

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA INGENIERÍA ELÉCTRICA - PROCESAMIENTO DIGITAL DE SEÑALES

Clasificación de señales EMG empleando características tiempo-frecuencia para el diagnóstico de desórdenes neuromusculares

TESIS

QUE PARA OPTAR POR EL GRADO DE: MAESTRO EN INGENIERÍA

PRESENTA: JONATHAN ROBERTO TORRES CASTILLO

Director de tesis: Dr. Miguel Angel Padilla Castañeda Instituto de Ciencias Aplicadas y Tecnología

Ciudad Universitaria, CD. MX. Julio 2018



Universidad Nacional Autónoma de México



UNAM – Dirección General de Bibliotecas Tesis Digitales Restricciones de uso

DERECHOS RESERVADOS © PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Reconocimiento

Reconozco de manera muy especial a mis sinodales quienes desde el primer momento me brindaron su valioso tiempo y apoyo durante todo el proceso:

Presidente Dr. Savage Carmona Jesús

Secretario Dr. Pérez Alcázar Pablo Roberto

1^{er}. Vocal Dr. Padilla Castañeda Miguel A.

2^{do}. Vocal Dr. Arámbula Cosío Fernando

 $3^{er}.$ Vocal Dr. Escalante Ramírez Boris

Dedico este trabajo a mi hija Gabriela. Me diste la fuerza necesaria para completar este enorme logro en mi vida, que es tuyo. Has sabido entender y soportar largas horas sin mi compañía, por eso y más es que sigues y siempre serás mi más grande inspiración, le trajiste sentido a mi vida, fuiste la causante de mi anhelo de salir adelante, progresar y culminar con éxito mi carrera. Te amo.

Agradecimientos

Esta investigación no hubiera sido posible sin la inestimable ayuda de mi tutor de tesis, el Dr. Miguel Ángel Padilla Castañeda, capaz de encauzarme y dirigirme en la consecución de la misma, argumentando todos los puntos que la componen de forma correcta y a la vez concisa. Le agradezco la confianza depositada en mí ya que me ha servido para lograr una gran motivación, ayudándome a continuar en los momentos más difíciles, enriqueciéndome con conocimientos a lo largo de este emocionante periodo.

Un sentimiento especial de agradecimiento a mi madre por su infinito amor, cariño, comprensión y apoyo, por soportar estos meses lejos de ella, por acompañarme en los buenos y malos momentos y sobre todo por ayudarme a que este momento llegara. A mi padre que es mi ejemplo de vida y sus palabras de aliento y empuje me han dado la tenacidad para siempre seguir adelante. A mis hermanos les agradezco porque nunca han dejado de estar a mi lado. Son muy especiales para mí.

Agradezco a las personas que estuvieron conmigo por su desinteresada ayuda, por brindarme su tiempo cuando siempre lo necesité, por aportar considerablemente en este proyecto y en toda mi vida. Siempre los recordaré con mucho cariño.

Finalmente quiero reconocer y agradecer la financiación recibida por parte del Consejo Nacional de Ciencia y Tecnología - CONACYT y a la Unidad de Investigación y Desarrollo Tecnológico - UIDT entidades que han hecho posible la realización de esta investigación.

Resumen

La electromiografía (EMG) es una técnica de recolección de señales eléctricas producidas por la contracción de los músculos esqueléticos del cuerpo humano. Los impulsos eléctricos recogidos mediante el uso de electrodos se conocen como potenciales de acción de la unidad motora (PAUMs) y son una valiosa fuente de información sobre el funcionamiento y el estado del sistema musculo esquelético, lo que es útil para el diagnóstico de diversos trastornos neuromusculares que se manifiestan con un deterioro progresivo de los músculos (miopatía) o nervios (neuropatía). Por lo tanto, es práctica clínica típica que un electrofisiólogo experimentado examine el musculo realizando inspección visual de la señal EMG identificando los PAUMs y reproduciendo la misma señal para asemejar el audio a algún sonido característico de alguna enfermedad. Sin embargo, la evaluación subjetiva de estos PAUMs, incluso si es satisfactoria para la detección de anormalidades obvias, puede no ser suficiente para describir desviaciones menos aparentes o patrones mixtos de anormalidades. En consecuencia, para un análisis efectivo de estos trastornos es necesario implementar nuevas técnicas adecuadas para cuantificar de forma exhaustiva estas señales EMG.

Se ha implementado una técnica de reconocimiento de patrones que permite clasificar señales EMG, provenientes tanto de sujetos sanos como con esclerosis lateral amiotrófica (ALS) y con miopatía, descomponiendo la señal en una serie de secuencias de datos llamados funciones de modo intrínseco (FMIs). Esta técnica, llamada descomposición empírica de modos por conjuntos (EEMD por sus siglas en ingles), es adecuada para el análisis de señales no estacionarias y no lineales como las EMG. Cada componente pasa por una etapa de extracción de características tiempo-frecuencia, empleando características temporales útiles para describir la forma de onda, así como, la transformada de Hilbert-Huang, para obtener las frecuencias instantáneas de cada componente, seguida de una fase de selección de características apropiadas para la tarea discriminatoria usando una función criterio estadística conocida como la prueba de Kruskal-Wallis, para luego reducir la dimensionalidad mapeando el conjunto de datos obtenidos a sub-espacios derivados del espacio original de menor dimensión, utilizando una técnica novedosa robusta ante la correlación alta en el conjunto de información llamada análisis discriminante lineal no correlacionado (ULDA por sus siglas en ingles).

Finalmente, clasificadores potentes, como k-vecinos más cercanos (K-NN por sus si-

glas en ingles), el análisis discriminante lineal (LDA por sus siglas en ingles) y basados en árboles de decisión (TREE por sus siglas en ingles), fueron empleados para descifrar el método supervisado óptimo. Cada uno de los sistemas de clasificación fue validado con la estrategia de validación cruzada de 3-folds, reparticionada 10 veces, clasificando señales provenientes de 10 sujetos sanos, 8 sujetos con miopatía y 7 sujetos con Esclerosis Lateral Amiotrófica (neuropatía), de los cuales se obtuvieron un total de 350 señales EMG.

La metodología descrita en este trabajo muestra resultados prometedores para clasificar desordenes neuromusculares, dando relevancia al proceso de selección adecuado de características para reducir el tiempo de predicción y evitar la redundancia en la información, estableciendo a la red K-NN como método supervisado de clasificación óptimo (exactitud > 99 %). Estos resultados infieren que la metodología propuesta seria de gran utilidad para apoyar en el diagnóstico de trastornos neuromusculares, resaltando la descomposición de la señal EMG usando la EEMD como una técnica de descomposición automatizada y efectiva para señales biológicas.

Índice general

Re	esum	\mathbf{en}		\mathbf{V}
Lis	sta d	e figur	as	IX
Lis	sta d	e tabla	as	XI
Ac	cróni	\mathbf{mos}		XII
1.	Intr 1.1.	oducci Objeti 1.1.1.	ón vos	1 4 4
2.	Enfe 2.1.	ermeda Señale 2.1.1. 2.1.2. 2.1.3.	ades neuro-musculares y la Electromiografía s electromiográficas Unidades motoras Potenciales de acción de unidad motora Morfología de los PAUM	5 6 7 8 8
3.	Met 3.1. 3.2. 3.3. 3.4. 3.5. 3.6.	Conju: Adquis Descon Descon Extrac 3.6.1. 3.6.2. 3.6.3. 3.6.4. 3.6.5. 3.6.6. 3.6.7. 3.6.8. 3.6.9.	gía nto de Señales clínicas EMG sición y Pre-procesamiento de la señal nposición de la señal EMG nposición Empírica de Modos nposición Empírica de Modos por Conjuntos nogitud formal de Modos por Conjuntos cción de características tiempo-frecuencia Longitud formal de onda (LFO) Cruces por cero (CPC) Cambios en la pendiente de la señal (CPS) Raíz media cuadrática (RMS) Coeficientes Auto-Regresivos (CR) Valor absoluto medio (VAM) Valor absoluto integrado (VAI) Característica de ancho de banda Momento Espectral de la Densidad Espectral de Potencia (ME _{DEF})	12 12 12 17 18 19 20 20 20 22 22 22 22 23 23 23 23 23 25 >) 26

		3.6.10. Media de la FI (MFI)	26
		3.6.11. Media de la Primera Derivada de FI (MPD _{FI})	26
		3.6.12. Valor pico de la DEP con el metodo Welch (DEP_{PEAK})	27
	3.7.	Selección de características y la prueba Kruskal-Wallis	27
		3.7.1. Prueba de comparación múltiple de Dunn con un control	29
	3.8.	Reducción de características	32
		3.8.1. Análisis discriminante lineal no correlacionado (ULDA)	33
4.	Clas	sificación	37
	4.1.	Clasificación de patrones	37
		4.1.1. Árboles de decisión	38
		4.1.2. Análisis Discriminante Lineal (LDA)	41
		4.1.3. K-vecinos más cercanos	43
	4.2.	Tasa de error de clasificación	45
5.	Res	ultados, Análisis y Discusión	48
	5.1.	Clasificación de señales EMG	48
		5.1.1. Fase de entrenamiento	48
		5.1.2. Fase de predicción	49
6.	Con	clusiones	55

Índice de figuras

2.1. 2.2.	Esquema general de obtención de señales EMG y PAUM Representación gráfica de las fibras musculares, las moto-neuronas y PAUM. La primera representación hace parte de un sujeto normal, la segunda de un neuropático y la tercera de un miopático	7 9
3.1. 3.2.	Esquema de adquisición de la señal EMG	13 14
3.3.	Preprocesamiento de la señal EMG y eliminación de ruido	15
3.4.	Interferencia causada por el amplificador EMG a) señal ruidosa, b) his-	16
3.5	Descomposición EEMD de una señal EMG en sus 13 FML	$\frac{10}{21}$
3.6.	Boxplots de las distribuciones de datos de características discriminatorias entre diferentes ENM. $\dots \dots \dots$	31
3.7.	Boxplots de las distribuciones de datos de características que no son útiles en la clasificación de ENM.	31
3.8.	Diagramas de dispersión usando el método ULDA para reducir la alta dimensionalidad del conjunto de características. a) Diagrama de dispersión obtenido de reducir el conjunto original de 234 características a uno de 2 características. b) Diagrama de dispersión obtenido al reducir el conjunto M_{π} - con 103 características a uno con 2 características	25
	$Conjunto M_{CaR}$ con 105 caracteristicas a uno con 2 caracteristicas	55
4.1.	Esquema general de la clasificación de un atributo y su mapeo en la nueva característica.	38
4.2.	Esquema general de la clasificación de un atributo y su mapeo en la	
13	nueva característica.	40
4.0.	dimensión inferior (línea). La línea debe elegirse de modo que la proyec-	
	ción maximice la "separabilidad" de las muestras proyectadas	41
4.4.	Esquema de la construcción de una matriz de confusión.	44

5.1.	Sistema de clasificación de señales EMG	49
5.2.	Indices clínicos en cada una de las pruebas efectuadas en la validación	
	cruzada	54

Índice de tablas

La morfología de los PAUM y las características de las fibras musculares.	10
Características de la base de datos de señales EMG clínicas (H representa a la población de Hombres y M la de Mujeres)	12 32
de los FMI_k seleccionadas para el proceso de clasificación	33
Parámetros estadísticos para validar un clasificador de ENM $\ .\ .\ .\ .$	47
Matrices de confusión promedio para las 30 pruebas $(\mu \pm \sigma)$ y sus métri- cas clínicas, empleando diferentes clasificadores. Los números que están en negrita representan el numero de subconjuntos promedio clasificados correctamente.	51
Matrices de confusión promedio para las 30 pruebas $(\mu \pm \sigma)$ y sus métri- cas clínicas, empleando diferentes clasificadores. Los números que están en negrita representan el numero de señales promedio clasificadas correc- tamente	53
	La morfología de los PAUM y las características de las fibras musculares. Características de la base de datos de señales EMG clínicas (H representa a la población de Hombres y M la de Mujeres)

Acrónimos

ACC	Exactitud			
ALS Esclerosis lateral amiotrófica				
$\mathbf{A}\mathbf{M}$	Modulación de amplitud			
AMN	Sujetos con ALS, con miopatía y sujetos normales			
ANN	Red neuronal artificial			
BAM	Ancho de banda de la modulación de amplitud			
\mathbf{BFM}	Ancho de banda de la modulación de frecuencia			
CaR Característica				
CPC	Cruces por cero			
\mathbf{CPS}	Cambios en la pendiente de la señal			
\mathbf{CR}	Coeficientes auto-regresivos			
\mathbf{DEP}_{PEAK}	Valor pico de la DEP con el metodo Welch			
\mathbf{DEP}	Densidad espectral de potencia			
\mathbf{DTW}	Trasnformación discreta de wavelet			
EEMD	Descomposición empírica de modos por conjuntos			
ELA	Esclerosis lateral amiotrófica			
EMD	Descomposición empírica de modos			
EMG	Electromiografía			
EMGC	Electromiografía cuantitativa			
ENM	Enfermedad neuromuscular			
\mathbf{ES}	Especificidad			
\mathbf{FM}	Modulación de frecuencia			
\mathbf{FMIs}	Funciones de modo intrínseco			
\mathbf{FN}	Falso-Negativo			
\mathbf{FP}	Falso-Positivo			
KNN	k-vecino más cercano			
LB	Línea base			
LDA	Análisis discriminante lineal			
LFO	Longitud formal de onda			
\mathbf{ME}_{DEP}	Momento Espectral de la Densidad Espectral de Potencia			
MFI	Media de la FI			

MI	Miopatías inflamatorias		
\mathbf{MPD}_{FI}	Media de la Primera Derivada de FI		
OLB Oscilaciones de línea base			
PAUM Potencial de acción de la unidad motor			
PCA Análisis por componentes principales			
RMS	Raíz media cuadratica		
\mathbf{RP}	Reconocimiento de patrones		
\mathbf{SE}	Sensibilidad		
STFT Transformada corta de fourier			
TREE Arboles de decisión			
TW Transformada wavelet			
ULDA Análisis discriminante lineal no correlacion			
UM	Unidad motora		
VAI	Valor absoluto integrado		
VAM	Valor absoluto medio		
\mathbf{VN}	Verdadero-Negativo		
\mathbf{VP}	Verdadero-Positivo		
VPN	PN Valor predictivo negativo		
\mathbf{VPP}	Valor predictivo positivo		
WOE	Medida de ponderación de la evidencia		
\mathbf{WPT}	Transformación de paquetes wavelet		

Capítulo 1 Introducción

Un desorden o enfermedad neuromuscular (ENM) es un término amplio utilizado para referirse a más de 40 enfermedades diferentes que afectan los músculos y/o el control directo del sistema nervioso [1]. La mayoría de estas enfermedades son raras, complejas e incurables y su principal característica es la pérdida progresiva de fuerza muscular, reducción de rangos de movimiento, pérdida de reflejos e incluso discapacidad significativa. Algunas de estas, como la esclerosis lateral amiotrófica (ELA), son debilitantes o incluso fatales [2]. El diagnóstico de éstas enfermedades a menudo implica una evaluación física, análisis de ADN, biopsia muscular y diferentes pruebas electrodiagnósticas en las que intervienen el análisis de señales fisiológicas como la electromiografía (EMG). EMG es la metodología estándar establecida y efectuada para determinar si una persona presenta alguna ENM, va que ésta posee una alta resolución temporal y espacial de la sinapsis nervio-muscular, necesaria para la detección de lesiones, de fatiga en las fibras musculares y de procesos de reinervación [3]. Esta técnica permite capturar señales eléctricas producidas por la contracción de los músculos esqueléticos del cuerpo humano y cuyo proceso subvacente radica en las unidades funcionales del músculo llamadas unidades motoras (UM), las cuales generan impulsos eléctricos conocidos como potenciales de acción de la unidad motora (PAUM). Estos PAUM son una valiosa fuente de información de la actividad y el estado del sistema musculo esquelético.

En la práctica clínica actual, la caracterización del estatus del músculo se realiza principalmente mediante el análisis cualitativo, tanto visual como auditivo, de las señales EMG detectadas durante contracciones musculares de bajo nivel y se centra en el análisis de forma de los PAUMs individuales y en los patrones de descarga de las MU catalogando la enfermedad encontrada como neuropática o miopática [3]. Los trastornos miopáticos resultan de la muerte o atrofia de las fibras musculares, e.g. Distrofia Muscular. Los trastornos neuropáticos ocurren cuando algunas neuronas motoras mueren y las supervivientes deben reinervar las fibras musculares huérfanas, e.g. ELA. Se sabe que el tamaño y la forma de los PAUMs detectados en los músculos afectados por un trastorno miopático son más pequeños y continuos debido a la mayor variabilidad de diámetro de las fibras musculares, mientras que las formas de los PAUMs detectados en los músculos neuropáticos son de mayor amplitud que los detectados en los músculos normales y miopáticos. Específicamente, los patrones de PAUMs neuropáticos presentan una reducción de los promedios de disparos y retrasos en el reclutamiento muscular dado que la reinervación conlleva a que las UMs tengan más fibras musculares produciendo más tensión y alcanzando el mismo nivel de contracción con menos UMs.

En el análisis auditivo, un clínico identifica la frecuencia y la amplitud de los clics y crujidos producidos por señales EMG amplificadas para tratar de asemejar el sonido a algún patrón de reclutamiento de las UMs de alguna ENM. Las herramientas de inspección visual son usadas para tratar de aislar los PAUMs detectados de una misma UM, para luego superponerlos en tiempo real dando una estimación aproximada de la forma de onda de los PAUMs que es comparada subjetivamente con la forma de onda correspondiente a los PAUMs normales. Ambos métodos cualitativos son crudos, con escasa sensibilidad y especificidad, y carecen de datos cuantitativos objetivos a partir de los cuales puedan hacerse fácilmente comparaciones longitudinales. Por ejemplo, un estudio escrito por Kendall et al. [4], realizado en la Universidad de Utah tuvo como objetivo determinar la eficiencia del diagnóstico de radiculopatía a partir de señales EMG pregrabadas, tomando como sujetos evaluadores tanto al personal médico docente como residentes, los cuales no tuvieron acceso al diagnóstico subyacente de cada señal EMG, mostrando como resultados tan solo una precisión promedio del 46,9% (medico docente 60.5%, residente 28.5%) con respecto al diagnóstico real [4]; demostrando que para un médico experimentado la precisión en el diagnóstico de una neuropatía a partir de solo señales EMG es poco certera. Otro ejemplo se puede encontrar en el análisis de señales EMG en miopatías inflamatorias (MI), las cuales suelen mostrar lo que se define habitualmente como "patrón neurógeno-miopático" o "patrón mixto": actividad espontánea con PAUMs pequeños, cortos y polifásicos, y reclutamiento precoz. Este patrón es altamente sugestivo, pero no específico, de una MI ya que también puede observarse en algunas miopatías con importante destrucción muscular como la distrofia facioescapulohumeral, algunas distrofias de cinturas, o en las distrofinopatías [5].

Es por eso que aunque la evaluación subjetiva de PAUMs, sea satisfactoria para la detección de anormalidades obvias, no es suficiente para describir desviaciones menos aparentes o patrones mixtos de anormalidades presentes en una ENM. En consecuencia, para un análisis efectivo de estos trastornos se han desarrollado una serie de técnicas que permiten cuantificar de forma profunda estas señales EMG [6]. Además las ciencias de la computación han sugerido que la evaluación basada en técnicas cuantitativas tiene el potencial de ser más específica y sensible que la evaluación cualitativa [7], inclinando numerosas investigaciones a la cuantificación y/o discriminación de patrones característicos de las EMG logrando obtener altas tasas de precisión [8–13].

La agrupación de las ENM como neuropáticos o miopáticos proporciona un marco genérico que es útil para predecir los cambios inducidos por la enfermedad neuromuscular en la estructura y/o forma de las señales EMG. Esta agrupación de ENM se pretende adoptar en esta investigación, con el fin de determinar si las señales EMG corresponden a sujetos normales, miopáticos o neuropáticos, empleando métodos robustos de extracción, selección y reducción de características, y clasificación; formando un sistema clasificador de señales EMG, empleando lo que se conoce como electromiografía cuantitativa (EMGC) realizando procesos de detección y análisis cuantitativo de señales EMG para la extracción de información clínicamente útil. Argumentando que mediante el uso de la descomposición de una señal EMG y las técnicas anteriores, se puede medir y mostrar con precisión un conjunto completo de características, obteniendo una gran cantidad de información apropiada para una clasificación efectiva de las ENM, lo que le servirá de apoyo al clínico experto para realizar un diagnóstico mas certero y en un tiempo menor. Actualmente diferentes investigaciones se ha enfocado en desarrollar varios algoritmos de análisis EMG cuantitativos basados en computadora [6, 8, 11, 12, 14-33].

Pattichis et al. [34] evaluó el rendimiento de una red neuronal artificial (ANN por sus siglas en ingles) utilizando aprendizaje supervisado y no supervisado. En la investigación compararon el desempeño de una ANN y la técnica de K vecino mas cercano (KNN por sus siglas en ingles). El vector de características se componía de la desviación estándar y la media de siete características de dominio de tiempo. Para el entrenamiento supervisado, utilizaron la retropropagación (del inglés backpropagation), mientras que un algoritmo de mapa de características de auto-organización fue implementado para el paradigma no supervisado. Ambos paradigmas ANN mostraron un rendimiento comparable con una precisión diagnóstica del 80 %, que excedió sustancialmente al KNN.

Pfeiffer et al. [16] usaron el análisis discriminante lineal para mapear la duración, área, número de giros y características de frecuencia central en dos puntajes. El mapeo fue una función lineal de las características y se infirió, usando los datos de entrenamiento, para maximizar la separabilidad entre puntajes para diferentes clases. El algoritmo utilizado también excluyó características que no mejoraron la discriminación. El centroide de cada categorización se estimó y durante la clasificación, la probabilidad a posteriori se calculó usando la regla de Bayes. Las probabilidades de verosimilitud se estimaron utilizando la distancia euclidiana de los centroides de clase, suponiendo que las características se distribuyeran normalmente con igual covarianza para todas las clases. Para el primer PAUM, las probabilidades previas de la clasificación se basaron en datos epidemiológicos. La probabilidad a posteriori del PAUM anterior se usó como la probabilidad previa para PAUM subsiguientes. La experimentación mostró probabilidades de diagnóstico superiores a 0,95 en el 91 % de 223 músculos bíceps braquiales de 80 pacientes.

Pino et al. [17] utilizaron la clasificación basada en las reglas de asociación de eventos para la caracterización muscular. Durante la fase de entrenamiento, se descubrieron patrones repetibles a partir de vectores de características cuantificadas. Luego se estimó una medida de ponderación de la evidencia (WOE por sus siglas en ingles) para reflejar el apoyo o la refutación de cada uno de los patrones para una de las clases. Durante la clasificación, las sumas de las medidas WOE de todos los patrones para las tres clases se usaron luego para estimar las probabilidades a posteriori. Estas caracterizaciones de los PAUM se agregaron utilizando la regla de Bayes o se promediaron para producir una caracterización muscular. La experimentación basada en datos, tanto clínicos como simulados, utilizando solo cuatro características de dominio temporal, tuvo un rendimiento similar al obtenido mediante el método descrito por Pfeiffer et.al. [16].

En los últimos años se han desarrollado diferentes investigaciones [11,16,22,24,30,32, 33,35,35–38], que se han enfocado en proporcionar un sistema preciso y computacionalmente eficiente de clasificación cuantitativo de las señales EMG; las cuales aportan una fuente importante de información para el diagnóstico de los trastornos neuromusculares.

1.1. Objetivos

Desarrollo de un sistema cuantitativo de clasificación de señales electromiográficas para el apoyo al diagnostico de desordenes neuromusculares.

1.1.1. Objetivos específicos

- Obtener una base de datos de señales EMG de aguja, provenientes de sujetos con ENM y sujetos sanos.
- Pre-procesar y acondicionar las señales EMG, empleando filtros adecuados para los diferentes tipos de ruido que se puedan encontrar en las señales.
- Implementar técnicas novedosas para el análisis de señales EMG, robustas ante la no linealidad y no estacionariedad de las señales, como la descomposición de modo empírico mejorada (EEMD) y la transformada de Hilbert.
- Extraer características tiempo-frecuencia de las señales EMG determinando cuáles son adecuadas para la tarea discriminatoria de ENM, empleando un test estadístico paramétrico o no parametrico combinado con métodos de reducción de características.
- Implementar y evaluar diferentes algoritmos de reconocimiento de patrones para clasificar la señal EMG, indicando si pertenece a un sujeto sano o a uno con alguna ENM.

Capítulo 2

Enfermedades neuro-musculares y la Electromiografía

Las enfermedades neuromusculares (ENM) afectan las fibras músculares y/o los nervios que controlan los músculos voluntarios, con lo cuales se pueden controlar, por ejemplo, los brazos y las piernas. Las células nerviosas, también llamadas moto-neuronas, envían mensajes que controlan esos músculos. Cuando las neuronas se enferman o se mueren, la comunicación entre el sistema nervioso y los músculos se interrumpe¹. Como resultado, los músculos se debilitan y se consumen. La debilidad puede conducir a espasmos musculares, calambres, dolores y problemas articulares y del movimiento. Algunas veces, también afecta la función cardíaca y la capacidad para respirar [39].

Básicamente las ENM pueden ser clasificadas clínicamente en dos grupos: las miopatías y las neuropatías. El primer grupo (miopatías) comprometen principalmente la fibra muscular ya sea en forma primaria o secundaria. Se incluyen las que están determinadas genéticamente y aquellas de causas metabólicas, endocrinas o inflamatorias. El segundo grupo (Neuropatías) comprometen el nervio periférico en cualquiera de sus componentes básicos, la mielina o el axón. En este grupo la clasificación de enfermedades es múltiple de acuerdo a las causas o el daño en la mielina, el axón o los dos.

En este trabajo se hace referencia a las ENM, como cualquier desorden neuromuscular que presente las características anteriormente mencionadas y que hagan parte en grandes rasgos a cualquiera de los dos grupos anteriormente mencionados, sin especificar el origen genético o metabólico que lo haya podido originar. Para realizar un diagnostico de ENM existen diferentes procedimientos clínicos, el procedimiento más común y contundente para el diagnostico y clasificación de las ENM es a partir de las señales Electromiograficas (EMGs).

¹Este tipo de enfermedad se clasifica como una neuropatía o una miopatía, dependiendo del origen del daño muscular.

2.1. Señales electromiográficas

La EMG es una técnica de diagnóstico clínico que se utiliza para evaluar la salud de los músculos y las neuronas que los controlan (moto-neuronas). Las moto-neuronas transmiten señales eléctricas que hacen que los músculos se contraigan. Las señales electromiográficas son una indicación eléctrica de la activación neuromuscular conectada con un músculo contraído [40]. Es una señal extremadamente complicada que está influenciada por las propiedades anatómicas y fisiológicas de los músculos, el control del sistema sensorial marginal y también las características de la instrumentación que se utiliza para identificar y observar la señal. Una EMG convierte estas señales en gráficos, sonidos o valores numéricos para ser analizados, las cuales son conocidas como señales electromiografícas (EMGs). En la técnica EMG se hace uso de electrodos, que permiten la trasmisión y detección de las señales eléctricas. Tales electrodos pueden ser insertados en el músculo (electrodos de aguja) o pueden superponerse superficialmente (electrodos de superficie), permitiendo obtener la señal eléctrica del movimiento, la velocidad v/ola intensidad de la señal recibida debido a la contracción muscular. En este trabajo unicamente se tienen en cuenta las señales EMGs originarias de un procedimiento con aguja [41].

Independientemente de la ENM, generalmente existen dos parámetros clave de la forma de onda de respuesta sensorial o motora utilizada en la práctica clínica habitual. Esto hace que la interpretación básica de los estudios de conducción nerviosa sea relativamente sencilla [42]. Estos parámetros son:

- **Amplitud:** Depende del número absoluto de potenciales de acción y la sincronización de su llegada al electrodo de grabación. Menos potenciales de acción o mayor dispersión temporal darán como resultado un registro de amplitud menor, pero los dos se pueden distinguir observando la duración de la respuesta, que se prolonga con la dispersión temporal.
- **Duración:** Refleja el grado de dispersión temporal y ayuda a determinar si una pérdida de amplitud se debe a una reducción en el número de potenciales de acción o la sincronía de su llegada.

Por lo que, el resultado de la aplicación de la técnica de diagnostico con señales EMG, puede dar como resultado, una disfunción nerviosa (Neuropatia) o muscular (Miopatía). El termino EMG fue un termino asociado unicamente al examen con electrodo de aguja, pero actualmente su uso común esta asociado a las evaluaciones enteras de electrodiagnostico (incluyendo los electrodos de superficie).

2.1.1. Unidades motoras

Las EMGs miden el signo eléctrico conectado con la representación del músculo. Esto puede ser una compresión muscular intencionada o automática. La EMG de la acción de la contracción voluntaria del músculo se identifica con la presión. La unidad práctica de la compresión muscular es una unidad motora, que está incorporada a la moto-neurona alfa solitaria y a todos las fibras que inerva. Esta fibra muscular se contrae cuando las posibilidades de actividad (impulso) del nervio que lo suministra logran un límite de despolarización. La despolarización crea un campo electromagnético y el potencial inducido por tal campo electromagnetico se mide como un voltaje. La despolarización, que se extiende a lo largo del músculo, es un potencial de acción muscular ó potencial de acción de unidad motora (PAUM). El PAUM es la suma espacial y transitoria de las posibilidades de actividad muscular individual para todos las fibras de una sola unidad motora. De esta forma, la señal EMG es la suma aritmética de las posibilidades de actividad de la unidad motora dentro del territorio de captación del terminal que se está utilizando. La zona de captación de un electrodo muy a menudo incorporará más de una unidad motora sobre la base de que las fibras de los músculos de las unidades motoras distintivas se mezclan en todo el músculo. Cualquier parte del músculo puede contener fibras que tengan un lugar con más de 20-50 unidades motoras [42], (ver Fig. 2.1).



Figura 2.1: Esquema general de obtención de señales EMG y PAUM.

2.1.2. Potenciales de acción de unidad motora

Una EMG por aguja registra únicamente un pequeño volumen de músculo, sin embargo, las unidades motoras registradas cubren un gran número de fibras, denominado territorio de la unidad motora, que contiene hasta varios cientos de fibras musculares. Algunos investigadores estiman que puede haber más de 1000 fibras musculares en una sola unidad motora. Siendo así, se debe tener en cuenta clínicamente que el electrodo de aguja no puede registrar simultáneamente los potenciales de todas las fibras musculares en una unidad motora.

Como se mencionó anteriormente, los potenciales de acción de unidad motora (PAUM) son la suma espacial y transitoria de las posibilidades de actividad muscular individual para todos las fibras de una sola unidad motora. Para entender las diferencias entre un sujeto normal y un sujeto con una ENM, es necesario entender la diferencia entre los PAUM de cada uno de los grupos (sujeto normal, miopática o neuropática) [40–42].

En un paciente sano, cuando inicia el proceso de medición con la técnica EMG con aguja, al inicio no se presenta ningún tipo de señal. Cuando aparece la contracción muscular voluntaria empiezan a aparecer los PAUM, los cuales van aumentando su amplitud a medida que aumenta la contracción. Este proceso se debe al disparo de las unidades motoras generados por las moto-neuronas delgadas que están en contacto con las fibras musculares.

Retomando las definiciones previamente realizadas, el PAUM está determinado por varios potenciales de acción de la fibra muscular con respecto a una sola unidad motora, pero no refleja la actividad de todas las fibras musculares en esa unidad motora. En su nivel más básico, la unidad motora puede ser anormalmente pequeña, en cuyo caso un potencial de acción activa menos fibras musculares de lo esperado o anormalmente grande, donde muchas fibras musculares son activadas por un solo axón. Representando de esta forma el comportamiento de las ENM. Ya que se han clasificado las ENM en neuropatías o miopatías se establecen diferencias anatómicas y fisiológicas en los sujetos miopáticos o neuropáticos [40–42]. En el caso de un sujeto neuropático, se tiene una mayor activación de moto-neuronas, una cantidad de fibras musculares normales y otras reinervadas debido a la actividad neuronal (ver Fig. 2.2.b) y en el caso de los sujetos miopáticos se presenta una degeneración en algunas de las fibras musculares (ver Fig. 2.2.c). Cualquiera que sea el tipo de ENM que presente el sujeto, se sabe que las características clínicas mencionadas anteriormente, afectan la señal EMG, cambiando la morfología normal de la señal.

2.1.3. Morfología de los PAUM

El potencial de acción de la unidad motora está determinado por varios potenciales de acción de fibra muscular de una sola unidad motora, pero no refleja la actividad de todas las fibras musculares en esa unidad motora. En su nivel más básico, la unidad



Figura 2.2: Representación gráfica de las fibras musculares, las moto-neuronas y PAUM. La primera representación hace parte de un sujeto normal, la segunda de un neuropático y la tercera de un miopático.

motora (no el potencial de acción de la unidad motora, que es la medición eléctrica en oposición a la estructura anatómica) puede ser anormalmente pequeña, en cuyo caso un potencial de acción activa menos fibras musculares de lo esperado o anormalmente grande, donde muchas fibras musculares son activadas por un solo axón [42].

Las unidades motoras anormalmente pequeñas tienden a encontrarse en las miopatías, donde la patología muscular da como resultado la pérdida o la disfunción de una proporción de fibras musculares. En una miopatía, la duración del potencial de acción de la unidad motora es corta debido a una reducción en el número de fibras musculares en la unidad motora, con pocos cambios en la sincronía de su disparo. La amplitud se reduce ya que hay menos interferencia constructiva dado que hay una reducción en el número de potenciales de acción de fibra muscular. Las fibras musculares también pueden ser más delgadas de lo normal y pueden estar presentes a una densidad más baja en la punta de la aguja que en el músculo normal, lo que contribuye a la pérdida de amplitud. La pérdida de muchas fibras musculares significa que el potencial de acción de la unidad motora de baja amplitud y corta duración también puede ser polifásico.

Es importante apreciar que cualquier razón para la pérdida de transmisión de una

	Normal	Miopático	Neuropático
Músculo Normal Degenerado Reinervado			
PA Libres (singulares)			
PAUM		M	-M/L
Duración	Normal	Corta	Larga
Amplitud	Normal	Pequeña	Alta

Tabla 2.1: La morfología de los PAUM y las características de las fibras musculares.

proporción de las ramas del axón terminal a las fibras musculares individuales, o algunas de las uniones neuromusculares, puede causar la pérdida funcional de un número de fibras musculares y causar así *miopatías*, lo cual puede ser determinado a partir de los potenciales de acción de la unidad motora. Sin embargo, este recurso resulta ser incompleto en el momento de realizar un diagnostico certero de la ENM [42].

En condiciones miopáticas, la mayoría de las unidades motoras contienen menos fibras musculares que las normales, y como resultado, los PAUMs son de corta duración, baja amplitud y polifásicos [42]. Sin embargo, algunos potenciales de acción de la unidad motora de gran amplitud y duración relativamente larga pueden entremezclarse como resultado de la reinervación posterior a la división de fibras musculares o la degeneración de los axones motores terminales intramusculares. Se requieren al menos varias semanas para la remodelación de dicha unidad motora. En este contexto, los grandes potenciales de acción de la unidad motora no implican un proceso neuropático adicional (ver Tabla 2.1). Los PAUMs de corta duración no son específicos de las miopatías y pueden verse con la reinervación después de la patología axonal, es decir puede estar relacionado con una neuropatía.

Las unidades motoras grandes se generan por el crecimiento de axones terminales para inervar las fibras musculares cercanas que han perdido su suministro nervioso habitual. Esto puede dar como resultado cúmulos inusualmente densos de fibras musculares que comparten una inervación común y, por lo tanto, se disparan de forma relativamente sincrónica. Cuando están cerca de la punta de la aguja, el resultado es un PAUM de amplitud anormalmente alta (ver Tabla 2.1).

El número de fibras musculares en la unidad motora se incrementa, al igual que su territorio, lo cual se ve reflejado en un aumento en la duración del potencial de acción de la unidad motora (ver Tabla 2.1). Los nuevos axones y las uniones neuromusculares inmaduras a menudo son más lentos, e inicialmente menos confiables, que las conexiones neuromusculares establecidas un tiempo atras, lo que contribuye a la polifasia, a la larga duración y a la inestabilidad del potencial de acción de la unidad motora (ver Tabla 2.1).

Aunque las unidades motoras grandes se encuentran característicamente en la enfermedad neuropática de larga evolución, después de la pérdida de una proporción de axones motores, también se pueden ver en miopatías crónicas donde ha habido daño intramuscular a los axones motores terminales o división de fibras musculares y posterior remodelación de unidades motoras. Es común que los potenciales de acción de la unidad motora de larga duración tengan una gran amplitud, pero esto no es inevitable y, por lo tanto, hablar de potenciales "grandes" versus "pequeños" es menos preciso que describir tanto su amplitud como su duración (ver Tabla 2.1).

La afección neurogénica se observa en una EMG después de una lesión del nervio motor en cualquier punto de su longitud, o debido a la degeneración del propio cuerpo celular del cuerno anterior. Estas características ayudan al diagnostico cualitativo del tipo de neuropátia que padece el individuo.

Los PAUMs amplios y de gran amplitud a veces se observan en condiciones miopáticas. El patrón más amplio de las apariencias de EMG generalmente proporciona una pista para la patología miopática: algunos potenciales de acción de la unidad motora polifásica pequeña se entremezclan con los más grandes, y el reclutamiento rápido se ve en algunas áreas. La presentación clínica generalmente proporciona evidencia convincente para sugerir una miopatía primaria en este entorno.

En lesiones axonales parciales, de los axones motores no afectados brotan ramas nerviosas terminales adicionales durante un período de semanas y meses. Suministran fibras musculares denervadas cercanas, lo que resulta en unidades motoras anormalmente grandes. En EMG, esto se refleja en los potenciales de acción de la unidad motora de larga duración que son de gran amplitud y polifásicos. Se debe tener en cuenta que son las unidades motoras supervivientes y comparativamente saludables las que generan señales EMG.

Capítulo 3 Metodología

3.1. Conjunto de Señales clínicas EMG

La base de datos objeto de estudio en el presente trabajo es publica y fue construida en Faculty of Health Science, University of Copenhagen por Miki Nikolic [43], de la cual se tomaron las señales provenientes del Bíceps Braquial, ya que este músculo fue el más investigado en los tres grupos de pacientes. Este conjunto de datos está divido en tres grupos: un grupo control con señales de sujetos sanos, un grupo de pacientes con miopatía y un grupo de pacientes con una neuropatía especifica conocida como Esclerosis Lateral Amiotrófica (ELA). Ninguno en el grupo de control tenía signos o antecedentes de trastornos neuromusculares. Los grupos con ELA y miopatía fueron diagnosticados clínicamente usando tanto el análisis EMG como también evaluación física, análisis de ADN, biopsias musculares y diferentes pruebas electrodiagnósticas.

Tabla 3.1: Características de la base de datos de señales EMG clínicas (H representa a la población de Hombres y M la de Mujeres).

Grupo	N ^o Sujetos	Η	Μ	Edades (años)	\mathbf{N}^o_{Total} de registros
ELA	8	4	4	35 - 67	80
Normal	10	4	6	21 - 37	200
Miopáticos	7	5	2	19 - 63	70
Total	25	13	12	19 - 67	350

3.2. Adquisición y Pre-procesamiento de la señal

El procedimiento sobre el cual se basó M. Nikolic para registrar cada una de las señales EMG fue el siguiente [43]:

 Se insertó un electrodo de aguja concéntrico en el músculo (uno por cada ensayo) y se colocó el electrodo de referencia en la superficie de la extremidad del brazo.



Figura 3.1: Esquema de adquisición de la señal EMG. Tomado de [43]

El cable que conecta la aguja al amplificador se fijó al músculo con un trozo de cinta para evitar el movimiento de la aguja.

- Se le pidió al paciente que aplicara una contracción leve y constante (menor a 30 % de la máxima contracción voluntaria). La señal fue evaluada tanto visual como auditivamente identificando un sonido repetitivo crujiente característico cuando la punta de la aguja estaba cerca de algunas fibras musculares.
- Una vez el examinador determinó que la señal tenía una calidad útil, se dio inicio a la grabación con una duración de 11.2 segundos por ensayo. Al término de esta digitalización, la aguja se movía a otro nivel de profundidad o a otro lugar de inserción para iniciar una nueva grabación. Además, el autor tuvo cuidado de no grabar desde la misma unidad motora para así explorar todo el músculo. Obteniendo de esta forma cada uno de los 350 registros.

Para la adquisición de la señal, M. Nikolic [43] usó un electrodo de aguja concéntrico estándar de 0.07 mm² conectado a un amplificador diferencial de alta impedancia (DISA, 15C01), amplificando la señal 500 μ V/DIV (4000 veces) y filtrándola con filtros analógicos paso alto y paso bajo establecidos a frecuencias de corte de 2 Hz y 10 kHz respectivamente; estos parámetros fueron estudiados y establecidos por Buchthal et al., argumentando que de esa forma se obtenía la mejor compensación entre la reducción de ruido y la distorsión de la señal [44]. Por último, la señal EMG se digitalizó a una frecuencia de muestreo de 23437,5 Hz, cuantificando a su vez las amplitudes en una resolución de 16 bits (Motorola DSP56ADC16); en la Figura 3.1. se muestra el esquema de esta etapa.



Figura 3.2: a) Señal original con filtro notch a 50 Hz de sujetos con ALS d) normal y g) Miopático. b) Señal con filtro notch y filtro de OLB de sujetos con ALS e) normal y h) Miopático. c) Señal filtro notch, filtro de OLB y filtro Wavelet contra la interferencia instrumental de sujetos con ALS f) normal y i) Miopático.

14

La calidad de estas señales EMG digitalizadas puede verse degradada por el ruido inducido a través de la red eléctrica, el ruido inherente de alta frecuencia atribuido a los equipos electrónicos y por el ruido de baja frecuencia generado por las oscilaciones de la línea base (OLB) (ver Figura 3.2.a,d,g), alterando los procesos de extracción, clasificación y análisis de la señal. Es por eso que a partir del proceso de adquisición descrito anteriormente se implementó en este trabajo una etapa de pre-procesamiento adicional para eliminar estos artefactos, compuesta por una serie de filtros digitales en cascada, específicos para cada ruido (ver Figura 3.3). El primero es el filtro rechaza banda (notch) que permite eliminar la interferencia causada por el cableado de alimentación AC del dispositivo de adquisición, la frecuencia de corte fue fijada a 50 Hz atribuida al país de origen en donde se obtuvieron las señales.

Una supresión adecuada de las OLB mejoraría la calidad de la señal y, en consecuencia, facilitaría y haría más fiable el proceso de clasificación. En condiciones ideales (sin fluctuación, ruido ni artefactos), la línea de base (LB) coincidiría con el cero eléctrico del equipo. Pero estas señales sin ruido normalmente no existen en el entorno real y se pueden observar movimientos de baja frecuencia (Figura 3.2.a,d,g).



Figura 3.3: Preprocesamiento de la señal EMG y eliminación de ruido.

Estas OLB presentes en las señales grabadas se debe a artefactos de diferente naturaleza, tales como: movimiento de la aguja de registro en relación con el músculo, variación del potencial de la piel inducida por la aguja y/o el equipo de adquisición [45]. Esto representaría un problema en la etapa de descomposición y extracción de características ya que en cada una de las señales pueden encontrarse patrones diferentes que no tienen que ver con el origen de la enfermedad. Por lo tanto, se utiliza un filtro digital pasa altas *Butterworth* de tercer orden, con frecuencia de corte a 30 Hz, límite de 3 dB y con distorsión de fase cero, para suprimir los movimientos de línea base de baja frecuencia (ver Figura 3.2.b,e,h).

Para suprimir el ruido inherente del amplificador se puede empezar modelando este como ruido blanco gaussiano:

$$x(t) = s(t) + e(t) \quad y \quad e(t) \in N(0, \sigma_2)$$
(3.1)

donde s(t) es la señal EMG sin ruido y e(t) es un proceso de ruido blanco gaussiano como se muestra en la Figura 3.4. Una de las técnicas actuales de eliminación de este tipo de ruido se basa en la transformada wavelet (TW) que permite lograr una estimación óptima de la señal EMG libre de ruido e(t), por lo que ha sido adoptada plenamente para la eliminación de interferencias en señales fisiológicas [46,47]. Esta técnica presenta la ventaja de que no reduce la amplitud de los PAUM, como lo hacen los filtros clásicos FIR y IIR pasa bajas y produce una señal suave sin ruido [46].



Figura 3.4: Interferencia causada por el amplificador EMG a) señal ruidosa, b) histograma de la señal y c) gráfico de probabilidad normal. Tomado de [43]

Para aplicar la TW en la eliminación de ruido, se deben llevar a cabo los tres pasos siguientes:

- 1. **Descomposición:** Elegir una wavelet madre y un nivel N de descomposición máximo y luego calcular los coeficientes de la transformada wavelet de la señal.
- 2. Umbralización: Realización de un proceso específico, es decir, descomposición y umbral, sobre estos coeficientes.
- 3. Reconstrucción: Calcular la TW inversa para obtener la señal libre de ruido.

De acuerdo con estos pasos, es necesario elegir 3 parámetros, que son la wavelet madre, el nivel máximo de descomposición y los valores de umbral. MA. Awal et al. [47], determinaron que la función wavelet de Symlet 6 se desempeña mejor en un amplio rango del ruido en términos de mejora de la SNR, estableciendo un nivel 8 como valor óptimo de descomposición. P. Kumar et al. [46], evaluaron diferentes métodos de umbralización (sqtwolog, heursure y minimax) resaltando al método heursure como el más óptimo, ya que fue con el cual obtuvieron una mejor SNR, argumentando además que con este método no se presentaron cambios en los detalles de la señal (ver Figura 3.2.c,f,i).

El efecto del filtro de eliminación de ruido inherente y del filtro supresor de línea base en las señales de cada tipo de ENM es ilustrado en la Figura 3.2.

3.3. Descomposición de la señal EMG

Una vez se ha conseguido tener la señal EMG libre de ruido, es común emplear técnicas analíticas cuantitativas para evaluar características únicas de las unidades motoras individuales del músculo y así ayudar a determinar la presencia o ausencia de alguna ENM. Habitualmente los electrofisiólogos estudian las características morfológicas como la amplitud, número de fases y número de picos [48]; sin embargo, el requerir la intervención subjetiva del experto para evaluar estas condiciones, unido al hecho de que una sola señal es la suma de los potenciales de todas las fibras que componen una unidad motora, ha llevado a desarrollar métodos cuantitativos automáticos que permitan descomponer la señal para obtener sus PAUMs individuales. Entre estas técnicas se destacan como pioneras las basadas en análisis temporal por su sencillez y facilidad de evaluación, debido a que no requieren ningún tipo de transformación de la señal. También están las basadas en análisis espectral, para las cuales se requiere de la transformación de la señal, como la transformada de Fourier de tiempo corto (STFT short time Fourier transform) con la cual se obtiene información de la señal en el dominio tiempo-frecuencia [49–51]; sin embargo, esta técnica asume la condición de estacionariedad en la señal, lo cual es contradictorio a la naturaleza de las señales EMG. A pesar de reportar resultados con un desempeño bueno, su naturaleza estocástica no estacionaria ha hecho necesario explorar técnicas alternativas que ayuden a mejorar el proceso de extracción de características.

Una solución a este inconveniente se refleja en los últimos trabajos de investigación en el área de procesamiento de señales con la técnica de análisis espectral basada en la "teoría de wavelets", mediante las transformadas wavelets: DTW (Discrette Wavelet Transform) y WPT (Wavelet Packet Transform). Con esta técnica se consigue una representación de la señal en los dominios tiempo-frecuencia mucho más compacta que la conseguida por transformada de Fourier STFT, puesto que permite disponer de información de la señal en sus dominios de tiempo y frecuencia de manera simultánea [52–54]. El principal inconveniente de esta herramienta reside en la selección a priori de algunos parámetros como las funciones base predeterminadas (wavelet madre) y el nivel de descomposición. Por lo tanto, se pretende usar una técnica reciente, adecuada para el análisis de señales no estacionarias y no lineales, denominada la Descomposición Empírica de Modos [55]. Este análisis permite la extracción de las oscilaciones embebidas que se producen en las señales EMG. El uso de esta técnica reporta resultados iguales y en algunos casos superiores a los obtenidos con las técnicas anteriores [8, 56, 57].

3.4. Descomposición Empírica de Modos

La Descomposición Empírica de Modos (Empirical Mode Decomposition, EMD), es un método adaptativo para el análisis de señales no lineales y no estacionarias, cuyo objetivo es descomponer la señal multicomponente en un conjunto finito de componentes oscilante,s modulados en frecuencia y amplitud, denominados funciones de modo intrínseco (FMI). Cada FMI debe cumplir con las siguientes condiciones: (1) La cantidad de puntos extremos (máximos y mínimos) y la cantidad de cruces por cero deben ser iguales o diferir a lo sumo en uno; y (2) La media local, definida como el valor medio de las envolventes superior e inferior, debe ser nula para todo punto. Esto implica que el valor medio de cada FMI es cero. A su vez EMD es autoadaptativo porque los FMI, que funcionan como funciones básicas, están determinados por la señal en sí. Por lo que este método no requiere ningún conocimiento a priori de la señal y evita la suposición sobre la estacionariedad y linealidad de las señales [55].

Para descomponer completamente una señal x[n] mediante EMD, obteniendo sus K modos o componentes $(FMI_k[n])$, se deben seguir los siguientes pasos:

- 1. Inicializar el índice k = 1, y hacer u[n] = x[n].
- 2. Encontrar los extremos de la señal u[n] y unir todos los máximos y mínimos locales de forma independiente con una interpolación segmentaría cúbica, formando la envolvente superior $(h_{max}[n])$ e inferior $(h_{min}[n])$.
- 3. Calcular la media local de las dos envolventes como $m[n] = \frac{h_{max}[n] + h_{min}[n]}{2}$
- 4. Obtener una posible FMI restando la media a la señal u[n], c[n] = u[n] m[n]y verificar si c[n] cumple con las condiciones de extremos y cruces por cero, y

m[n] = 0.

- Si cumple, establecer c[n] como componente FMI valida, $FMI_k[n] = c[n]$.
- Si no cumple, c[n] pasa a ser considerada como la señal original u[n] = c[n]y se repite desde el paso 2.
- 5. Continuar con el proceso hasta alcanzar un criterio de detención establecido cuando u[n] pasa a ser una función monótona creciente o decreciente.

Al final de la descomposición, la señal x[n] se puede representar de la siguiente manera:

$$x[n] = \sum_{i=1}^{K} FMI_k[n] + r[n]$$
(3.2)

Donde r[n] es el residuo final y K es el numero total de FMI. Cada nivel de descomposición presenta diferentes componentes espectrales, siendo la primera FMI la componente de mayor frecuencia y la última componente FMI la de menor frecuencia.

Este proceso produce una separación local y completamente guiada por los datos, en oscilaciones rápidas y lentas. No obstante, la EMD presenta algunos problemas, tales como la presencia de oscilaciones de amplitud muy dispar en uno o mas modos, o de oscilaciones muy similares en diferentes modos, fenómeno conocido como mezcla de modos. Para disminuir este problema, en [58] se propuso un nuevo método: la Descomposición Empírica en Modos por Conjuntos, la cual realiza una EMD sobre cierta cantidad de realizaciones (habitualmente algunos cientos) de ruido blanco gaussiano sumadas a la señal de interés, reduciendo el problema de la mezcla de modos al poblar por completo el espacio tiempo-frecuencia [59].

3.5. Descomposición Empírica de Modos por Conjuntos

La Descomposición Empírica de Modos por Conjuntos (Ensemble Empirical Mode Decomposition, EEMD), define a los modos "verdaderos"¹ como el promedio de las FMIs obtenidas con EMD sobre un conjunto de señales generadas al sumar diferentes realizaciones de ruido blanco de varianza finita, a la señal original (x[n]). El algoritmo de EEMD puede describirse de la siguiente manera:

1. Generar $x^{(i)}[n] = x[n] + w^{(i)}[n]$, donde $w^{(i)}[n]$ (i = 1, ..., I) es una realización de ruido blanco gaussiano,

¹Se simbolizan en esta parte como \overline{FMI}

- 2. Descomponer completamente cada $x^{(i)}[n]$ (i = 1, ..., I) mediante EMD, obteniendo sus $FMI^{(i)}[n]$, donde k = 1, ..., K indica el modo, empleando el método descrito en la sección 3.4:
- 3. Asignar \overline{FMI}_k como el k-ésimo modo de x[n], obtenido al promediar los correspondientes $FMI_k^{(i)} : \overline{FMI}_k[n] = \frac{1}{I} \sum_{i=1}^{I} FMI_k^{(i)}[n]$.

La extracción de cada $FMI_k^{(i)}$ se realiza mediante un proceso que requiere $j = 1, ..., J_k^{(i)}$ iteraciones, denominado sifting. En la Figura 3.5. se puede apreciar el modo en que es dividida una señal EMG de un sujeto con ALS, obteniendo 13 FMIs característicos y un residuo, de igual manera, para fines de clarida en la imagen, de los 11.2 segundos de grabación que tiene la señal se muestra únicamente desde el segundo 2 hasta el 7, es por eso que el FMI 13 parece que no cumpliera estrictamente con el concepto de señal AM o FM, y esto es porque del segundo 7 al 11 faltante es donde se completa la onda.

3.6. Extracción de características tiempo-frecuencia

La señal EMG descompuesta generalmente presenta información redundante debido a la duración de la grabación EMG y a la contracción isométrica a la que se somete el musculo evaluado, por lo que obtener información directamente de la misma no es la opción mas óptima en la clasificación de estas señales. En esta sección, el objetivo es extraer un conjunto de características relevantes de la señal que permitan representar una señal a partir de un conjunto de características determinantes e importantes para la precisión en un sistema clasificador. La extracción de características consiste en obtener información relevante de la señal EMG descompuesta y relacionarla con el estado del musculo. Estas características pueden ser obtenidas en el dominio del tiempo y en el dominio de la frecuencia mediante una transformación de los datos originales, formando así un vector de características tiempo-frecuencia.

Las características en el dominio del tiempo son las más populares en aplicaciones de tiempo real [22], esto se debe a que no se necesita hacer transformación alguna de los datos. Se basan simplemente en la amplitud de la señal, forma de onda y algunas características que se relacionan con la frecuencia. A continuación se describen las características mas comunes que se pueden extraer del dominio del tiempo.

3.6.1. Longitud formal de onda (LFO)

Se refiere a la longitud de onda acumulada a lo largo del segmento. Ofrece una medida de la amplitud, frecuencia y duración de la señal [60].



Figura 3.5: Descomposición EEMD de una señal EMG en sus 13 FMI_k .
$$LFO = \sum_{i=1}^{N-1} |x_{i+1} - x_i|$$
(3.3)

3.6.2. Cruces por cero (CPC)

Es el número de veces que la señal pasa por cero, es decir, el número de veces que la señal cambia de signo en un segmento dado [60]. Se debe incluir un umbral en amplitud para evitar los cruces por cero producidos por el ruido de la señal. Si se tienen dos muestras, x_{i+1} , x_i , entonces la función g en su posición i - ésima guardará un 1 si se encuentra un cruce por cero o de lo contrario guardara un 0:

$$g(i) = \{x_i > 0 \land x_{i+1} < 0\} \lor \{x_i < 0 \land x_{i+1} > 0\} \land |x_{i+1} - x_i| \ge \epsilon$$

Donde ϵ es el umbral definido en amplitud. La sumatoria de estos cruces es un estimador de la frecuencia con la cual la forma de onda sufre cambios significativos.

$$CPC = \sum_{i=1}^{N-1} g(i)$$
 (3.4)

3.6.3. Cambios en la pendiente de la señal (CPS)

Es el cambio de signo de la pendiente de la señal y proporciona una medida de la frecuencia [60]. Debe de introducirse un umbral para evitar el ruido. Dadas tres muestras consecutivas x_{i-1} , x_i , x_{i+1} , se incrementará el cambio de signo de la pendiente de la señal si:

$$g(i) = \{x_i > x_{i-1} \land x_i > x_{i+1}\} \lor \{x_i < x_{i-1} \land x_i > x_{i+1}\} \land |x_{i+1} - x_i| \ge \epsilon \lor |x_i - x_{i-1}| \ge \epsilon$$

$$CPS = \sum_{i=1}^{N-1} g(i)$$
 (3.5)

3.6.4. Raíz media cuadrática (RMS)

EL valor RMS se calcula tomando la raíz cuadrada de la media aritmética de las amplitudes de muestra cuadradas de una forma de onda, y se denota como [61]:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^{N} x_i^2} \tag{3.6}$$

3.6.5. Coeficientes Auto-Regresivos (CR)

Estas características modelan la señal de EMG como una serie de tiempo lineal auto regresiva y provee información acerca del estado de contracción muscular [62]. Describe cada muestra de la señal de EMG como la combinación de muestras previas más un término de error del tipo ruido blanco Gaussiano. Se define como:

$$x_k = -\sum_{i=1}^N a_i x_{k-i} + e_k \tag{3.7}$$

Donde a_i es el coeficiente auto regresivo, k es el número de segmento, e_k es el término de error de ruido blanco Gaussiano y N es el orden del modelo AR. En este caso es de orden 6, por lo que se obtienen 6 coeficientes AR para cada segmento de la FMI.

3.6.6. Valor absoluto medio (VAM)

Estima el promedio del valor absoluto de los datos en un determinado segmento [60].

$$VAM = \frac{1}{N} \sum_{i=1}^{N} |x_i|$$
(3.8)

3.6.7. Valor absoluto integrado (VAI)

El VAI es una medida relacionada con la potencia de la señal EMG. También se le conoce como EMG integrada porque se define como una suma de valores absolutos de la amplitud de la señal EMG, que se puede expresar como

$$VAI = \sum_{k=1}^{N} |x_k| \tag{3.9}$$

Donde N es el tamaño del segmento. Y x_k es el valor de cada elemento del segmento [60].

Si bien las características del dominio del tiempo son útiles para describir la forma de onda, el análisis espectral permite conocer la tasa de disparo de las UM en el rango de las bajas frecuencias (debajo de 50Hz), y la morfología de los potenciales de acción viajando a través de la fibra muscular en el rango de las altas frecuencias; estas características se utilizan principalmente para estudiar la fatiga del músculo y el análisis de reclutamiento de la UM [50,63]. La Densidad Espectral de Potencia (DEP) se convierte en un análisis importante en el dominio de la frecuencia, lo que hace vital realizar el análisis de las señales EMG sobre este parámetro, obteniendo diferentes tipos de propiedades estadísticas a la DEP, a su vez un análisis robusto con técnicas de tiempo - frecuencia es crucial. Para dicho análisis se retoman las FMI_k , las cuales presentan la particularidad de contener señal modulada en amplitud y frecuencia, lo que llevó a Huang. N, a completar su método de descomposición EMD con la transformada de Hilbert denominando su técnica como transformada de Hilbert - Huang [55] y es explicada en el siguiente apartado.

Dada una serie de FMI_k obtenido con EMD, el siguiente paso es aplicar la transformada Hilbert a cada una, definida como:

$$y(t) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau$$
(3.10)

Donde P indica el valor del principio de Cauchy. Con esta definición es posible expresar x(t) de forma fasorial, de tal forma que podemos tener una señal analítica. Una señal analítica es una señal compleja que tiene representación en el espectro de Fourier en un solo cuadrante, correspondiente a las frecuencias positivas y que son adecuadas para conocer la frecuencia instantánea y la amplitud instantánea de las señales [64]. Esta representación de la señal original en una señal analítica elimina la redundancia de información contenida en las frecuencias negativas del espectro [56]. La parte real de una señal analítica es la serie temporal original, mientras que la parte imaginaria es la transformada de Hilbert, de esta forma se puede expresar una función analítica como:

$$z(t) = x(t) + iy(t) = a(t) \cdot e^{i\theta(t)}$$
(3.11)

donde,

$$a(t) = \sqrt{x(t)^2 + y(t)^2}$$
(3.12)

$$\theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right) \tag{3.13}$$

$$\omega(t) = \frac{d\theta(t)}{dt} \tag{3.14}$$

Donde

a(t) es la amplitud instantánea, $\theta(t)$ es la fase instantánea y $\omega(t)$ es la frecuencia instantánea. Finalmente, combinando la amplitud y la frecuencia instantánea, es posible obtener la representación tiempo, frecuencia y amplitud de la señal original.

$$x(t) = Real \sum_{i=1}^{N} a_j(t) \cdot e^{i \int \omega_j(t) dt}$$
(3.15)

Donde N es el numero de FMI de la señal descompuesta.

Una parte importante para obtener información propia del espectro de la señal es la frecuencia instantánea como indicador principal en la representación tiempo frecuencia; sin embargo, en muchos casos, incluyendo el de esta tesis, se necesita la frecuencia (cantidad de ciclos por unidad de tiempo), en lugar de la frecuencia angular (radianes por unidad de tiempo), para lo cual se utiliza la relación entre frecuencia angular y frecuencia, $f = \omega/2\pi$, expresada como:

$$FI = \frac{1}{2\pi} \cdot \frac{d\theta}{dt} \tag{3.16}$$

A partir de la DEP y de la FI es posible obtener 6 características en el dominio de la frecuencia, ideales para el análisis de señales EMG cuyas sus definiciones se describen de la siguiente manera:

3.6.8. Característica de ancho de banda

El ancho de banda de cualquier señal es una medida del alcance de la frecuencia. Esta función proporciona información sobre el ancho de banda modulado en frecuencia y amplitud de cualquier señal. El objetivo de esta característica es proporcionar la información, ya sea que la difusión de frecuencia en las señales EMG se deba a la modulación de amplitud (AM), o a la modulación de frecuencia (FM), o a ambas [65]. La proporción de frecuencia debido a la AM y FM en el ancho de banda total de la señal se puede escribir como:

$$B^{2} = \frac{1}{E} \left\{ \int \left(\frac{dA(t)}{dt} \right)^{2} dt + \int \left(\frac{d\varphi(t)}{dt} - \langle \omega \rangle \right)^{2} A^{2}(t) dt \right\}$$
(3.17)

Donde,

$$\langle \omega \rangle = \frac{1}{E} \int \frac{d\varphi(t)}{dt} A^2(t) dt$$

La ecuación 3.17 tiene dos partes importantes: la primera depende de la amplitud y la segunda de la fase de una señal de esa forma se pueden obtener el ancho de banda AM (B_{AM}) y el ancho de banda FM (B_{FM}) y se representan como:

$$B_{AM} = \frac{1}{E} \int \left(\frac{dA(t)}{dt}\right)^2 dt$$
(3.18)

у

$$B_{FM} = \frac{1}{E} \int \left(\frac{d\varphi(t)}{dt} - \langle \omega \rangle \right) A^2(t) dt$$
(3.19)

Donde $E = \sum_{k=1}^{N} DEP_k$.

3.6.9. Momento Espectral de la Densidad Espectral de Potencia (ME_{DEP})

La Densidad Espectral de Potencia (DEP) es un parámetro útil para encontrar la potencia y la frecuencia dominante en una señal [65]. La DEP de cualquier señal se puede representar como:

$$S_z(f) = \lim_{T \longrightarrow \infty} \left\{ \frac{1}{2T} \left| \int_{-T}^T z(t) e^{-j2\pi f t} dt \right|^2 \right\}$$
(3.20)

Para encontrar la forma de orden mayor, se emplea el momento espectral de la DEP y se puede representar como

$$ME_{DEP} = \sum_{k=1}^{N} k \cdot DEP_k \tag{3.21}$$

Donde N es la longitud de la DEP, k es el k-ésimo valor de DEP.

3.6.10. Media de la FI (MFI)

La MFI se obtiene dividiendo la FI multiplicada por el espectro de densidad de potencia (DEP) entre la sumatoria de los valores de la DEP [65].

$$MFI = \frac{FI \cdot DEP_k}{\sum_{i=1}^{N} DEP_k}$$
(3.22)

Donde N es la longitud del DEP, k es el k-ésimo valor de DEP.

3.6.11. Media de la Primera Derivada de FI (MPD_{FI})

Para encontrar la diferencia entre dos valores consecutivos de FI, se calcula la primera derivada [65]. El valor medio de estas diferencias se calcula para usarlo como característica y se puede expresar como

$$\delta_f = |diff(f_i)| \tag{3.23}$$

El valor medio de la primera derivada de FI se puede representar como:

$$MPD_{FI} = \sum_{l=1}^{N-1} \frac{\delta_f(l)}{N-1}$$
(3.24)

Donde N es el numero total de muestras presentes en la primera derivada de la FI.

3.6.12. Valor pico de la DEP con el metodo Welch (DEP_{PEAK})

Es el valor máximo de la función de densidad espectral (DEP) usando el método **Welch**.

$$DEP_{PICO} = max(DEP[n]) \tag{3.25}$$

3.7. Selección de características y la prueba Kruskal-Wallis

Por cada una de las señales EMG se obtiene un conjunto total de 234 características formado a partir de las características de la sección 3.6 extraídas a cada una de las funciones en las cuales se descompone la señal con EEMD (18 caracteristicas * 13 FMI_k), lo cual lo hace un conjunto grande de información ocasionando generalmente problemas al entrenar un modelo clasificador; esto debido a la alta dimensionalidad de los datos que frecuentemente presentan redundancia, por lo tanto es necesario un proceso adicional de selección de características relevantes disminuyendo el número de elementos del conjunto de información, permitiendo ahorrar tiempo de procesamiento y memoria, y mejorando el rendimiento del clasificador [66].

Existen dos categorías generales involucradas en un proceso de selección de características, una es conocida como método-filtro y la otra está basada en un proceso de encapsulado. Este último selecciona los subconjuntos de características en función del desempeño de un clasificador (lineal, no lineal, con modelos generativos, etc.), revelando sobreajustes en el modelo elegido y haciéndolo costoso computacionalmente, necesitando estrategias robustas de búsqueda para explorar en forma eficiente el espacio de características.

Por otro lado, la selección de características basada en filtro, obtiene las características más importantes y útiles de forma independiente al clasificador, usando un criterio de "relevancia". En otras palabras, la ejecución de la reducción de características depende completamente de la característica intrínseca del conjunto de datos lo que lo hace robusto contra un posible sobreajuste en la clasificación. Estos métodos se pueden implementar de forma selectiva obteniendo un subconjunto con n características del conjunto inicial de N características, manteniendo el significado físico de las mismas, donde (n < N), o por transformación de espacios permitiendo obtener un subconjunto de características a partir de la multiplicación del conjunto de información por una matriz de transformación (generalmente una matriz de covarianza ver secc. 3.8.)

En el presente trabajo se implementaron estas dos técnicas de selección de forma serial empezando con la selección adecuada de características discriminatorias y luego obteniendo la matriz de transformación $G \in \mathbb{R}^{N \times l}$ (l < N) para mapear todo el espacio de información a un nuevo conjunto de solo l características.

El enfoque principal dado a esta fase de selección es el de optimizar, en términos de eficiencia al sistema clasificador, y a su vez disminuir de forma severa el tiempo computacional tanto en el entrenamiento como en reconocimiento de ENM, enfatizando el hecho de que las características catalogadas como irrelevantes serán descartadas para el sistema clasificador final evitando calcularlas nuevamente en futuros eventos de predicción. Para determinar cuáles características tiempo-frecuencia son determinantes para el modelo de clasificación, se implementó un proceso de análisis de relevancia estadística empleando como función criterio una prueba no paramétrica sobre k muestras independientes (grupo de ENM y sujetos sanos) llamada 'la prueba de Kruskal-Wallis'.

La prueba de Kruskal-Wallis, también conocida como la prueba H, es la alternativa no paramétrica al test ANOVA de una vía para datos no pareados, en la que en lugar de comparar medias, el test de Kruskal-Wallis contrasta si las diferentes muestras están equidistribuidas considerando simplificativamente la comparación de las medianas. Para esta prueba se plantean dos hipótesis.

- **Hipótesis Nula** H_0 : Todas las muestras provienen de la misma población (distribución).
- **Hipótesis Alternativa** H_A : Al menos una muestra proviene de una población con una distribución distinta.

La prueba de Kruskal-Wallis es adecuada cuando los datos tienen un orden natural, es decir, cuando para darles sentido tienen que estar ordenados o bien cuando no se satisfacen las condiciones para poder aplicar un ANOVA como la normalidad de los datos.

Supóngase que se dispone de k grupos cada uno con n observaciones. Si se ordenan todas las observaciones de menor a mayor y se le asigna a cada una de ellas su rango, cuando se obtenga la suma de rangos para cada uno de los grupos (R_i) es de esperar que, si se cumple la hipótesis nula, todos los grupos tengan un valor similar. Partiendo de esta idea se calcula el estadístico H como:

$$H = \frac{12}{N(N+1)} \sum_{i=1}^{k} \frac{R_i^2}{n_i} - 3(N+1)$$
(3.26)

Luego es determinada la significancia del test aproximando el *valor* p a través de la $Pr(\chi^2_{k-1} \ge K)$.

Si la prueba de Kruskal-Wallis es significativa (p < 0.05), implica que al menos dos grupos de entre los comparados son significativamente diferentes, pero no indica cuales. Para saberlo es necesario comparar todas las posibles parejas de muestras. Esto implica realizar una corrección del nivel de significancia para evitar incrementar el error de tipo I. El método de comparación post-hoc más empleado para un test de Kruskal-Wallis es la prueba de Dunn para comparar múltiples grupos.

3.7.1. Prueba de comparación múltiple de Dunn con un control

La prueba de Dunn puede ser aplicada a múltiples comparaciones con un solo control:

$$\left|\overline{R_0} - \overline{R_j}\right| > z_{1-\alpha*/2} \sqrt{\left[\frac{n(n+1)}{12} - B\right] \left[\frac{1}{n_0} + \frac{1}{n_j}\right]}$$
(3.27)

Donde $\overline{R_0}$ denota la suma media de rango del experimento de control. En este caso el numero de prueba es reducido a m = k - 1, con cambios de ajuste p de acuerdo a Benferroni(u otros).

A través de este análisis estadístico podemos determinar la probabilidad de que dada una misma característica extraída a cada una de las señales EMG de sujetos con ALS, con miopatía y sujetos normales (grupo AMN), ésta no presente diferencia estadística entre las distribuciones de datos estableciendo una probabilidad alta de que al evaluarla no tenga la capacidad de discriminar entre las diferentes clases, o dar una probabilidad alta de que esta característica provenga de distintas distribuciones (al menos dos de las tres clases), proponiéndola como característica apropiada para ser extraída y evaluada en nuevas señales.

Con el fin de evitar un sobreajuste en el modelo predictivo al seleccionar las características adecuadas teniendo en cuenta todo el conjunto de señales disponibles en la base de datos, se emplea el método de retención o método Holdout [31],para lo cual solo se toma el 70% de los datos por clase para realizar la evaluación discriminante y se plantea el siguiente procedimiento para su análisis:

- 1. Se toma una muestra homogénea de 49 señales aleatorias por cada ENM (ver Tabla 3.1.), correspondiente al 70% del conjunto con menos datos (EMGs miopáticos).
- 2. Se extrae una sola característica CaR (tiempo o frecuencia) por cada una las señales EMG de cada grupo AMN y se crean 3 vectores de características $V_{ALS}[n]$, $V_{Nor}[n]$, $V_{Myo}[n]$ usando el método expuesto en la sección 3.6.
- 3. Se plantean las hipótesis:
 - \mathbf{H}_0 : La característica CaR es la misma para cada clase de AMN.
 - \mathbf{H}_A : La característica CaR es diferente en al menos alguna clase de AMN.
- 4. Se obtiene el valor p con el test de Kruskal-Wallis.
- 5. Si p < 0.05 se usa el test de Dunn para determinar entre que clases de AMN la característica CaR tiene la capacidad discriminatoria.

Una forma visual para comprender la utilidad de este análisis es usando la herramienta estadística descriptiva conocida como diagrama de caja, la cual permite ver como es la dispersión de los datos con la mediana, los percentiles 25 y 75 y los valores máximos y mínimos. Al poner en contraste las distribuciones de los datos de cada clase ANM es posible observar la similitud entre conjuntos de información, por ejemplo se muestra en la Figura 3.6.a, como la característica MPD_{FI} extraída de la primer componente FMI_1 de todas las señales por cada grupo AMN, se postula como candidata discriminante entre las clases de AMN, específicamente entre las clases de ALS-Miopática y las clases Normal-Miopática. Es aquí donde la prueba de Kruskal-Wallis muestra su potencial utilidad, ya que se puede obtener la capacidad discriminante de cada CaRsin necesidad de graficar. En la Tabla 3.2 se observa que la $CaR MPD_{FI}$ obtuvo un valor p = 3,96E - 274 rechazando la hipótesis nula de tener la misma distribución de información en todas las clases de ANM. De igual manera en la Figura 3.6.b se muestra el poder discriminatorio de la característica CPC de la FMI_9 entre los 3 grupos ANM sustentado por el valor p = 4,25E - 205 (ver Tabla 3.2; casilla con fondo verde).

En las Figuras 3.7. a,b se puede visualizar como las características CR5 y MPD_{FI} de la FMI_1 e FMI_{13} , respectivamente, no muestran diferencias estadística entre diferentes grupos de ANM haciéndolas inútiles a la hora de realizar una clasificación entre estos grupos y esto se puede comprobar de igual manera obteniendo el valor p para cada característica, los cuales fueron p = 0, 9 y p = 0,64 (ver Tabla 3.2; casillas fondo rojo).



a) Característica MPD_{FI} de la FMI_1 .

b) Característica CPC de la FMI_9 .

Figura 3.6: Boxplots de las distribuciones de datos de características discriminatorias entre diferentes ENM.



a) Característica CR5 de la FMI_1 .



Figura 3.7: Boxplots de las distribuciones de datos de características que no son útiles en la clasificación de ENM.

En la Tabla 3.2. se muestran los diferentes valores p, evaluando la capacidad discriminatoria de todas las características por cada FMI_k , de la cual se deduce que sólo 103 características $(M_{CaR}^{N\times103})$ de las 234 disponibles son relevantes y útiles para la clasificación de desórdenes neuromusculares (ver Tabla 3.3), optimizando de esta manera procesos futuros de entrenamiento y clasificación, ya que las 131 características que se catalogaron como no relevantes ya no serán tenidas en cuenta para el sistema de predicción final, lo que ahorra tiempo de cómputo suponiendo además que esto va a repercutir de forma positiva en la eficacia del clasificador.

Tabla 3.2: Valor p de diferentes características tiempo – frecuencia por cada FMIs.

CaR	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10	IMF11	IMF12	IMF13
LFO	$^{5,6E-28}$	1,3E-46	1,4E-77	$^{8,2E-128}$	4,5E-173	2,4E-216	$1,\!4E-229$	$7,\!1E-218$	$4,\!1\text{E}{-}208$	3,7E-218	$1,\!6E-\!158$	1,5E-90	$^{8,1E-65}$
\mathbf{CPC}	$_{0,0\mathrm{E}+00}$	$2,\!1\text{E-}210$	1,5E-52	2,2E-21	$1,\!6E-05$	1,7E-33	4,9E-195	$1,\!2E-278$	4,3E-205	3,2E-216	3, 2E-129	$7,\!4E\!-\!51$	2,0E-23
CPS	$_{0,0\mathrm{E}+00}$	$5,\!4E\!-\!249$	$1,\!8E-92$	1,0E-02	3,8E-86	$2,\!6E-224$	1,3E-73	1,9E-05	$1,\!1E-06$	$4,\!1E-07$	6,9E-10	6,9E-45	$6,\!4E-05$
RMS	$3,\!4E-256$	6,9E-218	$7,\!6E-293$	$6,\!6E\!-\!277$	1,5E-223	1,3E-213	3,3E-226	1,5E-240	$1,\!4\text{E-}214$	1,3E-167	2,0E-56	$1,\!5E-60$	$1,\!3E\!-\!52$
CR1	$2,\!4\text{E-}198$	2,5E-82	1,2E-53	$7,\!6E-62$	1,9E-36	$1,\!1E-04$	2,7E-169	1,5E-35	2,4E-77	5,3E-21	1,5E-13	9,8E-03	$6,\!6E-140$
CR2	7,4E-56	$4,\!4E\!-\!20$	5,8E-07	$^{5,2E-08}$	$9,\!6E-17$	1, 2E-02	5,7E-05	$1,\!1E-06$	$2,\!1E-06$	$1,\!6E-02$	1, 2E-06	$1,\!2E-07$	3,7E-07
CR3	2,3E-04	8,3E-10	9,2E-11	6,9E-10	1,4E-09	$4,\!1E-07$	4,4E-09	3,9E-09	3,7E-03	$1,\!4E-09$	3,3E-03	$1,\!1E-01$	$1,\!2E-04$
CR4	2,5E-05	$1,\!1E-05$	6, 4E-05	$^{2,4E-01}$	4,3E-01	2,4E-01	$^{8,1E-02}$	9,3E-02	8,7E-01	2,3E-06	$4,\!4E-01$	6,9E-01	$^{8,9E-01}$
$\mathbf{CR5}$	9,0E-01	1,0E-09	$4,\!8E-06$	7,4E-01	9,0E-01	9,3E-01	7,5E-01	1,0E-06	$1,\!1E-02$	$^{8,0E-01}$	7,8E-01	7,5E-01	7,3E-01
CR6	6, 2E-03	$^{5,4E-03}$	3,9E-01	3,9E-01	$4,\!1E-01$	4,5E-01	$^{3,2E-03}$	4,5E-02	1,8E-01	1,7E-01	1,5E-01	1, 2E-01	4,0E-02
VAM	4,9E-190	$1,\!6E-\!102$	$1,\!3E-182$	3,3E-209	$5,\!4E -213$	2,4E-232	5,7E-234	2,3E-242	1,3E-209	2,0E-173	$^{5,3E-49}$	$9,\!6E-58$	$1,\!4E\!-\!46$
VAI	4,9E-190	$1,\!6E-\!102$	$1,\!3E-182$	3,3E-209	5,4E-213	$2,\!4\text{E-}232$	5,7E-234	2,3E-242	1,3E-209	2,0E-173	5, 3E-49	$9,\!6E-58$	$1,\!4E\!-\!46$
\mathbf{B}_{AM}	$1,\!1E-191$	$^{8,6E-81}$	$2,\!2\text{E-}140$	2,4E-53	$6,\!6E\!-\!27$	3,5E-07	3,7E-03	$1,\!6E-01$	$1,\!1E-01$	3,9E-01	$1,\!6E-01$	1,5E-02	7,9E-01
\mathbf{B}_{FM}	$^{5,0E-172}$	$1,\!1E\!-\!40$	2,4E-90	$7,\!4E{-}101$	$^{8,2E-12}$	2,7E-02	3,3E-01	1,7E-01	6, 1E-01	3,0E-01	9,7E-02	$9,\!8E-02$	$^{8,8E-01}$
$\mathrm{ME}_{\mathrm{DEP}}$	$5,\!4\text{E-}115$	$1,\!6E-74$	$1,\!3E-\!138$	3,0E-137	5,7E-76	1,3E-40	$^{5,3E-63}$	$^{8,1E-86}$	6,9E-45	$6,\!6E\!-41$	$2,\!1E-02$	2,2E-05	$1,\!0E-02$
$\mathrm{MPD}_{\mathrm{FI}}$	4,5E-146	7,3E-54	2,8E-291	$6,\!4E\!-\!157$	2,8E-53	7,5E-18	$1,\!4E-05$	$7,\!6E-02$	$^{8,0E-01}$	3,0E-02	$^{3,8E-03}$	5,7E-01	6,4E-01
MFI	4,0E-274	5,5E-179	$_{0,0\mathrm{E}+00}$	3,0E-198	6,7E-87	$4{,}0\text{E-}140$	$2,\!6E\!-\!56$	2,3E-29	$1,\!6E-33$	3,5E-26	8,7E-14	$5,\!4E-01$	3, 4E-01
$\mathbf{DEP}_{\mathrm{PICO}}$	$3,\!5E-156$	$6,\!6E-28$	1,5E-41	7,3E-75	6,7E-12	$1,\!1E-07$	$9,\!3E-28$	$1,\!1E-69$	7,9E-37	$1,\!6E-40$	$4,\!3E-02$	$4,\!9E-05$	$1,\!3E-02$

3.8. Reducción de características

Los métodos de selección de características por transformación son conocidos como métodos de reducción de características y son aquellos que permiten obtener un subconjunto de información a partir de la transformación o combinación de las características originales. Los métodos ampliamente utilizados en esta categoría son el análisis de componentes principales (Principal Components Analysis PCA) [30, 67] y el análisis discriminante Lineal (Linear Discriminant Analysis LDA), para mapear el vector de características a un espacio de dimensiones inferiores; en consecuencia, la sobrecarga computacional asociada con el procedimiento de clasificación posterior se reduciría. PCA es un enfoque estadístico no supervisado, que convierte las observaciones de variables, que probablemente se correlacionen, en valores de variables linealmente sin correlación a través de una transformada ortogonal. A diferencia de PCA, el objetivo de LDA es encontrar características discriminantes óptimas bajo condiciones supervisadas maximizando la relación entre la dispersión entre clases y la dispersión dentro de la clase de un conjunto de observaciones. Sin embargo, se debe tener en cuenta que el LDA clásico no es adecuado para datos sobremuestreados, es decir, la dimensión del vector de características es mayor que el tamaño de la muestra (clases), ya que encuentra un problema de singularidad al intentar realizar una auto-descomposición en las matrices de dispersión que son singulares. Es por esto que una versión mejorada de LDA, es decir, LDA no correlacionado (ULDA por sus siglas en inglés), introduce un requerimiento adicional de extracción de vectores de características que contienen características no correlacionadas, minimizando así la redundancia entre las características seleccionadas. La mejora adicional de ULDA, que incorpora un criterio de optimización y la descomposición del valor singular generalizado, mitiga los problemas relacionados con la

Tabla 3.3: Matriz de características funcionales extraídas de todos los FMI_k (CaR: Característica), las casillas sombreadas en color azul representan las CaR de los FMI_k seleccionadas para el proceso de clasificación.

		FMI_k											
CaR	1	2	3	4	5	6	7	8	9	10	11	12	13
LFO													
CPC													
CPS													
RMS													
CR1													
CR2													
CR3													
CR4													
CR5													
VAM													
VAI													
B _{AM}													
B_{FM}													
ME_{DEP}													
MPD_{FI}													
MFI													
DEP _{PICO}													

singularidad [66, 68] por lo que se adopta esta versión para reducir la dimensionalidad del conjunto de características M_{CaR} resultante del proceso de selección de la sección 3.7.

3.8.1. Análisis discriminante lineal no correlacionado (ULDA)

ULDA tiene como objetivo encontrar los vectores discriminantes óptimos que son S-ortogonal². Específicamente, supongamos que r vectores ϕ_1 . ϕ_2 , ..., ϕ_r se obtienen, luego se encuentra el (r + 1)-ésimo vector ϕ_{r+1} para maximizar la función del criterio Fisher [69]:

$$f(\phi) = \frac{\phi^T S_b \phi}{\phi^T S_w \phi} \tag{3.28}$$

sujeto a las restricciones: $\phi_{r+1}^T = 0$, para i = 1, ..., r.

²Dos vectores x y y son S-ortogonales, si $x^T y = 0$

Donde S_b es la matriz de dispersión inter-clase y S_w es la matriz de dispersión intra-clase. Siendo mas precisos:

$$S_b = \sum_C N_C (\mu_c - \mu) (\mu_c - \mu)^T)$$
(3.29)

$$S_w = \sum_c \sum_{i \in C} (x_i - \mu_C) (x_i - \mu_C) T$$
(3.30)

Siendo μ_C la media de cada clase, μ la media de todos los datos, N_C la cantidad de patrones de la clase C.

El algoritmo en [69] encuentra ϕ_i sucesivamente de la siguiente manera: El *j*-ésimo vector discriminante ϕ_j de ULDA es el vector propio correspondiente al valor propio máximo del siguiente problema de autovalores generalizados: $U_j S_b \phi_j = \Lambda_j S_w \phi_j$, donde:

$$U_{i} = I_{N},$$

$$D_{j} = [\phi_{1}, ..., \phi_{j-1}]^{T} (j > 1),$$

$$U_{j} = \phi_{i}^{T} S \phi_{j}$$
(3.31)

y I_N es la matriz identidad.

Supongamos que $\{\phi_i\}_i = 1^d$ son los vectores discriminantes d óptimos para la fórmula ULDA anterior. Luego, la matriz de datos original A se transfiere a $Z = G^T A$, donde $G = [\phi_1, ..., \phi_d]$. El componente *i*-ésimo de Z es $z_i = \phi_i^T A$, y la covarianza entre z_i y z_j es:

$$Cov(z_i, z_j) = E(z_i - Ez_i)(z_j - Ez_j)$$

= $\phi_i^T \{ E(A - EA)(A - EA)^T \} \phi_j$
= $\phi_i^T S \phi_j$ (3.32)

Por lo tanto, su coeficiente de correlación es:

$$Cor(Z_i, Z_j) = \frac{\phi_i^T S \phi_j}{\sqrt{\phi_i^T S \phi_i} \sqrt{\phi_j^T S \phi_j}}$$
(3.33)

Como los vectores discriminantes de ULDA son S-ortogonales, es decir, $\phi_i^T S \phi_j = 0$, para $i \neq j$, tenemos $Cor(Z_i, Z_j) = 0$, para $i \neq j$. Es decir, los vectores de característica transformados por ULDA no están mutuamente correlacionados. Esta es una propiedad deseable para la reducción de características. Para abordar con [69].

A partir del método ULDA, el proceso de reducción de dimensión de características es llevado a cabo en principio por la obtención de la matriz $G^{M \times l}$ de transformación



Figura 3.8: Diagramas de dispersión usando el método ULDA para reducir la alta dimensionalidad del conjunto de características. a) Diagrama de dispersión obtenido de reducir el conjunto original de 234 características a uno de 2 características. b) Diagrama de dispersión obtenido al reducir el conjunto M_{CaR} con 103 características a uno con 2 características.

usando el 70 % de los datos como conjunto de entrenamiento con el fin evitar sobreajuste. Luego esa matriz se le multiplica a la matriz de información $M_{CaR}^{N \times M}$ ($M_{CaR} \times G$) dando paso a una transformación de la matriz principal compuesta de M = 103 columnas a una nueva proyección con solo l columnas. El valor de l esta dado por el numero de clases menos uno (l = K - 1 = 2).

Una forma preliminar de evaluar la utilidad del proceso de selección (Kruskal -Wallis) y de reducción (ULDA) es ilustrando en una gráfica de dispersión la localización de los datos que componen cada conjunto de información. En la Figura 3.8.a. se muestra el diagrama obtenido al reducir el conjunto original de 234 características a uno de 2 características, empleando unicamente el metodo ULDA sin pasar por el proceso de selección. En dicha imagen se puede observar una notoria superposición de datos característicos entre el conjunto de EMGs Normales y el conjunto de EMGs Miopáticas lo que podría repercutir negativamente en la precisión al clasificar estas dos ENM. Al contrario de esto, en la Figura 3.8.b se evidencia que el conjunto M_{CaR} obtenido en el proceso de selección (sección 3.8) luego de pasar por el proceso de reducción ULDA, tiene una superposición mínima de datos entre grupos, lo que se traduce en técnicas de selección y reducción óptimas de características tiempo-frecuencia enfocadas a la clasificación de ENM.

Capítulo 4 Clasificación

4.1. Clasificación de patrones

El reconocimiento de patrones (RP) tiene como fin clasificar automáticamente patrones multidimensionales (n muestras de m dimensiones) en diferentes categorías. Los métodos de RP son útiles en bioinformática, diagnóstico de enfermedades, entre otros. Aplicar este análisis a partir de un conjunto de datos permite adquirir conocimientos sobre el tipo de población relacionada con los datos, debido a que los sistemas de reconocimiento de patrones incorporan algún método de aprendizaje, normalmente mediante un algoritmo inductivo, existe la necesidad de introducir un método de evaluación para analizar dicho algoritmo. Si la evaluación del algoritmo resulta negativa, existe la posibilidad de una disminución en la eficiencia del mismo [70].

La tarea fundamental de un sistema de reconocimiento de patrones (clasificador) es la de asignar a cada patrón de entrada una etiqueta. Dos patrones diferentes deberían asignarse a una misma clase si son similares y a clases diferentes si no lo son. En general, al aplicar una técnica de clasificación de patrones,9 la idea es obtener información relevante a partir de la clasificación de la información suministrada [71]. Esto es, la entrada es un conjunto de patrones (n-dimensionales) $X = [x_1, x_2, ..., x_n]$ que al aplicar la técnica de reconocimiento de patrones deseada permite obtener un conjunto de características d-dimensionales $Y = [y_1, y_2, ..., y_d]$ del conjunto X, donde d = n.

Una de las formas eficientes para realizar la clasificación de patrones es por medio de una reducción de dimensionalidad de los datos, debido a que se disminuye el costo computacional y el reconocimiento para la clasificación puede ser más eficiente debido a que no hay una probabilidad alta de solapamiento de características ¹. Una vez realizada la reducción de características se realiza la clasificación por clases al nuevo conjunto conjunto da datos. Las clases idealmente son disyuntas, quedando claramente discriminada la pertenencia o exclusión de un elemento a una clase concreta. La pro-

¹Método utilizado en este trabajo.



Figura 4.1: Esquema general de la clasificación de un atributo y su mapeo en la nueva característica (imagen adaptada de [72]).

blemática empieza cuando estos patrones no están agrupados de manera ideal o en el peor de los casos, cuando están solapados, dando entonces lugar a una problemática de clasificación, donde puede existir un patrón que puede pertenecer a una o tal vez dos clases. Este problema es solucionado a partir del aprendizaje supervisado incluido en los métodos de clasificación de patrones aquí expuestos [70].

Los clasificadores de patrones usados para el desarrollo de este trabajo son de tres tipos: Método de Árboles de decisión², Método de Análisis Disciminante lineal (LDA)³ y Método de K-vecinos cercanos⁴. Los cuales fueron seleccionados con el fin de determinar la eficiencia en la clasificación de señales EMG en el conjunto de las ENM, siendo esto de gran interés para los investigadores en la era moderna. Aunque cabe mencionar la existencia de otros métodos utilizados en este tipo de trabajos, tales como la Red Neuronal Artificial (ANN), el Mapa de Auto-organización (SOM) y las Máquinas de Vector de Soporte (SVM). La entrada de estos clasificadores generalmente es un vector de características dado por el proceso de extracción de características de la señal EMG cruda (ver secc. 3.6).

4.1.1. Árboles de decisión

Un árbol de decisión es un modelo de clasificación y predicción utilizado en diversos ámbitos de la ciencia. Se puede considerar como un mapa de los posibles resultados de una serie de elecciones relacionadas. Permite evaluar las posibles acciones entre sí, en función de sus costos, probabilidades y beneficios. Dado un conjunto de datos se fabrican diagramas de construcciones lógicas, muy similares a los sistemas de predicción basados en reglas, que sirven para representar y categorizar una serie de condiciones que ocurren de forma sucesiva, para la resolución de un problema [70, 71, 73].

Un árbol de decisión generalmente comienza con un solo nodo, que se bifurca en posibles resultados. Cada uno de esos resultados conduce a nodos adicionales, que se

²Clasificador no lineal

³Clasificador lineal

⁴Clasificador de tipo Bayesiano

ramifican hacia otras posibilidades. Hay tres tipos diferentes de nodos: nodos aleatorios, nodos de decisión y nodos finales. Un nodo aleatorio muestra las probabilidades de ciertos resultados. Un nodo de decisión muestra una decisión a tomar y un nodo final muestra el resultado final de un camino de decisión. Un árbol de decisión se construye de arriba hacia abajo desde un nodo raíz e implica dividir los datos en subconjuntos que contienen instancias con valores similares (homogéneos).

Los objetos base, a partir de los cuales se desarrolla una regla de clasificación, se conocen solo a través de los valores de un conjunto de propiedades o atributos, y los árboles de decisión a su vez se expresan en términos de estos atributos. Uno de los algoritmos más reconocidos para la construcción de arboles de decisión es el llamado ID3 (J. R. Quinlan) [73] que emplea una búsqueda exhaustiva de arriba hacia abajo a través del espacio de posibles ramas sin retroceso [73]. El algoritmo ID3 usa entropía para calcular la homogeneidad de una muestra. Si la muestra es completamente homogénea, la entropía es cero y si la muestra está dividida por igual, tiene entropía de uno.

Los árboles de decisión están formados por nodos, vectores de números, flechas y etiquetas. Cada nodo se puede definir como el momento en el que se ha de tomar una decisión de entre varias posibles, lo que va haciendo que a medida que aumenta el número de nodos aumente el número de posibles finales a los que puede llegar. Esto hace que un árbol con muchos nodos sea complicado de dibujar a mano y de analizar debido a la existencia de numerosos caminos que se pueden seguir.

- Los vectores: Se tiene vectores iniciales y finales. Los vectores iniciales son las entradas y los finales serían la clasificación que se obtiene en función de las diversas posibilidades.
- Las fechas: Son las uniones entre un nodo y otro, y representan cada acción distinta.
- Las etiquetas: Se encuentran en cada nodo y cada flecha, y dan nombre a cada acción.

En los árboles de decisión se tiene que cumplir una serie de reglas. Se tiene un nodo inicial el cual no esta siendo apuntado por alguna flecha, el resto de los nodos solo pueden ser apuntados por una única flecha. Por lo que, solamente existe un camino para llegar al nodo inicial desde cada uno de los nodos hijos, por lo que solo hay una forma de llegar a la solución final, pues los nodos son excluyentes [73]. En los árboles de decisiones a medida que se van seleccionando las opciones se van cerrando otras, lo que implica que no hay marcha atrás. Un ejemplo de esto puede verse en la Figura 4.2.

El aprendizaje del método de árbol de decisiones utiliza un árbol de decisiones (como modelo predictivo) para pasar de las observaciones sobre un elemento (representadas en



Figura 4.2: Esquema general de la clasificación de un atributo y su mapeo en la nueva característica (imagen tomada de [72]).

las ramas) a conclusiones sobre el valor objetivo (representado en las hojas). Es uno de los enfoques de modelado predictivo utilizados en estadística, minería de datos y aprendizaje automático. Los modelos de árbol donde la variable objetivo puede tomar un conjunto discreto de valores se denominan árboles de clasificación; en estas estructuras de árbol, las hojas representan etiquetas de clase y las ramas representan conjunciones de características que conducen a esas etiquetas de clase. Los árboles de decisión donde la variable objetivo puede tomar valores continuos (típicamente números reales) se llaman árboles de regresión.

El objetivo del aprendizaje mediante el método de árboles de decisión es crear un modelo que prediga el valor de una variable objetivo en función de varias variables de entrada [71]. Cada nodo interior corresponde a una de las variables de entrada; hay bordes para los hijos para cada uno de los valores posibles de esa variable de entrada. Cada hoja representa un valor de la variable objetivo dados los valores de las variables de entrada representadas por la ruta desde la raíz hasta la hoja.

En conclusión, el aprendizaje mediante el método de árbol de decisión es la construcción de un árbol de decisiones a partir de una lista ordenada de elementos de entrenamiento con etiquetas de clase. Un árbol de decisión es una estructura tipo diagrama de flujo, donde cada nodo interno (no hoja) denota una prueba en un atributo, cada rama representa el resultado de una prueba y cada nodo hoja (o terminal) contiene una etiqueta de clase. El nodo superior en un árbol es el nodo raíz [71].

4.1.2. Análisis Discriminante Lineal (LDA)

El análisis discriminante lineal (LDA) es una generalización del discriminante lineal de Fisher, un método utilizado en estadística, reconocimiento de patrones y aprendizaje automático para encontrar una combinación lineal de características que caracteriza o separa dos o más clases de objetos. La combinación resultante se puede usar como un clasificador lineal o, más comúnmente, para la reducción de dimensionalidad antes de la clasificación posterior. Es simple, matemáticamente robusto y a menudo produce modelos cuya precisión es tan buena como los métodos más complejos.



Figura 4.3: Las muestras de datos en dos dimensiones se proyectan en un espacio de dimensión inferior (línea). La línea debe elegirse de modo que la proyección maximice la "separabilidad" de las muestras proyectadas (Imagen adaptada de [74]).

La intuición detrás del método es determinar un sub-espacio de dimensión inferior, en comparación con la dimensión de muestra de datos original, en la que los puntos de datos del problema original son "separables" (ver Figura 4.3). La separabilidad se define en términos de medidas estadísticas de valor medio y varianza. Una de las ventajas de LDA es que la solución se puede obtener resolviendo un sistema de auto-valoración generalizado. Esto permite un procesamiento rápido y masivo de muestras de datos. Además, LDA puede extenderse a no-LDA a través del truco del kernel [74, 75]. El algoritmo original se propuso para problemas binarios, pero también se han propuesto generalizaciones multiclase. Se muestra el ejemplo para un problema de dos clases, ya que puede extenderse a casos más complejos [74, 75].

LDA se basa en el concepto de buscar una combinación lineal de variables (predictores) que mejor separe dos clases (objetivos) [74,75]. Para capturar la noción de separabilidad, Fisher definió la siguiente función de puntuación:

$$Z = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_d x_d \tag{4.1}$$

A su vez se nombra la función de puntuación:

$$S(\beta) = \frac{\beta^T \mu_1 - \beta^T \mu_2}{\beta^T C \beta} \tag{4.2}$$

La cual puede ser escrita como:

$$S(\beta) = \frac{\overline{Z_1} - \overline{Z_2}}{\sigma^2(Z_i)} \tag{4.3}$$

Dada la función de puntuación, se deben estimar los coeficientes lineales que maximizan la puntuación, los cuales se pueden resolver por medio de las siguientes ecuaciones:

$$\beta = C^{-1}(\mu_1 - \mu_2) \tag{4.4}$$

Los cuales son denominados como coeficientes de modelado, y C esta dada por:

$$C = \frac{1}{n_1 + n_2} (n_1 C_1 + n_2 C_2) \tag{4.5}$$

Donde C es conocida como la matriz de covarianza combinada, β son los coeficientes lineales del modelo, C_i son las matrices de covarianza y μ_i son los vectores de los promedios [74].

Una forma de evaluar la efectividad de la discriminación es mediante el calculo de la distancia de *Mahalanobis* entre dos grupos. Una distancia mayor que 3 significa que en dos promedios difiere en más de 3 desviaciones estándar. Significa que la superposición (probabilidad de clasificación errónea) es bastante pequeña, esta distancia se puede determinar de la siguiente manera:

$$\Delta^2 = \beta^T (\mu_1 - \mu_2) \tag{4.6}$$

siendo Δ la distancia de *Mahalanobis* entre dos grupos. Finalmente, un nuevo punto se clasifica proyectándolo en la dirección de separación máxima y clasificándolo como C1 si cumple:

$$\beta^T \left(x - \left(\frac{\mu_1 + \mu_2}{2} \right) \right) > -log \left(\frac{p(C_1)}{p(C_2)} \right)$$
(4.7)

Nuevamente se esclarece que β es el vector de coeficientes, x es el vector de datos, $\left(\frac{\mu_1+\mu_2}{2}\right)$ es el vector promedio y $p(C_i)$ es la probabilidad de las clases [74].

4.1.3. K-vecinos más cercanos

La clasificación de k-vecino más cercano (KNN) es uno de los métodos de clasificación más fundamentales y simples y debería ser una de las primeras opciones para un estudio de clasificación cuando hay poco o ningún conocimiento previo sobre la distribución de los datos. La clasificación de K-vecino más cercano se desarrolló a partir de la necesidad de realizar análisis discriminante cuando las estimaciones paramétricas confiables de las densidades de probabilidad son desconocidas o difíciles de determinar. En un informe inédito de la Escuela de Medicina Aeronáutica de la Fuerza Aérea de EE. UU. en 1951, Fix y Hodges introdujeron un método no paramétrico para la clasificación de patrones que desde entonces se conoce como la regla del vecino más cercano [76]. Hacia 1967, se desarrollaron algunas de las propiedades formales de la regla del k-vecino más cercano; por ejemplo, se demostró que para k = 1 y $n \longrightarrow \infty$, el error de clasificación k-vecino más cercano está limitado por encima del doble del índice de error de Bayes [77]. Una vez establecidas tales propiedades formales de la clasificación k-vecino más cercano, se inició una larga línea de investigación que incluyó nuevos enfoques de rechazo (Hellman, 1970), refinamientos con respecto a la tasa de error de Bayes, enfoques ponderados por distancia, métodos soft computing y métodos difusos.

Característica del método KNN

El clasificador k-vecino más cercano se basa comúnmente en la distancia euclidiana entre una muestra de prueba y las muestras de entrenamiento especificadas. Deje xi ser una muestra de entrada con p características $(x_{i1}, x_{i2}, ..., x_{ip})$ donde n es el número total de muestras de entrada (i = 1, 2, ..., n) y p el número total de características (j = 1, 2, ..., p). La distancia euclidiana entre la muestra x_i y x_l con (l = 1, 2, ..., n) se define como:

$$d(x_i, x_l) = \sqrt{(x_{i1} - x_{l1})^2 + (x_{i2} - x_{l2})^2 + \dots + (x_{ip} - x_{lp})^2}$$
(4.8)

Regla de clasificación matriz de confusión

La clasificación generalmente implica partición de muestras en categorías de entrenamiento y prueba. Sea x_i una muestra de entrenamiento, x una muestra de prueba, ω la clase verdadera de una muestra de entrenamiento y $\hat{\omega}$ la clase predicha para una muestra de prueba ($\omega, \hat{\omega} = 1, 2, ..., \Omega$). Donde Ω es el número total de clases.

Durante el proceso de entrenamiento, usamos solo la clase verdadera ω de cada muestra de entrenamiento para entrenar al clasificador, mientras que durante la prueba predecimos la clase $\hat{\omega}$ de cada muestra de prueba. Se garantiza que el KNN es un método

de clasificación "supervisadoza que utiliza las etiquetas de clase de los datos de entrenamiento. Los métodos de clasificación no supervisados, o métodos de .ªgrupamiento", por otro lado, no emplean las etiquetas de clase de los datos de entrenamiento.



Figura 4.4: Esquema de la construcción de una matriz de confusión [77].

Con la regla de 1 vecino más cercano, la clase predicha de la muestra de prueba x se establece igual a la clase verdadera ω de su vecino más cercano, donde m_i es el vecino más cercano a x si la distancia:

$$d(m_i, x) = \min_j d(m_j, x). \tag{4.9}$$

Para k vecinos más cercanos, la clase predicha de la muestra de prueba x se establece igual a la clase verdadera más frecuente entre las k muestras de entrenamiento más cercanas. Esto forma la regla de decisión:

$$D: x \longrightarrow \hat{\omega}$$

La matriz de confusión utilizada para tabular las predicciones de clase de muestra de prueba durante la prueba se denota como C y tiene dimensiones $\Omega \times \Omega$. Durante la prueba, si la clase predicha de la muestra de prueba x es correcta (es decir, $\hat{\omega} = \omega$), entonces el elemento diagonal $c_{\omega\omega}$ de la matriz de confusión se incrementa en 1. Sin embargo, si la clase predicha es incorrecta (es decir, $\hat{\omega} \neq \omega$), entonces el elemento fuera de la diagonal $c_{\omega\hat{\omega}}$ se incrementa en 1. Una vez clasificadas todas las muestras de prueba, la precisión de la clasificación se basa en la relación entre el número de muestras correctamente clasificadas y el número total de muestras clasificadas, indicadas en la forma:

$$A_{cc} = \frac{\sum_{\omega}^{\Omega} C_{\omega\omega}}{n_{total}} \tag{4.10}$$

donde $c_{\omega\omega}$ es un elemento diagonal de C y n_{total} es el número total de muestras clasificadas.

4.2. Tasa de error de clasificación

La medicina es una ciencia de probabilidades y un arte de manejar la incertidumbre. Dicha incertidumbre se extiende no sólo a las actividades preventivas, terapéuticas y pronósticas sino también a las diagnósticas. En las fases del proceso diagnóstico intervienen la historia clínica, la exploración física y la realización de pruebas complementarias. Una propuesta alternativa catalogada como prueba diagnostica es el sistema clasificador desarrollado en esta tesis. Para evaluar debidamente este enfoque se definen las siguientes métricas:

- **VP:** Resultados positivos en sujetos enfermos, verdaderos-positivos.
- FP: Resultados positivos en sujetos sanos, falsos-positivos.
- VN: Resultados negativos en sujetos sanos, verdaderos-negativos.
- **FN:** Resultados negativos en sujetos enfermos, falsos negativos.

A partir de las cuales se puede determinar la utilidad de este clasificador, evaluando la capacidad para detectar correctamente la presencia o ausencia de las enfermedades ENM. En esta tesis se usaran fundamentalmente los conceptos que determinan la validez de un clasificador (sensibilidad y especificidad) y su seguridad (valores predictivos positivos y negativos).

- Validez: Es el grado en que una prueba mide lo que se supone que debe medir. ¿Con qué frecuencia el resultado del clasificador es confirmado por la discriminación de nuevas señales?. La sensibilidad y la especificidad de un test son medidas de su validez.
- Seguridad: La seguridad viene determinada por el valor predictivo de un resultado positivo o negativo. ¿Con qué seguridad un el clasificador predecirá la presencia o ausencia de enfermedad? Ante un resultado positivo del clasificador ¿qué probabilidad existe de que este resultado indique presencia de la enfermedad?.

De esos conceptos se generan 4 índices estadísticos: sensibilidad, especificidad, valor predictivo positivo y valor predictivo negativo. Ademas se usa como métrica general de evaluación la exactitud del clasificador, todas las ecuaciones para obtener estas métricas se muestran en la tabla 4.1 y su descripción es la siguiente:

- Sensibilidad (SE): Se define como la probabilidad de que un individuo enfermo tenga una prueba positiva. De esta manera, la sensibilidad nos indica la capacidad del clasificador para identificar una enfermedad, por lo que se le llama también tasa o proporción de verdaderos positivos.
- **Especificidad (ES):** La especificidad valora la utilidad de una prueba con el fin de identificar a los no enfermos (tasa o proporción de verdaderos negativos) o, dicho de otra forma, la especificidad indica la proporción de individuos sanos confirmados como tales por el resultado negativo del clasificador.

Para que un clasificador sea útil debe presentar una alta sensibilidad y especificidad. A partir de estos 2 conceptos podemos hablar de una proporción de falsos negativos, que es la probabilidad de que una persona enferma obtenga un resultado negativo en la prueba (enfermos que han tenido un resultado negativo de entre el total de enfermos) y de forma similar encontraremos una proporción de falsos positivos, es decir, la probabilidad de que un individuo sano tenga un resultado positivo (sanos con prueba positiva de entre todos los sujetos que no presentan la enfermedad).

- Valor predictivo positivo (VPP): Es la probabilidad de que un individuo con resultado positivo en la prueba tenga la enfermedad. Este concepto se denomina también probabilidad a posteriori así como la precisión del diagnostico.
- Valor predictivo negativo (VPN): Es la probabilidad de que un individuo con resultado negativo en la prueba no tenga la enfermedad. Se trata de los sujetos libres de enfermedad y con clasificación negativa dentro de todos aquellos con prueba negativa.
- **Exactitud (ACC por sus siglas en ingles):** Es el número de señales clasificadas correctamente sobre el número total de señales.

Si bien las métricas anteriores permiten evaluar el rendimiento del clasificador en una serie de pruebas con datos provenientes de diferentes sujetos, esas métricas dan como resultado una tasa de error aparente, es decir que solo calculan las probabilidades a partir de los resultados obtenidos del modelo clasificador entrenado con todo el conjunto de información, por lo que no tiene en cuenta las implicaciones de esa clasificación en futuros eventos, dando resultados generalmente optimistas y con un sesgo grande. Una forma de evitar ese sesgo es tomando en varias pruebas una serie de datos para entrenar el clasificador y el restante para evaluar el nivel de predicción promediando el numero de VP, FP, VN y FN obtenidas en cada pruebas para luego calcular las métricas de la tabla 4.1.

En esta tesis la tasa de error de clasificación así como su exactitud fue estimada mediante el método de *validación cruzada de K iteraciones* [10, 21, 54]], con k = 3 y consistió en dividir todo el conjunto de señales de cada clase AMN en 3 partes

Características	Definición	Comentarios
SF (taga VP)	VP	Probabilidad de clasificación positiva
SE (tasa vi)	$\overline{VP+FN}$	para el conjunto positivo (sensibilidad)
FS (tase VN)	VN	Probabilidad de clasificación negativa
ED (tasa VIV)	$\overline{VN+FP}$	para el conjunto negativo (especificidad)
VPP (Procisión)	VP	Probabilidad de tener la enfermedad
VII (I recision)	$\overline{VP+FP}$	si el resultado de la prueba es positivo.
VDN	VN	Probabilidad de no tener la enfermedad
VI IN	$\overline{VN+FN}$	si el resultado de la prueba es negativo.
		Probabilidad de que el resultado del clasificador
ACC (Exactitud)	$\frac{TP+TN}{TP+TN+FP+FN}$	prediga correctamente la presencia o ausencia
		de la enfermedad

Tabla 4.1: Parámetros estadísticos para validar un clasificador de ENM

iguales tomando para cada parte un numero m de muestras aleatorias. Luego se tomaron dos partes de la muestra para realizar el entrenamiento del clasificador y la tercera parte es usada para predecir la clase. Este proceso fue realizado k veces tomando para cada prueba dos conjuntos distintos de entrenamiento y el restante como conjunto de validación. De esa manera, la tasa de error por K-iteraciones se calculó como la suma de los errores cometidos en cada prueba, dividido en el numero de pruebas. La tasa de error por validación cruzada tiene poco sesgo, pero una alta variabilidad. Para reducir dicha variabilidad, se repitió la estimación varias veces; por tal motivo, se incluyeron 10 pruebas mas, en cada una de ellas se realizaron K-iteraciones calculando la tasa de error promedio de cada realización. Finalmente, la tasa de error total se tomó como el promedio de las 10 tasas de error de cada validación cruzada con K-iteraciones.

Capítulo 5 Resultados, Análisis y Discusión

En este capítulo se presentan los resultados obtenidos con el sistema de clasificación de señales de EMG para el reconocimientos de patrones característicos de enfermedades neuromusculares (ALS y Miopatías) y de sujetos con músculos sanos, cuya metodología fue descrita en el Capítulo 3. Para todas las pruebas realizadas se tomaron los 350 registros de sujetos de la base de datos disponible (ver Tabla 3.1).

5.1. Clasificación de señales EMG

El diagrama esquemático en la figura 5.1 describe la propuesta estratégica destinada a clasificar los datos de EMG para diagnosticar enfermedades neuromusculares, es decir, miopáticas y ALS. La linea azul muestra la fase de entrenamiento y la linea roja la fase de clasificación.

5.1.1. Fase de entrenamiento

A partir del método de validación cruzada con k iteraciones (ver secc 4.2), se tomaron las k-1 partes (k=3) del conjunto de señales para entrenamiento de los modelos y la parte restante para validar el sistema. Tanto en el entrenamiento como en la validación el sistema realizó un filtrado para acondicionar cada señal, luego la EEMD descompuso la entrada en sus FMI_K y se segmentaron en 10 partes a partir de los cuales se extrajeron las características en el dominio del tiempo y la frecuencia dadas por el criterio de selección de Kruskal-Wallis (ver tabla 3.3).

En la fase de entrenamiento, luego del proceso anterior, se formó una matriz de entrenamiento M_E con 2334 subconjuntos de información, i.e. No. de señales X No. de ventanas X 2/3 conjuntos pasa validación cruzada = $\frac{350\cdot10\cdot2}{3}$, cada conjunto con 103 características. De la matriz M_E se obtuvo la matriz de transformación $G_{ULDA}^{103\times2}$ usando el método ULDA, para reducir la dimensionalidad de la información.



Figura 5.1: Sistema de clasificación de señales EMG.

$$M_E^{2334 \times 103} \Rightarrow M_E \cdot G_{ULDA} = M_E^{2334 \times 2} \tag{5.1}$$

Posteriormente, el conjunto reducido de características pasan a realizar el entrenamiento de los modelos clasificadores LDA, KNN y TREE.

5.1.2. Fase de predicción

En la fase de entrenamiento se formó una matriz de predicción M_P con 1166 subconjuntos de información, i.e. No. de señales, multiplicado por el No. de ventanas y por un tercio de conjuntos = $\frac{350\cdot10\cdot1}{3}$, para la validación cruzada, cada conjunto con las mismas 103 características. Luego la matriz M_p fue reducida con la matriz de transformación $G_{ULDA}^{103\times2}$ obtenida en la fase de entrenamiento.

$$M_p^{1166\times103} \Rightarrow M_p \cdot G_{ULDA} = M_p^{1166\times2} \tag{5.2}$$

Por ultimo, esta matriz M_p es clasificada en cada una de sus filas por los modelos predictivos entrenados anteriormente.

Tanto la fase de entrenamiento como la fase de predicción fue realizada 10 veces, con una repartición en cada una de las pruebas de k veces, es decir, No de pruebas = $10 \cdot k = 30$ y cada prueba con diferentes señales seleccionadas de forma aleatoria para cada conjunto de sujetos con ALS, con miopatía y sujetos normales (AMN). Todos las técnicas empleadas anteriormente han sido tratadas en detalle en el capitulo 3.

Los resultados de estas fases son mostradas en la Tabla 5.1, en la cual se pueden ver las matrices de confusión en donde los números de cada casilla representan; 1) el promedio de veces que una señal entrante fue catalogada entre el grupo de AMN y 2) el error estadístico dado por la desviación estándar en las 30 pruebas. La diagonal principal de estas matrices de confusión resaltadas con negrita son los aciertos de clasificación para cada clase de AMN. Las matrices de confusión fueron obtenidas para cada uno de los clasificadores propuestos en la secc 4.1.

Se puede observar que con el clasificador LDA (ver Tabla 5.1.a), se discriminó mejor que en los otros dos el subconjunto de información proveniente de las señales de sujetos sanos, sin embargo, no fue tan efectivo a la hora de clasificar señales de sujetos con alguna de las dos enfermedades neuromusculares. De igual forma usando el clasificador TREE (ver Tabla 5.1.b), se obtuvieron resultados superiores al clasificar señales EMG de sujetos con Miopatía, pero el clasificador KNN (ver Tabla 5.1.c), fue mejor el mejor a la hora de determinar con mayr certeza que la señal EMG provenía de un sujeto con ALS. Desde luego la discusión anterior es solo valida para evaluar los clasificadores en casos aislados, es por eso que al lado derecho de cada una de las matrices de confusión se muestran los indices o métricas probabilísticas clínicas usadas para validar una prueba diagnostica (ver Tabla 4.1).

Por ejemplo, de acuerdo al análisis anterior la métrica que debería indicar que con el clasificador LDA es mas probable discriminar entre un sujeto sano y uno con alguna ENM debería ser la especificidad (ES), sin embargo, este indice muestra que el LDA tiene el nivel de especificidad mas bajo entre los 3 clasificadores, esto debido a que en el panorama general de clasificación, señales provenientes de otras clases fueron catalogadas como Normales en mas casos que con los otros métodos, lo que hace que su especificidad sea muy baja. Por esta razón es de esperar que la probabilidad de que un sujeto sea sano dado que fue diagnosticado como sano sea mas alta que en el método LDA que en los demás y esto se puede comprobar con el indice de valor predictivo negativo (VPN).

El indice que permite evaluar de forma general si el clasificador es apropiado para determinar correctamente la presencia o ausencia de una ENM es la exactitud (ACC por sus siglas en ingles). La exactitud de los clasificadores LDA, TREE y KNN es de Tabla 5.1: Matrices de confusión promedio para las 30 pruebas ($\mu \pm \sigma$) y sus métricas clínicas, empleando diferentes clasificadores. Los números que están en negrita representan el numero de subconjuntos promedio clasificados correctamente.

Entrodo	Cla	se Recono	cida
Entrada	ALS	Normal	Miopatía
ALS	729 ± 6	68 ± 6	2 ± 1
Normal	23 ± 4	$1954~\pm 5$	22 ± 4
Miopatía	1 ± 1	41 ± 4	657 ± 4

a) Clasificador LDA

b) Clasificador TREE

Entrada	Clase Reconocida					
Entrada	ALS	\mathbf{Normal}	Miopatía			
ALS	755 ± 3	43 ± 3	2 ± 1			
Normal	$46~\pm 5$	1919 ± 6	35 ± 4			
Miopatía	1 ± 1	24 ± 3	$675\ \pm 3$			

ACC	0.957 ± 0.0015
$\mathrm{SE}_{\mathrm{ALS}}$	0.943 ± 0.0031
${ m SE}_{ m Miopatía}$	0.964 ± 0.0036
\mathbf{ES}	0.955 ± 0.0027
VPP	0.9517 ± 0.0022
VPN	0.97 ± 0.0011

c) Clasificador KNN

Entrodo	Clase Reconocida					
Entrada	ALS	\mathbf{Normal}	Miopatía			
ALS	762 ± 4	37 ± 4	1 ± 2			
Normal	29 ± 7	1951 ± 7	19 ± 5			
Miopatía	2 ± 2	24 ± 5	$674~\pm5$			

ACC	0.968 ± 0.0018
$\rm SE_{ALS}$	0.952 ± 0.0044
${ m SE}_{ m Miopatía}$	0.963 ± 0.0064
\mathbf{ES}	0.959 ± 0.0038
VPP	0.967 ± 0.0025
VPN	0.981 ± 0.0013

95.5%, 95.7% y 96.8% respectivamente, lo que lleva a pensar que al usar KNN siempre se va a tener un mejor desempeño y certeza en la clasificación de ENM, desde luego debido a la no homogeneidad del conjunto de información por cada clase de AMN, es necesario fijarse en las métricas restantes, como la sensibilidad (SE) para diagnosticar cada una de las ENM acertadamente y el valor predictivo positivo (VPP) para garantizar que dado que un sujeto fue diagnosticado con la enfermedad, este realmente la padezca. Al realizar estas comparaciones entre métodos de clasificación, es el método KNN el que mejor desempeño demuestra.

Hay que recordar que todos estos 3500 subconjuntos de información fueron obtenidos porque cada señal se dividió en 10 partes, por lo que es apropiado promediar el resultado de clasificación de cada una de estas partes y así determinar si la procedencia de la señal realmente es diagnosticada con certeza. Al realizar dicho proceso se obtuvieron las matrices de confusión de la tabla 5.2.

De la tabla 5.2 se puede resumir que se mantiene la relación de desempeño entre los tres métodos de clasificación obtenida a partir de la tabla 5.1, esto es, el clasificador KNN supera en todos los aspectos al metodo LDA y al TREE. Lo que resulta alentador es el hecho de que aumentaron en aproximadamente 2 puntos porcentuales los niveles de las metricas clinicas en todos los enfoques, esto se debe a que, si bien, se tuvieron problemas al discriminar adecuadamente entre AMN en varios subconjuntos, esto no infirió en el promedio de partes clasificadas correctamente, es decir la mayoría de las 10 partes en las que se dividió la señal fueron clasificadas con exito. Los desaciertos en estas divisiones pueden ser atribuidas a los lapsos de tiempo en el que no se generaban PAUMs seguramente por las fases de relajación previas a realizar una nueva contracción muscular.

En la figura 5.2, se ilustran cada una de las pruebas que se contemplaron en el método de validación cruzada, recordando que por cada prueba se tomaron 2/3 partes aleatoriamente de cada conjunto de ANM para el entrenamiento de cada clasificador y todos los registros disponibles para validar el sistema, se muestra como fue el desempeño por cada realización. En la columna izquierda se pueden ver los resultados de las pruebas al tomar como conjunto de información los 3500 registros obtenidos al ventanear cada señal y en la columna de la derecha se observan las mismas gráficas pero esta vez promediando los resultados obtenidos en las 10 partes en las que fueron divididas las señales.

En las figuras 5.2.a,c,e se puede observar una baja variabilidad entre cada prueba, atribuida a la alta dimensionalidad de la información junto con los niveles altos de las diferentes métricas probabilísticas, es decir, entre mas datos se tengan, mas estable serán los resultados de clasificación siempre y cuando este clasificador tenga una alta tasa de predicción. Por otro lado en las figuras 5.2.b,d,f se puede inferir que la variabilidad empieza a aumentar ya que son los resultados con un conjunto reducido de información, a pesar de esto, el clasificador KNN se sigue postulando como la mejor opción manteniendo un 99 porciento o mas de exactitud en cada prueba, demostrando la estabilidad y repetibilidad del método.

Tabla 5.2: Matrices de confusión promedio para las 30 pruebas ($\mu \pm \sigma$) y sus métricas clínicas, empleando diferentes clasificadores. Los números que están en negrita representan el numero de señales promedio clasificadas correctamente.

Entrodo	Clase Reconocida				
Entrada	ALS	\mathbf{Normal}	Miopatía		
ALS	77 ± 1	3 ± 1	0		
Normal	1 ± 1	199 ± 1	1 ± 1		
Miopatía	0	3 ± 2	67 ± 2		

a) Clasificador LDA

ACC	0.981 ± 0.0037
$\rm SE_{ALS}$	0.959 ± 0.0094
${ m SE}_{ m Miopatía}$	0.963 ± 0.016
ES	0.96 ± 0.0087
VPP	0.98 ± 0.0037
VPN	0.99 ± 0.002

b) Clasificador TREE

Entrada	Clase Reconocida					
Entrada	ALS	Normal	Miopatía			
ALS	78 ± 1	2 ± 1	0			
Normal	2 ± 2	197 ± 2	1 ± 1			
Miopatía	0	1 ± 1	$69~\pm 1$			

ACC	0.982 ± 0.0039
$\rm SE_{ALS}$	0.977 ± 0.0063
${ m SE}_{ m Miopatía}$	0.98 ± 0.0089
\mathbf{ES}	0.978 ± 0.0055
VPP	0.981 ± 0.0053
VPN	0.989 ± 0.0027

c) Clasificador KNN

Entrada ·	Clase Reconocida		
	ALS	Normal	Miopatía
ALS	$79\ \pm 1$	1 ± 1	0 ± 1
Normal	1 ± 1	199 ± 1	0 ± 1
Miopatía	0 ± 1	1 ± 1	$69~\pm 1$

ACC	0.992 ± 0.0043
$\mathrm{SE}_{\mathrm{ALS}}$	0.99 ± 0.0079
${ m SE}_{ m Miopatía}$	0.984 ± 0.011
ES	0.988 ± 0.0062
VPP	0.993 ± 0.0047
VPN	0.996 ± 0.0026





a) Clasificador LDA con 3500 subconjuntos.



b) Clasificador LDA con las 350 señales .



c) Clasificador TREE con 3500 subconjuntos.



e) Clasificador KNN con 3500 subconjuntos.

d) Clasificador TREE con las 350 señales .



f) Clasificador KNN con las 350 señales .

Figura 5.2: Indices clínicos en cada una de las pruebas efectuadas en la validación cruzada

Capítulo 6 Conclusiones

El estudio sobre EMG es muy amplio, desde el diseño de electrodos hasta técnicas de registro, métodos de análisis y aplicaciones para diversos fines. Se han realizado muchos estudios en un intento de caracterizar diferentes desordenes neuromusculares, usando métodos tradicionales como el análisis en el dominio tiempo-frecuencia. En esta tesis se ha descrito un esquema automatizado de clasificación de señales EMG intramusculares y se ha validado su rendimiento empleando métricas cuantitativas. Este enfoque descompone una señal EMG no estacionaria, de un solo canal, en funciones estacionarias con el método adaptativo EEMD, selecciona las características adecuadas del dominio tiempo-frecuencia para cada función y reduce su dimensionalidad con el método robusto ante la correlación alta de esta características usando ULDA, por ultimo clasifica las señales. Para la evaluación, se utilizaron las señales EMG correspondientes a sujetos normales, miopáticos y con ALS, y la precisión de clasificación informada es prometedora. Dado que los neurofisiólogos pueden tener un acceso sustancial a los datos de un paciente en un entorno clínico, una investigación interesante sería determinar la influencia de los datos clínicos en tiempo real en el resultado de la clasificación. Aunque los hallazgos empíricos son alentadores, se requieren evaluaciones clínicas adicionales para validar aún más la aplicabilidad de nuestro método en la práctica. Sobre la base de los resultados experimentales, se prevé que el desarrollo de un sistema de análisis de señal EMG completamente automático, que sea lo suficientemente preciso, simple, rápido y confiable como para ser aplicado en un entorno clínico, está a la vista.

La principal novedad de esta tesis está en el enfoque propuesto basado en EEMD, que apunta a descomponer de forma adaptativa la señal EMG no estacionaria en funciones de modo intrínsecos (FMI), mostrando la diversidad frecuencial de la señal, lo que es útil para la obtención de información en sus diferentes bandas AM y FM, ampliando a su vez el conjunto de información, e.g. los resultados al descomponer una señal EMG monocanal muestran que en promedio se pueden obtener 13 FMI, lo que se traduce en un incremento sustancial a la hora de obtener información de dichas señales a diferencia de hacerlo con la señal original. Una de las principales contribuciones de este trabajo fue establecer un método de selección de características con modelos estadísticos útiles, para analizar la varianza poblacional de cada clase, permitiendo establecer el conjunto adecuado de características que poseen poder discriminatorio alto entre las clases de AMN, ya que un conjunto muy grande de información afecta el rendimiento de la clasificación. A partir de los resultados experimentales obtenidos, se puede sugerir el uso de características tiempo-frecuencia, extrayendolas de acuerdo a su utilidad en cada una de las FMI. Esto permite no solo reducir el tiempo de procesamiento en un enfoque predictivo, sino que además reduce la redundancia en el conjunto de datos, evitando usar características que posean la misma distribución estadística en todas las clases de AMN. Si bien las características temporales son las mas adecuadas para esta tarea, no es posible prescindir de las características en frecuencia, si lo que se quiere es obtener una alta tasa de rendimiento, tanto en exactitud como en valores predictivos positivos y negativos.

Los resultados experimentales muestran que el método combina alto rendimiento, interpretabilidad de los resultados, modo de operación automatizado y un conjunto reducido de entrenamiento; a su vez, permiten determinar que el clasificador KNN es la mejor opción para realizar un diagnóstico de ENM. En los experimentos, se verificó que el parámetro de k-vecinos con k=1 mostró beneficios en la clasificación de ENM, a diferencia de los valores predeterminados que mostraron un rendimiento inferior. Se ha logrado obtener una precisión del 99.2 %, una sensibilidad ante la ALS del 99 % y de 98.4 % para las Miopatías, una especificidad del 98.8 % y un VPP del 99.3 %, lo que se traduce en que el método KNN logra interpretar de forma adecuada la información extraída del análisis cuantitativo de la señal EMG y transformarla en conocimiento coherente para la práctica clínica actual. Por lo tanto, es un esquema muy adecuado para un sistema de apoyo a la toma de decisiones clínicas, proporcionando una herramienta valiosa a los neurofisiólogos para la clasificación de señales EMG. Los resultados de diagnóstico podrían validarse aún más en futuros trabajos con conjuntos de datos más grandes.

Bibliografía

- E. R. Kandel, H. Schwarts, James, T. M. Jessell, S. A. Siegelbaum, and A. J. Hudspeth, *Principles Of Neural Science*. 2013.
- [2] National Institute of Neurological Disorders and Stroke, "Amyotrophic Lateral Sclerosis (ALS) Fact Sheet," 2013.
- [3] J. R. Daube and D. I. Rubin, "Needle electromyography," 2009.
- [4] R. Kendall and R. A. Werner, "Interrater reliability of the needle examination in lumbosacral radiculopathy," *Muscle and Nerve*, vol. 34, pp. 238–241, aug 2006.
- [5] G. Gutierrez-Gutierrez, C. Barbosa Lopez, F. Navacerrada, and A. Miralles Martinez, "Utilidad del electromiograma en el diagnóstico de las miopatías inflamatorias," *Reumatologia Clinica*, vol. 8, pp. 195–200, jul 2012.
- [6] A. Subasi, "Classification of EMG signals using combined features and soft computing techniques," *Applied Soft Computing Journal*, vol. 12, no. 8, pp. 2188–2198, 2012.
- [7] S. D. Nandedkar, "Emerging techniques in the electrodiagnostic laboratory," *PM* and *R*, vol. 5, no. 5 SUPPL., 2013.
- [8] V. K. Mishra, V. Bajaj, A. Kumar, and G. K. Singh, "Analysis of ALS and normal EMG signals based on empirical mode decomposition," *IET Science, Measurement & Technology*, vol. 10, no. 8, pp. 963–971, 2016.
- [9] B. D. Bue and J. M. Killian, "Classification and Diagnosis of Myopathy from EMG Signals *," Workshop on Data Mining for Medicine and Healthcare, in conjunction with the 13th SIAM International Conference on Data Mining (SDMDMMH), Austin, TX., no. May, 2013.
- [10] D. Barmpakos, P. Kaplanis, S. A. Karkanis, and C. Pattichis, "Classification of neuromuscular disorders using features extracted in the wavelet domain of sEMG signals: a case study," *Health and Technology*, vol. 7, no. 1, pp. 33–39, 2017.
- [11] S. Koçer, "Classifying Myopathy and Neuropathy Neuromuscular Diseases Using Artificial Neural Networks," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 24, no. 05, pp. 791–807, 2010.
- [12] G. R. Naik, S. E. Selvan, and H. T. Nguyen, "Single-channel EMG classification with ensemble-empirical-mode-decomposition-based ICA for diagnosing neuromuscular disorders," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 24, no. 7, pp. 734–743, 2016.
- [13] V. K. Mishra, V. Bajaj, A. Kumar, and D. Sharma, "Discrimination between Myopathy and Normal EMG Signals using Intrinsic Mode Functions," *International Conference on Communication and Signal Processing*, pp. 299–303, 2016.
- [14] C. Christodoulou and C. Pattichis, "A new technique for the classification and decomposition of EMG\nsignals," *Proceedings of ICNN'95 - International Conference on Neural Networks*, vol. 5, 1995.
- [15] C. S. Pattichis, C. N. Schizas, and L. T. Middleton, "Neural Network Models in EMG Diagnosis," *IEEE Transactions on Biomedical Engineering*, vol. 42, no. 5, pp. 486–496, 1995.
- [16] G. Pfeiffer, "The diagnostic power of motor unit potential analysis: an objective bayesian approach.," *Muscle & nerve*, vol. 22, pp. 584–91, may 1999.
- [17] L. J. Pino, "Neuromuscular Clinical Decision Support using Motor Unit Potentials Characterized by 'Pattern Discovery'," *Thesis*, 2008.
- [18] L. Pino, D. Stashuk, S. Boe, and T. Doherty, "Probabilistic muscle characterization using QEMG: Application to neuropathic muscle," *Muscle & Nerve*, vol. 41, pp. 18– 31, jan 2010.
- [19] A. Procházka, O. Vyšata, O. Ťupa, M. Yadollahi, and M. Vališ, "Discrimination of axonal neuropathy using sensitivity and specificity statistical measures," *Neural Computing and Applications*, vol. 25, no. 6, pp. 1349–1358, 2014.
- [20] S. Koçer and A. E. Tümer, "Classifying neuromuscular diseases using artificial neural networks with applied Autoregressive and Cepstral analysis," *Neural Computing and Applications*, vol. 28, pp. 945–952, 2017.
- [21] R. Istenič, P. A. Kaplanis, C. S. Pattichis, and D. Zazula, "Multiscale entropy-based approach to automated surface EMG classification of neuromuscular disorders," *Medical and Biological Engineering and Computing*, vol. 48, no. 8, pp. 773–781, 2010.
- [22] N. F. Güler and S. Koçer, "Use of support vector machines and neural network in diagnosis of neuromuscular disorders," *Journal of Medical Systems*, vol. 29, no. 3, pp. 271–284, 2005.
- [23] S. Koçer, "Classification of emg signals using neuro-fuzzy system and diagnosis of neuromuscular diseases," *Journal of Medical Systems*, vol. 34, no. 3, pp. 321–329, 2010.

- [24] D. Kajaree and R. Behera, "Approach for Classification of Neuromuscular Disorder using EMG Signals," *International Journal of Innovative Research in Computer* and Communication Engineering, vol. 5, no. 2, pp. 1302–1309, 2017.
- [25] A. Goen, "Classification of EMG Signals for Assessment of Neuromuscular Disorders," *International Journal of Electronics and Electrical Engineering*, vol. 2, no. 3, pp. 242–248, 2014.
- [26] A. K. Bhoi, K. S. Sherpa, and P. K. Mallick, "A comparative analysis of neuropathic and healthy EMG signal using PSD," *International Conference on Communication* and Signal Processing, ICCSP 2014 - Proceedings, pp. 1375–1379, 2014.
- [27] A. B. M. S. U. Doulah, S. Member, S. A. Fattah, W. Zhu, S. Member, and M. O. Ahmad, "Wavelet Domain Feature Extraction Scheme Based on Dominant Motor Unit Action Potential of EMG Signal for Neuromuscular Disease Classification," *Ieee Transactions on Biomedical Circuits and Systems*, vol. 8, no. 2, pp. 155–164, 2014.
- [28] A. Sengur, Y. Akbulut, Y. Guo, and V. Bajaj, "Classification of amyotrophic lateral sclerosis disease based on convolutional neural network and reinforcement sample learning algorithm," *Health Information Science and Systems*, vol. 5, no. 1, p. 9, 2017.
- [29] I. Elamvazuthi, N. Duy, Z. Ali, S. Su, M. A. Khan, and S. Parasuraman, "Electromyography (EMG) based Classification of Neuromuscular Disorders using Multi-Layer Perceptron," *Proceedia Computer Science*, vol. 76, no. Iris, pp. 223–228, 2015.
- [30] E. Gokgoz and A. Subasi, "Effect of multiscale PCA de-noising on EMG signal classification for diagnosis of neuromuscular disorders," *Journal of Medical Systems*, vol. 38, no. 4, 2014.
- [31] A. Subasi, "Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders," *Computers in Biology and Medicine*, vol. 43, no. 5, pp. 576–586, 2013.
- [32] R. Istenic, P. Kaplanis, C. S. Pattichis, and D. Zazula, "Analysis of Neuromuscular Disorders Using Statistical and Entropy Metrics on Surface EMG," WSEAS Transactions on signal processing, vol. 4, no. 2, pp. 28–35, 2008.
- [33] V. Kaur, Gurmanik and Arora, AS and Jain, "EMG Diagnosis via AR Modeling and Binary Support Vector Machine Classification," Int J Eng Sci Technol, vol. 2, no. 6, pp. 1767–1772, 2010.
- [34] C. Pattichis, C. Schizas, and L. Middleton, "Neural network models in EMG diagnosis," *IEEE Transactions on Biomedical Engineering*, vol. 42, pp. 486–496, may 1995.

- [35] L. Pino, D. Stashuk, S. Boe, and T. Doherty, "Motor unit potential characterization using "pattern discovery"," *Medical Engineering & Physics*, vol. 30, pp. 563–573, jun 2008.
- [36] K. K. Al-barazanchi and A. H. Al-timemy, "Ensemble of Bagged Tree Classifier for The Diagnosis of Neuromuscular Disorders," *Fourth International Conference* on Advances in Biomedical Engineering, 2017.
- [37] R. Istenic, M. Lenic, P. A. Kaplanis, C. S. Pattichis, and D. Zazula, "Classification of Neuromuscular Disorders Using Wavelets and Entropy Metrics on Surface Electromyograms," WSEAS International Conference on Signal, Speech and Image Processing, Beijing, China, pp. 159–163, 2007.
- [38] P. David and S. Barbara, "34 Neuromuscular Junction Disorders," *Electromyo-graphy and Neuromuscular Disorders*, pp. 529–548, 2013.
- [39] E. Feldman, W. Grisold, J. W. Russell, and U. A. Zifko, Atlas of neuromuscular diseases. Springer, 2016.
- [40] B. Mokhlesabadifarahani and V. K. Gunjan, *EMG signals characterization in three states of contraction by fuzzy network and feature extraction*. Springer, 2015.
- [41] R. H. Ropper, Allan H, Brown, Adams and Victor's Principles of Neurology. 10. Education. McGraw-Hill Medical, 2014.
- [42] A. Michell, Understanding EMG. Oxford University Press, aug 2013.
- [43] M. Nikolic, Detailed Analysis of Clinical Electromyography Signals EMG Decomposition, Findings and Firing Pattern Analysis in Controls and Patients with Myopathy and Amytrophic Lateral Sclerosis. PhD thesis, Faculty of Health Science, University of Copenhagen, 2001.
- [44] F. Buchthal, C. Guld, and P. Rosenfalck, "Action Potential Parameters in Normal Human Muscle and their Dependence on Physical Variables.," Acta Physiologica Scandinavica, vol. 32, pp. 200–218, apr 1954.
- [45] I. Rodríguez-Carreño, A. Malanda-Trigueros, L. Gila-Useros, J. Navallas-Irujo, and J. Rodríguez-Falces, "Filter design for cancellation of baseline-fluctuation in needle EMG recordings," *Computer Methods and Programs in Biomedicine*, vol. 81, no. 1, pp. 79–93, 2006.
- [46] P. Kumar and D. Agnihotri, "Biosignal Denoising via Wavelet Thresholds," *IETE Journal of Research*, vol. 56, no. 3, p. 132, 2010.
- [47] M. A. Awal, S. S. Mostafa, M. Ahmad, and M. A. Rashid, "An adaptive level dependent wavelet thresholding for ECG denoising," *Biocybernetics and Biomedical Engineering*, vol. 34, no. 4, pp. 238–249, 2014.

- [48] E. K. Richfield, B. A. Cohen, and J. W. Albers, "Review of Quantitative and Automated Needle Electromyographic Analyses," *IEEE Transactions on Biomedical Engineering*, vol. BME-28, no. 7, pp. 506–514, 1981.
- [49] M. Zecca, S. Micera, M. C. Carrozza, and P. Dario, "Control of multifunctional prosthetic hands by processing the electromyographic signal.," *Critical reviews in biomedical engineering*, vol. 30, no. 4-6, pp. 459–85, 2002.
- [50] A. Subasi and M. K. Kiymik, "Muscle fatigue detection in EMG using timefrequency methods, ICA and neural networks," *Journal of Medical Systems*, vol. 34, no. 4, pp. 777–785, 2010.
- [51] J. Yousefi and A. Hamilton-Wright, "Characterizing EMG data using machinelearning tools," 2014.
- [52] H. A. Romo, J. C. Realpe, P. E. Jojoa, and U. Cauca, "Surface EMG Signals Analysis and Its Applications in Hand Prosthesis Control," Avances en Sistemas e Informática, vol. 4, no. 1, pp. 127–136, 2007.
- [53] R. Morales pinzón, D. A. Morales, and V. H. Grisales, "Caracterizacion de Señales Electromiográficas Para la discriminación de Seis Movimientos de la Mano," *Scientia et technica*, no. 42, pp. 278–283, 2009.
- [54] M. Ozsert, O. Yavuz, and L. Durak-Ata, "Analysis and classification of compressed EMG signals by wavelet transform via alternative neural networks algorithms," *Computer Methods in Biomechanics and Biomedical Engineering*, vol. 14, no. 6, pp. 521–525, 2011.
- [55] N. Huang, Z. Shen, S. Long, M. Wu, H. SHIH, Q. ZHENG, N. Yen, C. Tung, and H. Liu, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," *Proceedings of the Royal Society* A: Mathematical, Physical and Engineering Sciences, vol. 454, no. 1971, pp. 995, 903, 1998.
- [56] R.-D. Pinzon-Morales, K.-A. Baquero-Duarte, A.-A. Orozco-Gutierrez, and V.-H. Grisales-Palacio, "Pattern Recognition of Surface EMG Biological Signals by Means of Hilbert Spectrum and Fuzzy Clustering," in *Software Tools and Algorithms for Biological Systems* (H. R. Arabnia and Q.-N. Tran, eds.), pp. 201–209, New York, NY: Springer New York, 2011.
- [57] G. Sahu, N. Chaurasia, P. P. Suwalka, V. Bajaj, and A. Kumar, "HHT Based Features for Discrimination of EMG Signals," in *Information Systems Design and Intelligent Applications: Proceedings of Second International Conference INDIA* 2015, Volume 2 (J. K. Mandal, S. C. Satapathy, M. Kumar Sanyal, P. P. Sarkar, and A. Mukhopadhyay, eds.), pp. 95–103, New Delhi: Springer India, 2015.

- [58] Z. WU and N. E. HUANG, "Ensemble Empirical Mode Decomposition: a Noise-Assisted Data Analysis Method," Advances in Adaptive Data Analysis, vol. 01, no. 01, pp. 1–41, 2009.
- [59] M. Colominas, P. Flandrin, and E. Torres, "Descomposición empírica en modos por conjuntos completa con ruido adaptativo y aplicaciones biomédicas," XVIII Congreso Argentino de Bioingeniería SABI 2011 - VII Jornadas de Ingeniería Clínica, no. SEPTEMBER, p. 10, 2011.
- [60] E. J. Rechy-Ramirez and H. Hu, "Stages for Developing Control Systems using EMG and EEG signals: A survey," School of Computer Science and Electronic Engineering, University of Essex, pp. 1744–8050, 2011.
- [61] M. A. Oskoei and H. Hu, "Myoelectric control systems—A survey," Biomedical Signal Processing and Control, vol. 2, no. 4, pp. 275–294, 2007.
- [62] D. Tkach, H. Huang, and T. A. Kuiken, "Study of stability of time-domain features for electromyographic pattern recognition," *Journal of neuroengineering and rehabilitation*, vol. 7, no. 1, p. 21, 2010.
- [63] H. Xie and Z. Wang, "Mean frequency derived via Hilbert-Huang transform with application to fatigue EMG signal analysis," *Computer Methods and Programs in Biomedicine*, vol. 82, no. 2, pp. 114–120, 2006.
- [64] S. Lawrence Marple, "Computing the discrete-time analytic signal via fft," IEEE Transactions on Signal Processing, vol. 47, no. 9, pp. 2600–2603, 1999.
- [65] V. K. Mishra, V. Bajaj, A. Kumar, D. Sharma, and G. K. Singh, "An efficient method for analysis of EMG signals using improved empirical mode decomposition," AEU - International Journal of Electronics and Communications, vol. 72, pp. 200–209, 2017.
- [66] J. Ye, R. Janardan, Q. Li, and H. Park, "Feature reduction via generalized uncorelated linear discriminant analysis," *IEEE Transactions on Knowledge and Data Engineering*, vol. 18, no. 10, pp. 1312–1322, 2006.
- [67] C. Sapsanis, G. Georgoulas, and A. Tzes, "EMG based classification of basic hand movements based on time frequency features," 2013 21st Mediterranean Conference on Control and Automation, MED 2013 - Conference Proceedings, pp. 716–722, 2013.
- [68] A. Chan and Green, "Myoelectric control development toolbox," 30th Conference of the Canadian Medical & Biological Engineering Society, pp. 141–144, 2007.
- [69] Z. Jin, J. Y. Yang, Z. S. Hu, and Z. Lou, "Face recognition based on the uncorrelated discriminant transformation," *Pattern Recognition*, vol. 34, no. 7, pp. 1405– 1416, 2001.

- [70] J. R. Quinlan, "Induction of Decision Trees," Machine Learning, vol. 1, pp. 81–106, mar 1986.
- [71] H. Wang and C. Zaniolo, "CMP: A fast decision tree classifier using multivariate predictions," in *Data Engineering*, 2000. Proceedings. 16th International Conference on, pp. 449–460, IEEE, 2000.
- [72] P.-N. Tan, M. Steinbach, and V. Kumar, "Classification: basic concepts, decision trees, and model evaluation," *Introduction to data mining*, vol. 1, pp. 145–205, 2006.
- [73] L. Breiman, *Classification and regression trees*. Routledge, 2017.
- [74] P. Xanthopoulos, P. M. Pardalos, and T. B. Trafalis, *Linear Discriminant Analysis*, pp. 27–33. New York, NY: Springer New York, 2013.
- [75] A. J. Izenman, *Linear Discriminant Analysis*, pp. 237–280. New York, NY: Springer New York, 2008.
- [76] B. Silverman and M. C. Jones, "E. Fix and J.L. Hodges (1951): An Important Contribution to Nonparametric Discriminant Analysis and Density Estimation: Commentary on Fix and Hodges (1951)," *International Statistical Review / Revue Internationale de Statistique*, vol. 57, 1989.
- [77] L. Peterson, "K-nearest neighbor," Scholarpedia, vol. 4, no. 2, 2009.