

**Análisis de Señales Electromiográficas de
Superficie para la Estimación de Estados de Fatiga
Muscular Mediante el Uso de la Transformada
Wavelet y Regresión Logística Binaria.**

Luis Alfonso Flórez Prias

Trabajo de grado para optar al título de

**Magister en Ingeniería con
Énfasis en Eléctrica y Electrónica**

Director: Sonia Contreras,PhD.

**Universidad Tecnológica de Bolívar
Facultad de Ingeniería
Cartagena**

Enero 18 de 2018

**Análisis de Señales Electromiográficas de
Superficie para la Estimación de Estados de Fatiga
Muscular Mediante el Uso de la Transformada
Wavelet y Regresión Logística Binaria.**

Luis Alfonso Flórez Prias
Director: Sonia Contreras, PhD.

**Universidad Tecnológica de Bolívar
Facultad de Ingeniería
Maestría en Ingeniería con Énfasis en Eléctrica y Electrónica
Cartagena**

Enero 18 de 2018

UNIVERSIDAD TECNOLÓGICA DE BOLÍVAR
FACULTAD DE INGENIERÍA

Título: Análisis de Señales Electromiográficas de Superficie para la Estimación de Estados de Fatiga Muscular Mediante el Uso de la Transformada Wavelet y Regresión Logística Binaria.

Autor: Luis Alfonso Flórez Prias

Jurado

Jurado

Director:

Cartagena, Enero 18 de 2018

Resumen

La fatiga muscular no solo conlleva a la disminución del rendimiento físico de un individuo, sino también al aumento del riesgo de sufrir lesiones a nivel muscular, es por ello que el propósito de la presente investigación consiste en predecir dichos estados de fatiga (Ausencia/Presencia) al realizar actividades físicas repetitivas. Para ello la señal Electromiográfica (EMG) fue sometida a un proceso de extracción de características mediante el uso de la Transformada Discreta de Wavelet (DWT) con el ánimo de obtener las variables independientes (Coeficientes de energía y Voltaje RMS) requeridas por el algoritmo clasificador de regresión logística binaria. Con esta estrategia se obtuvieron resultados por encima del 85 % de probabilidad para pronosticar la ocurrencia de fatiga muscular, lo que la convierte en una buena herramienta de clasificación de dichos estados.

Agradecimientos

En primer lugar agradezco a Dios por permitirme alcanzar esta nueva meta en mi vida profesional, de igual manera a mi familia en especial a mi madre por el apoyo incondicional en todas las aventuras que emprendo.

A La Universidad Tecnológica de Bolívar por darme la oportunidad de ser parte de su comunidad estudiantil y haber puesto en mi camino personas con una calidad humana admirable.

A mi directora de tesis y profesora Dra. Sonia Contreras quien con su conocimiento, experiencia, motivación, pero sobretodo paciencia fue pieza clave para la culminación de esta nueva etapa con éxito.

También agradezco a los profesores que durante estos dos años hicieron parte activa de este proceso de crecimiento profesional, en especial a los docentes: José Luis Villa, Juan Carlos Martínez, Oscar Acevedo y Andrés Marrugo.

Índice general

1. Introducción	15
1.1. Planteamiento del Problema	15
1.2. Justificación	15
1.3. Estado del Arte	17
1.3.1. La Fatiga Muscular	17
1.3.2. Importancia de su Detección a Tiempo	17
1.3.3. Aplicaciones y Usos	17
1.3.4. Trabajos Relacionados	19
1.4. Objetivos	22
1.4.1. Objetivo General	22
1.4.2. Objetivos Específicos	23
1.5. Nuestra Contribución	23
2. Marco Teórico	25
2.1. Biopotenciales	25
2.1.1. Unidades Anatómicas y Motoras	26

2.1.2.	Contracción Muscular y su Proceso Eléctrico	26
2.2.	Señales Electromiográficas de Superficie	27
3.	Marco Experimental	29
3.1.	Extracción de Características	29
3.1.1.	Adquisición de la Señal EMG	29
3.1.2.	Actividad Física del Experimento	30
3.1.3.	Delimitación de la Señal	31
3.1.4.	Transformada Discreta de Wavelet	32
	Selección Wavelet Madre	34
	Selección de Niveles de Descomposición Wavelet	34
	Selección Wavelet Madre tipo Daubechies	35
3.2.	Clasificación de Patrones	37
3.2.1.	Regresión Logística Binaria	37
3.2.2.	Base de Datos del Experimento	39
3.2.3.	Algoritmo Clasificador	40
4.	Resultados y Discusión	45
4.1.	Comparación de Parámetros Característicos	47
4.2.	Resultado del Clasificador	48
4.3.	Prueba Diagnóstica	49
4.3.1.	Matriz de Confusión	49

4.3.2. Determinantes de la Eficacia de la Prueba	50
4.4. Trabajo Futuro	52
5. Conclusiones	53
Bibliografía	55

Lista de Figuras

2.1. Esquema representativo del mecanismo básico de control y de los componentes de las unidades Motoras (Sale, 1991, Roberto Merletti and Parker, 2004) [14]	27
2.2. Representación gráfica de la descomposición de la señal EMG de superficie en componentes de potenciales de acción de su unidad motora. (Adaptado de De Luca et al. 1982a) [5]	28
3.1. Adquisición de la señal EMG	30
3.2. Cambios de la señal EMG de un estado de reposo hasta uno de fatiga muscular	31
3.3. Señal EMG durante una contracción muscular	32
3.4. Descomposición de la señal EMG mediante DWT.(Adaptado de M. S. Hussain 2012) [8]	33
3.5. Wavelet Madre tipo Daubechies	34
3.6. Niveles de descomposición DWT- Coeficientes de aproximación	35

3.7.	Descomposición de la señal usando wavelet Daubechies Db[1,2,4,10,45] como Wavelet Madre	36
3.8.	Base de Datos - Experimento Fatiga	41
4.1.	(a) Contracción muscular en ausencia de fatiga - (b) Contracción muscular en presencia de fatiga	46
4.2.	Descomposición de la señal en términos de la frecuencia - Ausencia de fatiga muscular	46
4.3.	Descomposición de la señal en términos de la frecuencia - Presencia de fatiga muscular	47
4.4.	Modelo de regresión logística binaria de variable dependiente cualitativa	50

Lista de Tablas

3.1. Covarianza Wavelet Madre - Daubechies.	36
4.1. Comparación de Coeficientes: Músculo Fatigado Vs No Fatigado . . .	48
4.2. Matriz de Confusión - FP: Falsos positivos, FN: Falsos Negativos, VP: Verdaderos Positivos, VN: Verdaderos Negativos, TP: Total Positivos, TN: Total Negativos, CP: Condición Positiva, CN: Condición Negativa	50

Capítulo 1.

Introducción

1.1. Planteamiento del Problema

Cualquier actividad física sea laboral, deportiva o cotidiana que requiera realizar un esfuerzo físico prolongado o repetitivo suele verse afectado por la fatiga muscular. Dicho estado trae consigo una reducción en el rendimiento físico y un aumento considerable del riesgo de sufrir lesiones a nivel muscular. Las señales EMG de superficie entrega la información necesaria para detectar y predecir dichos estados de fatiga.

El éxito de la presente investigación recae en la exactitud y eficiencia de los algoritmos de procesamiento de la señal EMG para estimar y clasificar los parámetros de fatiga muscular al realizar actividades físicas repetitivas. Para ello se consideró una etapa de extracción de características y otra de clasificación.

1.2. Justificación

En el mundo deportivo la diferencia entre ganar o perder puede ser cuestión de milésimas de segundos, por lo que los deportistas debe estar preparados para hacer frente

a un sinnúmero de variables tanto intrínsecas como extrínsecas que pueden afectar su desempeño y por consiguiente el resultado de cualquier competencia. En un proceso de entrenamiento el objetivo es mejorar dichos parámetros, realizar un seguimiento y determinar aspectos para corregir o mejorar.

La Organización Mundial de la Salud (OMG) en su nota descriptiva de Junio de 2016, define la actividad física como cualquier movimiento corporal producido por los músculos esqueléticos, con el consiguiente consumo de energía. Ello incluye las actividades realizadas al trabajar, jugar y viajar, las tareas domésticas y las actividades recreativas que no debe ser confundida con “ejercicio”, que es una subcategoría de la misma [11].

Díaz Murillo, en su ensayo “La Actividad Física Deportiva: Más allá de lo Saludable” [6] en 2004, hace una reflexión entre la actividad física deportiva, cuerpo y salud en la que resalta que la primera no necesariamente fortalece la salud, sino que por el contrario puede ocasionar daño físicos e incluso mentales si no se realiza adecuadamente, aquí es donde recae la importancia del presente estudio ya que se busca obtener una herramienta para monitorizar el desempeño muscular de una persona en aras de contrarrestar dichos factores intrínsecos relacionados a la fatiga muscular.

1.3. Estado del Arte

1.3.1. La Fatiga Muscular

La fatiga muscular puede definirse como la disminución de la capacidad de un músculo para generar fuerza, lo que conlleva a otras complicaciones que pueden afectar la salud y el rendimiento de una persona sea cual sea su ocupación (obreros, campesinos, militares, deportistas, etc.) limitando la realización de sus actividades físicas diarias. En el caso particular de los deportistas, un entrenamiento intenso, inadecuado y sin supervisión puede traer efectos negativos para su desempeño ocasionando incluso lesiones, por lo que para este caso “El deporte no necesariamente es salud”.

1.3.2. Importancia de su Detección a Tiempo

Los recientes avances en estudios fisiológicos han demostrado la importancia de la detección y predicción de la fatiga muscular en diversos aspectos de nuestras vidas, incluyendo deportes, rehabilitación y ergonomía. El reto actual consiste en automatizar dicha detección y predicción en tecnologías vestibles, ya que no es mucho lo que se ha hecho al respecto [1].

1.3.3. Aplicaciones y Usos

Actualmente las tecnologías vestibles han tomado gran auge y aceptación en el mundo científico debido a su versatilidad y aplicabilidad. La tendencia actual apunta cada vez más al uso de dispositivos sensoriales que se adaptan a la anatomía de las

personas para la adquisición de señales biomédicas. Esta tendencia está alineada con la presente investigación ya que a través de este tipo de tecnologías se puede entender el comportamiento muscular de una persona al realizar determinada actividad física. El marco de aplicaciones de presente estudio abarca los siguientes frentes [1]:

Deportes y Acondicionamiento Físico

- Rendimiento deportivo.
- Uso correcto del trabajo muscular tanto en términos de economía de esfuerzo como de rentabilidad y prevención de lesiones.

Medicina Deportiva

- Evaluación funcional de los procesos musculares.
- Respuesta a terapias de rehabilitación médica.

Medicina Ocupacional y Ergonomía

- Estudio ergonómico y análisis de la carga de trabajo.
- Prevención de la fatiga muscular en las actividades de las ocupaciones humanas.
- Análisis de marcha en estudios de fatiga muscular

1.3.4. Trabajos Relacionados

Con el ánimo de hacer frente al reto de determinar un método de extracción de características que brinde la información más relevante, necesaria y suficiente para obtener parámetros ocultos dentro de las señales Electromiográficas (EMG) y que permitan estimar el comportamiento muscular en términos de fatiga se han desarrollado varios estudios en los que se resalta la investigación realizada en 2012 por A. Phinyomark, P. Pornchai Phukpattaranont y C. Limsakul titulada “Feature reduction and selection for EMG signal classification” donde analiza las propiedades de 37 diferentes tipos de características tanto en el dominio del tiempo como de frecuencia suministrando las herramientas necesarias para el análisis de dicha señal [13].

En este mismo año M. Yochum, T. Bakir, R. Lepers y S. Binczak dirigieron sus investigaciones hacia el estudio “Estimation of Muscular Fatigue Under Electromyostimulation Using CWT” donde proponen un nuevo índice de fatiga basado en la Transformada Wavelet. Dicho índice es comparado con otros índices de fatiga como es el caso de la Frecuencia Media, Mediana y factor RMS (Root Mean Square) obtenidos de sujetos con problemas musculares, para lo cual se hizo necesario implementar un sistema estimulador eléctrico muscular con el objetivo de emular los impulsos eléctricos necesarios para contraer el músculo [15]. Como aporte a la presente investigación, además de ratificar el desempeño de dicho índice al momento de detectar fatiga muscular, también se corroboró que los índices obtenidos con la transformada

Wavelet son menos propensos a las perturbaciones de ruido que los índices basados en frecuencia como la media y la mediana.

También en 2012 los autores M. S. Hussain y Md. Mamun publicaron la investigación “Effectiveness of the wavelet transform on the surface EMG to understand the muscle fatigue during walk” demostrando que mediante el uso de la transformada Wavelet se puede observar una diferencia significativa entre una contracción muscular en presencia y ausencia de fatiga. Este estudio reafirma a la Transformada Wavelet como la piedra angular del método de extracción de características a utilizar para la presente investigación [8].

Hablando en términos de fatiga muscular en el ámbito deportivo, en 2015 Giorgio Biagetti, Alessandro Curzi y Simone Orcioni publicaron “Analysis of the EMG Signal During Cyclic Movements Using Multicomponent AM - FM Decomposition” donde propusieron una técnica para extraer índices tanto de fatiga muscular como de cadencia en ejercicios provenientes de señales electromiográficas al realizar actividades que requieren la ejecución de movimientos repetitivos [2].

En 2015 J.L. Correa-Figueroa implementó un sistema para la adquisición, análisis y procesamiento de señales EMG utilizando LabVIEW y Matlab, para lo cual se obtuvieron ciertos componentes en el dominio de frecuencia necesarios para detectar fatiga muscular, tales como: Transformada de Fourier, densidad espectral de potencia y frecuencia media instantánea. En este estudio, las etapas de amplificación y filtrado

se implementaron en componentes discretos [4].

Tomando en cuenta el artículo de investigación mencionado, se observó que aunque el objetivo principal de dicho estudio era detectar fatiga muscular, la mayor parte de la investigación se centró en la implementación del circuito electrónico en discreto. No obstante, la etapa de extracción de características de la señal EMG descrita brinda información valiosa en cuanto al procesamiento de señales mediante la Transformada Rápida de Fourier.

También en 2015 M. Montoya enfocó su investigación “Surface EMG based muscle fatigue detection using a low-cost wearable sensor and amplitude frequency analysis” en probar un sensor de bajo costo tipo Myo, con el fin de realizar análisis de amplitud y frecuencia de la señal EMG. El estudio revela la factibilidad de utilizar este tipo de sensor para la cuantificación de la fatiga muscular [12].

Como trabajo futuro M. Montoya propone la validación de lo expuesto con grupos estadísticamente significativos, así como la inclusión de nuevos sensores de bajo coste tipo Kinect para la medición de movimiento.

El objetivo de la investigación presentada en 2013 por R.H. Chowdhury “Surface Electromyography Signal Processing and Classification Techniques” consistió en obtener información relevante sobre la eliminación de ruido y artefactos comúnmente asociados a las señales EMG, explorando varias metodologías de extracción de características. Este estudio enfatizó los algoritmos y metodologías utilizadas para la

detección, procesamiento y clasificación de señales EMG [3].

Por último también se tomó como referencia la investigación “Identification of motion from multi-channel EMG signals for control of prosthetic hand” realizada en 2011 por P. Geethanjali, en donde los autores proponen una eficiente técnica de reconocimiento de patrones de señales EMG para el control de mano protésica basados en el Análisis de Regresión Logística (SLR). Este resultado fue obtenido después de compararlo con clasificadores tales como Árboles de Decisiones (DT), Redes Neuronales (NN) y Análisis Discriminante Lineal (LDA). Además de obtener una alta exactitud utilizando dicho clasificador (SLR), también ofrece ventajas significativas en cuanto a espacio de memoria, tiempo de procesamiento y al porcentaje de error promedio de clasificación, el cual de acuerdo a dicho estudio se encuentra por debajo del 10 % a diferencia del resto de clasificadores analizados [7].

1.4. Objetivos

1.4.1. Objetivo General

Determinar la probabilidad de ocurrencia de estados de fatiga muscular mediante el procesamiento de señales EMG obtenidas de personas al realizar actividades físicas cíclicas.

1.4.2. Objetivos Específicos

- Obtener la señal EMG de tipo superficial producida por la contracción muscular al realizar determinada actividad física.
- Realizar el proceso de acondicionamiento de la señal mediante su amplificación y filtrado con el objeto de mitigar ruidos y/o artefactos que la puedan afectar.
- Seleccionar la técnica de extracción de características más adecuada.
- Estimar la probabilidad de estados de fatiga muscular al ejecutar actividades físicas repetitivas.
- Contrastar los resultados concernientes a los índices de fatiga obtenidos con diferentes individuos bajo las mismas condiciones experimentales.

1.5. Nuestra Contribución

La contribución principal del presente trabajo investigativo se fundamenta en el procesamiento, descomposición y análisis de señales EMG haciendo uso tanto de la transformada Discreta de Wavelet como la implementación de un algoritmo de clasificación basado en el análisis de regresión logística binario. Gracias a lo anterior se logró la implementación de una técnica eficiente que permita predecir la ocurrencia de fatiga muscular en una persona al ejecutar actividades físicas repetitivas. Parte de los resultados de este trabajo de grado se presentaron en el 13th International Symposium

on Medical Information processing and analysis con la ponencia: Analysis of sEMG signals using discrete wavelet transform for muscle fatigue detection [10].

Capítulo 2.

Marco Teórico

2.1. Biopotenciales

La electricidad se encuentra presente de muchas formas en la naturaleza, de tal forma que el cuerpo humano no es la excepción. En él podemos encontrar pequeños impulsos eléctricos mediante los cuales se llevan a cabo funciones importantes del organismo: latir del corazón, respirar, pensar, el fenómeno de la vista etc. Uno de los primeros en contribuir en el campo de la actividad eléctrica en el cuerpo fue Luigi Galvani, quien en 1786 descubrió la electricidad animal en una extremidad de rana haciendo pasar corriente eléctrica en los nervios de la extremidad y se percató que se producía un movimiento como respuesta al estímulo eléctrico [14].

Desde un punto de vista fisiológico, las funciones realizadas por el cuerpo humano son llevadas a cabo a través de impulsos eléctricos, que a su vez son el resultado de la acción electroquímica de ciertos tipos de células, dichas células generan la diferencia de potencial mediante partículas ionizadas tales como iones de sodio y potasio. Muchos de estos intercambios de potenciales tienen lugar en el cerebro, el cual envía

la orden en forma de impulsos eléctricos los cuales son transportados a otra parte del cuerpo a través del sistema nervioso mediante las neuronas, estas no son más que células especializadas en recibir y transmitir impulsos eléctricos a los que se les denomina potenciales de acción. Dichas descargas eléctricas viajan a través de la membrana celular y es el principal medio de comunicación entre tejidos y células dentro del cuerpo humano [15].

2.1.1. Unidades Anatómicas y Motoras

A nivel muscular se puede diferenciar dos unidades estructurales denominadas unidad anatómica y unidad funcional. La primera es la llamada fibra muscular formada por células alargadas de aspecto filamentoso que son contráctiles y constituyen el tejido muscular, mientras que la segunda recibe el nombre de unidad motora y está conformada por un grupo de fibras musculares inervado por una sola neurona motora. Realizar un simple movimiento requiere la intervención de muchas neuronas tanto sensoriales como motoras, que trabajando en conjunto logran ejecutar la acción indicada.

2.1.2. Contracción Muscular y su Proceso Eléctrico

El funcionamiento eléctrico del cuerpo humano al realizar una contracción muscular es el siguiente: se genera la orden en el cerebro en forma de un impulso eléctrico, este impulso viaja a través de la espina dorsal y llega hasta las motoneuronas responsables de inervar el músculo que realizará la acción estimulando las fibras musculares,

produciendo así la expansión o inhibición del músculo. Cabe mencionar que para realizar un movimiento complejo, como por ejemplo la extensión o flexión del brazo, intervienen muchas motoneuronas y no puede lograrse solo estimulando un único músculo debido a que está ligado a más de una Unidad Motora [14].




Figura 2.1: Esquema representativo del mecanismo básico de control y de los componentes de las unidades Motoras (Sale, 1991, Roberto Merletti and Parker, 2004) [14]

2.2. Señales Electromiográficas de Superficie

En una contracción muscular voluntaria la fuerza es modulada por un serie de cambios en la frecuencia de la actividad de las Unidades Motoras (UMs), es decir que la frecuencia de disparo de los potenciales de las UMs depende de la fuerza aplicada y

la velocidad de contracción muscular, por lo que se puede decir que la señal EMG es una señal aleatoria que consiste en la suma de los potenciales de acción de todas las unidades motoras activas en la zona. [5].




Figura 2.2: Representación gráfica de la descomposición de la señal EMG de superficie en componentes de potenciales de acción de su unidad motora. (Adaptado de De Luca et al. 1982a) [5]

Capítulo 3.

Marco Experimental

El presente trabajo analiza los cambios que aparecen en la señal EMG al realizar actividades físicas repetitivas hasta llegar al límite de resistencia corporal en donde el músculo es incapaz de mantener cierto nivel de fuerza. Para lo cual se extraen las características de dicha señal e implementa un algoritmo de predicción de estados de fatiga. El procedimiento se divide en las siguientes etapas: Una de extracción de características mediante la descomposición Wavelet y otra etapa de clasificación a través de regresión logística binaria.

3.1. Extracción de Características

3.1.1. Adquisición de la Señal EMG

La adquisición de la señal se realizó con un sensor EMG de superficie (AT-04-001, MyoWare, Raleigh, NC) con una impedancia de entrada de $110G\Omega$, corriente de alimentación de 9mA y relación de rechazo a modo común de 110. Dicho sensor se ubicó sobre el músculo flexor radial del carpo de un voluntario con el fin de observar cómo se comporta eléctricamente dicho músculo. También se utilizó un sensor de presión

(Flexiforce Sensor A201) para determinar en qué momento el sujeto de pruebas es incapaz de mantener cierto nivel de fuerza. Posteriormente los sensores fueron conectados a una placa de microcontrolador Arduino UNO utilizando su módulo ADC para digitalizar la señal a una frecuencia de muestreo de 8928 Hz propia del mismo. (Ver Figura 3.1)

3.1.2. Actividad Física del Experimento

Como primer ejercicio físico se le pidió al sujeto mantener apretado al máximo un Hand Grip durante cinco segundos, luego relajar la mano igual periodo de tiempo y posteriormente repetir el proceso hasta que el músculo sea incapaz de responder. Este procedimiento permitió observar cómo es el comportamiento de la señal EMG al pasar de un estado de no fatiga a un estado de musculo fatigado.




Figura 3.1: Adquisición de la señal EMG

La Figura 3.2 muestra una señal EMG que cambia de un estado de reposo a fatiga, de modo que se pueden observar los cambios que se producen durante la transición entre estos dos estados. El voluntario realiza ejercicio físico semanal moderado y pudo realizar 30 contracciones completas bajo las condiciones del experimento.




Figura 3.2: Cambios de la señal EMG de un estado de reposo hasta uno de fatiga muscular

3.1.3. Delimitación de la Señal

Al estudiar el comportamiento de las contracciones a medida que el músculo se fatigaba, fue necesario aislar una contracción del conjunto original de 30 contracciones, para ello. La Figura 3.3 muestra la señal sEMG delimitada a 1130 muestras que corresponde a la primera contracción, posteriormente se realiza el mismo procedi-

miento aislando la última contracción la cual corresponde al músculo fatigado para finalmente comparar el comportamiento de ambas señales.




Figura 3.3: Señal EMG durante una contracción muscular

3.1.4. Transformada Discreta de Wavelet

Para la presente investigación se utilizó la Transformada Discreta de Wavelet (DWT) con el fin de aprovechar su eficacia en términos de reducción de ruido, descomposición y extracción de características. La DWT se calcula tomando la señal original y pasándola a través de una serie de filtros como se observa en la Figura 3.4

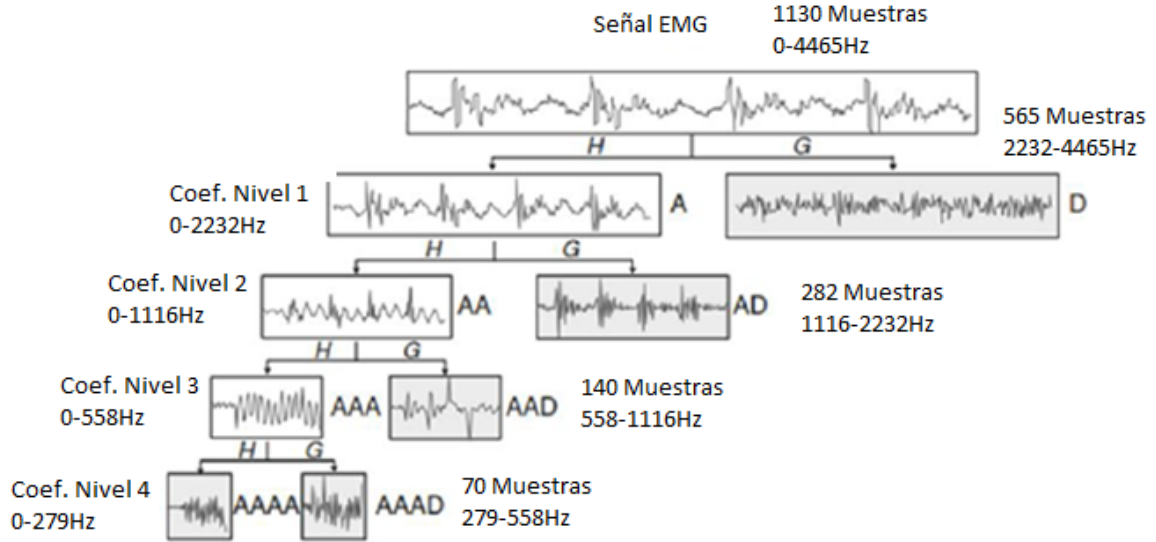


Figura 3.4: Descomposición de la señal EMG mediante DWT. (Adaptado de M. S. Hussain 2012) [8]

En primer lugar las muestras de $x[n]$ se pasan a través de un filtro pasa bajo con respuesta de impulso $g[n]$. De la misma manera, la señal pasa a través de un filtro pasa alto con respuesta de impulso $h[n]$. Los coeficientes de detalle $y_{high}[n]$ de la descomposición wavelet se obtienen del filtro pasa alto y los coeficientes de aproximación $y_{low}[n]$ provienen del filtro de paso bajo.

Por último la salida pasa por un proceso de decimación, todo este proceso se ve reflejado en las ecuaciones dadas:

$$y_{low}[n] = \sum_{k=0}^{\infty} x[k] \cdot g[2n - k] \quad (3.1)$$

$$y_{high}[n] = \sum_{k=0}^{\infty} x[k] \cdot h[2n - k] \quad (3.2)$$

Selección Wavelet Madre

La selección de la función wavelet madre es uno de los pasos más importantes para obtener un buen desempeño a la salida del algoritmo clasificador. Su objetivo principal se enfocó en encontrar una onda wavelet que describa la perturbación que se da en el músculo afectado a causa de la fatiga muscular. De acuerdo con la literatura, las Wavelets madre tipo Daubechies son las más apropiadas y por ende comúnmente utilizadas en señales EMG. Sin embargo es necesario determinar el número apropiado de niveles de descomposición y el tipo de onda Daubechies para este caso en particular. [8]




Figura 3.5: Wavelet Madre tipo Daubechies

Selección de Niveles de Descomposición Wavelet

Para determinar el número adecuado de niveles de descomposición es importante tener en cuenta que a medida que los niveles de descomposición aumentan, la señal no solo eliminará componentes de ruido, sino que también será propensa a eliminar información útil. De igual manera el tiempo de cálculo se incrementa ya que el costo computacional también se hace mayor. Es por ello que se hizo necesario determinar el nivel de descomposición más adecuado. Para la señal que se está estudiando, una

descomposición a 4 niveles proporciona una buena reducción de ruido a la vez que conserva la sensibilidad a los cambios de señal, tal como lo muestra la Figura 3.6

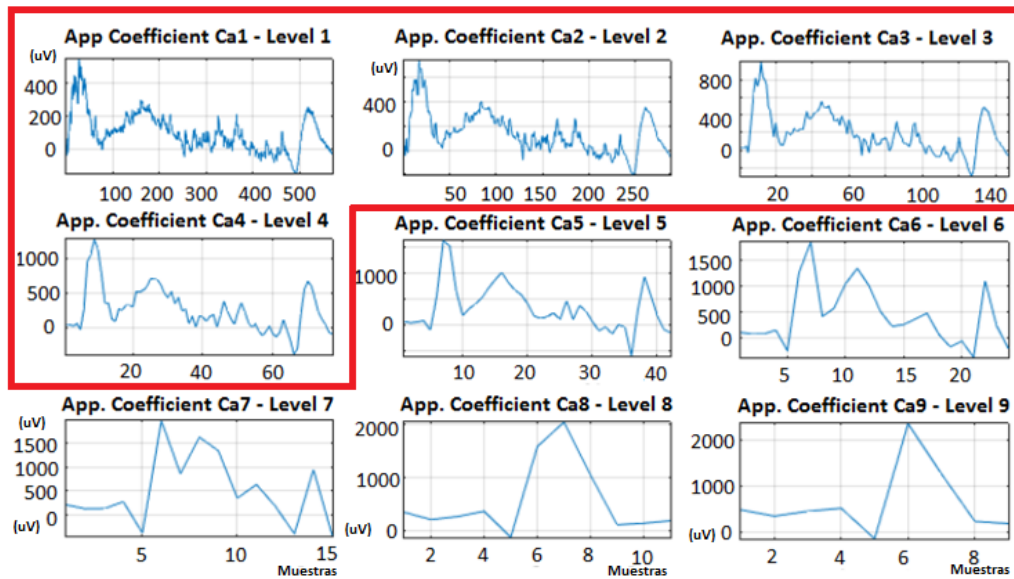


Figura 3.6: Niveles de descomposición DWT- Coeficientes de aproximación

Selección Wavelet Madre tipo Daubechies

Para determinar qué tipo de wavelet madre implementar, se tuvo en cuenta el grado de similitud entre la wavelet seleccionada y la señal reconstruida, para conocer su grado de dispersión en términos de datos, para ello fue necesario utilizar como herramienta estadística la covarianza que para fines prácticos se obtiene mediante la correlación cruzada entre los Daubechies tipo MWT (Db1, Db2, Db4, Db10, Db45) y la señal EMG filtrada. Tal como muestra el Cuadro 3.1, la wavelet madre Db45 es la que tiene la mayor similitud con respecto a la señal EMG. De forma similar, también se observa que a partir de Db4, no hay mucha diferencia entre el uso de cualquiera

de los tipos de madre Wavelet Daubechies.

Wavelet Madre	Db1	Db2	Db3	Db4	Db45
Covarianza	142.7	60.19	56.57	55.4	54.8

Cuadro 3.1: Covarianza Wavelet Madre - Daubechies.

En la Figura 3.7 se visualiza el comportamiento de la descomposición de la señal utilizando diferentes tipos de wavelet madre de tipo Daubechies, dejando claro que en cuanto mayor sea el subíndice Dbx ($Db1$ - $Db45$), mejor será su respuesta a los cambios abruptos de la señal y/o discontinuidades, asegurando así una resolución mejorada.

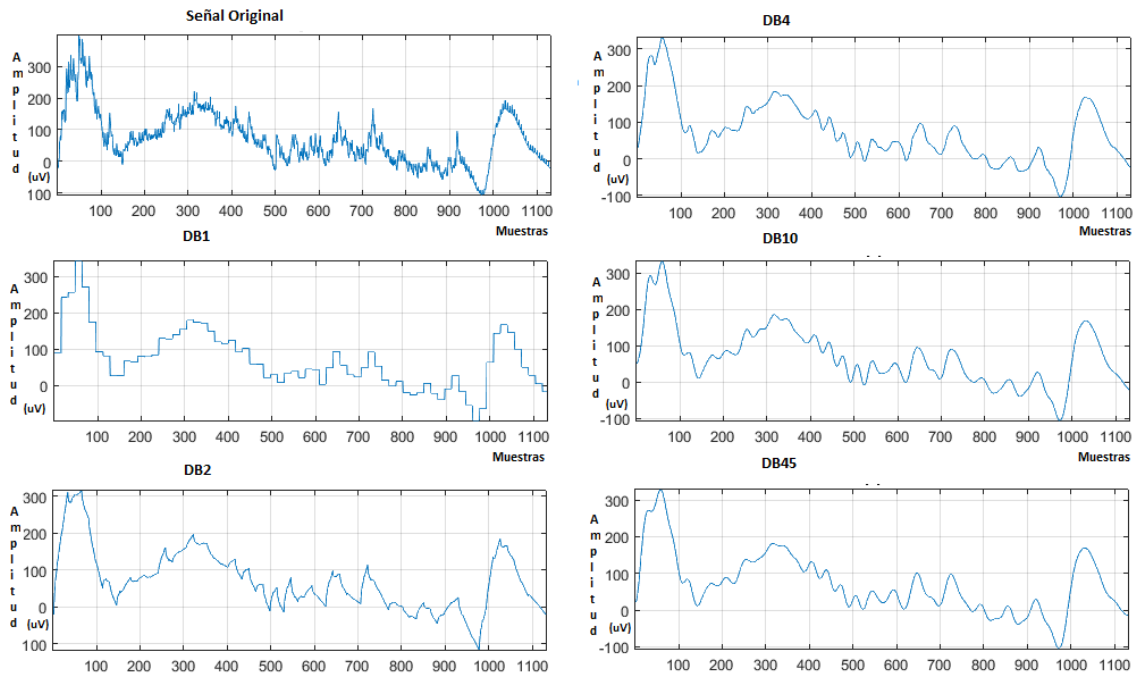


Figura 3.7: Descomposición de la señal usando wavelet Daubechies $Db[1,2,4,10,45]$ como Wavelet Madre

Con base en lo anterior, se puede inferir que la mejor combinación a la hora de configurar la transformada discreta de Wavelet consiste en una descomposición a 4 niveles

seleccionando la wavelet madre Daubechies 45.

3.2. Clasificación de Patrones

3.2.1. Regresión Logística Binaria

Una vez terminado el proceso de descomposición de la señal en coeficientes de energía, se implementó un algoritmo de clasificación que busca determinar la probabilidad de ocurrencia de fatiga muscular al realizar determinada actividad física. Esta investigación se enfocó en un modelo de regresión logística debido a su flexibilidad en cuanto a la naturaleza de las variables explicativas o independientes, que para este caso son de tipo escalar (Ed4 y RMS). Estas a su vez afectan directamente la variable respuesta de tipo categórico (Fatigado/No fatigado). De acuerdo a la literatura el clasificador de Regresión Lineal Simple (SLR) ajustado para trabajar variables categóricas (Regresión Logística Binaria) es la técnica más adecuada de reconocimiento de patrones en señales EMG debido a su alta exactitud en la clasificación de patrones y bajo costo computacional [7].

Para resolver el problema de clasificación se planteó la condición inicial (Hipótesis) a demostrar la cual refleja la presencia o ausencia de fatiga muscular.

$$y = \begin{cases} \text{Presencia de Fatiga Muscular} & 1 \\ \text{Ausencia de Fatiga Muscular} & 0 \end{cases} \quad (3.3)$$

En la presente etapa de clasificación se utilizaron dos variables explicativas (x_1, x_2) con el objetivo de garantizar una independencia entre los datos. Por un lado se tomó el coeficiente de detalle (Ed4) que es entre los coeficientes de energía el que mayor cambio genera al pasar de un estado de fatiga muscular a otro. Mientras que como segunda variable se utilizó el voltaje RMS del intervalo de la señal en donde se desarrolla la contracción muscular, dicho valor va en aumento a medida que el músculo se fatiga, esto debido a que las fibras musculares sufren de varios cambios en la estructura química de sus membranas celulares, lo que ocasiona que la señales EMG obtenidas sufran un aumento en su amplitud. [4]

Como condición de uso para el análisis de regresión se debe garantizar la linealidad de sus datos. Sin embargo para el caso de la regresión lineal (Ecuación 3.4) esto no se cumple ya que la variable dependiente es de tipo categórico (ausencia/presencia de fatiga) por lo que no se puede predecir un valor exacto de fatiga muscular.

Para obtener el modelo que pronostique la probabilidad de ocurrencia de dicha variable se le debe agregar el logaritmo neperiano dentro de la ecuación de la regresión lineal garantizando así la linealidad del modelo en el plano logarítmico (Ecuación 3.5).

$$Y = \theta_0 + \theta_1 x_1 + \theta_2 x_2 \quad \text{Regresión Lineal} \quad (3.4)$$

$$\ln \left\{ \frac{p}{1-p} \right\} = \theta_0 + \theta_1 x_1 + \theta_2 x_2 \quad \text{Regresión Logística} \quad (3.5)$$

Donde p hace referencia a la probabilidad de que exista ú ocurra el estado de fatiga muscular. $(1-p)$ corresponde a la probabilidad de fracaso o No ocurrencia del estado. θ corresponde a los coeficientes del modelo de regresión a optimizar. Para efectos prácticos se realiza el reemplazo $Y^* = \ln(p/(1-p))$ en la ecuación(3.5) obteniendo $Y^* = \theta_0 + \theta_1 x_1 + \theta_2 x_2$, despejando las ecuaciones se observará que el modelo de regresión logística parte de la hipótesis de que los datos siguen el siguiente modelo:

$$p = \frac{e^{Y^*}}{1 + e^{Y^*}} \quad (3.6)$$

3.2.2. Base de Datos del Experimento

Para obtener la base de datos del experimento se tomaron un total de 100 muestras provenientes de 50 personas. A cada uno de los sujetos de prueba se le instaló el sensor EMG en la cara anterior del antebrazo sobre el músculo flexor radial del carpo y se le pidió realizar una contracción muscular sostenida apretando el dispositivo de prueba tipo hand grid por un periodo de tiempo de 5 segundos para luego relajar el músculo por otros 5 segundos y registrar los datos obtenidos indicando que dicha señal pertenece a un músculo No fatigado. Posteriormente se continuó realizando el ejercicio hasta detectar síntomas de cansancio en el músculo (incapacidad de mantener el hand

grid completamente cerrado) en ese instante se registra los datos obtenidos indicando que hace referencia a un músculo fatigado (Ver Figura 3.8). A todos los sujetos se les explico el procedimiento y que este no representaba ningún riesgo para su salud. Así mismo se solicitó su consentimiento para participar en el presente estudio

Con base en lo anterior, la base de datos para el presente experimento cuenta con 100 muestras, donde el número de observaciones es el mismo para todas las clases (Datos Balanceados), lo que garantiza que las proporciones de las diferentes clases afecten negativamente el desempeño del algoritmo clasificador. Cada uno de los datos cuenta con dos características más un tercer dato que indica la presencia o ausencia de fatiga muscular (1,0).

Para implementar el algoritmo clasificador de patrones se hizo necesario realizar una división aleatoria de las muestras. Por un lado se tomó el 80 % de los datos originales para entrenar el algoritmo de clasificación, mientras que por el otro se utilizó el 20 % restante como datos de prueba para determinar el desempeño de dicho algoritmo.

3.2.3. Algoritmo Clasificador

El algoritmo clasificador de regresión logística se basa en su función de coste $J(\theta)$, la cual arroja un valor que entre más cercano a cero, mejor es las predicción de la hipótesis $h(x)$ del algoritmo de aprendizaje.




Figura 3.8: Base de Datos - Experimento Fatiga

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \text{Cost}(h_{\theta}(x^i), y^i)$$

$$\text{Cost}(h_{\theta}(x^i), y^i) = \begin{cases} -\log(h_{\theta}(x)) & \text{si } y=1 \\ -\log(1 - h_{\theta}(x)) & \text{si } y=0 \end{cases} \quad (3.7)$$

$$J(\theta) = \frac{1}{m} [\sum_{i=1}^m -y^i \log(h_{\theta}(x^i)) - (1 - y^i) \log(1 - h_{\theta}(x^i))]$$

La función h emitida por el algoritmo de aprendizaje denominada como **función hipótesis** es una función que toma como entrada las características de los casos de prueba ($X1', X2', X3', \dots, Xn'$) y con los valores de θ (theta) óptimos almacenados logra generar una predicción sobre el caso de prueba seleccionado. [9]

$0 \leq h_\theta \leq 1$ Regresión Logística

$$h(x) = g(\theta^T x); \text{ siendo } g(z) = \frac{1}{1+e^{-z}} \quad (3.8)$$

$$\text{Por tanto } h(x) = \frac{1}{1+e^{\theta^T x}}$$

$$h(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_3 + \dots \theta_n x_n)$$

La salida de la función hipótesis $h(x)$ está comprendida entre '0' y '1', indicando la probabilidad estimada de que el valor 'Y' sea igual a '1'. En este caso particular la idea consiste en pronosticar la presencia de fatiga muscular al tomar el valor '1' y de ausencia de la misma cuando toma el valor de '0'. Es decir que si la función hipótesis arrojaba un resultado de 0.89, la probabilidad de que el músculo estuviera fatigado era del 89%.

El clasificador se llevó a cabo mediante la implementación de un Algoritmo de Regresión Logística de clase binaria utilizando Matlab como herramienta de desarrollo, en donde a partir de las características extraídas (Ed4 y RMS) provenientes de una señal EMG se determina si un sujeto está o no fatigado.

El algoritmo clasificador está compuesto por las siguientes etapas:

- La primera etapa consiste en la carga de los datos, los cuales fueron organizados en 3 columnas en un archivo tipo txt. Los datos de las dos primeras columnas hacen referencia a las características (Ed4 y RMS) extraídas de la señal EMG. Los datos de la tercera columna indican si dichas características pertenecen a un sujeto que presenta fatiga muscular (1,0).

- Con el ánimo de visualizar los datos obtenidos, se desarrolló una función que grafica dichos datos. La función identifica los datos positivos y negativos de la tercera columna marcándolos con el signo '+' y 'o' respectivamente para posteriormente graficarlos junto con los datos de la columna uno y dos (ver Figura 3.8).
- Para la tercera etapa se implementó la función de coste mencionada con anterioridad (ver Ecuación 3.7). En un principio los valores iniciales de los coeficientes θ se hacen cero para luego ser reajustados mediante una etapa de optimización. Posteriormente se calcula la hipótesis mediante las formulas: $h_{\theta}(x) = g(\theta^T X)$ y $g(z) = l/(l + e^{-z})$, siendo g la Función Sigmoidea o logística.
- Por último se desarrolló una función de optimización, cuyo objetivo radica en encontrar los valores de θ que minimicen la función de coste anteriormente determinada.

Capítulo 4.

Resultados y Discusión

En la Figura 4.1 se observa el comportamiento de la señal EMG en el instante en que el sujeto de pruebas ejecuta una contracción muscular de cinco segundos de duración partiendo de un estado de reposo, posteriormente se realiza el mismo tipo de ejercicio pero esta vez en presencia de fatiga muscular.

En la parte (a) de la imagen la forma de la señal describe su pico máximo de amplitud al iniciar la contracción seguida por un decaimiento de la misma hasta cruzar por cero, sin embargo en la parte (b) de la imagen la forma de la señal presenta un comportamiento errático, caracterizado por la aparición de varios picos pronunciados que ocasiona la re-distribución de la energía a lo largo de la contracción muscular. No obstante en el dominio del tiempo no es posible determinar en qué banda de frecuencia se dan dichos cambios en la señal, es por ello que se debe descomponer dicha señal en términos de frecuencia, que es donde radica la importancia de trabajar con la DWT.

Cuando se realiza el proceso de descomposición de la señal EMG proveniente del músculo no fatigado mediante el uso de la Transformada Discreta de Wavelet se obtienen los respectivos coeficientes de aproximación y detalle de la DWT.

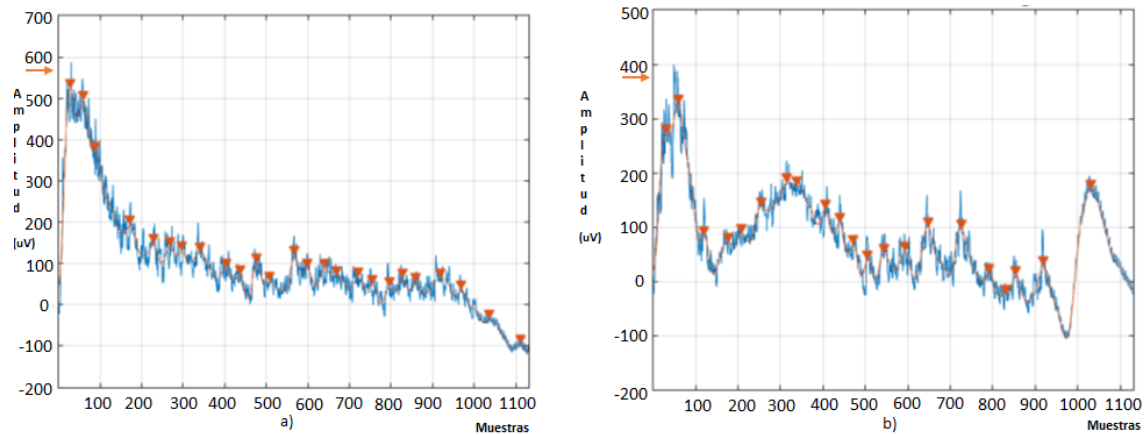


Figura 4.1: (a) Contracción muscular en ausencia de fatiga - (b) Contracción muscular en presencia de fatiga

En la Figura 4.2 se detalla el porcentaje de energía contenida en dichos coeficientes (A4, Ed1, Ed2, Ed3, Ed4) junto con sus respectivas sub-bandas de frecuencia que indican en que intervalo de frecuencia existe una mayor variación de dichos coeficientes, notando que para el caso particular de la fatiga muscular se genera en Ed4.

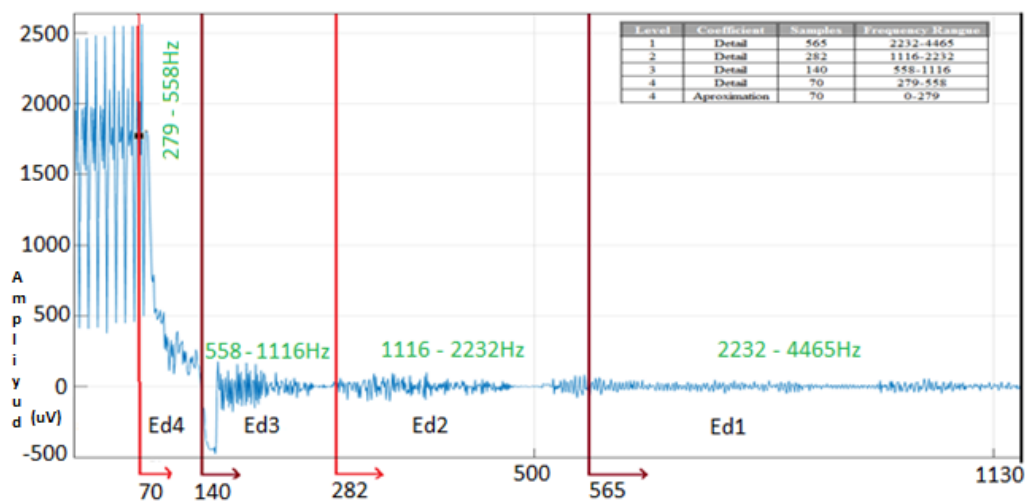


Figura 4.2: Descomposición de la señal en términos de la frecuencia - Ausencia de fatiga muscular

Realizando el mismo proceso de descomposición anterior sobre la señal obtenida

de un músculo fatigado y comparándola con el resultado obtenido del músculo No fatigado, se observa en la Figura 4.3 una cierta diferencia en la distribución de los coeficientes de energía de la siguiente manera: En los coeficientes Ed1 y Ed2 reflejan un ligero aumento en la energía de la señal. No obstante, los cambios más relevantes aparecen en los coeficientes Ed3 y en especial en el Ed4 en donde no solo aumentó el porcentaje de energía sino también en el número de picos de la señal durante la contracción muscular lo cual es un indicador de fatiga muscular.




Figura 4.3: Descomposición de la señal en términos de la frecuencia - Presencia de fatiga muscular

4.1. Comparación de Parámetros Característicos

El Cuadro 4.1 muestra el comportamiento de la señal EMG tanto en presencia como en ausencia de fatiga muscular, detallando por un lado como los valores de energía

contenidos en los coeficientes de detalle Ed1 y Ed2 al iniciar la actividad física partiendo de un estado de reposo son prácticamente cero. Sin embargo al alcanzar un estado de fatiga el porcentaje de energía aumenta. Por otro lado, en los coeficientes Ed3 y Ed4 es donde se genera el aumento mas significativo en el valor total de la energía, apreciandose también un comportamiento más errático. Finalmente también se observa como el voltaje RMS sufre un aumento en sus valores a medida que el músculo se fatiga, lo cual según la literatura es un indicativo de fatiga muscular [4]. Para este primer experimento de extracción de características, se tomaron diez repeticiones en cada estado y se promediaron para obtener la siguiente tabla de resumen:

Coeficientes de Energía	Músculo No Fatigado		Músculo Fatigado	
	Porcentaje de Energía	RMS	Porcentaje de Energía	RMS
Ed1 - Detalle	0.079	495.71	0.222	325.78
Ed2 - Detalle	0.171	203.37	0.490	263.62
Ed3 - Detalle	0.291	199.04	0.927	200.20
Ed4 - Detalle	0.591	208.24	1.926	220.29
A4 - Aproximación	98.873	221.37	96.43	290.24

Cuadro 4.1: Comparación de Coeficientes: Músculo Fatigado Vs No Fatigado

4.2. Resultado del Clasificador

A la salida de la etapa de clasificación se obtiene los siguientes coeficientes: $[\theta_0 = -9.887647, \theta_1 = 4.019462, \theta_2 = 0.040528]$, los cuales junto con las variables independientes $x_1 = 4$ to Coeficiente de detalle y $x_2 =$ valor RMS de la señal conformarían el Modelo de Regresión Logística que permite determinar la probabilidad de ocurrencia

de la variable dependiente, en este caso a la presencia o ausencia de fatiga muscular:

$$Y^* = \ln \left\{ \frac{p}{1-p} \right\} = -9,887647 + 4,019462x_1 + 0,040528x_2 \quad (4.1)$$

$$p = \frac{e^{Y^*}}{1 + e^{Y^*}}$$

Graficando en un mismo plano tanto el modelo descrito en la ecuación 4.1 más el conjunto de muestras utilizadas para el entrenamiento del algoritmo clasificador, se observó la categorización de la variable dependiente detallando la frontera del estado de fatiga muscular (ver Figura 4.4). Para realizar la respectiva verificación del clasificador, se ingresaron al algoritmo 20 muestras no antes visto por él en su entrenamiento (datos de prueba) con el ánimo de compararlos con los datos reales y finalmente registrar los resultados en una matriz de confusión.

4.3. Prueba Diagnóstica

4.3.1. Matriz de Confusión

Una vez recopilada la información anterior, fue necesario evaluar el desempeño real del clasificador y para ello se elaboró una matriz de confusión con el fin de obtener ciertos parámetros como son exactitud, precisión, sensibilidad, etc., los cuales son importantes para determinar el grado de credibilidad del modelo.

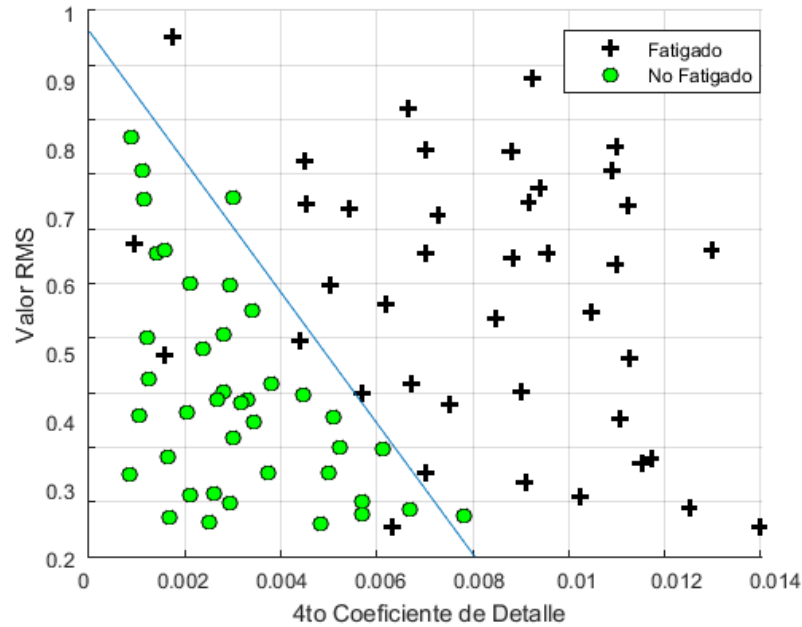


Figura 4.4: Modelo de regresión logística binaria de variable dependiente cualitativa

		PREDICCIÓN					
		POSITIVO		NEGATIVO			
VALOR REAL	POSITIVO	VP	8	FN	1	CP	9
	NEGATIVO	FP	2	VN	9	CN	11
	TP	10	TN	10			

Cuadro 4.2: Matriz de Confusión - FP: Falsos positivos, FN: Falsos Negativos, VP: Verdaderos Positivos, VN: Verdaderos Negativos, TP: Total Positivos, TN: Total Negativos, CP: Condición Positiva, CN: Condición Negativa

4.3.2. Determinantes de la Eficacia de la Prueba

Exactitud: Este parámetro indica que porcentaje del conjunto de datos que se clasificó correctamente.

$$EXACTITUD = \frac{VP+VN}{TOTAL_DATA} * 100\% = 85\% \quad (4.2)$$

Tasa de Error: Este parámetro indica que porcentaje de los datos se clasificó inco-

rectamente.

$$TASA_ERROR = \frac{FP+FN}{TOTAL_DATA} * 100\% = 15\% \quad (4.3)$$

Precisión: es la probabilidad de que, si la prueba ha dado positivo, el individuo esté realmente fatigado.

$$PRECISION = \frac{VP}{VP+FP} * 100\% = 80\% \quad (4.4)$$

Valor de Predicción Negativa: es la probabilidad de que, si la prueba ha dado negativa, el individuo no esté realmente fatigado.

$$VPN = \frac{VN}{TN} * 100\% = 90\% \quad (4.5)$$

Sensibilidad: es la probabilidad de que, dado que un individuo realmente está fatigado, la prueba lo detecte.

$$SENSIBILIDAD = \frac{VP}{TOTAL_POSITIVOS} * 100\% = 88,8\% \quad (4.6)$$

Especificidad: es la probabilidad de que, dado que un individuo no está realmente fatigado, la prueba llegue a la misma conclusión.

$$ESPECIFICIDAD = \frac{VN}{TOTAL_NEGATIVOS} * 100\% = 81,81\% \quad (4.7)$$

4.4. Trabajo Futuro

Como trabajo futuro relacionado con el proceso extracción de características y clasificación de patrones desarrollados en la presente trabajo, actualmente se tiene proyectado realizar una investigación para comparar diferentes algoritmos de clasificación entre ellas: Redes Neuronales, Clasificador bayesiano y Regresión logística a manera de obtener cual entrega una mayor exactitud en sus predicciones. De igual manera también se buscará comparar el comportamiento de la señal EMG tanto en personas sedentarias, como en atletas de alto rendimiento en presencia de fatiga muscular.

Capítulo 5.

Conclusiones

Partiendo de los resultados obtenidos en la presente investigación se corroboró el buen desempeño que ofrece La Transformada Discreta de Wavelet como herramienta de extracción de características en señales no estacionarias (EMG).

El algoritmo de clasificación basado en el análisis de regresión logística binaria para variables cualitativas responde adecuadamente con una exactitud de entrenamiento del 85 %, lo que lo convierte en una buena herramienta de clasificación para determinar estados de fatiga muscular al analizar señales EMG.

Al ingresar datos nunca antes vistos por el algoritmo de clasificación en su etapa de entrenamiento, se observó la aparición de errores tipo I (Falsos Positivos) en la matriz de confusión en un 20 % del total de las muestras de prueba. No obstante, en errores tipo II (Falsos Negativos) el algoritmo de clasificación presentó un mejor desempeño siendo afectado solo en un 10 %.

Gracias al análisis de Sensibilidad y Especificidad se corroboró que el algoritmo clasificador es capaz de predecir con una alta probabilidad, cuando el sujeto de pruebas

se encuentra verdaderamente fatigado y cuando no.

En cuanto a la distribución de los datos, se observó que el grado de credibilidad del modelo tiende a ser más exacto hacia los extremos, mientras que para valores próximos a la línea de división el coeficiente de exactitud disminuye considerablemente.

Bibliografía

- [1] M. R. Al-Mulla, F. Sepulveda, and M. Colley. *sEMG Techniques to Detect and Predict Localised Muscle Fatigue*, book section 9, page 532. InTech, 2012.
- [2] G. Biagetti, P. Crippa, A. Curzi, S. Orcioni, and C. Turchetti. Analysis of the emg signal during cyclic movements using multicomponent am–fm decomposition. *IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS*, 19(5 September 2015), 2015.
- [3] R. H. Chowdhury, M. B. I. Reaz, M. A. Bin Mohd Ali, A. A. A. Bakar, K. Chellappan, and T. G. Chang. Surface electromyography signal processing and classification techniques. *mdpi.com journal sensors*, 13(17 September 2013):36, 2013.
- [4] J. Correa-Figueroa, E. Morales-Sanchez, J. Huerta-Ruelas, J. Gonzalez-Barbosa, and C. Cardenas-Perez. Sistema de adquisicion de senales semg para la deteccion de fatiga muscular. *Revista Mexicana de BioIngenieria BioMedica*, 37:17–27, 2016.
- [5] C. DeLuca, D. Gilmore, and M. Kuznetsov. Filtering the surface emg signal: Mo-

- vement artifact and baseline noise contamination. *Journal of Biomechanics.*, 8(2010 Mar 5):16, 2010.
- [6] M. Diaz. La actividad física deportiva: MÁS allÁ de lo saludable. *Rev Fac Med Univ Nac Colomb*, 52(3):10, 2004.
- [7] P. Geethanjali and K. Ray. Identification of motion from multi-channel emg signals for control of prosthetic hand. *Australas Phys Eng Sci Med*, 34:419–427, 2011.
- [8] M. S. Hussain and M. Mamun. Effectiveness of the wavelet transform on the surface emg to understand the muscle fatigue during walk. *MEASUREMENT SCIENCE REVIEW*, 12:6, 2012.
- [9] D. Jurafsky and J. martin. Logistic regression. (*Ed.*), *Mr. Mark Schwartz*, 34:419–427, 2017.
- [10] S. H. C.-O. L. A. Flórez-Prias. Analysis of semg signals using discrete wavelet transform for muscle fatigue detection, 2017.
- [11] R. Mello, L. Oliveira, and J. Nadal. Detection of the anaerobic threshold by surface electromyography. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, 59(Aug 30-Sept 3):4, 2006.
- [12] M. Montoya. Surface emg based muscle fatigue detection using a low-cost wearable sensor and amplitudefrequency analysis. In *CONFERENCIA INTERNA-*

- [13] S. Thongpanja, A. Phinyomark, P. Phukpattaranont, and C. Limsakul. Mean and median frequency of emg signal to determine muscle force based on time-dependent power spectrum. *ELEKTRONIKA IR ELEKTROTECHNIKA*, 19:6, 2013.
- [14] D. WINTER. *Biomechanics and Motor Control of Human Movement*, volume 4. JOHN WILEY and SONS, INC., Waterloo, Ontario Canada, 4 edition, 2009.
- [15] M. Yochum, T. Bakir, R. Lepers, and S. Binczak. Estimation of muscular fatigue under electromyostimulation using cwt. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, 59(12 Dec 2012):7, 2012.