6	Fs7	Fs8	Fs9	Fs10
Índice	94,47	92,26	91,23	92,17	93,54	93,86	95,06	95,33	96,74	97,20

La clasificación del subconjunto Fs8, es la menos afectada por la fatiga muscular a largo plazo, siendo su media de clasificación correcta la más elevada. Además, haciendo un análisis del índice obtenido, se puede constatar que el subconjunto que menos variabilidad presentó durante la clasificación de los mismos en cada sujeto fue el que agrupa todos los rasgos extraídos, el Fs10.

Esta medida muestra como mejor desempeño el Fs10, sin embargo, los subconjuntos Fs8 y Fs9 presentan similares resultados con menos cantidad de rasgos agrupados. Es de destacar además, el hecho de que 5 subconjuntos muestran índices por debajo del 94,47 % mostrado por el Fs1, que se toma como línea base en este proyecto.

Desde el punto de vista del costo computacional, el subconjunto de mayor costo es el Fs10 puesto a que es el que agrupa todos los rasgos extraídos de las señales. En comparación con este, el Fs8 es el próximo en cantidad de rasgos agrupados, pero resultó ser el que tuvo un mejor comportamiento durante la clasificación. El Fs9 agrupa solamente los coeficientes autorregresivos, por lo que su costo es el menor, y además, tiene la segunda mejor tasa de clasificación correcta. Los demás subconjuntos, agrupan menos rasgos que el Fs8, por lo que el costo computacional también es menor.

3.2.4. Clasificación por tramas.

Este procesamiento se llevó a cabo gracias a un programa computacional, implementado en el Software Matlab. Aplicando Análisis Discriminante Lineal, se extrajeron las tramas de señal a los 3s, 10s y 30s. Posteriormente, se calcula la variabilidad por tramas a lo largo del tiempo en cada sujeto, a partir de las variables de error total y error total activo.

3.2.4.1. Error total.

Esta variable no es más que el porcentaje de la razón del número de decisiones incorrectas y el número total de decisiones. El error total fue calculado para cada uno de

los sujetos de la muestra, y luego se calculó la media de error de clasificación por trama y se muestra en la Fig. 3.2.4.1 a), donde es apreciable el deterioro de la señal electromiográfica por cada trama estudiada, debido a la fatiga muscular, durante el transcurso del tiempo.




Fig. 3.2.4.1 a) Error Total promedio de clasificación de cada sujeto por tramas.

Es notable el deterioro sufrido por la señal a los 30 segundos de duración, llegando a alcanzar un promedio entre los sujetos de 26,28% de error de clasificación.

Para un mejor entendimiento, se muestra la gráfica de la Fig. 3.2.4.1 c), donde se grafican estos datos por cada trama, durante el transcurso del tiempo.




Fig. 3.2.4.1 b) Media del error total de clasificación por trama.

Como se hace evidente, la variable medida aumenta con el paso del tiempo en cada uno de los sujetos, demostrando el deterioro de la clasificación de los subconjuntos de rasgos.

3.2.4.2. Error Activo.

Otras de las variables determinadas para mostrar el deterioro de los subconjuntos de rasgos es el Error Activo, que no es más que el porcentaje de la razón del número de decisiones activas incorrectas y el número total de decisiones, la cual debe aumentar también a medida que pasa el tiempo.

Al igual que en el sub-apéndice anterior, se determinó una media global de dicha variable por cada trama, para hacer más comprensible estos resultados, mostrándose en la Fig. 3.2.4.2 a).




Fig. 3.2.4.2 a). Error Total Activo promedio de clasificación de cada sujeto por tramas.

Igualmente, ocurrió un aumento del error de clasificación luego de haber transcurrido 30 segundos de comenzar a inducir la fatiga muscular.

Además, para una mejor visualización, se muestra en la Fig. 3.2.4.2 b), una gráfica con la “trayectoria” que realiza la variable Error Activo a través del paso del tiempo, donde por lo general, se aprecia un aumento de la misma, debido a la presencia de fatiga muscular, y por tanto, un deterioro de la señal electromiográfica.

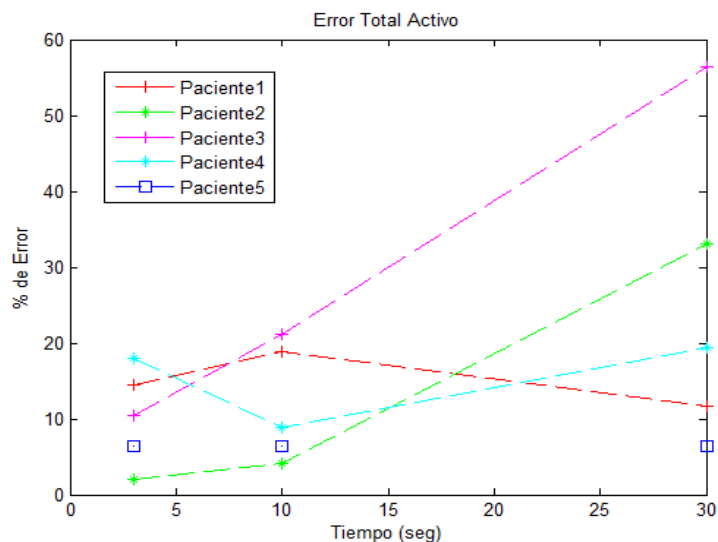


Fig. 3.2.4.1 b) Media del Error Activo de clasificación por trama.

3.3. Análisis estadístico.

El análisis estadístico se realizó con el objetivo de demostrar si existen o no diferencias significativas entre los subconjuntos de rasgos de mejor y peor desempeño, según la clasificación. En este caso resultaron el Fs8 y Fs2 respectivamente.

El valor de “p” obtenido fue de 0.5476, para $h=0$, lo que hace que se acepte la hipótesis de que los subconjuntos tienen distribuciones y medianas iguales, lo cual indica que todos los rasgos se degradan con el tiempo debido a la fatiga muscular, y no se puede afirmar de que existe una diferencia estadísticamente significativa entre ellos.

3.4. Conclusiones parciales del capítulo.

Luego de los procesamientos realizados a los subconjuntos de rasgos determinados, se analizaron los resultados obtenidos en este capítulo y se concluye que:

- La clasificación del subconjunto Fs8 fue la de menor error de clasificación, conjuntamente con el Fs9 y Fs10; sin embargo el subconjunto Fs9, solo agrupa a los coeficientes autorregresivos, mientras que el Fs10 reúne todos los rasgos extraídos.
- Las clases 6, 1 y 5 (puño cerrado, no movimiento y pronación de la muñeca), son las menos afectadas a largo plazo por la presencia de fatiga muscular; resultando la de peor comportamiento la clase 3 o “extensión de la muñeca”.

-
- El subconjunto más sensible entre los sujetos resultó el que agrupa todos los rasgos extraídos, mientras que el de mayor variabilidad fue el Fs3.
 - Se evidencia una cierta dispersión entre los sujetos.

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

La realización de los experimentos y los resultados alcanzados en este trabajo permiten arribar a las siguientes conclusiones:

- El subconjunto con menos variación en el experimento realizado aplicando Análisis Discriminante Lineal fue el Fs8, integrado por los rasgos *MAV*, *ZC*, *NT*, *WL*, *AR*, *WAMP*.
- El subconjunto que agrupa a todos los rasgos extraídos (Fs10), es el de menos variabilidad por sujeto, el de mayor variabilidad resultó el subconjunto Fs3.
- No existe diferencia estadísticamente significativa entre los subconjuntos de mayor y menor índice de estabilidad, por lo que en todos los casos se puede concluir que la presencia de fatiga muscular afecta el desempeño de la extracción de características, y a su vez, de la clasificación de los subconjuntos de rasgos.

Recomendaciones

Una limitación de este trabajo es que no se cuantifica el índice de fatiga muscular, por lo que, aunque la hipótesis de que ésta debe afectar el desempeño se confirma, no queda claro desde el punto de vista cuantitativo los valores críticos de fatiga. Por otro lado, solo se han tenido en cuenta rasgos dominio-temporales, lo que si bien está en correspondencia con la necesidad de procesamiento en tiempo real, sesga el resultado desde el punto de vista científico. Teniendo en cuenta lo anterior, se proponen las siguientes recomendaciones:

- Cuantificar el índice de fatiga muscular que presente el paciente.
- Utilizar uno de los subconjuntos con menor cantidad de rasgos para entrenar el clasificador.
- Extender esta investigación a rasgos que no sean del dominio temporal.

REFERENCIAS BIBLIOGRÁFICAS

1. Farry, K., Walker, I., Baraniuk, R. “Myoelectric Teleoperation of a Complex Robotic Hand”. IEEE Transaction On Robotic and Automation, Vol. 12, No. 5, October 1996.
2. Baquero, F., Fredy, J., Giraldo Suarez, E. “reconocimiento de patrones de movimiento del sistema fisiológico brazo-antebrazo, a partir de señales electromiográficas”, Universidad Tecnológica de Pereira, 2004.
3. Rodríguez Doncel, V. “Entrenador para el control de prótesis mioeléctricas”, 2001.
4. 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. 11-19, 2002.
5. Davies, E. J., Fenz. B. R., Clippenger, W. “Statistics on Hand and Arm Loss”, The Disability Statistics Center at the University of California, San Francisco, Estados Unidos, 2012.
6. Kaufmann, P., Englehart, K., Platzner, M. “Fluctuating EMG Signals: Investigating Long-term Effects of Pattern Matching Algorithms”, 32nd Annual International Conference of the IEEE EMBS, Buenos Aires, Argentina, 2010.
7. Scheme, E., Biron, K., Englehart, K. “Improving Myoelectric Pattern Recognition Positional Robustness Using Advanced Training Protocols”, 33rd Annual International Conference of the IEEE EMBS, Boston, Massachusetts USA, 2011.
8. Zecca, M., Micera, S., Carroza, M., Dario, P., “Control Of Multifunctional Prosthetic Hands By Processing The Electromyographic Signal”, Critical Reviews™ in Biomedical Engineering. Vol. 30, pp. 459 485. 2002.

9. Reaz, M. B. I., Hussain, M. S., Mohd-Yasin, F. "Techniques of EMG Signal Analysis: Detection, Processing, Classification and Applications", *Biological Procedures Online*, vol. 8, issue 1, pp. 11–35, March 2006.
10. Basmajian, J. V., De Luca, C. J. "Muscles alive. Their function revealed by electromyography", Williams & Wilkens, Baltimore, 1985.
11. Duda, R., Hart, P., Stork, D. "Pattern classification", 2ª edición, Wiley, New York, cap. 1, pp. 11-12, 2001.
12. Englehart, K., Hudgins, B., Parker, P., "A Wavelet Based Continuous Classification Scheme for Multifunction Myoelectric Control", Department of Electrical and Computer Engineering and the Institute of Biomedical Engineering, University of New Brunswick, Canada, Vol. 48, pp. 302-311, 2001.
13. Gerdle, B., Karlsson, S., Day, S., Djupsjobacka, M. "Acquisition, Processing and Analysis of the Surface Electromyogram", *Modern Techniques in Neuroscience*, Ed. Windhorst U. & Johanson H. Springer Verlag, Berlín, cap.26, pp.705-712, 1999.
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. DU, S., Vuskovic, M., "Temporal vs. Spectral Approach to Feature Extraction from Prehensile EMG Signals", Department of Computer Science, San Diego State University, 2003.
16. Romo, H. A., Realpe, J. C., Jojoa, P.E., "Surface EMG Signals Analysis and Its Applications in Hand Prosthesis Control", Universidad Del Cauca, 2007.
17. Ostrovsky, L. A., Potapov, A. S. "Modulated Waves, Theory and Applications", Baltimore: The Johns Hopkins University Press, 1999.
18. Murray, S., "Estadística", McGraw-Hill, México, 1970.
19. Fougner, A. "Proportional myoelectric control of a multi-function upper limb prosthesis", Ms. Tesis, 2007, Norwegian University of Science and Technology, Trondheim, Norway.
20. Tkach, D., Huang, H. and Kuiken, T.A. "Study of stability of time-domain features for electromyographic pattern recognition." *Journal of NeuroEngineering and Rehabilitation*, s.l. : BioMed, 2010.

21. Boostani R., Moradi M. H. "Evaluation of the forearm EMG signal features for the control of a prosthetic hand Tesis", 2003.
22. Lee S., Saridis G. "The control of a prosthetic arm by EMG pattern recognition" IEEE TransAutoControl, 1984.
23. Zardoshti-Kermani, M., Wheeler, B. C., Badie, K., Hashemi, R. M. "EMG feature evaluation for movement control of upper extremity prostheses", IEEE TransRehabilitationEng, 1995.
24. Doerschuk, P. C., Gustafson, D. E., Willsky, A. S. "Upper extremity limb function discrimination using EMG signal analysis", IEEE TransBiomedEng. 1983.
25. Graupe, D., Salahi, J., Kohn, K. H. "Multifunctional prosthesis and orthosis control via microcomputer identification of temporal pattern differences in single site myoelectric signals", J BiomedEng. 1982.
26. Huang, Y., Englehart, K. B., Hudgins, B., Chan, A. D. "A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses", IEEE Trans BiomedEng, 2005.
27. Hargrove, L. J., Englehart, K., Hudgins B. "A comparison of surface and intramuscular myoelectric signal classification", IEEE TransBiomedEng, 2007.
28. Lucas, M. F., Gaufriau, A., Pascual, S., Doncarli, C., Farina, D. "Multi-channel surface EMG classification using support vector machine and signal based wavelet optimization", BiomedSignalProcessControl, 2008.
29. Englehart, K., Hudgins, B., Parker, P. A., Stevenson, M. "Classification of the myoelectric signal using time-frequency based representations", MedEngPhys, 1999.
30. Hargrove, L. J., Li, G., Englehart, K. B., Hudgins, B. S. "Principal components analysis preprocessing for improved classification accuracies in pattern recognition based myoelectric control", IEEE TransBiomedEng. 2009.
31. Naik, G. R., Kumar, D. K., Palaniswami, M. "Surface EMG based hand gesture identification using semiblind ICA: Validation of ICA matrix analysis", ElectromyogrClinNeurophysiol, 2008.
32. Gallant, P. J., Morin, E. L., Peppard, L. E. "Feature based classification of myoelectric signals using artificial neural networks", MedBiolEngComput, 1998.

33. Englehart, K., Hudgins, B., Parker P. "A Wavelet-Based Continuous Classification Scheme for Multifunction Myoelectric Control", IEEE, 2001.
34. Yücel, K., Mehmet, K. "EMG Signal Classification Using Wavelet Transform And Fuzzy Clustering Algorithms", Istanbul Technical University, Faculty of Electrical and Electronics Engineering, Department of Electronics and Communication Engineering, Ayazaga, Istanbul, Turkey, 2002.
35. Zhang, X., Yang, Y., Xu, X., Zhang, J., Gao, Z., Hu, T., Chen, T., Chen, Z. "Clinical Detection and Movement Recognition of Neuro Signal", Journal of Zhenjian University SCIENCE, 2004.
36. Zhang, X., Yang, Y., Xu, X. Zhang, Ming. "Wavelet Based Neuro Fuzzy Classification for EMG Control", Department of Automation, Shanghai Jiaotong University, Shanghai, China. Vol. 2, pp. 1087-1089, 2002.
37. Reaz, M., Hussain, M., MohdYasin, F., "Techniques of EMG Signal Analysis: Detection, Processing, Classification and Applications", Faculty of Engineering, Multimedia University, Cyberjaya, Selangor, Malaysia. Vol. 8, pp. 11 35, 2006.
38. Englehart, K., Hudgins, B. "A robust, real-time control scheme for multifunction myoelectric control", IEEE TransBiomedEng, 2003.
39. Winkler, M., Boschmann, A., Kaufmann, P., Platzner, M. "Towards multi-movement hand prostheses: combining adaptive classification with high precision socket", Proceedings of the 2nd European Conference on Technically, Berlin, Germany, AssistedRehabilitation, 2009.
40. Yang, D., Zhao, J., Gu, Y., Jiang, L., Liu, H. "EMG pattern recognition and grasping force estimation: Improvement to the myocontrol of multi-DOF prosthetic hands", Proceedings of the 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems; St. Louis (MO), Piscataway (NJ): IEEE Press, 2009.
41. Chan, A. D., Englehart, K. B. "Continuous myoelectric control for powered prostheses using hidden Markov models", IEEE TransBiomedEng, 2005.
42. Li, Y., Chen, X., Tian, J., Zhang, X., Wang, K., Yang, J. "Automatic recognition of sign language sub-words based on portable accelerometer and EMG sensors", Proceedings of the International Conference on Multimodal Interfaces and the Workshop on Machine Learning for Multimodal Interaction; Beijing, China, 2010.

-
43. Balakrishnamaand, S., Ganapathiraju, A. "Linear discriminant analysis a brief tutorial", Institute for Signal and information Processing, 1998.
 44. Gibbons, J. D. "Nonparametric Statistical Inference". New York, 1985.

ANEXOS

Anexo I “Programación en Matlab para la extracción de los rasgos.”

```

fs = salida.fs;
win_ms = 250;
inc_ms = 250;
win = win_ms * fs/1000;
inc = inc_ms * fs/1000;
length_3s = fs * 3;
%%
flat = 0;
for index = 1:8 % para las 8 clases de movimiento
    clase = salida.outbyclass(1,index).name;
    datos_rep = salida.outbyclass(1,index).data; % todas las repeticiones de una misma
    clase
    reps = length(datos_rep);
    MVA_ch1 = []; MVA_ch2 = []; MVA_ch3 = []; MVA_ch4 = []; MVA_ch5 = []; MVA_ch6 = [];
    ZC_ch1 = []; ZC_ch2 = []; ZC_ch3 = []; ZC_ch4 = []; ZC_ch5 = []; ZC_ch6 = [];
    NT_ch1 = []; NT_ch2 = []; NT_ch3 = []; NT_ch4 = []; NT_ch5 = []; NT_ch6 = [];
    WL_ch1 = []; WL_ch2 = []; WL_ch3 = []; WL_ch4 = []; WL_ch5 = []; WL_ch6 = [];
    VAR_ch1 = []; VAR_ch2 = []; VAR_ch3 = []; VAR_ch4 = []; VAR_ch5 = []; VAR_ch6 = [];
    MAC_ch1 = []; MAC_ch2 = []; MAC_ch3 = []; MAC_ch4 = []; MAC_ch5 = []; MAC_ch6 = [];
    AR_ch1 = []; AR_ch2 = []; AR_ch3 = []; AR_ch4 = []; AR_ch5 = []; AR_ch6 = [];
    WAMP_ch1=[];WAMP_ch2=[];WAMP_ch3=[];WAMP_ch4=[];WAMP_ch5=[];WAMP_ch6=[];
    MYOP_ch1=[]; MYOP_ch2=[]; MYOP_ch3=[]; MYOP_ch4=[]; MYOP_ch5=[]; MYOP_ch6=[];
    for ch = 1:6 % para cada uno de los 6 canales
        datos_ch = salida.outbyclass(1,index).data(1,reps).dat(:,ch);
        frame = enframe(datos_ch,win,inc);
        [f,c] = size(frame);
        for index1 = 1:f
            x1 = frame(index1,:);
            MVA = myMVAcalc(x1);
            ZC=myZeroCrosscalc(x1);
            NT=myNumberTurncalc(x1);
            WL=myWaveLengtcalc(x1);
            VAR=myVARcalc(x1);
            MAC=myMACcalc(x1);

```

```
AR=mylpcconv(x1);AR = AR(2:end);
WAMP=myWAmplitudecalc(x1);
MYOP=myMyopulsecalc(x1);
switch ch
case 1
MVA_ch1 = [ MVA_ch1;MVA ];
ZC_ch1 = [ ZC_ch1;ZC ];
NT_ch1 = [ NT_ch1;NT ];
WL_ch1 = [ WL_ch1;WL ];
VAR_ch1 = [ VAR_ch1;VAR ];
MAC_ch1 = [ MAC_ch1;MAC];
AR_ch1 = [ AR_ch1;AR ];
WAMP_ch1 = [ WAMP_ch1;WAMP ];
MYOP_ch1 = [ MYOP_ch1;MYOP ];
case 2
MVA_ch2 = [ MVA_ch2;MVA ];
ZC_ch2 = [ ZC_ch2;ZC ];
NT_ch2 = [ NT_ch2;NT ];
WL_ch2 = [ WL_ch2;WL ];
VAR_ch2 = [ VAR_ch2;VAR ];
MAC_ch2 = [ MAC_ch2;MAC];
AR_ch2 = [ AR_ch2;AR ];
WAMP_ch2 = [ WAMP_ch2;WAMP ];
MYOP_ch2 = [ MYOP_ch2;MYOP ];
case 3
MVA_ch3 = [ MVA_ch3;MVA ];
ZC_ch3 = [ ZC_ch3;ZC ];
NT_ch3 = [ NT_ch3;NT ];
WL_ch3 = [ WL_ch3;WL ];
VAR_ch3 = [ VAR_ch3;VAR ];
MAC_ch3 = [ MAC_ch3;MAC];
AR_ch3 = [ AR_ch3;AR ];
WAMP_ch3 = [ WAMP_ch3;WAMP ];
MYOP_ch3 = [ MYOP_ch3;MYOP ];
case 4
MVA_ch4 = [ MVA_ch4;MVA ];
ZC_ch4 = [ ZC_ch4;ZC ];
NT_ch4 = [ NT_ch4;NT ];
WL_ch4 = [ WL_ch4;WL ];
VAR_ch4 = [ VAR_ch4;VAR ];
MAC_ch4 = [ MAC_ch4;MAC];
AR_ch4 = [ AR_ch4;AR ];
WAMP_ch4 = [ WAMP_ch4;WAMP ];
MYOP_ch4 = [ MYOP_ch4;MYOP ];
```

```

case 5
    MVA_ch5 = [ MVA_ch5;MVA ];
    ZC_ch5 = [ ZC_ch5;ZC ];
    NT_ch5 = [ NT_ch5;NT ];
    WL_ch5 = [ WL_ch5;WL ];
    VAR_ch5 = [ VAR_ch5;VAR ];
    MAC_ch5 = [ MAC_ch5;MAC];
    AR_ch5 = [ AR_ch5;AR ];
    WAMP_ch5 = [ WAMP_ch5;WAMP ];
    MYOP_ch5 = [ MYOP_ch5;MYOP ];

case 6
    MVA_ch6 = [ MVA_ch6;MVA ];
    ZC_ch6 = [ ZC_ch6;ZC ];
    NT_ch6 = [ NT_ch6;NT ];
    WL_ch6 = [ WL_ch6;WL ];
    VAR_ch6 = [ VAR_ch6;VAR ];
    MAC_ch6 = [ MAC_ch6;MAC];
    AR_ch6 = [ AR_ch6;AR ];
    WAMP_ch6 = [ WAMP_ch6;WAMP ];
    MYOP_ch6 = [ MYOP_ch6;MYOP ];

end
end

allfeatures = [MVA_ch1,MVA_ch2,MVA_ch3,MVA_ch4,MVA_ch5,MVA_ch6];
allfeatures =[allfeatures,ZC_ch1,ZC_ch2,ZC_ch3,ZC_ch4,ZC_ch5,ZC_ch6];
allfeatures =[allfeatures,NT_ch1,NT_ch2,NT_ch3,NT_ch4,NT_ch5,NT_ch6];
allfeatures =[allfeatures,WL_ch1,WL_ch2,WL_ch3,WL_ch4,WL_ch5,WL_ch6];
allfeatures =[allfeatures,VAR_ch1,VAR_ch2,VAR_ch3,VAR_ch4,VAR_ch5,VAR_ch6];
allfeatures =[allfeatures,MAC_ch1,MAC_ch2,MAC_ch3,MAC_ch4,MAC_ch5,MAC_ch6];
allfeatures =[allfeatures,AR_ch1,AR_ch2,AR_ch3,AR_ch4,AR_ch5,AR_ch6];
allfeatures =[allfeatures,WAMP_ch1,WAMP_ch2,WAMP_ch3,WAMP_ch4,WAMP_ch5,WAMP_ch6];
allfeatures =[allfeatures,MYOP_ch1,MYOP_ch2,MYOP_ch3,MYOP_ch4,MYOP_ch5,MYOP_ch6];

[filas,colum] = size(allfeatures);
numericclass = repmat(index,filas,1);
matrix = cat(2,allfeatures,numericclass);
filas = filas + flat;
rango = strcat('A',num2str(1+flat),' :BU',num2str(filas));
flat = filas;
xlswrite('FEATURES',matrix,salida.subject,rango);

end

```

Anexo II “Programación en Matlab para la clasificación de los subconjuntos de rasgos.”

```
fs1=data;
%%
fs2=data;
%%
fs3=data;
%%
fs4=data;
%%
fs5=data;
%%
fs6=data;
%%
fs7=data;
%%
fs8=data;
%%
fs9=data;
%%
fs10=data;
%%
inicio = 1;
fin = inicio + 11;
rasgos1 = fs1(inicio:fin,1:end-1);
clase1 = fs1(inicio:fin,end);
rasgos2 = fs2(inicio:fin,1:end-1);
clase2= fs2(inicio:fin,end);
rasgos3 = fs3(inicio:fin,1:end-1);
clase3= fs3(inicio:fin,end);
rasgos4 = fs4(inicio:fin,1:end-1);
clase4= fs4(inicio:fin,end);
rasgos5 = fs5(inicio:fin,1:end-1);
clase5 = fs5(inicio:fin,end);
rasgos6 = fs6(inicio:fin,1:end-1);
clase6 = fs6(inicio:fin,end);
rasgos7 = fs7(inicio:fin,1:end-1);
clase7 = fs7(inicio:fin,end);
rasgos8 = fs8(inicio:fin,1:end-1);
clase8= fs8(inicio:fin,end);
rasgos9 = fs9(inicio:fin,1:end-1);
clase9= fs9(inicio:fin,end);
rasgos10 = fs10(inicio:fin,1:end-1);
clase10 = fs10(inicio:fin,end);
for i = 1:7
```

```
    inicio = inicio +120;
    fin = inicio +11;
    rasgos1 = [rasgos1;fs1(inicio:fin,1:end-1)];
    clase1 = [clase1; fs1(inicio:fin,end)];
    rasgos2 = [rasgos2;fs2(inicio:fin,1:end-1)];
    clase2 = [clase2;fs2(inicio:fin,end)];
    rasgos3 = [rasgos3;fs3(inicio:fin,1:end-1)];
    clase3 = [clase3; fs3(inicio:fin,end)];
    rasgos4 = [rasgos4;fs4(inicio:fin,1:end-1)];
    clase4 = [clase4; fs4(inicio:fin,end)];
    rasgos5 = [rasgos5;fs5(inicio:fin,1:end-1)];
    clase5 = [clase5; fs5(inicio:fin,end)];
    rasgos6 = [rasgos6;fs6(inicio:fin,1:end-1)];
    clase6 = [clase6; fs6(inicio:fin,end)];
    rasgos7 = [rasgos7;fs7(inicio:fin,1:end-1)];
    clase7 = [clase7; fs7(inicio:fin,end)];
    rasgos8 = [rasgos8;fs8(inicio:fin,1:end-1)];
    clase8 = [clase8; fs8(inicio:fin,end)];
    rasgos9 = [rasgos9;fs9(inicio:fin,1:end-1)];
    clase9 = [clase9; fs9(inicio:fin,end)];
    rasgos10 = [rasgos10;fs10(inicio:fin,1:end-1)];
    clase10 = [clase10; fs10(inicio:fin,end)];

end

A1 = dataset(rasgos1,clase1);
A2 = dataset(rasgos2,clase2);
A3 = dataset(rasgos3,clase3);
A4 = dataset(rasgos4,clase4);
A5 = dataset(rasgos5,clase5);
A6 = dataset(rasgos6,clase6);
A7 = dataset(rasgos7,clase7);
A8 = dataset(rasgos8,clase8);
A9 = dataset(rasgos9,clase9);
A10 = dataset(rasgos10,clase10);

%%

W_1 = fisherc(A1);
W_2 = fisherc(A2);
W_3 = fisherc(A3);
W_4 = fisherc(A4);
W_5 = fisherc(A5);
W_6 = fisherc(A6);
W_7 = fisherc(A7);
W_8 = fisherc(A8);
W_9 = fisherc(A9);
W_10 = fisherc(A10);

%%

for in = 1:9
```

```
inicio = 12*in+1;
fin = inicio+11;
rasgos1 = fs1(inicio:fin,1:end-1);
clase1 = fs1(inicio:fin,end);
rasgos2 = fs2(inicio:fin,1:end-1);
clase2 = fs2(inicio:fin,end);
rasgos3 = fs3(inicio:fin,1:end-1);
clase3 = fs3(inicio:fin,end);
rasgos4 = fs4(inicio:fin,1:end-1);
clase4 = fs4(inicio:fin,end);
rasgos5 = fs5(inicio:fin,1:end-1);
clase5 = fs5(inicio:fin,end);
rasgos6 = fs6(inicio:fin,1:end-1);
clase6 = fs6(inicio:fin,end);
rasgos7 = fs7(inicio:fin,1:end-1);
clase7 = fs7(inicio:fin,end);
rasgos8 = fs8(inicio:fin,1:end-1);
clase8 = fs8(inicio:fin,end);
rasgos9 = fs9(inicio:fin,1:end-1);
clase9 = fs9(inicio:fin,end);
rasgos10 = fs10(inicio:fin,1:end-1);
clase10 = fs10(inicio:fin,end);

for i = 1:7
    inicio = inicio +120;
    fin = inicio +11;
    rasgos1 = [rasgos1;fs1(inicio:fin,1:end-1)];
    clase1 = [clase1;fs1(inicio:fin,end)];
    rasgos2 = [rasgos2;fs2(inicio:fin,1:end-1)];
    clase2 = [clase2;fs2(inicio:fin,end)];
    rasgos3 = [rasgos3;fs3(inicio:fin,1:end-1)];
    clase3 = [clase3;fs3(inicio:fin,end)];
    rasgos4 = [rasgos4;fs4(inicio:fin,1:end-1)];
    clase4 = [clase4;fs4(inicio:fin,end)];
    rasgos5 = [rasgos5;fs5(inicio:fin,1:end-1)];
    clase5 = [clase5;fs5(inicio:fin,end)];
    rasgos6 = [rasgos6;fs6(inicio:fin,1:end-1)];
    clase6 = [clase6;fs6(inicio:fin,end)];
    rasgos7 = [rasgos7;fs7(inicio:fin,1:end-1)];
    clase7 = [clase7;fs7(inicio:fin,end)];
    rasgos8 = [rasgos8;fs8(inicio:fin,1:end-1)];
    clase8 = [clase8;fs8(inicio:fin,end)];
    rasgos9 = [rasgos9;fs9(inicio:fin,1:end-1)];
    clase9 = [clase9;fs9(inicio:fin,end)];
    rasgos10 = [rasgos10;fs10(inicio:fin,1:end-1)];
    clase10 = [clase10;fs10(inicio:fin,end)];
end
```

```
end

B1 = dataset(rasgos1,clase1);
B2= dataset(rasgos2,clase2);
B3 = dataset(rasgos3,clase3);
B4 = dataset(rasgos4,clase4);
B5 = dataset(rasgos5,clase5);
B6 = dataset(rasgos6,clase6);
B7 = dataset(rasgos7,clase7);
B8 = dataset(rasgos8,clase8);
B9 = dataset(rasgos9,clase9);
B10 = dataset(rasgos10,clase10);

tiempo1 = in*3; tiempo2 = (in+1)*3; tiempo = strcat(tiempo2,'-',tiempo1);
output_1 = B1*W_1;
disp('FS1');
disp(tiempo);
confmat(output_1);
E_FS1(in) = testc(B1,W_1,'soft');

output_2 = B2*W_2;
disp('FS2');
disp(tiempo);
confmat(output_2);
E_FS2(in) = testc(B2,W_2,'soft');

output_3 = B3*W_3;
disp('FS3');
disp(tiempo);
confmat(output_3);
E_FS3(in) = testc(B3,W_3,'soft');

output_4 = B4*W_4;
disp('FS4');
disp(tiempo);
confmat(output_4);
E_FS4(in) = testc(B4,W_4,'soft');

output_5 = B5*W_5;
disp('FS5');
disp(tiempo);
confmat(output_5);
E_FS5(in) = testc(B5,W_5,'soft');

output_6 = B6*W_6;
disp('FS6');
```

```
disp(tiempo);
confmat(output_6);
E_FS6(in) = testc(B6,W_6,'soft');

output_7 = B7*W_7;
disp('FS7');
disp(tiempo);
confmat(output_7);
E_FS7(in) = testc(B7,W_7,'soft');

output_8 = B8*W_8;
disp('FS8');
disp(tiempo);
confmat(output_8);
E_FS8(in) = testc(B8,W_8,'soft');

output_9 = B9*W_9;
disp('FS9');
disp(tiempo);
confmat(output_9);
E_FS9(in) = testc(B9,W_9,'soft');

output_10 = B10*W_10;
disp('FS10');
disp(tiempo);
confmat(output_10);
E_FS10(in) = testc(B10,W_10,'soft');

end
%%
figure;
plot(100*E_FS1,'-*b');
hold on;
plot(100*E_FS2,'-+r');
hold on;
plot(100*E_FS3,'g');
hold on;
plot(100*E_FS4,'c');
hold on;
plot(100*E_FS5,'m');
hold on;
plot(100*E_FS6,'k');
hold on;
plot(100*E_FS7,'-c');
hold on;
plot(100*E_FS8,'y');
```

```

hold on;
plot(100*E_FS9, 'b');
hold on;
plot(100*E_FS10, '--rs');
hold on;
title('Error de clasificación por subconjunto de rasgos');
ylabel('Error, %');
xlabel('Tiempo');
legend('FS1', 'FS2', 'FS3', 'FS4', 'FS5', 'FS6', 'FS7', 'FS8', 'FS9', 'FS10');
hold off;

```

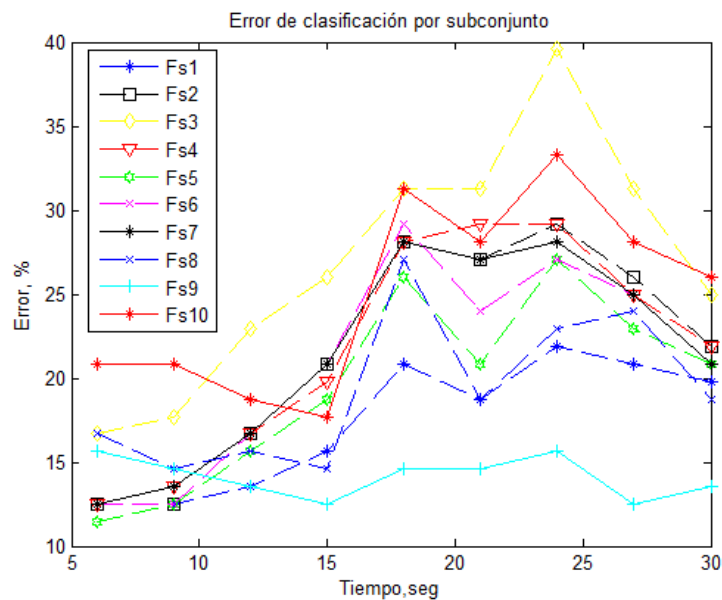
Anexo III “Programación en Matlab para la Prueba de Wilcoxon.”

```

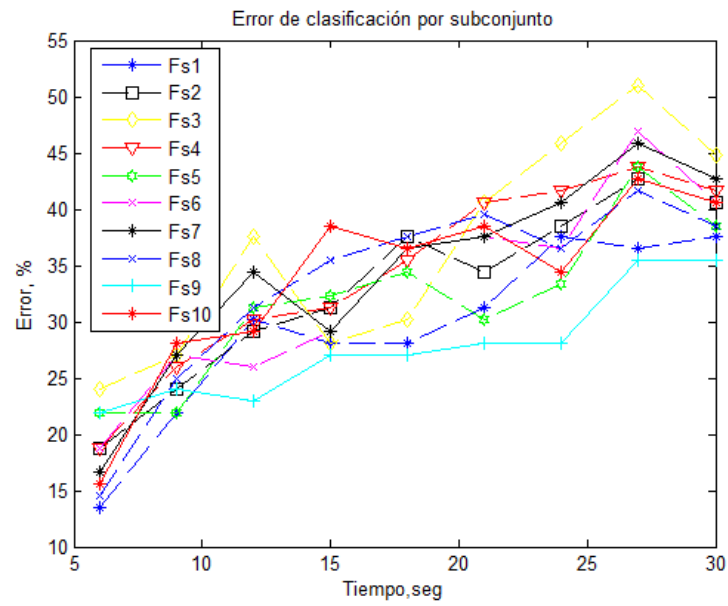
%%
X=[2.2  2.28  2.349  2.326  2.257  2.234  2.257  1.974  2.141  2.28
3.287  3.692  3.437  3.542  3.241  3.484  3.003  3.31  2.72  3.229
0.278  0.544  0.104  0.347  0.428  0.417  0.278  0.266  0.289  0.674
2.129  2.986  3.044  2.963  3.044  2.5  2.546  1.783  2.454  2.396
0.718  0.879  0.833  0.891  0.891  0.879  0.787  0.822  0.741  1.053];
%%
fs2=X(:,2);
fs8=X(:,8);
[p,h]=ranksum(fs2,fs8);

```


Anexo IV “Clasificación de subconjuntos de rasgos con Análisis Discriminante Lineal. Sujeto 1.”



Anexo V “Clasificación de subconjuntos de rasgos con Análisis Discriminante Lineal. Sujeto 2.”



Anexo VI “Clasificación de subconjuntos de rasgos con Análisis Discriminante Lineal. Sujeto 3.”



Anexo IX “Clasificación de las clases con Análisis Discriminante Lineal”.