



Universidad Popular Autónoma del Estado de
Puebla

Centro Interdisciplinario de Posgrados
Investigación y Consultoría
Doctorado en Ingeniería Mecatrónica

“Reconocimiento de Patrones de señales
mioeléctricas superficiales del movimiento de los
dedos de la mano en escenarios estructurados
usando Análisis Discriminante Lineal”

Tesis que para obtener el grado de
Doctor en Ingeniería Mecatrónica
presenta

Guadalupe Araceli Torres Valverde

Asesor de tesis
Dr. Victor Hugo Benitez Baltazar

Puebla, México.

2016



UPAEP – Secretaría General

Dirección General de Apoyos Académicos

Dirección del Centro de Recursos para el Aprendizaje y la Investigación.

Biblioteca Central - **Karol Wojtyla**

Tesis Digitales Restricciones de uso:

DERECHOS RESERVADOS ©

PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

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

El uso de textos, imágenes, gráficas, 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 de donde la obtuvo mencionando el autor o autores involucrados en el documento.

Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

CARTA DE AUTORIZACIÓN

Hermosillo, Sonora a 31 octubre de 2016.

A quien corresponda

Por medio de la presente, me permito informar que he revisado en su totalidad los capítulos correspondientes al documento de tesis, en mi calidad de Director de tesis de M.C. GUADALUPE ARACELI TORRES VALVERDE con matricula 89500022, ID 242180, alumna del programa de Doctorado en Ingeniería Mecatrónica de la Universidad Popular Autónoma del Estado de Puebla, UPAEP.

El contenido del citado documento, cuyo título es **“Reconocimiento de Patrones de señales mioeléctricas superficiales del movimiento de los dedos de la mano en escenarios estructurados usando Análisis Discriminante Lineal”**, ha sido revisado exhaustivamente y la alumna ha atendido oportunamente las observaciones y sugerencias correspondientes.

Por lo tanto, expreso que el documento cumple con la calidad en cuanto a formato y contenido necesario para que se continúen con los trámites administrativos pertinentes.

Sin otro particular, manifiesto mi disponibilidad para cualquier duda o aclaración a la presente.

Atentamente



Dr. Víctor Hugo Benítez Baltazar

Agradecimientos

La presente investigación es el resultado de experimentos realizados en las instalaciones del Laboratorio de Control del Departamento de Ingeniería Industrial de la Universidad de Sonora, mediante el financiamiento CONACYT otorgado en el marco de la Convocatoria de Ciencia Básica 2014, con número de proyecto 236207.

Aprovecho esta oportunidad para agradecer a la Universidad de Sonora por haberme otorgado la beca para mis estudios.

Expreso mi sincero agradecimiento en especial a mi Director de tesis, Dr. Víctor Hugo Benitez Baltazar por haberme confiado este trabajo. Su conocimiento, experiencia y apoyo fueron invaluable para la conclusión de la tesis.

A mis padres, Lupita y Guillermo, por ser el cimiento de mi desarrollo humano y profesional con su ejemplo de trabajo y dedicación.

A mi esposo José Carlos por su comprensión y paciencia.

A mis hijos, Karla Sofía, Melissa y Sael, por el apoyo incondicional durante estos años de estudio y desarrollo de esta tesis.

A mis hermanos, Gerardo, Herminia Patricia y Raquel, por la motivación y las charlas amenas en La Paloma.

A mis compañeros de doctorado María Elena, Flor, Aureliano y Víctor, por su colaboración y amistad.

A mis maestros de doctorado por compartir sus conocimientos para mejorar profesionalmente.

A todos ustedes, muchas gracias.

Índice

1. Introducción.....	1
1.1. Antecedentes	2
1.2. Planteamiento del Problema.....	5
1.3. Justificación del estudio	6
1.4. Objetivo.....	7
1.5. Alcance de la tesis.....	8
1.6. Preguntas de investigación.....	8
1.7. Impacto esperado.	9
1.8. Organización del estudio.....	9
2. Marco teórico.....	11
2.1. Bioseñales	11
2.2. Anatomía de los músculos del antebrazo	13
2.2.1. Compartimento anterior del antebrazo	14
2.2.2. Compartimento posterior del antebrazo	14
2.2.3. Definición de pronación, supinación, flexión y extensión de la mano.....	15
2.3. Tipos de electrodos para la captura de señales EMG.....	18
2.3.1. Electrodos profundos o de inserción	18
2.3.2. Electrodos superficiales.....	18
2.3.3. Características de los sensores.....	20
2.3.4. Localización de sensores	21
2.4. Muestreo y conversión A/D	22
2.5. Señal electromiográfica superficial.....	23
2.6. Reconocimiento de patrones estadístico	25
2.7. Reconocimiento de patrones de movimientos de la mano vía señales sEMG.	27
2.7.1. Extracción / Selección de características de la señal sEMG.	28
2.7.2. Entrenamiento.....	29
2.7.3. Validación.....	29
2.7.4. El problema de la dimensionalidad	30
2.8. Patrones de la señal sEMG basado en estadísticas en el dominio del tiempo.	31
2.8.1. Valor Medio Absoluto.....	32

2.8.2. Valor Raíz Media Cuadrática	32
2.8.3. Longitud de la onda	32
2.8.4. Varianza.....	33
2.8.5. Cruces por cero.....	33
2.8.6. Amplitud de Willison	34
2.8.7. Energía.....	34
2.8.8. Potencia media.....	34
2.9. Análisis multivariante	35
2.9.1. Análisis de valores atípicos	35
2.9.2. Datos multivariantes	35
2.9.3. Diseño de experimentos y análisis de varianza multivariante.....	37
2.9.4. Prueba de hipótesis multivariante.....	42
2.10. Clasificación.....	43
2.10.1. Clasificación de movimientos de los dedos de la mano	45
2.11. Clasificación supervisada: Análisis discriminante.....	46
2.11.1. Análisis discriminante lineal y clasificación	47
2.11.2. Análisis discriminante y la distancia Mahalanobis	51
2.11.3. Análisis discriminante cuando las poblaciones son desconocidas	52
3. Metodología	54
3.1. Etapa de muestreo y selección de patrones	54
3.1.1. Organización del experimento.....	54
3.1.2. Preparación del experimento	56
3.1.3. Captura de la señal ME.....	56
3.1.4. Generación de características	56
3.1.5. Vector de características	57
3.2. Etapa de clasificación con análisis discriminante	57
3.2.1. Reducción de dimensionalidad y la distancia Mahalanobis	58
3.2.2. Entrenamiento.....	58
3.2.3. Validación.....	58
3.2.4. Asignación a una clase	58
3.3. Etapa de evaluación.....	59
3.3.1. Evaluación del clasificador.....	60

3.3.2. Interpretación de los resultados.....	60
4. Resultados.....	62
4.1. Estructura del experimento y generación de patrones.....	62
4.1.1. Diseño del experimento.....	62
4.1.2. Realización del experimento	62
4.1.3. Captura de la señal ME.....	66
4.1.4. Generación de características	72
4.1.5. Vector de características.....	73
4.1.6. Prueba de significancia del análisis de varianza multivariante	77
4.2. Clasificación con LDA.....	81
4.2.1. Entrenamiento del clasificador LDA.....	81
4.2.2. Validación del clasificador LDA.....	83
4.2.3. Reducción de dimensionalidad mediante distancia Mahalanobis	84
4.2.4. Validación del clasificador LDA con características seleccionadas	85
4.2.5. Resultados de la clasificación LDA	86
4.3. Evaluación del clasificador	88
4.3.1. Precisión.	88
4.3.2. Flexibilidad.....	89
4.3.3. Interpretación de los resultados	90
4.4. Resultados adicionales de la clasificación LDA para sujeción de cinco esferas	92
5. Conclusiones.....	95
Referencias.....	98
Productividad académica	103

1. Introducción

En este capítulo introductorio se presenta la problemática que se aborda, la justificación del estudio, hipótesis, objetivo central, alcance, impacto esperado y organización de la tesis. El presente proyecto contempla la clasificación de las señales electromiográficas superficiales (en inglés *surface electromyography*, sEMG) que se capturan de los músculos del antebrazo. La clasificación de las señales mioeléctricas (en inglés *myoelectric*, ME) es la base para aplicaciones tales como diseños ergonómicos, estudios en la medicina del trabajo y el deporte, análisis del movimiento y la evaluación de las funciones neuromusculares, análisis de la fatiga muscular, interfaz hombre-máquina y control de prótesis. La interacción hombre-máquina permitida por las nuevas tecnologías de sensores, genera cambios en las interfaces de usuario. El uso de gestos como método de interacción, especialmente gestos con la mano, se ha convertido en una herramienta importante en el área, en los años recientes, motivando la investigación en su modelado, análisis y reconocimiento [34]. Un gesto es una secuencia de movimientos o configuraciones del cuerpo para comunicar información o interactuar con el entorno. Interpretar las intenciones de los gestos, conlleva limitar el número de variables clasificadoras posibles, sugerido para reducir el consumo de tiempo de procesamiento en el computador. Trabajos como el de [39] presentan el uso de un clasificador de distancia Mahalanobis y sólo dos características, valor medio absoluto y la tasa GUSSS (Guided Under-determined Source Signal Separation), logrando un 85% de precisión para 3 movimientos de mano; esto da la pauta de emplear características del análisis temporal que podrían conducir a un rendimiento de identificación mayor.

Este trabajo de investigación considera el estudio de tres tipos de movimientos de los dedos de la mano cuando el individuo ejecuta el agarre de objetos con geometría esférica. Se recurre al reconocimiento estadístico de patrones con el fin de identificar el movimiento efectuado en escenarios estructurados. La técnica de análisis discriminante lineal (en inglés *linear discriminant analysis*, LDA) es utilizada para predecir la correspondencia de un nuevo movimiento de los dedos de la mano, bajo el criterio de la distancia Mahalanobis. Las características usadas para la clasificación pertenecen al dominio del tiempo. Para la adquisición de las señales sEMG se siguen los lineamientos establecidos en el proyecto

SENIAM (por sus siglas en inglés *Surface Electromyography for the Non-Invasive Assessment of Muscles*).

1.1. Antecedentes

La mano humana es la parte más utilizada de nuestro sistema musculo esquelético, sus señales bioeléctricas se estudian en el campo de reconocimiento de patrones. Trabajos realizados en este tema se presentan en [18, 25, 44], donde se clasifican gestos de la mano y se utilizan en el diseño de controladores basados en señales EMG para personas que han sufrido la amputación de sus manos, discapacitados, en rehabilitación y áreas donde el control se basa en la intención del movimiento, facilitando la interacción entre un usuario y una computadora o máquina. Cuando los electrodos de superficie se colocan sobre la piel del músculo, el proceso de contracción muscular puede ser descrito por las señales sEMG; de ellas, se obtienen patrones que se transformarán en comandos para ejecutarse en un dispositivo. Las propiedades deseadas son la adaptabilidad, portabilidad y un mejor tiempo de respuesta en las tareas ejecutadas con prótesis multifunción, sillas de ruedas, control de asir, teclados virtuales y las interfaces basadas en gestos [35]. Se han dado avances en el entendimiento y estudio de las características que pueden utilizarse para identificar gestos de la mano, a través del uso de técnicas de reconocimiento de patrones. El reconocimiento de patrones estadístico es un proceso que asigna los estímulos sensoriales a categorías significativamente perceptivas [14]; es un área de investigación activa, por ejemplo, la tarea de reconocimiento de patrones puede implicar la identificación de la forma y tamaño del objeto que la mano contiene y posturas de ésta. El desarrollo de las técnicas del reconocimiento de patrones en los últimos años es explicado por la mayor potencia de cálculo disponible, impulsando que su aplicabilidad sea amplia; se ha hecho un esfuerzo considerable para simular las capacidades de reconocimiento de patrones humanos por parte de una máquina.

La señal ME es la vía para estudiar los procesos fisiológicos que hacen al músculo generar fuerza, producir movimiento y ejecutar innumerables funciones que permiten al hombre interactuar con el entorno. Con el estudio electromiográfico superficial el investigador

incursiona en muchos campos de la ingeniería como la biomecánica, donde tres aplicaciones sobresalen:

- Primera, la electromiografía superficial usada como un indicador de la iniciación de la activación del músculo: la señal puede proporcionar la secuencia de tiempo de uno o más músculos que realizan una tarea; las señales de los músculos activados voluntariamente por un usuario, se procesan y se utilizan como comandos para controlar dispositivos electromecánicos o interfaces de tipo software. En este campo se conjugan la electrónica y la medicina, teniendo aplicación en la industria, medicina, hogar, entretenimiento; son ejemplos el control de dispositivo de ratones y teclados mioeléctricos, dispositivos como prótesis mioeléctricas, robots móviles, brazos robóticos o brazos simulados mediante software, teniendo cabida el control utilizando señales mioeléctricas.
- Segundo, la electromiografía superficial usada para determinar la relación con la fuerza producida por un músculo: la señal provee información acerca de la contribución de fuerza de los músculos individuales, así como grupos de músculos, estas señales presentan niveles de voltaje empleados en diagnosticar patologías del sistema muscular, establecer la contracción máxima voluntaria del individuo o analizar las contracciones musculares sostenidas ante un esfuerzo al soportar cargas.
- Tercero, la electromiografía superficial usada para la estimación de un índice de los procesos de fatiga que se producen dentro de un músculo para efectuar la evaluación ergonómica de operaciones, estaciones de trabajo y en la manipulación de herramienta industrial [12].

A las señales captadas por sEMG, se puede realizar tratamientos matemáticos determinísticos y estadísticos que ayudan en la interpretación de los datos. Una interfaz mioeléctrica es un dispositivo electrónico que hace uso de señales biológicas producidas por los músculos del cuerpo, las cuales son procesadas por circuitos electrónicos y traducidas para recrear la acción de algún miembro funcional. Hudgins y su equipo [25] encontraron en las señales sEMG una estructura inherente para cada tipo de contracción, la cual a pesar de mostrar una componente determinística, también contiene una componente aleatoria [46].

Una forma de retener esta información estructural es segmentando la forma de onda transitoria y establecer el conjunto de características a partir de datos estadísticos evaluados en cada segmento.

Independientemente de la técnica de registro y procesamiento de la señal sEMG, la clasificación exacta es fundamental para su aplicación en cualquier campo. Con el fin de mejorar la fiabilidad de la clasificación, se han desarrollado trabajos que afrontan aspectos relativos a la selección y reducción de la dimensionalidad del vector de características, los cuales comúnmente incluyen una combinación de variables del análisis tiempo, tiempo-frecuencia y frecuencia [42]. La desventaja, es el descartar información valiosa de la señal. Los sistemas de reconocimiento de patrones son diseñados para atender los atributos de una situación específica estudiada, esto es, son técnicas de aplicación específica. De ahí surge, en consecuencia, que un sistema bien adaptado a un problema es inaplicable a otro. La diversidad, condiciones requeridas de obtención de datos y naturaleza de los patrones de señales sEMG analizados en la literatura consultada, aunado al aspecto tecnológico de la adquisición de señales que afecta la calidad de información disponible del proceso, son factores que impactan en el problema de especificidad de los sistemas de reconocimiento de patrones. La selección apropiada de las características o rasgos de la señal está vinculada a las particularidades del problema a resolver, no debe estar influenciada con la elección del método de clasificación; teniéndose esto en mente, se evitan errores en la selección del vector de características.

El diseñar un clasificador es un problema genérico, el enfoque adoptado está indicado con el término de clasificación supervisada; basándose en el hecho de disponer con información de la cantidad de clases, proveniente de los escenarios estructurados, que son conocidos. El diseño del clasificador está fundamentado por los principios básicos de las áreas de la estadística. En el caso de la clasificación supervisada, como se menciona anteriormente, las clases están predefinidas y se dispone de patrones previamente clasificados. El objetivo consiste básicamente en definir una regla (proceso de entrenamiento), para ubicar nuevas observaciones en alguna de las clases existentes. Las señales sEMG que serán sometidas al proceso de clasificación tienen determinado el tipo de movimiento de los dedos de la mano

al que pertenecen, lo que a su vez provee el número de clases existentes, condiciones que hacen posible utilizar clasificadores supervisados, para lo que es necesario, además, dividir los datos en dos grupos: datos de entrenamiento y datos de validación. Las clases definidas serán más de dos, lo que indica que el problema de clasificación es multiclase. El alcance general del proyecto es la clasificación de señales ME, que se sitúa dentro del dominio de la teoría de la señal [33].

1.2. Planteamiento del Problema

Investigaciones que presentan estudios con respecto al rendimiento de los sistemas de control usando como entrada la señal electromiográfica (EMG) se tiene en [25], donde se desarrolla un esquema de control basado en un conjunto de simples estadísticas del TD y un clasificador de red neuronal artificial, capaz de clasificar cuatro tipos de movimiento de las extremidades superiores con señales ME adquiridas del músculo bíceps y tríceps. En [18] se demostró que el uso de cuatro canales colocados en músculos flexores y extensores de la muñeca ofrecen suficiente información para la clasificación continua de señales sEMG. El conjunto de características consistió en estadísticas del TD, que se ingresan al clasificador LDA. El trabajo en [44], consistió en analizar la efectividad de diferentes configuraciones de electrodos en el rendimiento del control de prótesis, tanto en sujetos sanos como en amputados. La técnica desarrollada identifica hasta 12 movimientos de los dedos. Las características elegidas fueron Valor Medio Absoluto (MAV), Varianza (V), Longitud de la forma de onda (WL), y Amplitud de Willison (W). Utilizaron una red neuronal artificial Perceptrón Multicapa (ANN-MLP) como clasificador.

Las investigaciones antes mencionadas, las cuales están relacionadas con el tema de la clasificación de los movimientos de la mano que aprovechan la señal ME, consisten en experimentos para clasificar gestos de las manos, tales como abrir, cerrar, palma de la mano hacia arriba o abajo, entre otros; y clasificación de movimientos de la mano en acciones de sujeción de objetos de uso común. Todos esos estudios de movimientos de la mano se han llevado a cabo sin establecer condiciones específicas de experimentación, de manera arbitraria se establece la secuencia de ejecución de movimientos; no hay restricciones de peso y materiales de los objetos; además los movimientos son completamente diferentes entre sí.

Tomando en consideración lo expuesto anteriormente, el problema se plantea como:

Clasificar las posiciones de los dedos de la mano para el bajo nivel de contracción en los movimientos más sutiles, como la flexión de los dedos, que ocurre al sujetar tres objetos con geometría esférica que difieren únicamente en el tamaño del diámetro: D_1 , D_2 y D_3 , en escenarios estructurados.

Se define la sujeción, como la acción de tomar y sostener el objeto con los dedos de la mano.

1.3. Justificación del estudio

Las señales sEMG proveen información para los sistemas de control ME de dispositivos, por ejemplo, las prótesis de mano. Aprovechar esa información depende de varios factores, pero uno de ellos es la habilidad para encontrar métodos que permitan procesar la señal sEMG y obtener la clasificación que apoye a la toma de decisiones para la detección correcta del movimiento estudiado. El interés por realizar esta investigación es clasificar las señales sEMG para que el desempeño de las prótesis mioeléctrica al accionar movimientos, sea con la naturalidad de los efectuados por los dedos de la mano humana.

Se espera que con la captura de las señales sEMG generadas por la posición de los dedos de la mano impuesta por la geometría del objeto sujetado, se obtengan mediciones en el TD a partir de los patrones de activación de los músculos asociados al movimiento de agarre de esfera y poder clasificar correctamente dichos movimientos. A la vez, lograr que el LDA realice la clasificación de las señales sEMG usando un consumo de memoria bajo y proporcione la respuesta en un tiempo rápido, a un despreciable costo computacional.

LDA selecciona las características del dominio del tiempo e identifica la posición de los dedos en un escenario; posee la particularidad de distinguir las variables que proporcionan la mayor separación de las clases, esto es, efectúa la etapa de reducción de dimensionalidad; así evita la pérdida de información relevante. Las señales ME son señales producidas por la contracción y relajación de cualquier músculo, en este trabajo, la diferencia radica en clasificar la señal originada por la posición mecánica de los dedos al agarrar objetos esféricos

que difieren específicamente de diámetro, es decir, su forma es constante. El tamaño de la esfera es la variable a considerar en el análisis ante un escenario controlado para identificar si los pequeños movimientos provocarán diferencias significativas en las señales. En el estudio actual, las mediciones se tomaron para los músculos involucrados en el movimiento de los dedos de la mano, el movimiento ejecutado es de baja intensidad, pero se espera llevar a cabo la clasificación y medir el rendimiento del LDA en el reconocimiento de patrones.

1.4. Objetivo

El objetivo de la tesis es el reconocimiento de patrones estadístico de los movimientos de los dedos de la mano humana en escenarios estructurados, usando señales mioeléctricas superficiales, analizadas mediante LDA.

El análisis discriminante lineal mediante el criterio de asignación de distancia Mahalanobis (Md), será la técnica de clasificación supervisada empleada. Dentro de los objetivos particulares se tienen:

- Establecer una metodología para determinar las características en el dominio del tiempo, obteniendo como resultado el vector patrón.
- Selección de las características que contribuyen al proceso de discriminación de señales sEMG y estimar funciones de clasificación para ubicar nuevos casos.
- Validación de la metodología de reconocimiento y clasificación de patrones en señales sEMG.

Hipótesis de investigación:

Mediante el método de análisis discriminante lineal, es posible clasificar al menos tres movimientos diferentes de los dedos de la mano, en escenarios estructurados utilizando señales mioeléctricas superficiales.

1.5. Alcance de la tesis

Las señales electromiográficas crudas, serán procesadas y acondicionadas electrónicamente, estas señales tratadas, son la entrada al sistema de reconocimiento estadístico de patrones. La salida del sistema diseñado consiste en identificar patrones en las señales sEMG proporcionadas por los movimientos de los dedos, a pesar de las perturbaciones que puedan encontrarse en el entorno. La investigación emplea la electromiografía como la técnica de registro de la actividad eléctrica generada por la contracción muscular cuando se efectúan movimientos de la mano ante diferentes escenarios previamente diseñados, con sensores, circuitos y software especializado, dedicados para el análisis de señales sEMG. Se estudiará la fisiología básica acompañada de la biofísica que genera la señal EMG, así como las técnicas de registro, detección y acondicionamiento de la electromiografía de superficie y se describe, además, la obtención de las señales sEMG. Se detallan las etapas del proyecto en sí mismas: extracción de características, selección del clasificador, clasificación, evaluación e interpretación de resultados. También, se definen los escenarios estructurados bajo los cuales se realizaron los experimentos para la evaluación y validación del sistema de reconocimiento de patrones.

1.6. Preguntas de investigación

- ¿Será posible extraer las características del dominio del tiempo de las señales electromiográficas superficiales que sean útiles en el proceso de discriminación entre clases de movimientos de los dedos de la mano?
- ¿Será posible distinguir en la señal electromiográfica superficial los movimientos mecánicos tan pequeños como los radios de las esferas?
- ¿Tiene influencia el escenario estructurado en las señales electromiográficas superficiales?

- ¿El número de clases de movimientos de los dedos de la mano tiene impacto en el desempeño del clasificador de análisis discriminante lineal?
- ¿Cuál será la dimensión mínima del diámetro de la esfera que pueda ser clasificada?

1.7. Impacto esperado.

Hasta este momento, se ha revisado la literatura de la clasificación de las señales sEMG y no se ha encontrado un estudio que analice y clasifique el movimiento de los dedos de la mano en escenarios estructurados. Al estudiar la identificación de patrones de señales sEMG en un ambiente estructurado de movimientos de los dedos la mano, se considera la aportación de una clasificación factible y de esta manera, contribuir al desempeño eficiente de dispositivos e interfaces hombre máquina, como las prótesis de mano que se busca ejecuten movimientos finos. El algoritmo tiene la capacidad de ser flexible para adecuarse a nuevas investigaciones y se probará que sea robusto al modificar variables del entorno. Los estudios de naturaleza similar han consistido en clasificar los movimientos de la mano en entornos no estructurados, como pueden ser las posiciones donde la mano sujeta objetos en forma arbitraria, colocación de la mano sin ninguna disposición o arreglo. Estas acciones o movimientos son arbitrarios ya que no han sido formuladas bajo ningún criterio objetivo. El contar con un estudio de esta naturaleza determina que es posible la relación de un escenario específico estructurado y la colocación de los dedos de la mano. Dicha relación se identifica utilizando reconocimiento estadístico de patrones bajo la clasificación supervisada.

1.8. Organización del estudio.

Esta tesis inicia con la introducción en el capítulo 1, en el que se plantea la oportunidad, justificación del estudio, objetivo de la tesis, alcance, preguntas de investigación e impacto esperado. Para el capítulo 2 de la tesis se tiene descrito el marco teórico, que incluye la descripción de la señal sEMG, la descripción de las etapas de un sistema de reconocimiento de patrones estadístico, las características en el dominio del tiempo que se emplearon para construir el vector de características y la teoría del método estadístico de clasificación de las señales mioeléctricas denominado LDA. El capítulo 3, presenta la metodología, detallando las etapas para realizar el reconocimiento de patrones de las señales sEMG generadas por la

contracción muscular voluntaria al sujetar con los dedos de la mano objetos con geometría definida, en un entorno de escenarios estructurados controlados; se describe el diseño del experimento y las características de los sensores del equipo TrignoTM wireless EMG que capturan las señales superficiales en cinco músculos del antebrazo, que son el flexor carpi radialis (flexor radial del carpo), flexor carpi ulnaris (flexor cubital del carpo), flexor pollicis longus (flexor largo del pulgar), flexor digitorum profundus (flexor común profundo de los dedos de la mano) y extensor digitorum (extensor común de los dedos). Asimismo, se presenta el vector patrón generado por el algoritmo que será aplicado al clasificador. El capítulo 4, muestra los resultados, graficándose las señales, se muestra la matriz de confusión con los porcentajes de acierto logrados con la clasificación, la comparación de las características de clasificación requeridas para cada sujeto y la discusión de los resultados. Finalmente, en el capítulo 5, se presentan la conclusión de la tesis y recomendaciones, así como el trabajo a futuro.

2. Marco teórico

Las señales EMG se encuentran entre las señales electrofisiológicas ampliamente utilizadas en aplicaciones médicas e ingeniería [30]. En el contexto de la ingeniería, la EMG se aprovecha para generar comandos de control de interfaz hombre-computadora y aplicaciones de rehabilitación. Este capítulo incluye la descripción de bioseñales, específicamente ME, la anatomía de los cinco músculos del antebrazo considerados para el registro de las señales ME, los tipos de sensores, el muestreo y conversión A/D, las etapas en el reconocimiento de patrones estadístico, el análisis temporal de señales y el análisis discriminante (en inglés *discriminant analysis*, DA).

2.1. Bioseñales

En el cuerpo humano se producen bioseñales que regulan funciones de los órganos, las que se generan en los músculos se consideran, en este trabajo, para ser medidas y analizadas. Las células de los músculos generan señales bioeléctricas por cambios electroquímicos intra e intercelulares, estas señales también se denominan mioeléctricas y representan la actividad eléctrica resultado de la excitabilidad de las fibras musculares en la contracción muscular [5]. En el control neural del proceso de contracción muscular se identifica a la unidad motora (en inglés *motor unit*, MU), como el elemento funcional más pequeño. El número de fibras musculares en una MU, varía; se ha establecido que los músculos destinados a controlar movimientos finos y de ajuste son los que poseen menos cantidad de fibras por MU, mientras que los músculos de los miembros tienen MUs más grandes. Existen dos tipos de fibras dentro de un músculo: las fibras rojas, las cuales se encuentran mayormente en músculos posturales del área del tronco, son de contracción lenta y con actividad continua; las fibras blancas predominan en músculos relacionados con el movimiento de las extremidades, se contraen con mayor rapidez [5].

Un potencial de acción de una fibra muscular, es un cambio en el voltaje del potencial de la membrana, que va desde la negatividad del estado de reposo hasta valores positivos durante un corto lapso de tiempo. Un impulso nervioso es una onda eléctrica que se desplaza por la

neurona, producto de un cambio transitorio en la permeabilidad de la membrana plasmática, denominándose potencial de acción, mostrado en la figura 1.




Figura 1. Potencial de acción. Tomado de [21]

La señal eléctrica de las fibras musculares que detecta un sensor se conoce como el potencial de acción de la unidad motora (en inglés *motor unit action potential* MUAP), es la suma espacial y temporal de los potenciales de acción muscular individuales de todas las fibras de una sola MU. Para mantener una contracción muscular, las MUs se deben activar repetidamente. La secuencia de MUAPs se denomina trenes de potencial de acción de unidades motoras. Un solo MUAPT será manifestado cuando las fibras de una única MU están activas en la proximidad del electrodo. Tal circunstancia se produce exclusivamente durante una contracción muscular muy débil [21]. Al aumentar la fuerza del músculo, otras MUs quedan activas en la cercanía del electrodo y varios MUAPTs serán detectados a la vez. Se ilustra la generación de un MUAP en la figura 2.




Figura 2. Representación esquemática de la generación del potencial de acción de la unidad motora. Tomado de [5]

2.2. Anatomía de los músculos del antebrazo

En esta sección se explica el motivo por el que se seleccionaron cinco músculos del antebrazo para la captura de las señales EMG superficiales y su anatomía.

Las señales de EMG para el análisis de movimientos de la mano humana se registran de la parte del antebrazo en lugar de la propia mano, ya que la mayoría de los movimientos de los dedos son accionados por los músculos extrínsecos en el antebrazo [40, 43]. Las señales captadas de esos músculos proporcionan la forma más natural para controlar prótesis de mano [50]. Dichos músculos son los encargados de los movimientos de gran amplitud y potencia de los dedos, se encuentran situados en el antebrazo en el tercio superior [37]. Los músculos del antebrazo que se ubican en el compartimiento anterior y posterior se describen a continuación.

2.2.1. Compartimento anterior del antebrazo

Los músculos del compartimento anterior del antebrazo se disponen en tres planos, superficial, intermedio y profundo. En general, estos músculos se asocian con movimientos de la articulación de la muñeca, flexión de los dedos, incluido el pulgar y pronación.

- Plano superficial. Los cuatro músculos del plano superficial son el flexor cubital del carpo, palmar largo (palmaris longus), flexor radial del carpo y pronador redondo (pronator teres) tienen un origen común en el epicóndilo medial del húmero y, con excepción del pronador redondo, se extienden distalmente desde el antebrazo hasta la mano.
- Plano intermedio. El músculo del plano intermedio del compartimento anterior del antebrazo es el músculo flexor superficial de los dedos.
- Plano profundo. Los tres músculos profundos son el flexor profundo de los dedos, el flexor largo del pulgar y el pronador cuadrado.

2.2.2. Compartimento posterior del antebrazo

Los músculos del compartimento posterior del antebrazo se disponen en dos planos: un plano superficial y un plano profundo. Estos músculos se relacionan con los movimientos de la articulación de la muñeca, la extensión de los dedos y del pulgar, la supinación [16].

- Plano superficial. En el plano superficial se localizan siete músculos: braquiorradial, extensor radial largo del carpo, extensor radial corto del carpo, extensor de los dedos, extensor del dedo meñique, extensor cubital del carpo y ancóneo.
- Plano profundo. El plano profundo del compartimento posterior del antebrazo está formado por cinco músculos: supinador, abductor largo del pulgar, extensor corto del pulgar, extensor largo del pulgar y extensor del índice. Con excepción del músculo supinador, todos estos músculos del plano profundo se originan en las superficies posteriores del radio, el cúbito y la membrana interósea, y se dirigen al pulgar y a los dedos.

2.2.3. Definición de pronación, supinación, flexión y extensión de la mano

- Pronación y supinación. La pronación y la supinación de la mano se producen completamente en el antebrazo, e implican la rotación del radio en el codo y el desplazamiento del extremo distal del radio sobre el cúbito. Supinación es la rotación lateral del antebrazo y de la mano. La palma de la mano se dirige hacia arriba con el pulgar hacia afuera. En ella el radio y el cúbito están alineados. Este movimiento implica un ángulo de 90°. Pronación es a la rotación medial del antebrazo y de la mano. Aquí la palma de la mano mira hacia abajo con el pulgar hacia dentro. En este movimiento el radio pasa por delante del cúbito. Este movimiento implica un ángulo de 85°.
- Extensión: dorso de la mano se acerca a la cara.
- Flexión: la palma de la mano se acerca a la cara anterior del antebrazo.

La figura 3 muestra la pronación, supinación, extensión y flexión de la mano.




Figura 3. Pronación, supinación, extensión y flexión de la mano.

En la tabla 1 se presenta el origen, inserción y función de los músculos seleccionados, mientras que la figura 4 muestra la posición de los músculos en el antebrazo. A continuación se describen brevemente cada uno de los cinco músculos [16].

- Flexor carpi radialis. El músculo flexor radial del carpo se sitúa lateral al palmar largo, y tiene un tendón largo y prominente en la mitad distal del antebrazo. El tendón del

flexor radial del carpo se coloca justo lateral a la línea media del antebrazo. En esa posición se puede palpar fácilmente, por lo que constituye un punto de referencia destacado para encontrar el pulso de la arteria radial, que se sitúa inmediatamente lateral al tendón.

- Flexor carpi ulnaris. Este músculo es el más medial de los músculos flexores del plano superficial. Tiene un origen alargado lineal desde el olécranon y el borde posterior del cúbito, además de otro origen en el epicóndilo medial del húmero.
- Flexor pollicis longus. Se origina en la superficie anterior del radio y en la mitad adyacente de la superficie anterior de la membrana interósea. Es un potente músculo cuyo único tendón alargado pasa por el túnel del carpo, lateral a los tendones del flexor superficial de los dedos y del flexor profundo de los dedos, y llega al pulgar, donde se inserta en la base de la falange distal.
- Flexor digitorum profundus. Se origina en las zonas anterior y medial del cúbito y en la mitad adyacente de la superficie anterior de la membrana interósea. Origina cuatro tendones, que pasan por el túnel del carpo y se dirigen hacia los cuatro dedos mediales. En la mayor parte de su recorrido, sus tendones discurren en profundidad a los del músculo flexor superficial de los dedos.
- Extensor digitorum. Este músculo es el principal extensor de los cuatro dedos mediales (índice, medio, anular y meñique). Se origina en el epicóndilo lateral del húmero y forma cuatro tendones, cada uno de los cuales se dirige a un dedo.

Tabla 1. Músculos del antebrazo. Tomado de [16]

Músculo	Origen	Inserción	Función
Flexor carpi radialis	Epicóndilo medial del húmero. Desde ahí se abre para con su bode exterior formar un ángulo con el supinador largo y continuarse con un tendón en el 1/3 inferior del antebrazo.	Base del II y III metacarpiano.	Flexiona y abduce la muñeca, pero con tendencia a la abducción de ésta.
Flexor carpi ulnaris.	Cabeza humeral: epicóndilo medial del húmero; cabeza cubital: olécranon y borde posterior del cúbito.	En el hueso piramidal, pisiforme y V metacarpiano.	Flexiona y aduce la articulación de la muñeca.
Flexor pollicis longus.	Superficie anterior del radio y mitad radial de la membrana interósea.	Superficie palmar de la base de la falange distal del pulgar.	Flexiona la articulación interfalángica del pulgar y puede flexionar la metacarpofalángica del pulgar.
Flexor digitorum profundus.	Superficies anterior y medial del cúbito, y mitad medial anterior de la membrana interósea.	Cuatro tendones que se insertan en las superficies palmares de las falanges distales de los dedos índice, medio, anular y meñique.	Flexiona las articu-laciones interfalángicas distales de los dedos índice, medio, anular y meñique; también puede flexionar las articulaciones metacarpofalángicas de estos dedos y la articulación de la muñeca.
Extensor digitorum.	Epicóndilo lateral del húmero y tabique intermuscular y fascia profunda adyacentes.	Cuatro tendones, que se insertan a través del capuchón extensor en la cara dorsal de las bases de las falanges media y distal de los dedos índice, medio, anular y meñique.	Extiende los dedos índice, medio, anular y meñique; también puede extender la muñeca.




Figura 4. Identificación de los músculos del antebrazo. Adaptado de [16]

2.3. Tipos de electrodos para la captura de señales EMG.

Existen dos formas de registrar las señales electromiográficas, la electromiografía invasiva y la electromiografía de superficie (no invasiva). Los electrodos que recogen la actividad eléctrica del músculo son por inserción dentro del mismo o a través de la piel que lo recubre. Los electrodos se utilizan individualmente o en pares, esta configuración se conoce como monopolar y bipolar, respectivamente.

2.3.1. Electrodos profundos o de inserción

Electrodos profundos o de inserción (electrodos de aguja) pueden ser de varios tipos

- Monopolar. Consiste en una aguja corriente cuya longitud total (excepto en la punta) ha sido aislada. La variación de potencial se mide entre el extremo de la punta, ubicada en el músculo y el electrodo de referencia ubicado en la piel o tejido subcutáneo.
- Coaxial. Es el más adecuado para la práctica clínica y consiste en una aguja hipodérmica en cuyo interior se han insertado uno o varios conductores metálicos finos aislados entre sí y con respecto a la aguja. Sólo el extremo de estos conductores se encuentra desprovisto de aislamiento y es por este punto por el que se captura la señal procedente del tejido muscular.

2.3.2. Electrodos superficiales

El término electrodo se refiere a la interface pasiva y eléctrica entre el individuo y el equipo [46], son pequeños conos o discos metálicos, fabricados de plata o acero inoxidable, que se adaptan íntimamente a la piel. Para reducir la resistencia de contacto se utiliza pasta conductora. Con estos electrodos se puede obtener una idea de la electrogénesis global del músculo, pero no detectan potenciales de baja amplitud o de elevada frecuencia por lo cual su uso se encuentra bastante restringido en electromiografía: se emplean para la determinación de latencias en la pruebas de conducción y en los estudios cinesiología. Los electrodos hacen una transferencia iónica del tejido vivo del cuerpo hacia un dispositivo electrónico, el cual se encarga de procesarla para posteriormente obtener información útil de

la medición; son elementos que leen las señales fisiológicas y las convierten en señales eléctricas que puedan ser visualizadas en aparatos que admiten este tipo de señales.

Los electrodos superficiales con gel están compuestos por una parte metálica que generalmente es de oro o cloruro de plata. La capa de cloruro de plata permite que la corriente emitida por los músculos pase libremente a través de la juntura entre el gel electrolítico y el electrodo. La parte metálica está adherida a una superficie diferente conocida como soporte, el cual puede estar fabricado de micropore o espuma, este material contiene en una de sus caras un pegamento que se adhiere a la piel. El soporte de micropore o espuma contiene también una parte de gel conductor sólido, éste tiene contacto directo con la piel y la parte metálica.

La señal EMG registrada por los electrodos de superficie es afectada por una serie de factores. Estos factores incluyen los mostrados en la figura 5.





Figura 5. Factores que afectan el registro de la señal EMG superficial.

- Ruido eléctrico. El registro EMG se compone de señales provenientes de las fibras musculares y señales de otras fuentes que no interesan y que se denominan ruido. Hay muchas fuentes de ruido, algunas de ellas son la piel, los campos electromagnéticos, ruido por movimiento y los equipos electrónicos que

generan ruido eléctrico con componentes de 0-100 Hz, que están en el área durante el registro de la señal sEMG. Además del ruido de la fuente de alimentación (60 Hz) debido a las líneas de transmisión eléctrica, que comúnmente se pueden evitar con una buena colocación del electrodo de referencia.

- Crosstalk. Al utilizar electrodos de superficie, se debe considerar el fenómeno del crosstalk, que es la posibilidad de que se registren señales de otros músculos adyacentes al que está en estudio. Una investigación para conocer las consecuencias de las dimensiones del sensor sobre la cantidad de crosstalk detectado se efectuó en [9], concluyendo que un pequeño espaciado entre electrodos de 10 mm es preferible, ya que se reducirá la cantidad de señal crosstalk detectada a partir de los músculos activos adyacentes. El registro diferencial amplifica la diferencia entre los potenciales en los dos electrodos, cuanto mayor es el espaciado de los electrodos mayor es la diferencia de la señal crosstalk de propagación. Las estrategias para reducir el crosstalk son



2.3.3. Características de los sensores

El término sensor, en lugar de electrodos, se utiliza para enfatizar el hecho de que cada medición sEMG necesita del ensamble de al menos 2 electrodos individuales y el preamplificador puede estar integrado en la carcasa. Con un electrodo bipolar se registra una única señal de sEMG como el diferencial de potencial eléctrico entre dos electrodos sobre el músculo que están relativamente poco espaciados en comparación con las dimensiones del músculo. El registro sEMG bipolar está influenciado por la forma, tamaños, posiciones y orientaciones de los electrodos y la distancia entre ellos. De esta manera, sensor se define como el conjunto de electrodos, integrados a un pre-amplificador, siendo una configuración

de dos electrodos. El sensor utilizado para registrar la señal de sEMG, como se menciona en [52] debe poseer las siguientes propiedades o características

■ Medida del electrodo:	Diámetro < 10mm
■ Distancia entre electrodos	< 20mm, o < 1/4 de la longitud del músculo
■ Localización del electrodo	Cualquier distancia más pequeña entre la zona más distal de la inervación y el tendón distal
■ Localización del electrodo de referencia	Entre la zona más próxima a la inervación y el tendón proximal; no sobre una zona inervada como la muñeca, el tobillo o en otra área eléctricamente inactiva.

2.3.4. Localización de sensores

El posicionamiento de los electrodos según la normatividad SENIAM [52] señala que, después de que el sujeto ha sido colocado en una postura de inicio recomendada, la localización de los sensores de sEMG puede ser determinada y marcada. La localización de los sensores es definida como la posición del centro de dos electrodos bipolares en el músculo. Los factores que influyen una incorrecta adquisición de sEMG son la presencia de puntos motores y/o tendones musculares y la presencia de otros músculos activos cerca del sensor sEMG (crosstalk). Las recomendaciones de localización de los electrodos están descritas como el punto entre dos lugares anatómicos de interés. Primero la posición de los puntos de interés debe ser localizada de acuerdo a las recomendaciones SENIAM para localización de sensores. A continuación, es necesario dibujar una línea entre los dos puntos de interés. La localización de los sensores puede ser en cualquier sitio de esta línea. Las recomendaciones para músculos individuales están basadas en dos aspectos generales,

- *Con respecto a la localización longitudinal del sensor sobre el músculo*, posicionar el sensor a mitad de distancia entre los extremos del músculo o grupo muscular.
- *Con respecto a la localización transversal del sensor sobre el músculo*, posicionar el sensor en la superficie lejana del límite con otras subdivisiones o músculos, de tal forma que la distancia geométrica del músculo a estas subdivisiones y otros músculos sea maximizada.

2.4. Muestreo y conversión A/D

La forma más común de adquirir una representación discreta de una señal continua se denomina muestreo periódico, esto es expresado en la ecuación 2.1

$$x[n] = x_c(nT_s) \quad -\infty < n < \infty \quad (2.1)$$

Se tienen valores de la señal en instantes de tiempo regularmente espaciados. Con T_s como el periodo de muestreo (tiempo entre dos muestras), su inversa $f_s = \frac{1}{T_s}$, es la frecuencia de muestreo (número de muestras por segundo). A un sistema que realice esta acción se le denomina Conversor Analógico Digital (en inglés *analog-to-digital converter*, ADC). La operación de muestreo no es generalmente reversible, ya que existen muchas señales continuas que pueden producir la misma salida de muestras discretas. Esta ambigüedad inherente en el proceso de muestreo es importante en el procesamiento de señales. El teorema de Nyquist establece que una señal para poder ser muestreada, estará por lo menos en una proporción de dos veces la frecuencia de su armónico más alto, esto con el fin de evitar una pérdida de información; este fenómeno es llamado aliasing [13]. Éste constituye un problema para los armónicos de la señal, con respecto a las frecuencias más altas; por el ruido que se presenta en el ancho de banda. Por esta razón son retirados aquellos componentes de ruido que afectan la señal.

Para casi todos los músculos y la mayoría de las aplicaciones en EMG, el rango de frecuencias en la señal entre 400 a 450Hz, es donde están los más altos armónicos; de tal modo que se requiere un filtro pasa bajo (anti-aliasing) con una frecuencia de corte fijada a estos rangos y un muestreo por lo menos de 1,000 muestras por segundo. La conversión analógica a digital (A/D), transforma los voltajes muestreados en niveles representados en código binario, aceptando señales en un rango de entrada de $\pm 5V$, las cuáles se subdividen en un número de niveles discretos dados por la ecuación $2^n - 1$; donde n es el número de bits del convertidor (A/D). La tabla 2, muestra los ejemplos resultantes para un amplificador de rango de entrada de $\pm 5V$ y ganancia de 1,000.

Tabla 2. Relación entre número de bits de un convertidor A/D, número de niveles, V/nivel y resolución referida a la entrada. Tomado de [30].

Número de bit n del convertidor A/D	Número de niveles $N=2^n-1$	V/nivel (Rango $\pm 5V$) $10/N$	Resolución referida a la entrada* (Amplificador de ganancia= 1000 y Rango de entrada $\pm 5V$ A/D)
8	225	39.06 mV	39.06 μV
10	1,023	9.765 mV	9.765 μV
12	4,095	2.441 mV	2.441 μV
14	16,383	0.610 mV	0.610 μV
16	65,535	0.152 mV	0.152 μV

*diferencia de voltaje correspondiente al último bit de significancia.

2.5. Señal electromiográfica superficial

Electromiografía es el registro de una bioseñal que se obtiene a partir de la superposición del potencial de acción de la unidad motora (MUAP) de muchas MUs activas simultáneamente, presentes en los músculos del esqueleto humano. La técnica EMG superficial consiste en colocar electrodos de superficie sobre la piel para detectar la actividad eléctrica del músculo. La señal registrada se llama electromiográfica superficial. Una representación eléctrica de la detección de la señal se muestra en la figura 6, la entrada con impedancia infinita se monitorea mediante el voltaje que proviene de un generador equivalente. G simboliza el generador de voltaje, V medidor de voltaje ideal y R equivale al generador de impedancia.




Figura 6. Esquema ideal de la detección de la señal sEMG. Adaptado de [30]

Dos factores afectan la forma de la señal muscular, MUAP, la posición del electrodo y los cambios bioquímicos en el músculo suscitados ante variaciones en el nivel de contracción. El índice de los pulsos neuronales, cuyos tiempos de ocurrencia exacta son de naturaleza aleatoria, está relacionada con la duración de tiempo y la fuerza de una contracción muscular. Matemáticamente, los intervalos se pueden expresar como una secuencia de deltas de Dirac de los impulsos δ_i convolucionados con un filtro $h(t)$, que representa la forma del MUAP [5]. De ahí que el MUAPT $u_i(t)$ puede expresarse

$$u_i(t) = \sum_{k=1}^n h_i(t - t_k) \quad (2.2)$$

donde

$$t_k = \sum_{l=1}^k x_l \quad \text{para } k, l = 1, 2, 3, \dots, n. \quad (2.3)$$

En la expresión anterior, t_k representa las ubicaciones en el tiempo de los MUAPs, x los intervalos interpulso, n es el número total de intervalos entre los pulsos en un MUAPT e i, k y l son enteros que denotan eventos específicos. Al representar los intervalos entre los pulsos como un proceso de renovación y limitando la forma del MUAP, de modo que sea invariante a lo largo del tren, es posible derivar las aproximaciones

Valor medio corregido

$$E\{|u_i(t, F)|\} \cong \lambda_i(t, F) \int_0^\infty |h_i(t)| dt \quad (2.4)$$

Valor medio cuadrado

$$MS\{|u_i(t, F)|\} \cong \lambda_i(t, F) \int_0^\infty h_i^2(t) dt \quad (2.5)$$

donde F es la fuerza generada por el músculo.

Cuando las tasas de disparo de MUs activas en contracción aumenta, la contracción asociada con cada disparo puede eventualmente unirse para producir grandes fuerzas (disparo se denomina a cada potencial de acción que la fibra recibe del nervio motor). Cuando

un potencial de acción nervioso llega a la fibra muscular antes que ésta se haya relajado completamente de la contracción previa, se produce una suma en la fuerza de contracción. Por medio de este mecanismo, la frecuencia de disparo de la motoneurona afecta la fuerza muscular generada por cada MU.

La señal EMG se puede sintetizar sumando linealmente los MUAPTs. La aproximación está expresada en la ecuación 2.6

$$m(t, F) = \sum_{i=1}^p u_i(t, F) \quad (2.6)$$

2.6. Reconocimiento de patrones estadístico

La identificación es una acción humana inherente con la cual se detectan rasgos y características de alimentos, animales, sonidos y objetos, que son empleados para agrupar en una categoría o clase para un fin dado. En la actualidad esa compleja acción humana se traslada al ámbito de la automatización, según Jain [26] el reconocimiento de patrones es el estudio de cómo las máquinas detectan señales del entorno, aprenden a distinguir los patrones de interés con base en datos de entrenamiento y toman decisiones apropiadas acerca de las categorías de los patrones. En el enfoque estadístico, cada patrón se representa en términos de m características o mediciones y la finalidad es elegir las características que permiten a los vectores de patrón que pertenecen a diferentes categorías ocupar regiones compactas pero disjuntas entre sí, en un espacio de características. La eficacia del espacio de representación de categorías está determinada por lo correcto que los patrones de diferentes clases pueden ser separados. Dado un conjunto de patrones de entrenamiento de cada clase, el objetivo es establecer límites de decisión en el espacio de características, los cuales separen los patrones pertenecientes a diferentes clases [17]. Los procesos perceptuales del ser humano pueden ser modelados como un sistema de tres estados [14].

- a) Adquisición de datos sensoriales.
- b) Extracción de características.
- c) Toma de decisiones.

En la figura 7, se muestra el sistema de reconocimiento de patrones genérico.




Figura 7. Etapas en un sistema de reconocimiento de patrones. Tomado de [14]

Brevemente se describen las etapas.

- **Sensor.** Utilizado para recopilar datos y convertir la información en formato digital. Su propósito es proveer una representación viable de los elementos del universo a ser clasificados [14]. La señal eléctrica, normalmente una corriente o un voltaje deben convertirse en una señal digital para lo cual debe pasar por un convertidor analógico-digital (A/D).
- **Extracción de características.** Se encarga de obtener la información discriminatoria eliminando la información redundante e irrelevante [14]. La extracción de características consiste en calcular los atributos que representan la señal y almacenarlas en forma vectorial. Ese formato del conjunto de descriptores, lo hace manejable, comprimiendo los datos sin pérdida de información relevante, con el objeto de reducir el número de variables de entrada para incrementar el desempeño de la fase de clasificación. El número de características que se extraen define la dimensión del espacio de características [6]. En reconocimiento de patrones de señales ME, un movimiento de los dedos de la mano se representa por m características, en cuyo caso se denota patrón. Para cada movimiento diferente que un ser humano pueda ejecutar, estaría representado por un punto en un hiperespacio euclidiano de m dimensiones.
- **Clasificador:** Etapa de toma de decisiones en el sistema, su rol es asignar a la categoría apropiada los vectores patrones de clase desconocida a priori. El clasificador asimila y explota la información contenida en los vectores de características de entrenamiento para decidir la asignación de una nueva observación a una clase [17].

2.7. Reconocimiento de patrones de movimientos de la mano vía señales sEMG.

La señal ME es esencialmente un patrón unidimensional, al que se pueden aplicar métodos y algoritmos desarrollados para el reconocimiento de patrones [25]. Previamente se describió la etapa de extracción de características, donde la información extraída de la señal ME, se representa en un vector de características. Estas características de las señales bioeléctricas provienen de una serie de canales, un conjunto de estadísticas que describen la señal muestreada en un sitio de control o algún otro conjunto de características reproducibles. Una vez que los patrones se describen en este espacio de características m -dimensional, un patrón desconocido puede compararse con ellos para determinar a cuál clase es asignado. En un estudio realizado por Hudgins y colegas [25] identificaron una estructura inherente reproducible para cada tipo de contracción. Dicha estructura es una componente determinista de corta duración y producida durante las fases iniciales de la contracción, el patrón de forma de onda para cada clase de contracción es distinto. La ejecución de los tipos de contracción podría variar entre los sujetos, por esa razón no se comparan los datos de una persona con los de otra persona. Concluyen que la observación de la señal ME durante el comienzo de la contracción muscular no es al azar y que la información en la estructura de la señal durante esta fase inicial, proporciona un medio de clasificar patrones a partir de diferentes tipos de contracción. Englehart y colaboradores [20] muestran un buen desempeño con datos de cuatro canales en el estado estacionario de la señal con hasta seis clases. En [18] se describe un esquema propuesto para reconocimiento de patrones que procesa datos de cuatro canales de electrodos para señales ME generadas por múltiples movimientos de una extremidad superior. El método no requiere la segmentación de la señal, permitiendo un flujo continuo de decisiones de clase dado el conjunto de características globales basado en el TD, en cada ventana de análisis.

El sistema de reconocimiento estadístico tiene de dos fases de operación, entrenamiento y clasificación [26]. En la fase de entrenamiento, el módulo de extracción de características encuentra los atributos apropiados para la representación de los patrones de entrada y el clasificador se entrena para dividir el espacio de características. La retroalimentación es el medio para optimizar las estrategias de pre-procesamiento y extracción de características. En

la fase de clasificación, el clasificador entrenado asigna un patrón de entrada a una de las clases basado en las características medidas. La figura 8 presenta el modelo del sistema de reconocimiento de patrones estadístico.




Figura 8. Modelo de reconocimiento de patrones estadístico.

En seguida se explican la extracción y selección de características, la etapa de entrenamiento, la etapa de validación y el problema de la dimensionalidad.

2.7.1. Extracción / Selección de características de la señal sEMG.

La generación o extracción de características es usada para dar énfasis a la estructura relevante en MES, alisar el ruido y anular información irrelevante [49]. La representación inicial de la señal mioeléctrica es el vector de medidas (patrón), que se optimiza a partir de las propiedades discriminatorias en la etapa de extracción y selección de características del modelo de la figura 8. Las técnicas empleadas en esta etapa detectan comportamientos comunes y particulares en la información, determinando el sub-espacio de dimensión m a partir del espacio original. La extracción de características se distingue por ser la transformación inicial elegida para representar las señales [20]. La señal sEMG registrada de cada canal de electrodos será sujeta a la extracción de características [19]; mientras que la selección busca y combina medidas o características con el objetivo de elegir el conjunto de atributos que reduzcan el error de la salida del sistema de reconocimiento. Una vez que la señal analógica sea discretizada, se efectúa la división de la señal en intervalos de tiempo iguales, nombrados segmento de tiempo. A cada uno de ellos se aplica la extracción o selección, según el caso, de las características discriminatorias para generar el conjunto de características total usado para representar un patrón de movimiento específico. Se ha identificado, que la estructura determinística de los patrones mioeléctricos es más

pronunciada en ciertos tipos de contracción muscular, mientras otros tipos, presentan una naturaleza casi al azar desde el inicio. La alteración en la estructura temporal de estas señales es alta, sin embargo las estadísticas de forma de onda pueden ser lo suficientemente estables como para permitir la clasificación de patrones [25]. Las investigaciones antes citadas, señalan que la efectividad de esta etapa es decisiva para una clasificación fiable y una manera de mejorar la precisión de la clasificación de patrones de la señal mioeléctrica [20]. Así, el éxito de un sistema de reconocimiento de patrones depende fundamentalmente de la elección de características usadas para representar las formas de onda. En la literatura revisada, no se ha podido obtener un único parámetro que refleje descriptivamente las características de la señal EMG medida. Debido a esto, es necesario elegir un conjunto de características como entrada a una etapa de clasificación de patrones. Idealmente, se desea un conjunto de características que obtenga la mayor cantidad de información posible de la señal mioeléctrica que discrimine los diferentes tipos de movimiento [18]. Las características en el TD son más eficaces, al ocupar una dimensión vectorial menor y homogenizar la varianza dentro de la clase [20].

2.7.2. Entrenamiento

El entrenamiento es la optimización de los parámetros del modelo para maximizar la calidad de la separación entre clases, haciendo una clasificación correcta en el grupo de entrenamiento dado. El objetivo del proceso de entrenamiento es incorporar evidencia a partir de un conjunto de muestras, evaluando si el clasificador se comporta con un error por debajo de un criterio de precisión. El grupo de vectores patrón de entrenamiento son muestras representativas para cada clase predefinida.

2.7.3. Validación.

La etapa de validación del clasificador procede una vez que se ha efectuado el entrenamiento. En la validación se mide la capacidad del clasificador para utilizar el conjunto de datos de entrenamiento y verificar que funciona satisfactoriamente ante datos fuera de ese conjunto. Si el clasificador genera la salida correcta para una observación de entrada fuera del conjunto de entrenamiento, entonces los resultados de la validación se utilizan para estimar el error de clasificación. Dado que se desea un error de validación bajo, se debe

entrenar el clasificador para que permita llegar a un mínimo error de validación factible. Para la validación del clasificador, se utiliza un grupo de vectores patrones de la base de biodatos obtenido con la misma cantidad de características del TD que la utilizada para el entrenamiento. Las muestras usadas para entrenamiento no formaron parte del grupo de muestras para la validación.

2.7.4. El problema de la dimensionalidad

El reto de las investigaciones en el desarrollo de prótesis multifuncionales controladas con EMG es mejorar la eficiencia de éstas, aumentando el número de los movimientos reconocidos, lo que directamente incrementa el número de comandos de control [4, 18, 25]. A la vez, esto conduce a desarrollar técnicas de extracción de datos de la señal EMG. Dos estrategias para ampliar la información proveniente de los sistemas de reconocimiento de EMG son la obtención de información de varios músculos y la segunda, utilizar las características presentes en la señal [36]. Mientras mayor sea el número de canales y de características, se obtiene un vector de patrón de características de alta dimensión provocando el problema de la dimensionalidad [25]. Jain [26] añade que se ha observado comúnmente en la práctica que las características añadidas pueden de hecho degradar el rendimiento de un clasificador si el número de muestras de entrenamiento que se utiliza para diseñar el clasificador, es pequeño en relación con el número de características. Las razones principales para fijar la dimensionalidad de la representación de patrones lo más pequeño posible son evitar la redundancia al trabajar con características altamente correlacionadas, el costo de la medición y la precisión de la clasificación. Modelos sencillos (con pocas características) son más robustos ante bases de datos pequeñas. Esto se explica porque modelos más simples tienen menos variación, debido a que varían menos en función de las particularidades de una muestra, incluyendo el ruido, los valores atípicos, entre otros [1]. Dentro del reconocimiento de patrones, la selección y la extracción de características, son métodos para reducir la dimensionalidad del espacio de características. Seleccionar características consiste en encontrar un número k de las d dimensiones que proporcionen la mayor información; son algoritmos que eligen el mejor subconjunto del conjunto de características de entrada. Un criterio puede ser establecido para calificar si un subconjunto de características es mejor que otro. Un ejemplo de estos criterios es medir la separabilidad de clases. La selección de

características ahorra el costo de medición y retiene su interpretación física original [26]. Por otra parte, los métodos que crean nuevas características basadas en transformaciones o combinaciones del conjunto de características original se llaman extracción de características. El interés de extraer características es conseguir un nuevo conjunto de k dimensiones que sean combinaciones de las d dimensiones originales.

Se necesita una técnica de reducción de dimensionalidad para producir un resultado eficaz, que abarque factores tales como la medición, almacenamiento, tiempo de cálculo y rendimiento del clasificador. LDA es un método supervisado para reducción de dimensionalidad de los problemas de clasificación. LDA puede manejar como entrada un conjunto de características de gran dimensión, que agrupa en clases buscando una transformación óptima. Mapea las características en un espacio de dimensión inferior, preserva la estructura de la clase, reduce al mínimo la distancia dentro de la clase y maximiza la distancia entre clases, logrando así la máxima discriminación. Esta transformación se calcula fácilmente con la descomposición del valor propio de las matrices de dispersión de un conjunto de datos de entrenamiento [38]. La distancia métrica es fundamental en algunos algoritmos de máquinas de aprendizaje y de sistemas de clasificación. La M_d es una medida entre dos puntos de datos en el espacio definido por el vector de características proporcionado. Dado que puede operar con varianzas desiguales, así también con las correlaciones entre las características, evaluará adecuadamente la distancia [48]. Sólo cuando las características no están correlacionados, la distancia bajo la métrica de M_d es idéntica a la distancia Euclidiana. Geométricamente, M_d puede ajustar la distribución geométrica de los datos de modo que la distancia entre los puntos de datos similares es pequeña. Por lo tanto, puede mejorar el rendimiento de la clasificación de los algoritmos. Tales ventajas se pueden utilizar para realizar entrenamiento en un conjunto de datos, si se usa la M_d como criterio de asignación en el método LDA.

2.8. Patrones de la señal sEMG basado en estadísticas en el dominio del tiempo.

La aproximación temporal permite conocer el comportamiento de una señal a través del tiempo. Su simplicidad de cálculo comparativo hace de las características del TD las más

populares en la clasificación mioelétrica [35]. En la extracción de características de una señal con fines de identificación, es relevante acumular la mayor cantidad de información acerca de la señal, lo que provoca que la aproximación temporal sea una herramienta de procesamiento de señales importante, porque proporciona una idea de frecuencia y comportamiento en el tiempo. Previo a la etapa de extracción de características, existen métodos de pre-procesamiento para señales, entre los cuales se encuentran la normalización, rectificación, filtrado, promediado, suavizado, integración, entre otros. Dichos métodos preparan la señal para la obtención de medidas estadísticas. A continuación se detallan las características en el TD consideradas en este trabajo.

2.8.1. Valor Medio Absoluto

Es una estimación del valor medio absoluto (en inglés, *mean of the absolute value*, MAV) de la señal x_i en un segmento i que tiene N muestras de longitud, está dado por

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (2.7)$$

2.8.2. Valor Raíz Media Cuadrática

La raíz media cuadrática (en inglés *root mean square*, RMS) mide la energía de la señal, proporcionando una medida más rigurosa del contenido de la información de la señal [10]. Su uso en electromiografía, sin embargo, ha sido escaso en el pasado. El reciente incremento en su uso es causado por la disponibilidad de chips analógicos que ejecutan la operación RMS y a la aumentada competencia técnica en electromiografía.

El valor RMS se obtiene mediante la realización de las operaciones descritas por

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i|^2} \quad (2.8)$$

2.8.3. Longitud de la onda

Una propiedad que proporciona información acerca de la complejidad de una señal en un segmento, está definida por la longitud de la onda (en inglés *waveform length*, WL). Es

simplemente la longitud acumulada de la forma de onda sobre el segmento de tiempo [25], definida

$$l_o = \sum_{k=1}^N |x_k - x_{k-1}| \quad (2.9)$$

siendo $x_k - x_{k-1}$ la diferencia de los valores de voltaje consecutivos en la muestra.

Asumiendo que el tiempo entre muestras es muy pequeño, el valor resultante provee una idea de la amplitud, frecuencia y duración de la onda en un solo valor.

2.8.4. Varianza

Un parámetro de la distribución de amplitud es la varianza y se asume es modulada usando un factor multiplicativo de una función estática de la fuerza muscular, la cual es en general no lineal [24]. La expresión para la varianza de la señal rectificada es más complicada, contiene todos los términos que están presentes en dos medidas: RMS y valor medio rectificado [5]. Por lo cual, refleja el efecto combinado de todas las correlaciones fisiológicas. El parámetro representa la potencia de la corriente alterna (AC) de la señal mioeléctrica rectificada y debe demostrar ser apropiado en el análisis de la señal, aunque se ha utilizado con moderación. La mayor parte de las últimas investigaciones han tratado con el nivel de corriente directa (DC) de la señal EMG. La varianza de la señal mioeléctrica es una función del nivel de contracción [25] y es una medida de la potencia de la densidad de la señal EMG [41], dada por

$$\text{VAR} = \frac{1}{N-1} \sum_{k=1}^N (x_k - \mu)^2 \quad (2.10)$$

donde μ es el promedio.

2.8.5. Cruces por cero

Este método consiste en contar el número de veces por unidad de tiempo que la amplitud de la señal contenga ya sea un pico o cruce un valor cero de la señal [10]. Lindström y su equipo demostraron que la relación entre las vueltas o ceros y el número de MUAPTs es lineal para las contracciones de bajo nivel. Pero a medida que aumenta el nivel de la

contracción, las unidades motoras reclutadas adicionalmente contribuyen a los MUAPTs de la señal EMG. Cuando la amplitud de la señal alcanza el carácter de ruido aleatorio gaussiano, la proporcionalidad lineal ya no se sostiene [5].

Dadas dos muestras consecutivas x_i y x_{i+1} , incremente cruces por cero si

$$\{x_i > 0 \text{ and } x_{i+1} < 0\} \text{ or } \{x_i < 0 \text{ and } x_{i+1} > 0\} \quad (2.11)$$

2.8.6. Amplitud de Willison

Es el número de recuentos para cada cambio de la amplitud de la señal ME que supera un umbral predefinido

$$W = \sum_{i=1}^N f(|x_i - x_{i-1}|) \quad (2.12)$$

donde

$$f(x) = \begin{cases} 1, & \text{si } x > \text{umbral} \\ 0, & \text{en lo contrario.} \end{cases}$$

Esta medida indica la activación del MUAP, por tanto, del nivel de contracción muscular [51].

2.8.7. Energía

Dado que las muestras están espaciadas en T_s segundos, el cálculo de la energía (W-s)

$$E = T_s \sum_{i=1}^N |x_i|^2 = \frac{1}{f_s} \sum_{i=1}^N |x_i|^2 \quad (2.13)$$

2.8.8. Potencia media

La potencia media de la señal discreta de una secuencia con N muestras puede calcularse a partir de

$$P = \frac{1}{N} \sum_{i=1}^N |x_i|^2 \quad (2.14)$$

2.9. Análisis multivariante

2.9.1. Análisis de valores atípicos

Es el procesamiento realizado a las características del TD antes de su utilización. Trata el problema que consiste en detectar valores atípicos en los datos multivariados. Los valores atípicos son observaciones que no son coherentes con el resto de los datos [47]. Un valor atípico es definido como un punto que se encuentra muy lejos de la media de la variable aleatoria correspondiente; en observaciones multivariantes pueden ser difíciles de detectar, sobre todo cuando hay varios valores atípicos presentes. Los puntos con valores muy diferentes respecto al valor medio ocasionan errores durante la clasificación. Ese efecto se aprecia más cuando los valores atípicos son el resultado de las mediciones de ruido. Si el número de valores atípicos es muy pequeño, normalmente se descartan. Un método sencillo consiste en calcular la Md de los puntos de datos, descartando los datos aislados que están lejos del centroide.

2.9.2. Datos multivariantes

El análisis multivariante es la parte de la estadística y del análisis de datos que analiza e interpreta los datos que resultan de observar más de una variable estadística sobre una muestra de individuos [17].

- Matrices de datos

Sean los individuos $w_1, \dots, w_c$ a los que se han observado las variables $X_1, \dots, X_p$ y con $x_{ij} = X_j(w_i)$ la observación de la variable X_j sobre el individuo w_i . La matriz de datos multivariantes es

$$\mathbf{X} = \begin{pmatrix} x_{11} & \cdots & x_{1j} & \cdots & x_{1p} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{i1} & \cdots & x_{ij} & \cdots & x_{ip} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nj} & \cdots & x_{np} \end{pmatrix} \quad (2.15)$$

Las filas de la matriz $\mathbf{X}$ se identifican con los sujetos observados y las columnas de $\mathbf{X}$ con las variables. El vector columna de las medias de las variables es

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (2.16)$$

La matriz simétrica $p \times p$ de covarianzas muestrales

$$\mathbf{S} = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1p} \\ s_{21} & s_{22} & \cdots & s_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ s_{p1} & s_{p2} & \cdots & s_{pp} \end{pmatrix} \quad (2.17)$$

siendo la covarianza entre las variables j, j'

$$s_{jj'} = \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ij'} - \bar{x}_{j'}) \quad (2.18)$$

- Distribución de Wishart

La distribución de Wishart es la que sigue una matriz aleatoria simétrica definida positiva y generaliza la distribución ji-cuadrado [7]. La distribución de la matriz de covarianzas $\mathbf{S}$, donde las filas son observaciones normales multivariantes, es Wishart.

Definición

Si las filas de la matriz $\mathbf{Z}_{n \times p}$ son independientes $N_p(0, \mathbf{\Sigma})$ entonces se dice que la matriz $\mathbf{Q} = \mathbf{Z}'\mathbf{Z}$ es Wishart $W_p(\mathbf{\Sigma}, n)$, con parámetros $\mathbf{\Sigma}$ y n grados de libertad.

Cuando $\mathbf{\Sigma}$ es definida positiva y $n \geq p$, la densidad de $\mathbf{Q}$ es

$$f(\mathbf{Q}) = c |\mathbf{Q}|^{(n-p-1)/2} \exp\left(-\frac{1}{2} \text{tr}(\mathbf{\Sigma}^{-1} \mathbf{Q})\right) \quad (2.19)$$

siendo

$$c^{-1} = 2^{np/2} \pi^{p(p-1)/4} |\mathbf{\Sigma}|^{n/2} \prod_{i=1}^p \Gamma\left[\frac{1}{2}(n+1-i)\right] \quad (2.20)$$

- Distribución de Wilks

La distribución F con m y n grados de libertad surge considerando el cociente

$$F = \frac{A/m}{B/n} \quad (2.21)$$

donde A y B son ji-cuadrados estocásticamente independientes con m y n grados de libertad.

Sea la distribución

$$\Lambda = \frac{A}{A + B} \quad (2.22)$$

la relación entre Λ y F_n^m , así como la inversa F_m^n , es

$$F_n^m = \frac{n}{m} \frac{\Lambda}{1 - \Lambda}, \quad F_m^n = \frac{m}{n} \frac{1 - \Lambda}{\Lambda} \quad (2.23)$$

La distribución de Wilks generaliza esta relación.

Definición

Si las matrices $\mathbf{A}$ y $\mathbf{B}$ de orden $p \times p$ son independientes Wishart $W_p(\mathbf{\Sigma}, m)$, $W_p(\mathbf{\Sigma}, n)$, respectivamente, con $m \geq p$, la distribución del cociente de determinantes

$$\Lambda = \frac{|\mathbf{A}|}{|\mathbf{A} + \mathbf{B}|} \quad (2.24)$$

es por definición la distribución lambda de Wilks $\Lambda(p, m, n)$.

2.9.3. Diseño de experimentos y análisis de varianza multivariante

Un experimento diseñado es una prueba o serie de pruebas en las cuales se inducen cambios deliberados en las variables de entrada de un proceso o sistema, de manera que sea posible observar e identificar las causas de los cambios en la respuesta de salida [32].

La terminología empleada se presenta como

- *Variable de interés o respuesta*: es la variable que se desea estudiar.
- *Factor*: son las variables independientes que pueden influir en la variabilidad de la variable de interés.
- *Nivel*: son los valores que puede tener el factor a estudiar. Según sean elegidos por el experimentador o elegidos al azar de una amplia población se denominan factores de efectos fijos o factores de efectos aleatorios.
- *Efecto*: cambio en la respuesta al modificar el nivel de un factor.
- *Tamaño del experimento*: es el número total de observaciones colectadas en el diseño.

Una técnica adecuada para contrastar diferencias entre las medias (centroides) de dos o más variables dependientes simultáneamente, es el análisis de varianza multivariante (en inglés *multivariate analysis of variance*, MANOVA), que es una generalización del análisis de la varianza (en inglés *analysis of variance*, ANOVA) para más de una variable de respuesta. MANOVA dispone de pruebas globales de significación y aprovecha la posible correlación entre diferentes variables y_j y y_k en $\mathcal{Y}$. Los métodos de análisis multivariante coinciden en explotar esta información. MANOVA cuestiona si la variabilidad que se observa en los datos es solamente al azar o si existen efectivamente diferencias significativas entre las clases, imputables al factor. Para esto, son comparadas las varianzas empíricas de cada muestra con la varianza de la muestra global. La media de las varianzas resume la variabilidad en el interior de las clases, de ahí el nombre de varianza *intra-clases* o varianza residual. La varianza de las medias describe las diferencias entre las clases que pueden deberse al factor, llamada varianza *inter-clases* o varianza explicada. Si los niveles del factor tienen evidentemente un efecto en la respuesta, se espera que la varianza explicada sea grande en comparación con la varianza residual.

Considere n observaciones independientes de p variables observables $Y_1, \dots, Y_p$, obtenidas bajo condiciones experimentales, como en el caso de una sola variable, se tiene la matriz de datos

$$\mathbf{Y} = \begin{pmatrix} y_{11} & y_{12} & \cdots & y_{1p} \\ y_{21} & y_{22} & \cdots & y_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n1} & y_{n2} & \cdots & y_{np} \end{pmatrix} = [\tilde{\mathbf{Y}}_1, \tilde{\mathbf{Y}}_2, \dots, \tilde{\mathbf{Y}}_p] \quad (2.25)$$

El modelo lineal multivariante es

$$\mathbf{Y} = \mathbf{XB} + \mathbf{E} \quad (2.26)$$

siendo $\mathbf{X}$ la matriz de diseño

$$\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{pmatrix} \quad (2.27)$$

B, matriz de parámetros de regresión

$$\mathbf{B} = \begin{pmatrix} \beta_{11} & \beta_{12} & \cdots & \beta_{1p} \\ \beta_{21} & \beta_{22} & \cdots & \beta_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \beta_{m1} & \beta_{m2} & \cdots & \beta_{mp} \end{pmatrix} \quad (2.28)$$

y **E** la matriz de desviaciones aleatorias

$$\mathbf{E} = \begin{pmatrix} e_{11} & e_{12} & \cdots & e_{1p} \\ e_{21} & e_{22} & \cdots & e_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ e_{n1} & e_{n2} & \cdots & e_{np} \end{pmatrix} \quad (2.29)$$

Las matrices **Y** y **X** son conocidas. Se supone que las filas de **E** son independientes con distribución normal de media cero y covarianza Σ , $N_p(0, \Sigma)$.

- Estimación de parámetros

En el modelo MANOVA se estiman los $m \times p$ parámetros de regresión contenidos en **B**, así como la matriz de covarianzas Σ [7].

Teorema 2.1. *Considere el modelo de regresión multivariante $\mathbf{Y} = \mathbf{XB} + \mathbf{E}$, siendo*

$$\mathbf{Y} = \begin{bmatrix} \mathbf{y}'_1 \\ \vdots \\ \mathbf{y}'_n \end{bmatrix}, \quad \mathbf{E} = \begin{bmatrix} \mathbf{e}'_1 \\ \vdots \\ \mathbf{e}'_n \end{bmatrix} \quad (2.30)$$

con las condiciones

1. $E(\mathbf{Y}) = \mathbf{XB}$, es decir, $E(\mathbf{E}) = \mathbf{0}$
2. $cov(\mathbf{y}_i) = cov(\mathbf{e}_i) = \Sigma$, donde $\mathbf{y}'_i$ son filas de **Y**, y $\mathbf{e}'_i$ son filas de **E**.
3. $cov(\mathbf{y}_i, \mathbf{y}_j) = cov(\mathbf{e}_i, \mathbf{e}_j) = \mathbf{0}$ para $i \neq j$.

Entonces las estimaciones de mínimos cuadrados (en inglés *least squares LS*) de los parámetros de regresión **B** verifican las ecuaciones normales

$$\mathbf{X}'\mathbf{X}\hat{\mathbf{B}} = \mathbf{X}'\mathbf{Y} \quad (2.31)$$

y vienen dados por

$$\hat{\mathbf{B}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} \quad (2.32)$$

Teorema 2.2 *Bajo las mismas condiciones del teorema 2.1, con $r = \text{rango}(\mathbf{X})$, puede expresarse la matriz de residuos como*

$$\mathbf{R}_0 = \mathbf{Y}'[\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}']\mathbf{Y}. \quad (2.33)$$

Una estimación centrada de la matriz de covarianzas Σ es

$$\hat{\Sigma} = \mathbf{R}_0/(n - r) \quad (2.34)$$

Teorema 2.3. *Sea $\mathbf{Y} = \mathbf{XB} + \mathbf{E}$ el modelo lineal normal multivariante donde las filas de $\mathbf{E}$ son $N_p(0, \Sigma)$ independientes. Sea $\mathbf{R}_0$ la matriz de residuos. Se verifica que la distribución de $\mathbf{R}_0$ es Wishart $W_p(\Sigma, n - r)$.*

- Contraste de hipótesis lineales

Una hipótesis lineal demostrable de rango t y matriz $\mathbf{H}$ es

$$H_0: \mathbf{HB} = \mathbf{0}$$

donde cada fila de $\mathbf{H}$ es combinación lineal de las filas de $\mathbf{X}$.

Teorema 2.4. *Sea $\mathbf{Y} = \mathbf{XB} + \mathbf{E}$ el modelo lineal multivariante, donde las filas de $\mathbf{E}$ son $N_p(0, \Sigma)$ independientes, $\mathbf{R}_0$ la matriz de residuos, $H_0: \mathbf{HB} = \mathbf{0}$ una hipótesis lineal demostrable y $\mathbf{R}_1$ la matriz de residuos bajo H_0 . Se verifica*

1. $\mathbf{R}_0 \sim W_p(\Sigma, n - r)$.
2. Si H_0 es cierta, las matrices $\mathbf{R}_1$ y $\mathbf{R}_1 - \mathbf{R}_0$ siguen la distribución de Wishart

$$\mathbf{R}_1 \sim W_p(\Sigma, n - r'), \quad \mathbf{R}_1 - \mathbf{R}_0 \sim W_p(\Sigma, t), \quad (2.35)$$

siendo $t = \text{rango}(H)$, $r' = r - t$.

3. Si H_0 es cierta, las matrices $\mathbf{R}_0$ y $\mathbf{R}_1 - \mathbf{R}_0$ son estocásticamente independientes.

La consecuencia más importante del teorema 2.4 es que, si H_0 es cierta, entonces $\mathbf{R}_0$ y $(\mathbf{R}_1 - \mathbf{R}_0)$ son Wishart independientes [7] y

$$\Lambda = \frac{|\mathbf{R}_0|}{|(\mathbf{R}_1 - \mathbf{R}_0) + \mathbf{R}_0|} = \frac{|\mathbf{R}_0|}{|\mathbf{R}_1|} \sim \Lambda(p, n - r, t). \quad (2.36)$$

Así $0 \leq \Lambda \leq 1$ sigue la distribución de Wilks. No se rechaza H_0 si Λ no es significativo y rechazar H_0 si Λ es pequeño y significativo. La tabla 3 muestra el análisis de varianza multivariante MANOVA general.

Tabla 3. Análisis de varianza multivariante general, MANOVA.

<i>Fuente de variación</i>	<i>Grados de libertad</i>	<i>Matriz Wishart</i>	<i>Lambda de Wilks</i>
Desviación hipótesis	t	$\mathbf{R}_1 - \mathbf{R}_0$	$\Lambda = \mathbf{R}_0 / \mathbf{R}_1 $
Residuo	$n-r$	$\mathbf{R}_0$	
Criterio decisión: Si $\Lambda < \Lambda_\alpha$ se rechaza H_0 , donde $P(\Lambda(p, n-r, t) < \Lambda_\alpha) = \alpha$.			

▪ Modelo MANOVA con un tratamiento

El modelo del diseño de un único tratamiento o causa de variabilidad es

$$\mathbf{y}_{ih} = \boldsymbol{\mu} + \boldsymbol{\alpha}_i + \mathbf{e}_{ih} \quad i = 1, \dots, k; h = 1, \dots, n_i \quad (2.37)$$

donde $\boldsymbol{\mu}$ es el vector de medias general, $\boldsymbol{\alpha}_i$ es el efecto del nivel i del factor, $\mathbf{y}_{ih}$ es la observación multivariante h en la situación o población i , correspondiendo a la misma situación experimental del análisis canónico de poblaciones, con $n = n_1 + \dots + n_k$. La hipótesis nula consiste en afirmar que las $\boldsymbol{\alpha}_i$ son iguales a cero. Se tiene que

$$\mathbf{W} = \mathbf{R}_0, \quad \mathbf{B} = \mathbf{R}_1 - \mathbf{R}_0, \quad \mathbf{T} = \mathbf{R}_1 = \mathbf{B} + \mathbf{W} \quad (2.38)$$

son las matrices de dispersión dentro de grupos entre grupos y total, respectivamente. La tabla 4, muestra el MANOVA de un tratamiento.

Tabla 4. Análisis de varianza multivariante, MANOVA para un tratamiento.

<i>Fuente de variación</i>	<i>Grados de libertad</i>	<i>Matriz Wishart</i>	<i>Lambda de Wilks</i>
Entre grupos	$k-1$	$\mathbf{B}$	$\Lambda = \mathbf{W} / \mathbf{T} $
Dentro de grupos	$n-k$	$\mathbf{W}$	$\sim \Lambda(p, n-k, k-1)$
Total	$n-1$	$\mathbf{T}$	

El objetivo del MANOVA es comparar grupos mediante combinaciones lineales de las múltiples variables dependientes $\mathbf{Y}$, para estudiar la influencia que provocan las variables independientes $\mathbf{X}$. MANOVA comprueba si las diferencias son estadísticamente significativas entre las medias de las variables dependientes en los niveles (tratamientos) de las variables independientes. En contraparte, DA trata de encontrar una manera de predecir una clasificación de la variable $\mathbf{X}$ (nominal u ordinal) basándose en las respuestas continuas conocidas $\mathbf{Y}$. Se puede considerar el DA como la predicción inversa a partir de un MANOVA [27].

2.9.4. Prueba de hipótesis multivariante

La prueba de hipótesis consiste en afirmar que las α_i son iguales a cero, esto es, el tratamiento no influye en las variables respuesta; α_i es el efecto del nivel i del factor o tratamiento. La hipótesis nula $H_0 = \alpha_1 = \alpha_2 = \dots = \alpha_g = 0$, involucra varianzas generalizadas.

Se rechaza H_0 si la razón de las varianzas generalizadas es muy pequeña en (2.39)

$$\Lambda = \frac{|\mathbf{W}|}{|\mathbf{B} + \mathbf{W}|} = \frac{\left| \sum_{\ell=1}^g \sum_{j=1}^{n_{\ell}} (\mathbf{x}_{\ell j} - \bar{\mathbf{x}}_{\ell})(\mathbf{x}_{\ell j} - \bar{\mathbf{x}}_{\ell})' \right|}{\left| \sum_{\ell=1}^g \sum_{j=1}^{n_{\ell}} (\mathbf{x}_{\ell j} - \bar{\mathbf{x}})(\mathbf{x}_{\ell j} - \bar{\mathbf{x}})' \right|} \quad (2.39)$$

donde Λ es el estadístico lambda de Wilks, $\bar{\mathbf{x}}_{\ell}$ es el vector de medias para $\ell=1,2,\dots, g$ poblaciones, $\mathbf{W}$ es la matriz de dispersión dentro grupos, $\mathbf{B}$ entre grupos y $\mathbf{T} = \mathbf{W} + \mathbf{B}$ es la matriz de dispersión total. En el contexto de muestras aleatorias provenientes de varias poblaciones, las pruebas multivariantes se basan en las matrices $\mathbf{W}$ y $\mathbf{B}$

$$\mathbf{W} = \sum_{\ell=1}^g \sum_{j=1}^{n_{\ell}} (\mathbf{x}_{\ell j} - \bar{\mathbf{x}}_{\ell})(\mathbf{x}_{\ell j} - \bar{\mathbf{x}}_{\ell})' \quad (2.40)$$

$$\mathbf{B} = \sum_{\ell=1}^g n_{\ell} (\bar{\mathbf{x}}_{\ell} - \bar{\mathbf{x}})(\bar{\mathbf{x}}_{\ell} - \bar{\mathbf{x}})' \quad (2.41)$$

Otras tres pruebas estadísticas multivariantes son comúnmente incluidas en los paquetes estadísticos [28]

- Traza de Hotelling-Lawley = $tr[\mathbf{B}\mathbf{W}^{-1}]$
- Traza de Pillai = $tr[\mathbf{B}(\mathbf{B} + \mathbf{W})^{-1}]$
- Raíz máxima de Roy = *máximo eigenvalor de $\mathbf{W}(\mathbf{B} + \mathbf{W})^{-1}$*

El estadístico de prueba traza de Pillai es ligeramente más robusto frente a la no normalidad.

2.10. Clasificación

La clasificación es el principal campo del reconocimiento de patrones [45]. Clasificar elementos de un conjunto finito consiste en la partición del conjunto en subconjuntos homogéneos, dado un criterio de clasificación [7]. Una clasificación de n objetos en relación a una matriz de datos cuantitativos $\mathbf{X}$, consiste en obtener g grupos homogéneos y excluyentes. Sean g grupos, la descomposición de la variabilidad total

$$\mathbf{T} = \mathbf{B} + \mathbf{W} \quad (2.42)$$

Una partición en g grupos que hace máxima $\mathbf{B}$ o mínima $\mathbf{W}$, en relación a algún criterio, dará una solución al problema, puesto que tendrán una máxima dispersión entre grupos. Algunos criterios, justificados por el análisis de varianza multivariante son

- a) Minimizar $|\mathbf{W}|$
- b) Minimizar $\Lambda = |\mathbf{W}|/|\mathbf{T}|$.

Se puede describir el problema de clasificación como

Considere un número finito c de categorías o clases $w_1, \dots, w_c$. Cada patrón es descrito por un vector de atributos $\mathbf{x} \in \mathbb{R}^d$, comprendiendo que es un vector aleatorio $\mathbf{X}$. Se supone que cada patrón pertenece a una y sólo una de estas categorías. Un clasificador de patrones es un mecanismo o una regla de decisión que mapea el espacio de características hacia el conjunto de catálogo de clases $w_1, \dots, w_c$, $D: \mathbb{R}^d \rightarrow \{1, \dots, c\}$. La regla de decisión divide el espacio de características en un número de regiones $D^{-1}(j)$, $j = 1, \dots, c$, nombradas regiones de

decisión, que están separadas una de la otra por superficies de decisión o frontera de decisión [45].

El reconocimiento de patrones que se considera en esta tesis se basa en vectores de características con números reales y discretos, y existe una medida de distancia natural entre dichos vectores. Para asignar un elemento a una clase predeterminada, se emplean funciones discriminantes. Una función discriminante es una combinación lineal de los componentes de $\mathbf{x}$, puede ser escrita como

$$g(\mathbf{x}) = \mathbf{w}^t \mathbf{x} + w_0 \quad (2.43)$$

donde $\mathbf{w}$ es el vector ponderado y w_0 el sesgo o umbral ponderado.

En la ecuación (2.43) $g(\mathbf{x})$ define la superficie de decisión que separa los puntos asignados a w_1 de los puntos asignados a w_2 , para el caso de dos clases. Cuando $g(\mathbf{x})$ es una función lineal, la superficie de decisión es un hiperplano H .

La mayoría de los clasificadores estadísticos pueden ser representados por un conjunto de funciones discriminantes $g_j(\mathbf{x})$, $j = 1, \dots, c$. Cuando se tienen más de dos clases, las funciones discriminantes son elegidas tal que un vector $\mathbf{x}$ es asignado a la clase w_j si

$$g_i(\mathbf{x}) > g_j(\mathbf{x}) \quad \forall i \neq j \quad (2.44)$$

esto es, la regla de decisión

$$D(\mathbf{x}) = \operatorname{argmax}_j g_j(\mathbf{x}) \quad j=1, \dots, c \quad (2.45)$$

Las fronteras de decisión están dadas por el conjunto de ecuaciones

$$g_i(\mathbf{x}) - g_j(\mathbf{x}) = 0 \quad \forall i \neq j \quad (2.46)$$

La mezcla de la función de densidad del vector aleatorio $\mathbf{X}$, según los supuestos previos, es

$$f(\mathbf{x}) = \sum_{j=1}^c P(w_j) f(\mathbf{x}|w_j) \quad (2.47)$$

Si las densidades condicionales de la clase son conocidas, entonces el clasificador Bayes está definido por

$$D_{\text{Bayes}}(x) = \operatorname{argmax}_{j=1,\dots,c} P(w_j)f(x|w_j) \quad (2.48)$$

donde, $f(x|w_j)$ es la denominada probabilidad condicionada a la clase, es decir, la probabilidad de que un patrón de la clase w_j tenga las características x , a esto se llama verosimilitud, es decir, lo creíble que un objeto de la clase w_j tenga las características x . Si $f(x|w_j)$ es cercano a 1, entonces x es común en la clase w_j .

La regla de Bayes en

$$P(w_j|x) = \frac{f(x|w_j) P(w_j)}{f(x)} \quad (2.49)$$

se aplica a 2.48, quedando una regla de decisión equivalente

$$D_{\text{Bayes_eq}}(x) = \operatorname{argmax}_{j=1,\dots,c} P(w_j|x) \quad (2.50)$$

Las reglas de decisión (2.48) y (2.50) son la base de muchos clasificadores estadísticos y neuronales [26]. Si las densidades condicionales verdaderas de la clase en (2.48) o las probabilidades posteriores en (2.50) son conocidas, dichas reglas minimizan la probabilidad de error de clasificación, por lo cual son llamados clasificadores óptimos. En la práctica las densidades verdaderas se remplazan por sus estimados, a partir del conjunto de datos de entrenamiento de manera paramétrica. La clasificación paramétrica asume que la forma de las densidades condicional de la clase es conocida, generalmente Gaussiana multivariante, pero algunos de los parámetros como la media y matrices de covarianzas de las clases se desconocen y las muestras de entrenamiento se usan para estimar los valores [17]. Si existen dos clases, Gaussiana multivariante, con matrices de covarianza iguales, la regla de Bayes resulta en un clasificador lineal conocido como LDA.

2.10.1. Clasificación de movimientos de los dedos de la mano

La clasificación de señales mioeléctricas ha permitido establecer la relación existente entre las diversas contracciones musculares y movimientos de los dedos de la mano, por

ejemplo, mover un lápiz, enroscar una tapa, sostener con la palma un objeto, desplazar un objeto [15, 29]. Como lo expresan Al-Timemy y colaboradores [2] el control de movimiento de varios dedos es más exigente que controlar el movimiento de la mano por dos razones. Primera, las señales sEMG detectadas para movimientos de los dedos son generalmente de menor amplitud en comparación con las de movimiento de la mano. Segunda, los músculos que controlan los movimientos de los dedos son compartimientos de músculos planos que corresponden a dedos específicos; estos músculos se encuentran en las capas intermedias y profundas del antebrazo [16]. Las señales captadas en la superficie de la piel, tendrán que recibir tratamiento de filtrado a causa del efecto crosstalk, esto es, la interferencia ocasionada por la actividad eléctrica de los músculos contiguos del antebrazo [11]. Por lo tanto, varios electrodos se utilizan generalmente para proporcionar información suficiente que descarte la ambigüedad del movimiento ejecutado.

Considerando la sujeción, una acción de tomar y sostener un objeto con los dedos de la mano, que puede representarse como un conjunto de n series de tiempo $f_i(t)$, $i = 1, \dots, n$, cada serie de tiempo constituye la amplitud de una señal EMG reunida simultáneamente por medio de canales, colocados en una de las n ubicaciones en el antebrazo. Una sujeción en particular, suponiendo recopilada con $n = 2$ canales, durante un intervalo de tiempo $T = 2$ segundos y cada canal a una frecuencia de muestreo de 1 kHz, tendría un conjunto de valores de la señal de 4,000 muestras. Seguidamente, a cada serie de tiempo colectada se parametriza en términos de un número reducido de características. La característica o patrón resulta de una o más medidas logradas al efectuar cálculos matemáticos a la señal sEMG.

2.11. Clasificación supervisada: Análisis discriminante

Cuando se asume que un conjunto de datos para entrenamiento están disponibles y el clasificador fue diseñado para aprovechar la información antes conocida, es el caso del reconocimiento de patrones estadístico supervisado [45]. En la clasificación supervisada la forma de entrada es identificada como un miembro de una clase predefinida. Es el método más extendido en comparación con el diseño de los clasificadores no supervisados, éstos comprenden operaciones de cálculo más complejos y la fiabilidad de la clasificación depende de la calidad de la muestra de datos disponible en los algoritmos de aprendizaje. DA es la

parte del análisis estadístico multivariante que tiene la finalidad de encontrar reglas de asignación de individuos a una de las clases de una clasificación preestablecida; utiliza una matriz de medidas de separabilidad o distancias entre individuos. Una propiedad de la función lineal discriminante es que el valor en el centro de gravedad, ilustrado en la figura 9, de la nube de individuos (individuo promedio) será cero.

2.11.1. Análisis discriminante lineal y clasificación

LDA es una herramienta estándar para clasificación y reducción de dimensión. LDA es un caso especial del clasificador Bayesiano, visto en la sección 2.10, donde se supone que las distribuciones condicionales de grupo son normal multivariante, tienen una matriz de covarianza común y vectores de medias diferentes para las distintas clases [31]. Los supuestos en que se basa el LDA son

- La distribución normal multivariante en la clase tiene la función de densidad condicional $p_i(\mathbf{x})$,
- Se tienen matrices de covarianzas Σ_i iguales para todas las clases, es decir, dentro de cada clase deben de ser aproximadamente iguales.

La figura 9 ilustra la representación geométrica del análisis discriminante para cuando existen dos clases. La interpretación de las medias multivariante se tiene para la versión muestral.




Figura 9. Interpretación geométrica del análisis discriminante, versión muestral para dos clases.

La piedra angular del LDA es la descomposición de la varianza, entendiendo que la variabilidad total de la muestra se puede descomponer en variabilidad dentro de los grupos y entre los grupos. Para ello, se desarrolla el aspecto matemático.

Suponer un conjunto de n d -dimensional muestras $\mathbf{x}_1, \dots, \mathbf{x}_n$, n_1 en el subconjunto $\mathcal{D}_1$ marcado w_1 y n_2 en el subconjunto $\mathcal{D}_2$ etiquetado w_2 . Formando una combinación lineal de las componentes de $\mathbf{x}$, se obtiene el producto punto escalar

$$y = \mathbf{w}^t \mathbf{x} \quad (2.51)$$

y un conjunto correspondiente de n muestras $y_1, \dots, y_n$ dividido en los subconjuntos de $\mathcal{Y}_1$ y $\mathcal{Y}_2$. Geométricamente, si $\|\mathbf{w}\| = 1$, cada y_i es la proyección de la $\mathbf{x}_i$ correspondiente sobre una línea en la dirección de $\mathbf{w}$. Una medida de la separación entre los puntos proyectados es la diferencia de las medias de la muestra. Si $\mathbf{m}_i$ es la media muestral d -dimensional dada por

$$\mathbf{m}_i = \frac{1}{n_i} \sum_{\mathbf{x} \in \mathcal{D}_i} \mathbf{x} \quad (2.52)$$

la media muestral para los puntos proyectados

$$\tilde{\mathbf{m}}_i = \frac{1}{n_i} \sum_{y \in \mathcal{Y}_i} y \quad (2.53)$$

Empleando la expresión de y , ecuación 2.51, remplazar en 2.53

$$\tilde{\mathbf{m}}_i = \frac{1}{n_i} \sum_{y \in \mathcal{Y}_i} y = \frac{1}{n_i} \sum_{y \in \mathcal{Y}_i} \mathbf{w}^t \mathbf{x} \quad (2.54)$$

La sumatoria de $\mathbf{x}$ de la ecuación 2.52 en 2.54, queda

$$\tilde{\mathbf{m}}_i = \frac{1}{n_i} \sum_{y \in \mathcal{Y}_i} \mathbf{w}^t \mathbf{x} = \mathbf{w}^t \mathbf{m}_i \quad (2.55)$$

la media muestral para los puntos proyectados $\tilde{\mathbf{m}}_i$ es simplemente la proyección de $\mathbf{m}_i$.

De ello se obtiene que la distancia entre las medias proyectadas es

$$|\tilde{\mathbf{m}}_1 - \tilde{\mathbf{m}}_2| = |\mathbf{w}^t (\mathbf{m}_1 - \mathbf{m}_2)| \quad (2.56)$$

La diferencia puede modificarse simplemente escalando $\mathbf{w}$. Para obtener una buena separación de los datos proyectados se quiere que la diferencia entre las medias sea

relativamente grande para algunas mediciones de las desviaciones estándar para cada clase. En lugar de formar varianzas de las muestras, se define la *dispersión* para las muestras proyectadas, etiquetadas w_i , mediante

$$\tilde{s}_i^2 = \sum_{y \in \mathcal{Y}_i} (y - \tilde{m}_i)^2 \quad (2.57)$$

La estimación de la varianza de los datos agrupados

$$\frac{1}{n} (\tilde{s}_1^2 + \tilde{s}_2^2) \quad (2.58)$$

donde $(\tilde{s}_1^2 + \tilde{s}_2^2)$ es llamada dispersión total dentro de la clase de las muestras proyectadas.

El discriminante lineal de Fisher emplea la función lineal $\mathbf{w}^t \mathbf{x}$, para el criterio de dicha función [17]

$$\mathcal{J}(\mathbf{w}) = \frac{|\tilde{m}_1 - \tilde{m}_2|^2}{\tilde{s}_1^2 + \tilde{s}_2^2} \quad (2.59)$$

que es máximo e independiente de $\|\mathbf{w}\|$. Mientras que $\mathbf{w}$ maximice a $\mathcal{J}(\cdot)$, se conduce a la mejor separación entre los dos conjuntos proyectados, también se necesita un criterio de umbral antes de que tener un verdadero clasificador. Para tener a $\mathcal{J}(\cdot)$ como una función explícita de $\mathbf{w}$ y con ella encontrar el $\mathbf{w}$ óptimo, se definen las matrices de dispersión $\mathbf{S}_i$ y $\mathbf{S}_W$

$$\mathbf{S}_i = \sum_{\mathbf{x} \in \mathcal{D}_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^t \quad (2.60)$$

y

$$\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2 \quad (2.61)$$

entonces,

$$\begin{aligned} \tilde{s}_i^2 &= \sum_{\mathbf{x} \in \mathcal{D}_i} (\mathbf{w}^t \mathbf{x} - \mathbf{w}^t \mathbf{m}_i)^2 \\ &= \sum_{\mathbf{x} \in \mathcal{D}_i} \mathbf{w}^t (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^t \mathbf{w} \\ &= \mathbf{w}^t \mathbf{S}_i \mathbf{w} \end{aligned} \quad (2.62)$$

por lo tanto, la suma de estas dispersiones se puede escribir

$$\tilde{S}_1^2 + \tilde{S}_2^2 = \mathbf{w}^t \mathbf{S}_W \mathbf{w} \quad (2.63)$$

Del mismo modo, las separaciones de las medias proyectadas cumplen

$$\begin{aligned} (\tilde{\mathbf{m}}_1 - \tilde{\mathbf{m}}_2)^2 &= (\mathbf{w}^t \mathbf{m}_1 - \mathbf{w}^t \mathbf{m}_2)^2 \\ &= \mathbf{w}^t (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^t \mathbf{w} \\ &= \mathbf{w}^t \mathbf{S}_B \mathbf{w} \end{aligned} \quad (2.64)$$

donde

$$\mathbf{S}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^t \quad (2.65)$$

$\mathbf{S}_W$ es la matriz de dispersión intra-clases, siendo proporcional a la matriz de covarianza muestral para los datos d -dimensionales agrupados. $\mathbf{S}_B$ se llama la matriz de dispersión entre clases. En términos de $\mathbf{S}_B$ y $\mathbf{S}_W$, el criterio de la función $\mathcal{J}(\cdot)$ puede ser escrito

$$\mathcal{J}(\mathbf{w}) = \frac{\mathbf{w}^t \mathbf{S}_B \mathbf{w}}{\mathbf{w}^t \mathbf{S}_W \mathbf{w}} \quad (2.66)$$

Un vector $\mathbf{w}$ que maximiza $\mathcal{J}(\cdot)$ debe satisfacer

$$\mathbf{S}_B \mathbf{w} = \lambda \mathbf{S}_W \mathbf{w} \quad (2.67)$$

Si $\mathbf{S}_W$ es no singular se tiene un problema de eigenvalor convencional

$$\mathbf{S}_W^{-1} \mathbf{S}_B \mathbf{w} = \lambda \mathbf{w} \quad (2.68)$$

Dado que $\mathbf{S}_B \mathbf{w}$ está en la dirección de $\mathbf{m}_1 - \mathbf{m}_2$ y el factor de escala de $\mathbf{w}$ es irrelevante, la solución para $\mathbf{w}$ que optimiza $\mathcal{J}(\cdot)$ es

$$\mathbf{w} = \mathbf{S}_W^{-1} (\mathbf{m}_1 - \mathbf{m}_2) \quad (2.69)$$

Se ha obtenido $\mathbf{w}$ para el discriminante lineal de Fisher, la función lineal permite el máximo coeficiente de la dispersión entre clases en relación a la dispersión dentro de clases. La solución dada a $\mathbf{w}$ en la ecuación (2.69) es a veces llamada la variante canónica. La complejidad computacional de encontrar el $\mathbf{w}$ óptimo está sujeto a la estimación de la dispersión total dentro de esa categoría y su inversa, un cálculo $O(d^2 n)$.

2.11.2. Análisis discriminante y la distancia Mahalanobis

Si $\mathbf{X} = (x_1, \dots, x_p)$ es una matriz de datos, con matriz de covarianzas $\mathbf{S}$, la definición de distancia de Mahalanobis (Md) entre las filas $\mathbf{x}_i' = (x_{i1}, \dots, x_{ip})$, $\mathbf{x}_j' = (x_{j1}, \dots, x_{jp})$ es

$$Md(i, j) = \sqrt{(\mathbf{x}_i - \mathbf{x}_j)' \mathbf{S}^{-1} (\mathbf{x}_i - \mathbf{x}_j)} \quad (2.70)$$

La distancia de Mahalanobis al cuadrado de una observación $\mathbf{x}_i$ al vector de medias $\bar{\mathbf{x}}$ de $\mathbf{X}$

$$(\mathbf{x}_i - \bar{\mathbf{x}})' \mathbf{S}^{-1} (\mathbf{x}_i - \bar{\mathbf{x}}) \quad (2.71)$$

A continuación se presenta la clasificación en dos poblaciones con un discriminador lineal. Sean los vectores de medias $\boldsymbol{\mu}_1$, $\boldsymbol{\mu}_2$ de las variables en $\boldsymbol{\Omega}_1$, $\boldsymbol{\Omega}_2$, respectivamente y la matriz de covarianzas $\boldsymbol{\Sigma}$ es común, las distancias Mahalanobis de las observaciones $\mathbf{x} = (x_1, \dots, x_p)'$ de un individuo w a las poblaciones son

$$M^2(\mathbf{x}, \boldsymbol{\mu}_i) = (\mathbf{x} - \boldsymbol{\mu}_i)' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \quad i = 1, 2. \quad (2.72)$$

Un criterio de clasificación consiste en asignar w a la población más cercana

$$\begin{array}{ll} \text{Si } M^2(\mathbf{x}, \boldsymbol{\mu}_1) < M^2(\mathbf{x}, \boldsymbol{\mu}_2) & \text{asignar } w \text{ a } \boldsymbol{\Omega}_1 \\ \text{en caso contrario} & \text{asignar } w \text{ a } \boldsymbol{\Omega}_2 \end{array} \quad (2.73)$$

Cambiando el criterio como una función discriminante

$$\begin{aligned} M^2(\mathbf{x}, \boldsymbol{\mu}_2) - M^2(\mathbf{x}, \boldsymbol{\mu}_1) &= \mathbf{x}' \boldsymbol{\Sigma}^{-1} \mathbf{x} + \boldsymbol{\mu}_2' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_2 - 2\mathbf{x}' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_2 \\ &\quad - \mathbf{x}' \boldsymbol{\Sigma}^{-1} \mathbf{x} + \boldsymbol{\mu}_1' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_1 + 2\mathbf{x}' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_1 \\ &= (\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1)' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_2 + \boldsymbol{\mu}_1) + 2\mathbf{x}' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \end{aligned} \quad (2.74)$$

Se define la función discriminante

$$L(\mathbf{x}) = \left[\mathbf{x} - \frac{1}{2} (\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2) \right]' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \quad (2.75)$$

esta función lineal es el discriminador lineal de Fisher [7].

Ahora se expresa la diferencia de la distancia cuadrada Mahalanobis

$$M^2(\mathbf{x}, \boldsymbol{\mu}_2) - M^2(\mathbf{x}, \boldsymbol{\mu}_1) = 2L(\mathbf{x}) - L((\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2)/2) \quad (2.76)$$

La regla 2.73 queda

$$\begin{array}{ll} \text{Si } L(\mathbf{x}) > 0 & \text{asignar } w \text{ a } \boldsymbol{\Omega}_1 \\ \text{en caso contrario} & \text{asignar } w \text{ a } \boldsymbol{\Omega}_2 \end{array} \quad (2.77)$$

En la realidad, $\boldsymbol{\mu}_1, \boldsymbol{\mu}_2, \boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2$ son desconocidos y se deberán estimar a partir de muestras de las poblaciones sustituyendo $\boldsymbol{\mu}_1, \boldsymbol{\mu}_2$ por los vectores de medias $\bar{\mathbf{x}}_1, \bar{\mathbf{x}}_2$ y $\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2$ por las matrices de covarianzas $\mathbf{S}_1, \mathbf{S}_2$. La estimación de $\boldsymbol{\Sigma}$ será

$$\mathbf{S} = \frac{(n_1 \mathbf{S}_1)(n_2 \mathbf{S}_2)}{(n_1 + n_2)} \quad (2.78)$$

Sustituyendo en 2.76, se tiene el discriminador lineal muestral

$$\hat{L}(\mathbf{x}) = [\mathbf{x} - \frac{1}{2}(\bar{\mathbf{x}}_1 + \bar{\mathbf{x}}_2)]' \mathbf{S}^{-1}(\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_2) \quad (2.79)$$

2.11.3. Análisis discriminante cuando las poblaciones son desconocidas

En la práctica el investigador en lugar de trabajar con poblaciones dispone de muestras. Sea $\mathbf{x}_{ijg}$ elementos de una matriz de n individuos y p variables, donde i representa al individuo, j la variable y g el grupo. Designar n_g al número de elementos en el grupo g y el número total de observaciones es

$$n = \sum_{g=1}^G n_g \quad (2.80)$$

$\mathbf{x}'_{ig}$ es el vector renglón ($1 \times p$) que contiene los p valores de las variables para el individuo i en el grupo g , $\mathbf{x}'_{ig} = (x_{i1g}, \dots, x_{ipg})$. El vector de medias dentro de cada clase será

$$\bar{\mathbf{x}}_g = \frac{1}{n_g} \sum_{i=1}^{n_g} \mathbf{x}_{ig} \quad (2.81)$$

que es un vector columna de dimensión p que contiene p medias para las observaciones de la clase g . La matriz de varianzas y covarianzas para los elementos de la clase g es

$$\hat{\mathbf{S}}_g = \frac{1}{n_g - 1} \sum_{i=1}^{n_g} (\mathbf{x}_{ig} - \bar{\mathbf{x}}_g)(\mathbf{x}_{ig} - \bar{\mathbf{x}}_g)' \quad (2.82)$$

Suponer que los G grupos tienen la misma matriz de varianzas y covarianzas, su mejor estimación centrada con todos los datos es una combinación lineal de las estimaciones centradas de cada población con peso proporcional a su precisión. De ahí se calcula

$$\hat{\mathbf{S}}_w = \sum_{g=1}^G \frac{n_g - 1}{n - G} \hat{\mathbf{S}}_g \quad (2.83)$$

$\mathbf{W}$ es la matriz de suma de cuadrados *dentro* de las clases, está dada por

$$\mathbf{W} = (n - G) \hat{\mathbf{S}}_w \quad (2.84)$$

Las funciones discriminantes utilizan $\bar{\mathbf{x}}_g$ para estimar μ_g y $\hat{\mathbf{S}}_w$ como estimación de Σ .

Considere las probabilidades a priori y los costos de clasificación errónea sean iguales para las clases dadas, clasificar un elemento en el grupo que conduzca a un valor mínimo de la Md, esto es, entre el punto $\mathbf{x}_0$ y la media del grupo

$$\min_g (\mathbf{x}_0 - \bar{\mathbf{x}}_g)' \hat{\mathbf{S}}_w^{-1} (\mathbf{x}_0 - \bar{\mathbf{x}}_g) \quad (2.85)$$

expresándose como

$$\min_g \hat{\mathbf{W}}_g' (\mathbf{x}_0 - \bar{\mathbf{x}}_g) \quad (2.86)$$

donde

$$\hat{\mathbf{W}}_g = \hat{\mathbf{S}}_w^{-1} \bar{\mathbf{x}}_g \quad (2.87)$$

Se observa que esta regla de clasificación estimada se ha obtenido sin imponer ninguna hipótesis sobre la distribución de la variable $\mathbf{x}$ en las poblaciones. Los métodos de DA basados en distancias pueden abordar todo tipo de datos y han sido estudiados por Cuadras [7]. DA permite mejorar la ordenación y formación de clústeres [3, 8].

La clasificación basada en la clasificación discriminante, asume un modelo directamente para el discriminante, sin pasar por la estimación de las probabilidades o posteriores. El enfoque basado en la clasificación discriminante, hace una suposición sobre la forma del discriminante entre las clases y no hace suposiciones sobre las probabilidades. No requiere ningún conocimiento de la función de densidad, por ejemplo, si es Gaussiana, o si las variables están correlacionadas entre sí, etcétera. Esta es una orientación inductiva diferente, en vez de hacer una suposición de la forma de las densidades de clase, se plantea una suposición de la forma de los límites que separan las clases [1].

3. Metodología

En este capítulo se detalla el procedimiento del reconocimiento de patrones estadístico para identificar la intención de movimiento de los dedos de la mano, mediante la colección de las señales ME superficiales de los músculos de la sección del antebrazo. La principal labor para el cumplimiento de los objetivos definidos en el capítulo 1, es obtener la clasificación correcta para cada uno de los tres gestos de la mano. Estos gestos son originados por la contracción muscular a causa de la diferencia de los diámetros de las esferas sujetadas, en un entorno de escenarios estructurados controlados. El número de clases está determinado por el conjunto de diámetros dispuestos en el estudio; por ello, el problema de clasificación es del tipo supervisado y multiclase.

La metodología engloba tres grandes etapas del reconocimiento de patrones estadístico, ilustradas en la figura 10. Las etapas son descritas a continuación.

3.1. Etapa de muestreo y selección de patrones

En esta etapa se registrarán muestras de señales ME para cada clase de movimiento conforme al diseño de experimentos que se establece. Se definirá qué características se procesarán y la etapa finaliza al generar los vectores patrón asociados a cada movimiento de los dedos de la mano.

3.1.1. Organización del experimento

Como parte de la organización del experimento se deben determinar la clase y cantidad de movimientos de los dedos de la mano, las características y cantidad de participantes, los músculos del antebrazo a considerar, lo que a la vez influirá en la cantidad de canales y dimensión del vector de características; la cantidad y tipo de objetos y, se elegirá el diseño del experimento de este estudio. Se definirán cuáles serán las características en el dominio del tiempo (TD). Los sujetos influyen en la amplitud de la señal ME, por lo que, se considera un factor no controlable.




Figura 10. Metodología del reconocimiento de patrones estadístico para señales ME en escenarios estructurados.

3.1.2. Preparación del experimento

Incluirá definir las instrucciones que deben seguir los participantes para realizar los movimientos de los dedos, el área dónde el sujeto realizará la sujeción de la esfera, la posición de la articulación del codo con respecto al área de apoyo, establecer la duración de los registros de la señal, determinación de los periodos de relajación, para evitar en lo posible, los efectos de la fatiga muscular y diseñar el formato para recabar datos tales como el nombre, la edad, altura y peso de los participantes. Por otra parte, el diseño experimental debe especificar la cantidad de repeticiones y la asignación aleatoria de ejecución de los movimientos a cada sujeto.

3.1.3. Captura de la señal ME

Con la finalidad de capturar la señal sEMG para evitar en lo posible el ruido, el electrodo debe ser colocado entre un punto motor y la inserción del tendón o entre dos puntos motores, y a lo largo de la línea media longitudinal del músculo [11]. El eje longitudinal del electrodo (que pasa a través de ambas superficies de detección) exige estar alineado en paralelo a la longitud de las fibras musculares. La figura 11, proporciona una representación esquemática de la localización sugerida del electrodo, entre el punto de motor (o zona de inervación) y la inserción tendinosa, con las superficies de detección dispuestas de modo que se cruzan tantas fibras musculares como sea posible.




Figura 11. Localización recomendada del electrodo superficial. Tomado de [11]

3.1.4. Generación de características

En esta etapa se segmentará la señal ME capturada para generar las características del TD elegidas en la sección 3.1.1 y que se utilizarán como entrada del clasificador.

- Segmentación de la señal. Antes de la caracterización de la señal, es necesario realizar una etapa de segmentación, en donde la señal de interés se aísla del resto. De esta manera, se tendrá la parte de la señal en la cual, se aplicará el procesamiento mediante un algoritmo implementado en el software Matlab. La señal se divide en segmentos de ventana que son intervalos de tiempo equitativos, obteniéndose un conjunto de datos disjuntos que formarán la base de datos.
- Generación de las características TD mediante el algoritmo. El código deberá incluir las operaciones matemáticas para calcular los valores cuantificables de interés de la señal ME.

3.1.5. Vector de características

- Base estadística de biodatos. La cantidad de sensores colocados al participante indicará la cantidad de canales a procesar. Dicha cantidad es un parámetro esencial en el desempeño del clasificador y en el número de movimientos diferentes a identificar, también afecta al vector de características. En esta etapa se construyen los vectores característicos del participante con los valores calculados en la sección 3.1.4.
- Análisis de valores atípicos. Se hará la identificación de las observaciones que se encuentren alejadas del centroide con el criterio de Md. Los valores extremos, se descartan de la base de datos del participante.

3.2. Etapa de clasificación con análisis discriminante

Clasificar constituye un componente importante de los sistemas inteligentes y puede considerarse como la actividad final de procesado. Cuando se ha terminado la captura, registro y pre-procesado de las señales convenientemente y el vector de características representativo está definido, el penúltimo paso de la metodología es la aplicación de un clasificador que pueda decidir a qué clase corresponde cada una de las señales ME. De este modo se esperaría la obtención de una nueva señal para el control de los dispositivos de salida.

En esta sección se presentan las tareas involucradas en la fase de clasificación de las señales ME a través de sus características TD. Los elementos detallados en los apartados siguientes serán el entrenamiento, la reducción de dimensionalidad y la Md, la validación y por último la asignación a una clase.

3.2.1. Reducción de dimensionalidad y la distancia Mahalanobis

La selección de características con LDA se implementará para reducir la dimensionalidad del vector patrón original. En esta etapa, las características son determinadas por el algoritmo LDA para cada participante.

3.2.2. Entrenamiento

Aplicada la etapa de reducción de dimensionalidad, se hará el entrenamiento del clasificador LDA con las muestras de entrenamiento. El clasificador LDA es de entrenamiento supervisado ya que la variable que identifica la clase guía el proceso de entrenamiento.

3.2.3. Validación

Realizado el proceso de entrenamiento es posible utilizar el clasificador para la categorización de los nuevos datos. La salida del clasificador será un vector de resultados, donde se almacenarán los índices de las clases en las que fueron clasificadas las nuevas muestras.

3.2.4. Asignación a una clase

La clasificación puede considerarse como la tarea final de procesamiento de señales, es el último paso para decidir a qué clase corresponde cada una de las señales. Se considera comúnmente que un sistema de reconocimiento de patrones consta de dos partes: extractor/selector de características y un clasificador [22]. La estructura interna del clasificador LDA se muestra en la figura 12, ocupa una función discriminante selectiva, en este caso será Md y un selector de mínimo valor, que decide situar las observaciones en una de las clases. Calculando la media multivariante a partir del vector patrón de entrenamiento,

se miden las Md y después son comparadas para cada muestra. Cuando se aplica una técnica de optimización para encontrar el menor número posible de características (reducción de dimensionalidad) con el mayor valor posible para un criterio (Md), el procedimiento matemático combina automáticamente el selector de características y el selector de función discriminante, optando por un subconjunto de características como la solución óptima. Simplificando, LDA tiene como entrada los vectores de entrenamiento y los vectores de validación; con las muestras de entrenamiento, la función de los dos bloques se combina para reducir el número de variables y las observaciones de validación comprueban si se logra una correcta clasificación. Es una acción simultánea, sin necesidad de dividir esta operación en dos etapas. La calidad de las características seleccionadas depende únicamente de las matrices de varianzas covarianzas estimadas, usadas para medir la separabilidad entre clases.




Figura 12. Estructura interna del clasificador

3.3. Etapa de evaluación

Esta etapa consiste en la aplicación del clasificador LDA entrenado a un conjunto de pruebas independientes de los vectores patrones etiquetados. Existen varias maneras de medir

el desempeño de un clasificador, la más común es la tasa de error. Al clasificador se realizarán las pruebas de validación para comprobar haber conseguido el mínimo error posible, recopilando los valores en tablas para su posterior análisis y discusión de resultados.

3.3.1. Evaluación del clasificador

La estimación del error del clasificador LDA, se obtiene contando el número de errores y dividiendo éstos por el número total de muestras. Para evaluar y comprobar la bondad del clasificador se tendrán en cuenta la precisión y flexibilidad con respecto al desempeño presentado.

- **Precisión.** Representa el nivel de confianza del clasificador, usualmente es la proporción de clasificaciones correctas que es capaz de generar. Es la capacidad de dar las respuestas correctas a pesar de algunos factores que pueden interferir durante el proceso de la detección y la adquisición de la señal. En el caso de las señales sEMG, el clasificador debe ser robusto generalmente ante la mala ubicación de los electrodos sobre la piel o por ruido. Una herramienta utilizada para evaluar la precisión es la matriz de confusión que indica los errores y aciertos ejecutados en el proceso de clasificación.
- **Flexibilidad.** Hace referencia a la adaptabilidad del clasificador a un entorno cambiante. Incluye el captar correctamente los vectores de características, incluso si esas características son considerablemente diferentes para cualquier característica que ha sido vista antes. En la situación de las características del TD, éstas difieren entre los participantes, así como en la localización de los sensores en el músculo del antebrazo. El clasificador debe ser capaz de adaptarse a las señales provenientes de los participantes, sin que esto afecte su buen desempeño.

3.3.2. Interpretación de los resultados.

Para la interpretación de las predicciones efectuadas por el clasificador se deberán analizar las matrices de confusión y si los resultados se explican por factores como el número de muestras, los músculos del antebrazo seleccionados, la dimensionalidad del vector patrón,

por la selección de un subconjunto apropiado de las características, etcétera. Otra eventualidad consiste en que el clasificador sea demasiado complejo, habiendo excesivos parámetros libres en relación al tamaño de muestra, con los cuales se modelará fielmente la señal ME y el ruido en conjunto. Esto provoca el problema denominado sobreajuste (en inglés *overfitting*). Si la función discriminante es estimada a partir de todo el conjunto de características original, entonces, el hiperplano puede separar satisfactoriamente los puntos de datos de entrenamiento, logrando así un error de ajuste muy bajo. El inconveniente del sobreajuste se presenta por que el ajuste es muy variable y el modelo fluctuará con los datos de validación debido al ruido, implantando un error de clasificación alto. Por otra parte, si el clasificador no es lo suficientemente complejo, se puede fracasar al capturar la estructura de los datos, el error de ajuste es grande y la variabilidad subyacente de la curva no se modela [47].

4. Resultados

En este capítulo se presenta la aplicación de la metodología propuesta del reconocimiento de patrones estadístico para identificar la intención de movimiento de los dedos de la mano, mediante la captura de las señales ME superficiales de los músculos de la sección del antebrazo y el análisis de los resultados obtenidos. El método LDA ha sido aplicado a la clasificación de señales ME, considerando la base de conocimiento formada a partir de un conjunto de muestras cuya pertenencia a una clase es conocida. Como muestras, se utilizaron señales a las que se extrajeron características del TD en cada clase. Se calcularon los valores a partir de un segmento de ventana para construir los vectores patrones para las tres clases involucradas.

4.1. Estructura del experimento y generación de patrones

En esta investigación se analiza el agarre de tres esferas de diámetro diferente que la mano pueda ejecutar, por lo tanto, tres tipos de movimientos de los dedos de la mano se definen. Considerando la literatura revisada se eligieron cinco músculos del antebrazo como los apropiados para los fines de la investigación y ocho características del TD. Las señales ME se registraron de seis participantes, tres mujeres y tres hombres.

4.1.1. Diseño del experimento

Las variables respuesta son ocho características del TD y el factor o variable independiente es el diámetro de la esfera. En este caso, el factor se llama de efectos fijos, consta de tres niveles del factor denominados por la letra y subíndice, D_1 , D_2 , D_3 respectivamente. Las muestras de señales sEMG se obtuvieron de seis sujetos sanos, tres mujeres (F1, F2, F3) y tres hombres (M1, M2, M3); rango de edad de 19 a 24 años.

4.1.2. Realización del experimento

El sujeto se sienta cómodamente, apoya el brazo en una mesa con la articulación del codo flexionada en ángulo de 90 grados. El individuo ase tres esferas, una a la vez, de material poliestireno expandido (EPS) con diámetro diferente; el peso es despreciable. La secuencia de los tiempos de sujeción de esferas y descanso se detalla en la figura 13, cada secuencia se

repitió 30 veces. En total se tienen 30 observaciones por 3 esferas, 90 muestras de acción de agarre para cada voluntario.

SECUENCIA	
1	Sujetar esfera D_i durante 3 segundos
2	Descansa 5 segundos
3	Sujetar esfera D_{i+1} durante 3 segundos
4	Descansa 5 segundos
5	Sujetar esfera D_{i+2} durante 3 segundos

Figura 13. Secuencia de sujeción de esferas y descansos.

- Aleatorización de las corridas del experimento. En la tabla 5 se presenta la asignación aleatoria de ejecución para la fijación requerida de las esferas. La tabla 6 muestra el formato para registrar los datos personales de los participantes del estudio.

Tabla 5. Orden de las corridas experimento de agarre de esfera.

Participante	Orden	Tamaño de muestra
F1	D_3, D_2, D_1	90
F2	D_1, D_2, D_3	90
F3	D_2, D_3, D_1	90
M1	D_2, D_3, D_1	90
M2	D_3, D_2, D_1	90
M3	D_2, D_3, D_1	90

Tabla 6. Datos personales de los participantes del estudio.

Participante	Nombre	Edad	Peso (Kg)	Altura (m)
F1				
F2				
F3				
M1				
M2				
M3				

- Descripción del movimiento de agarre con los dedos de la mano. Para agarrar la esfera, se pide al sujeto sentado
 - Colocar la palma de la mano con los dedos completamente relajados y hacia arriba.
 - Al entregarse la esfera, cerrar los dedos para sujetarla y mantener la posición durante 3 segundos.
 - Abrir la mano para que la esfera sea retirada.
 - Regresar a la posición de inicio con los dedos relajados.

- Enlace de los movimientos. Entre la primera y la segunda sujeción de esferas se dejan transcurrir 5 segundos de descanso, igualmente entre la segunda y tercera sujeción. Una breve contracción muscular voluntaria se lleva a cabo al sujetar la esfera con el fin de indicar el comienzo del movimiento de sujeción al registrar la señal. Después de ello, los sujetos mantienen sólo la pose de sostener la esfera. Otra contracción se produce justo antes de soltar la esfera, la mano se abre y cambia a una posición relajada de los dedos, en lugar de regresar de forma activa a la posición neutral. Los sujetos fueron instruidos para mantener sus dedos relajados hasta que ejecuten los movimientos y producir una cantidad de fuerza comfortable al principio y final de sujeción de cada esfera.

- Lote. Se define un lote como el tiempo requerido para el agarre de las tres esferas, incluyendo los intervalos de 5 segundos de descanso entre el agarre de la primera y segunda esfera y el agarre de la segunda y tercera esfera más el tiempo de 15 segundos de relajación. El tiempo de relajación es una estrategia que permite al sujeto estar preparado para la siguiente sucesión de movimientos y evitar la captura de datos incompletos, por la interrupción de la captura antes de que se complete la acción final. Asimismo, esto fue diseñado para superar los efectos de la fatiga muscular. Seis contracciones están contenidas en cada lote y su esquema se muestra en la figura 14.




Figura 14. Lote con tres eventos de agarre de esferas. Duración total 34 s.

- Diagrama de tiempos. La sucesión de movimientos y descansos de la figura 14, es representada en el diagrama de tiempo o cronograma de la figura 15. La gráfica muestra la forma de onda digital que indica cómo varía la señal en relación con el tiempo. Examinando el diagrama de tiempos, se puede determinar el estado, nivel alto o bajo, de la señal en cualquier instante y el momento en el que ésta cambia de estado. El reloj es una señal digital periódica que se utiliza como señal de temporización básica para sincronizar. El periodo del reloj es el periodo del bit, en este caso los cambios de la señal se producen en un flanco de la señal de reloj. La tabla 7 muestra la interpretación del diagrama de tiempo de la figura 15.




Figura 15. Diagrama de tiempo en segundos para un lote.

Tabla 7. Interpretación del diagrama de tiempo de la figura 15.

Reloj	Nivel de la señal	Valor binario	Descripción	Duración en segundos
t_0-t_3	Alto	1	Agarre de esfera D1	3
t_3-t_8	Bajo	0	Reposo	5
t_8-t_{11}	Alto	1	Agarre de esfera D2	3
$t_{11}-t_{16}$	Bajo	0	Reposo	5
$t_{16}-t_{19}$	Alto	1	Agarre de esfera D3	3

En la figura 16, se tiene el diagrama de tiempo junto con pulso de dirac que representan los transitorios entre la sujeción y liberación de cada esfera.




Figura 16. Diagrama de tiempo y pulso δ por contracción. $\delta(t)$ pulso muy corto.

- Sincronización del registro de la señal sEMG. Una indicación auditiva se utiliza para que el participante inicie la sujeción de la esfera y otra al transcurrir 3 segundos, para terminar el movimiento. Se elige un sonido diferente para señalar el momento de relajación de 15 segundos, de esta manera se sincronizan los datos.

4.1.3. Captura de la señal ME

En esta sección se presentan las funcionalidades del equipo con el que se captaron las señales ME, la localización de los sensores en el antebrazo, el procedimiento para el registro de la señal EMG superficial y una gráfica de la señal sEMG representativa de un lote.

- Sistema de captura Trigno™ Wireless EMG. El sistema consta de 16 canales y maneja sensores de tamaño 37 x 26 x 15 mm, 14 g. Entre las particularidades del equipo están la resolución de 16 bits y la frecuencia de muestreo que puede ser hasta 4,000 Hz. Las ventajas del sensor son bajo crosstalk, reducción del ruido por el movimiento, ya que el sistema amplifica la señal en la fuente e impide el movimiento del sensor por mala adherencia a la piel, eliminando las principales fuentes de ruidos. Al mantener constante la distancia entre electrodos, el sensor proporciona consistencia en el registro de los datos. Así que, se puede tener repetibilidad en los resultados del experimento. En la figura 17 se muestra el equipo Trigno™ Digital

Lab y los sensores. La figura 18, ilustra la diferencia entre un sensor bipolar típico y el sensor Trigno.




Figura 17. Sistema Trigno™ y sensor estándar Trigno™




Figura 18. Comparación del sensor bipolar tradicional con el sensor Trigno™

El sensor bipolar tradicional en la figura 18.a, tiene un alto riesgo de crosstalk por que la distancia entre electrodos es mayor que 10 mm. En figura 18.b, el sensor Trigno™ detecta la señal del músculo inmediato bajo la piel. En figura 18.c se muestra la distancia entre electrodos del sensor Trigno™, que al mantenerse constante en cada sensor empleado para la captura, descarta un factor de variabilidad en los datos, teniendo consistencia en el registro de los mismos. En seguida se presentan las especificaciones generales del sensor en la tabla 8.

Tabla 8. Especificaciones generales sensor Trigno™

Rango de operación típico	40 m
RF Frecuencia de banda	2400-2483 MHz (ISM band)
Consumo de potencia	< 65 mW
Potencia radiada efectiva	9mW
Protocolo RF	Patentado
Masa	14.7 g
Auto Shut-down timer	300 segundos

La tabla 9 muestra las especificaciones de EMG.

Tabla 9. Especificaciones EMG sensor Trigno™

Rango ¹	11 mV (r.t.i.)
Resolución (EMG Signal) ²	168 nV/bit (LSB)
Ancho de banda (EMG signal) ³	20 ± 5 Hz > 40 dB/dec 450 ± 50 Hz > 80 dB/dec
Rizado en el paso de banda	<2%
Ruido global del canal	<0.75uV
CMRR ⁵	>80dB
Tasa de muestreo	1926 muestras/seg
Número de contactos	4
Dimensiones del contacto	5 x 1 mm
Material del contacto	99.9 % plata

1. El rango se caracteriza por la entrada del sensor EMG y se muestrea con 16 bits.
2. Resolución ADC se especifica para la entrada del sensor.
3. El filtro está diseñado como un aplanamiento máximo Butterworth para preservar amplitud de la señal EMG y la linealidad de fase.
4. El ruido de entrada referida se calcula como la raíz cuadrada media sobre una ventana de 5 segundos muestreada a 2 kHz.
5. CMRR se mide para una señal de mínimo 1V modo de entrada común cuadrada a una frecuencia de 60 Hz.
6. EMG velocidad de muestreo de la señal es intrínseca al sensor y no se puede cambiar. Esto ha sido optimizado para el ancho de banda de comunicación y diseños de acondicionamiento de la señal.
7. DAC Filtro de ancho de banda: DC-500 Hz, 160 dB/Dec.

- Localización de los sensores en el antebrazo. La información de los datos se puede aumentar, para un valor de tiempo τ del segmento de ventana, mediante la adición de canales adicionales [36]. Esto permite una reducción en el error de estimación de parámetros e incrementa la dimensión del vector de características. Este enfoque dará

un aumento de SNR de hasta N canales [24]. Por lo anterior, cinco canales se utilizaron en el experimento. Los sensores TrignoTM se colocaron en los siguientes músculos del antebrazo, el flexor carpi radialis (flexor radial del carpo), flexor carpi ulnaris (flexor cubital del carpo), flexor pollicis longus (flexor largo del pulgar), flexor digitorum profundus (flexor común profundo de los dedos de la mano) y extensor digitorum (extensor común de los dedos).

- Procedimiento para el registro de la señal sEMG.
 - El primer paso en el registro de la señal EMG consiste en la colocación de los sensores al participante, como se observa en la figura 19. Para reducir algunos factores que provocan la interferencia en la señal, se intenta que la impedancia de la piel sea baja, lo que se logra frotándola con alcohol, previo rasurado del antebrazo.
 - Segundo, se captura la información personal del participante en la tabla 6 y en el software.
 - Tercero, se colocan las esferas en el orden asignado en la tabla 5.
 - Cuarto, se comprueba que exista comunicación entre los sensores y el equipo Trigno, efectuando unas corridas del experimento. Se especifican en el software las indicaciones auditivas que corresponden al tiempo de inicio y terminación del movimiento y la del momento de relajación de 15 segundos.
 - Quinto, al observarse el registro adecuado de la señal del paso anterior, se procede a la captura de las 30 muestras. En la figura 20, se muestra la sucesión de eventos de movimientos que el participante acciona al agarrar, aplicar fuerza leve por un instante y luego, sostener la posición de sujeción de la esfera.
 - Sexto, el sistema de captura crea un archivo para cada muestra, esto es, se registran los 34 segundos de duración total de un lote, como se ilustró en la figura 9. Termina el experimento.




Figura 19. Colocación de sensores.




Figura 20. Movimientos de los dedos de la mano para agarrar la esfera, aplicar una breve contracción muscular y sostener la pose.

- Gráfica de la señal sEMG. La figura 21 muestra la señal sEMG del participante F1. El eje x representa el tiempo en segundos, el eje y es la amplitud en volts. En esa figura claramente se identifican los periodos de descanso que se introdujeron entre los movimientos de agarre de esfera, como se estableció en el diseño del experimento. También visualmente destacan los 15 segundos del periodo de relajación.




Figura 21. Un lote de tres agarres de esfera del sujeto F1, canal 1.

Las dos fases de la señal sEMG se aprecian en la figura 22. El sujeto al cerrar la mano para posicionar los dedos en la esfera, es el momento que comienza la contracción muscular.




Figura 22. Señales sEMG de movimientos de la mano al sujetar esferas D₁, D₂ y D₃ respectivamente, sujeto F1, canal 1.

El periodo de contracción muscular se divide en una fase de inicio, llamada estado transitorio, con una duración aproximada de 1 segundo y posteriormente, la fase de estado estacionario, donde las características de la señal se suponen constantes en el tiempo. En la gráfica de la figura 22, se observa que el lapso de tiempo del estado estacionario es cercano a tres segundos. La amplitud de la señal es mayor en las

contracciones iniciales y finales que se realizan al sujetar y abrir la mano. Durante la pose de sostener, en cambio, la amplitud es menor, ya que el participante no aplica una contracción voluntaria constante. Esto denota la influencia que tiene el diseño del experimento en el registro de la señal sEMG. Dependiendo del objetivo de estudio, se establecerán la cantidad de sensores requeridos, la elección de los músculos apropiados, tamaño de muestra (cantidad de señales), participantes y otros aspectos relacionados. Cabe señalar que, se utilizó la señal segmentada de la fase de estado estacionario para calcular los valores de las características del TD. El algoritmo hace la lectura de los datos que provienen del registro de 256 ms de duración (512 puntos) en cada uno de los cinco canales y se integraron a una matriz de tamaño 512×5 , correspondiente a una observación.

4.1.4. Generación de características

Para los fines de este trabajo, las características TD forman un conjunto que describe y caracteriza las señales ME de los movimientos de los dedos de las manos muy similares en escenarios estructurados. Esas características fueron seleccionadas en investigaciones desarrolladas en [25, 41, 51]. Una característica o rasgo es una función de una o más medidas individuales de cada movimiento, calculadas de tal forma que, cuantifican algunas particularidades importantes de la señal. Con estos rasgos se construyeron lo que se conoce como los vectores patrones.

- Segmentación de una señal digital. La señal se dividió en segmentos de ventana que son intervalos de tiempo equitativos, obteniéndose un conjunto de datos disjuntos que formarán la base de datos. Las características fueron extraídas de un segmento de tiempo τ de 256 ms de duración; cada análisis comprende 512 datos a una frecuencia de muestreo de 2,000 Hz. Se descartan los 0.5 s del inicio de la contracción muscular [44] con el fin de no incluir transitorios de la señal y a la vez, disminuir el impacto del tiempo de reacción del participante entre la presentación de la indicación auditiva de referencia y la acción de agarre.

- Características del dominio del tiempo: Se implementó la rutina para la separación de la parte de la señal que contiene la información necesaria para la identificación del movimiento. En la figura 23 se muestran las características TD generadas mediante la aplicación de funciones programadas en Matlab que corresponden a las fórmulas de cada característica. Las únicas características para las que no se encontró un comando fueron la potencia media, energía y la amplitud de Willison. Para calcular sus valores se agregaron las fórmulas, declarándolas en el código.

<i>Características del dominio del tiempo</i>	Valor Medio Absoluto Valor Raíz Media Cuadrática Varianza Potencia media Energía Longitud de la onda Cruces por cero Amplitud de Willison	
---	--	--

Figura 23. Características TD.

4.1.5. Vector de características

- Base estadística de biodatos. Empleando la señal sEMG segmentada y ocho características del TD, los rasgos fueron calculados en cada uno de los cinco canales. Se agrupan los valores de una observación, construyéndose un vector patrón fila de dimensión 1×40 (8 características $\times$ 5 canales). Los vectores patrones se almacenan en tablas de registro del software Excel, para su análisis posterior. La información contenida es el nombre del participante, valores de cada característica, canal, número de muestra y diámetro asociado. La tabla 10 ejemplifica el vector patrón para una muestra y un diámetro D_i específico. La figura 24 representa una matriz con los vectores patrones. Las repeticiones realizadas para un movimiento fueron 30, quedando la matriz de tamaño 90×40 por participante.

Tabla 10. Vector patrón para una muestra y diámetro Di.

Número	Característica	Canal
1	Valor Medio Absoluto (MAV)	1
2	Valor Raíz Media Cuadrática (RMS).	1
3	Varianza (VAR).	1
4	Potencia media (P).	1
5	Energía (E).	1
6	Longitud de la onda (WL).	1
7	Cruces por cero (ZC).	1
8	Amplitud de Willison (W).	1
9	Valor Medio Absoluto (MAV)	2
10	Valor Raíz Media Cuadrática (RMS).	2
11	Varianza (VAR).	2
12	Potencia media (P)	2
13	Energía (E)	2
14	Longitud de la onda (WL).	2
15	Cruces por cero (ZC).	2
16	Amplitud de Willison (W).	2
⋮	⋮	⋮
40	Amplitud de Willison (W).	5



Figura 24. Matriz con los vectores patrones.

- Detección de valores atípicos. Los valores atípicos son observaciones no coherentes con el resto de los datos. Un valor atípico es definido como un punto que se encuentra muy lejos de la media de la variable aleatoria correspondiente; en observaciones multivariantes pueden ser difíciles de detectar. En el contexto de LDA, las observaciones lejos de la frontera de decisión, juegan un papel en la estimación de la matriz de covarianza común [23]. Esto significa que LDA no es robusto a los valores atípicos brutos. La detección del dato atípico puede ser más complicada con datos multivariantes. Se reconoce que no todos los valores atípicos son números equivocados, pueden ser parte del grupo y conducir a una mejor comprensión de los fenómenos en estudio. En problemas con una gran cantidad de variables, habrá valores atípicos que no pueden ser detectados en una gráfica univariante como en la figura 25, donde se grafican los valores de la variable amplitud de Willison (W) y las medias para cada clase de diámetro.




Figura 25. Gráfica univariante para característica W, sujeto F1, canal 1.

Esta gráfica univariante no debe emplearse para detectar datos atípicos porque carece del efecto de las demás variables, que al agregarse modificarán el espacio d -dimensional y por lo tanto, la ubicación de los centroides. Un procedimiento recomendado es calcular la Md con los vectores patrones. Las flechas de la figura 26

indican los valores distantes de la media para cada clase. En esa figura se tiene una perspectiva diferente de los valores atípicos identificados al calcular la Md empleando el software JMP.

En el espacio d -dimensional, un valor grande de la distancia al cuadrado generalizada $(\mathbf{x}_i - \bar{\mathbf{x}})' \mathbf{S}^{-1} (\mathbf{x}_i - \bar{\mathbf{x}})$ sugiere una observación inusual, aún a pesar de que no se pueda percibir visualmente. La gráfica de distancia Mahalanobis para valores atípicos, muestra la Md de cada punto a partir de la media multivariante (centroide). Md tiene en cuenta la estructura de correlación de los datos, así como las escalas individuales. Los valores atípicos multivariantes extremos pueden identificarse poniendo de relieve los puntos con los valores de distancia más grande.




Figura 26. Valores atípicos respecto a la media para cada clase, participante F1.

En la gráfica de distancia Mahalanobis de la figura 27, la línea de referencia señala el límite de control superior (en inglés *upper control limit*, UCL).




Figura 27. Gráfica de distancia Mahalanobis para valores atípicos de la muestra F1.

- Eliminación de valores atípicos. En la tabla 11 se muestran los datos atípicos que se suprimieron del conjunto de datos original.

Tabla 11. Valores atípicos eliminados.

Participante	observación
F1	17, 25, 58, 87
F2	4, 15, 50, 74
F3	25, 45, 52, 80
M1	20, 58, 59, 60, 70
M2	21, 22, 29, 61
M3	6, 31, 45, 72

Con esta actualización de los vectores patrones se procede al análisis MANOVA empleando el software JMP.

4.1.6. Prueba de significancia del análisis de varianza multivariante

Los vectores patrones de medias multivariantes de las señales ME se compararon de acuerdo a los niveles del tratamiento. La prueba estadística depende de una partición de la variación total en dos porciones, la variación atribuible al tratamiento y la variación explicada por las fuentes de error. Esta partición de la dispersión se conoce como el análisis de la varianza multivariante.

A continuación se resume el procedimiento desarrollado en esta sección para comparar los niveles del tratamiento.

- Establecer la hipótesis nula para la diferencia de medias multivariante.
 - Realizar una prueba de hipótesis multivariante.
 - Interpretación de los resultados de la tabla MANOVA.
- Establecimiento de la hipótesis para la diferencia de medias multivariantes.
La hipótesis nula para las medias multivariantes del experimento de sujeción de esferas es

El diámetro de la esfera no influye en las características del dominio del tiempo de la señal electromiográfica superficial

$$H_0 = \alpha_1 = \alpha_2 = \alpha_3 = 0$$

donde

α_1 es el efecto del nivel 1 del tratamiento esfera con diámetro $D_1 = 4.6154$ cm,

α_2 es el efecto del nivel 2 del tratamiento esfera con diámetro $D_2 = 7.6390$ cm y

α_3 es el efecto del nivel 3 del tratamiento esfera con diámetro $D_3 = 9.0713$ cm.

Cuando el número de variables, p , es grande, usualmente el computo muestra una tabla MANOVA compacta.

- Resultados de la prueba del análisis de varianza multivariante. Las tablas 12 a 17 muestran el MANOVA para la prueba de hipótesis H_0 . Se indica el valor ρ (Prob>F) para un nivel de confianza del 95% ($\alpha = 0.05$).

Tabla 12. MANOVA para el tratamiento diámetro de la esfera, muestra F1.

Prueba	Valor	Aprox. de F	G.L. numerador	G.L. denominador	Prob > F
Lambda de Wilks	0.0266	5.2603	80	82	<.0001
Traza de Pillai	1.6502	4.9531	80	84	<.0001
Hotelling-Lawley	11.1540	5.5907	80	72.99	<.0001
Raíz máxima de Roy	7.9550	8.3527	40	42	<.0001

Tabla 13. MANOVA para el tratamiento diámetro de la esfera, muestra F2.

Prueba	Valor	Aprox. de F	G.L. numerador	G.L. denominador	Prob > F
Lambda de Wilks	0.0433	3.9938	80	84	<.0001
Traza de Pillai	1.4635	2.9322	80	86	<.0001
Hotelling-Lawley	10.3806	5.3327	80	74.89	<.0001
Raíz máxima de Roy	9.0947	9.7768	40	43	<.0001

Tabla 14. MANOVA para el tratamiento diámetro de la esfera, muestra F3.

Prueba	Valor	Aprox. de F	G.L. numerador	G.L. denominador	Prob > F
Lambda de Wilks	0.0696	3.3950	74	90	<.0001
Traza de Pillai	1.4375	3.1774	74	92	<.0001
Hotelling-Lawley	6.0855	3.6264	74	80.33	<.0001
Raíz máxima de Roy	4.4459	5.5273	37	46	<.0001

Tabla 15. MANOVA para el tratamiento diámetro de la esfera, muestra M1.

Prueba	Valor	Aprox. de F	G.L. numerador	G.L. denominador	Prob > F
Lambda de Wilks	0.0581	3.7457	74	88	<.0001
Traza de Pillai	1.5051	3.6984	74	90	<.0001
Hotelling-Lawley	6.5234	3.7993	74	78.44	<.0001
Raíz máxima de Roy	4.2317	5.1466	37	45	<.0001

Tabla 16. MANOVA para el tratamiento diámetro de la esfera, muestra M2.

Prueba	Valor	Aprox. de F	G.L. numerador	G.L. denominador	Prob > F
Lambda de Wilks	0.1082	2.3152	74	84	0.0001
Traza de Pillai	1.2738	2.0386	74	86	0.0008
Hotelling-Lawley	4.7091	2.6155	74	74.64	<.0001
Raíz máxima de Roy	3.7737	4.3857	37	43	<.0001

Tabla 17. MANOVA para el tratamiento diámetro de la esfera, muestra M3.

Prueba	Valor	Aprox. de F	G.L. numerador	G.L. denominador	Prob > F
Lambda de Wilks	0.0261	6.1672	74	88	<.0001
Traza de Pillai	1.6663	6.0738	74	90	<.0001
Hotelling-Lawley	10.7686	6.2718	74	78.44	<.0001
Raíz máxima de Roy	6.9628	8.4683	37	45	<.0001

- Interpretación de los resultados de la tabla MANOVA. El propósito del estudio es investigar los efectos del factor diámetro de la esfera D_i , ($i= 1,2$ y 3), en las señales ME generadas al mover los dedos de la mano para sujetar una esfera. El criterio de decisión es rechazar H_0 si el valor calculado $\rho < 0.05$. En la tabla 18 se muestra el resumen del análisis estadístico mediante MANOVA.

Tabla 18. Resumen MANOVA para el tratamiento diámetro de la esfera, para cada participante.

Participante	Decisión
F1	Se rechaza H_0
F2	Se rechaza H_0
F3	Se rechaza H_0
M1	Se rechaza H_0
M2	Se rechaza H_0
M3	Se rechaza H_0

Dado que el valor ρ calculado es menor a $\alpha= 0.05$, se rechaza H_0 y se puede concluir que existen diferencias en los niveles de tratamientos, es decir, los diámetros de las esferas sí influyen en las características del dominio del tiempo de la señal sEMG.

Con MANOVA se prueba la hipótesis nula que la variable diámetro no influye en las características del TD. Lo anterior puede expresarse como: las variables del espacio de características tienen la media multivariante de cada clase coincidiendo en el mismo punto. En otras palabras, la hipótesis nula de la prueba es que todas las clases son iguales y la diferencia, en su caso, era puramente por casualidad. El valor ρ da la probabilidad de la hipótesis nula sea verdadera, como $\rho = 0.0001$ o 0.01% , el valor de ρ es tan pequeño que se puede rechazar la hipótesis nula a nivel de confianza del 95% es decir, $\rho < 0,05$. De esta manera, las clases no tienen el mismo valor para la media y la diferencia entre ellas no es por casualidad.

4.2. Clasificación con LDA

Una vez que se ha verificado que las características son afectadas por el factor diámetro de esfera, sigue realizar el entrenamiento, la validación, la reducción de la dimensionalidad y por último, la asignación de los vectores patrones de prueba a una clase de movimiento.

4.2.1. Entrenamiento del clasificador LDA

El conjunto de datos original se separó para formar un grupo de vectores patrones para el entrenamiento del clasificador, con el 80% de la base de datos. Las muestras restantes se usaron para la etapa de validación del clasificador. Cada grupo de vectores patrones, de entrenamiento y de validación, se almacena en una matriz para cada participante. La matriz tiene 41 columnas, la primera representa el diámetro de la esfera y se etiqueta D_i ($i=1, 2,3$) indicando la clase de movimiento a la cual pertenece cada observación del conjunto de entrenamiento; este vector columna es de dimensión $(n \times 1)$. Las demás columnas corresponden a las 40 características TD calculadas y las filas representan las observaciones (repeticiones).

La base de conocimiento preliminar para entrenar al clasificador se formó a partir de un conjunto de muestras cuya pertenencia a una clase es conocida. Los datos de las muestras para entrenamiento se emplean para calcular ciertas estadísticas respecto a cada clase de agarre de esfera, entre ellas están la media multivariante de cada clase y la matriz de covarianza. Esas estadísticas son usadas en la clasificación de los datos en el conjunto de validación. La tabla 19 muestra una parte de la matriz del grupo de muestras para entrenamiento del participante F1. En la tabla 20 se presenta la cantidad, expresada en porcentaje, de observaciones clasificadas correctamente empleando 40 características en el entrenamiento. Los porcentajes de acierto son elevados, encontrándose en general, por encima del 94%. Aparentemente, los vectores patrones de entrenamiento permitirán una exitosa validación.

Tabla 19. Matriz del grupo de vectores patrones de entrenamiento, sujeto F1.

Muestra entrenamiento	Clase (Diámetro)	MAV 1	RMS 1	VAR 1	P 1	...	W 5
1	D1	0.0000265	0.0000273	4.57E-11	7.47E-10	...	50
2	D1	0.0000266	0.0000273	4.38E-11	7.47E-10	...	47
3	D1	0.0000266	0.0000276	5.57E-11	7.60E-10	...	68
7	D1	0.0000267	0.0000284	1.12e-10	8.08e-10	...	79
11	D1	0.0000266	0.0000273	3.82e-11	7.48e-10	...	70
...	...	...	...	...	...	...	...
26	D1	0.0000265	0.0000273	5.31E-11	7.43E-10	...	37
27	D2	0.0000264	0.0000268	2.03e-11	7.17e-10	...	52
28	D2	0.0000265	0.0000267	1.13e-11	7.15e-10	...	47
31	D2	0.0000268	0.0000280	7.08E-11	7.84E-10	...	60
32	D2	0.0000265	0.0000268	1.34E-11	7.18E-10	...	4
33	D2	0.0000266	0.0000267	6e-12	7.14e-10	...	7
...	...	...	...	...	...	...	...
55	D2	0.0000266	0.0000268	9.19e-12	7.19e-10	...	55
56	D3	0.0000266	0.0000269	1.19e-11	7.22e-10	...	75
57	D3	0.0000268	0.0000276	5.96e-11	7.64e-10	...	146
59	D3	0.0000269	0.0000275	4.26E-11	7.58E-10	...	40
64	D3	0.0000265	0.0000279	7.7e-11	7.76e-10	...	133
65	D3	0.0000265	0.0000268	1.28e-11	7.17e-10	...	75
...	...	...	...	...	...	...	...
86	D3	0.0000267	0.0000271	2.27e-11	7.34e-10	...	183

Tabla 20. Porcentaje de aciertos para cada participante en la etapa de entrenamiento, usando inicialmente 40 características del TD.

Participante	Aciertos en la clasificación (%)
F1	98.1
F2	96.0
F3	94.7
M1	98.7
M2	94.0
M3	96.0

4.2.2. Validación del clasificador LDA

El proceso de entrenamiento se ha completado, ahora es posible utilizar el clasificador para la categorización de los nuevos datos, que al igual que los datos de entrenamiento, se organizaron en una matriz de tamaño $(41 \times m)$, siendo congruente con el número de columnas de la matriz de entrenamiento. Para la validación del clasificador, se utiliza el segundo grupo de vectores patrones, que representa el 20% de la base de datos. Las muestras usadas para entrenamiento no formaron parte del grupo para la validación. La salida del clasificador es el vector de resultados de tamaño $(m \times 1)$, donde se almacena la etiqueta de la clase (D_i) asignada a las nuevas muestras. En la tabla 21 se muestra el vector con los resultados obtenidos empleando 40 características TD para cada participante.

Tabla 21. Porcentaje de error en la etapa de validación.

Participante	Error en la clasificación (%)
F1	44.7
F2	57.0
F3	54.7
M1	38.0
M2	42.6
M3	49.0

Los porcentajes de error en la asignación de las muestras de validación a una clase determinada, no fueron los esperados, ya que como se observa en la tabla 21, el error en la clasificación supera en promedio el 47%.

Analizando el funcionamiento del clasificador e investigando las causas del elevado error en la validación, se encontró que este comportamiento se explica por el sobreajuste (en inglés *overfitting*). La cantidad de variables considerada para el entrenamiento fueron 40 características del TD, de tal manera que, se tiene una función discriminante con parámetros que reflejan fielmente al conjunto de datos de entrenamiento, pero que ante una nueva observación, falla en asignar a la clase correcta. Para evitar este efecto de sobreajuste de los datos, se recurre a la reducción de la dimensionalidad del problema.

4.2.3. Reducción de dimensionalidad mediante distancia Mahalanobis

En esta etapa se seleccionaron del total de características del TD, aquellas que contribuyeron a la mayor separación de las medias multivariadas y por lo cual, son las variables con mayor capacidad discriminatoria. Como efecto de este proceso, las matrices tienen menos columnas, reduciéndose la dimensión de las mismas. Al módulo de LDA del software JMP, se ingresaron los vectores de características originales para aplicar la reducción de la dimensionalidad. LDA evaluó cuales de las 40 características fueron más discriminantes, calculando la Md de cada observación hacia el centroide de cada clase multivariada. En la tabla 22, se muestran las variables obtenidas en la reducción de dimensionalidad con LDA.

Tabla 22. Variables discriminantes seleccionadas en la etapa de reducción de dimensionalidad.

Participante	Características TD discriminantes
F1	W1,W3, WL5
F2	WL1, W1, RMS2, VAR2, P2, RMS3, W3, MAV5, WL5, ZC5
F3	MAV1, VAR1, W1, W2, ZC3, W3, RMS4, VAR4, E4, ZC4, W4, RMS5, VAR5, P5, E5, ZC5, W5
M1	MAV1, RMS1, VAR1, P1, E1, WL1, MAV2,VAR2, P2, E2, ZC2, W2,MAV3, RMS3, VAR3, P3, E3, WL3, ZC3, W3, MAV4, RMS4, P4, E4, WL4, ZC4, W4, MAV5, RMS5, VAR5, E5, WL5, ZC5, W5
M2	W1, MAV2, W2, W3, W4, MAV5, W5
M3	RMS2, WL2, WL3, W3, VAR4, ZC4, WL5, ZC5

En la figura 28 se muestra la separabilidad alcanzada entre las clases, utilizando los vectores patrones de dimensión reducida resultantes, para el participante F1.




Figura 28. LDA separa las clases usando las variables seleccionadas para F1.

4.2.4. Validación del clasificador LDA con características seleccionadas

En esta sección se examinan los resultados de la validación efectuada con las variables discriminantes de la tabla 22 que fueron seleccionadas en la etapa de reducción de dimensionalidad. La tabla 23 contiene la clasificación con LDA para el grupo de muestras de entrenamiento y muestras de validación del participante F1. La muestra que pertenece al grupo de validación se identifica con el símbolo ~.

Tabla 23. Vector de asignación obtenido con LDA y características seleccionadas para el sujeto F1.

Clase real	Mínima Md ² (real)	Muestra	Decisión	Error	Clase real	Mínima Md ² (real)	Muestra	Decisión	Error
D1	0.3356		D1		D2	0.8641		D2	
D1	0.8389		D1		D2	1.4908	~	D2	
D1	2.0999		D1		D2	2.6247		D2	
D1	1.5722	~	D1		D2	1.2771		D2	
D1	1.2102	~	D1		D2	0.9142		D2	
D1	14.6698	~	D1		D2	0.0619		D2	
D1	10.9471		D1		D2	0.7355		D2	
D1	3.6522	~	D1		D2	0.1856	~	D2	
D1	0.4076		D1		D2	2.7449		D2	
D1	8.2492	~	D2	*	D2	1.2619		D2	
D1	1.0449		D1		D2	0.4056		D2	
D1	3.2468		D1		D2	0.4046	~	D2	
D1	3.0884		D2	*	D2	0.1926		D2	
D1	1.0964		D1		D2	0.3671		D2	
D1	3.0515		D1		D2	2.0649		D2	
D1	2.1638		D1		D2	0.3301		D2	
D1	0.9003		D1		D2	0.0960		D2	
D1	6.1928		D1		D2	0.6163		D2	
D1	10.7129		D1		D2	0.7384	~	D2	
D1	5.6026		D2	*	D2	1.2648		D2	
D1	0.8941		D1		D2	0.1254		D2	
D1	4.1493		D1		D2	1.0017		D2	
D1	1.3933		D1		D2	0.2192		D2	
D1	1.5927		D1		D3	4.8362		D2	*
D1	1.0080	~	D1		D3	3.7982		D3	
D1	10.9977		D3	*	D3	3.4375	~	D3	
D2	0.9135		D2		D3	6.4124		D3	
D2	0.1604		D2		D3	20.9559	~	D3	
D2	0.1924	~	D2		D3	2.6858	~	D3	
D2	2.3270	~	D2		D3	0.9522	~	D3	
D2	0.8368		D2		D3	1.3714	~	D3	
D2	2.1444		D2		D3	7.2002		D3	
D2	0.9135		D2		D3	1.4318		D3	

Clase real	Mínima Md ² (real)	Muestra	Decisión	Error	Clase real	Mínima Md ² (real)	Muestra	Decisión	Error
D3	7.8595		D3		D3	1.5020		D3	
D3	2.9429		D3		D3	0.2504		D3	
D3	4.6151		D3		D3	6.7580		D2	*
D3	1.0769	~	D3		D3	3.0174		D3	
D3	1.3370		D3		D3	5.5612		D2	*
D3	1.6910		D3		D3	4.6728		D3	
D3	1.6910		D3		D3	1.6160		D3	
D3	9.3403		D3		D3	5.7590		D2	*
D3	3.8256		D3		D3	7.8999		D3	

4.2.5. Resultados de la clasificación LDA

- Asignación a una clase. El clasificador LDA identificó la pertenencia de una señal sEMG a uno de los tres tipos de movimiento de los dedos de mano. La Md al cuadrado mostrada en la columna dos de la tabla 23 es la de mínimo valor y significa que se asignó a la clase más cercana. Con esta información se tiene la salida del clasificador, si coincide con la clase verdadera, la muestra está etiquetada como correcta, de lo contrario, se considera un error. En la tabla 24 se muestran las tres clases predefinidas.

Tabla 24. Tres clases de movimientos.

Clase	Descripción del movimiento	Diámetro	Símbolo
1	sujeción de esfera	4.6154 cm	D ₁
2	sujeción de esfera	7.6390 cm	D ₂
3	sujeción de esfera	9.0713 cm	D ₃

- Exactitud de la clasificación de las señales sEMG mediante LDA. En la tabla 25 se muestran los resultados de la clasificación para el grupo de muestras para la validación. De la tabla 23 se eligieron las muestras de validación para formar la tabla 25 que muestra los resultados de la validación para el participante F1.

Tabla 25. Resultados de la validación con LDA para el sujeto F1.

Muestra validación	Clase Real	Clase asignada	Clasificación Incorrecta
1	D1	D1	
2	D1	D1	
3	D1	D1	
4	D1	D1	
5	D1	D2	×
6	D1	D1	
7	D2	D2	
8	D2	D2	
9	D2	D2	
10	D2	D2	
11	D2	D2	
12	D2	D2	
13	D3	D3	
14	D3	D3	
15	D3	D3	
16	D3	D3	
17	D3	D3	
18	D3	D3	

En la tabla 26 se muestran los valores de asignación correctos en la clasificación. Incluye los porcentajes obtenidos en el entrenamiento y la validación, usando las características TD discriminantes seleccionadas en la reducción de la dimensionalidad.

Tabla 26. Exactitud de la clasificación en porcentaje.

	Entrenamiento	Validación
	72 muestras (80%)	18 muestras (20%)
Participante	% de exactitud	% de exactitud
F1	89.2	94.4
F2	92.4	88.9
F3	92.4	94.4
M1	98.4	83.3
M2	70.7	75.0
M3	87.7	83.3

La tabla 26 muestra los porcentajes de éxitos en la clasificación de los movimientos de la mano mediante las señales sEMG de los participantes. Los sujetos F1 y F3 alcanzan tasas de

reconocimiento de 94.4% en la validación. La tasa de exactitud más baja corresponde al sujeto M2, con 75% para las muestras de validación.

4.3. Evaluación del clasificador

4.3.1. Precisión.

La matriz de confusión sirve para la evaluación del desempeño del clasificador en cuanto a la precisión. En la tabla 27 se muestra la representación de la matriz de confusión para las tres clases incluidas en este estudio. La matriz es cuadrada y el tamaño depende de la cantidad de clases. Las filas representan la clase a la que la señal pertenece y las columnas a la clase en la cual la señal fue asignada. En la diagonal principal se ubicada la cantidad de muestras clasificadas correctamente y fuera de la diagonal, las muestras clasificadas de manera incorrecta.

Tabla 27. Esquema de la matriz de confusión para tres clases.

	Entrenamiento			Validación		
	D ₁	D ₂	D ₃	D ₂	D ₃	D ₃
D ₁						
D ₂						
D ₃						

En la tabla 28 se muestra la matriz de confusión a partir de los resultados de la clasificación para cada participante. Los porcentajes se calcularon dividiendo las asignaciones correctas para una clase entre el total de observaciones de dicha clase, tanto para las muestras de entrenamiento como para la validación.

Tabla 28. Matriz de confusión de los seis sujetos usando señales sEMG y clasificador LDA.

	Sujeto F1						Sujeto F2						Sujeto F3					
	Entrenamiento			Validación			Entrenamiento			Validación			Entrenamiento			Validación		
	D1	D2	D3	D1	D2	D3	D1	D2	D3	D1	D2	D3	D1	D2	D3	D1	D2	D3
D1	0.85	0.10	0.05	0.84	0.16	0.00	1.00	0.00	0.00	1.00	0.00	0.00	0.91	0.09	0.00	1.00	0.00	0.00
D2	0.00	1.00	0.00	0.00	1.00	0.00	0.05	0.90	0.05	0.00	1.00	0.00	0.05	0.90	0.05	0.00	1.00	0.00
D3	0.00	0.18	0.82	0.00	0.00	1.00	0.00	0.13	0.87	0.16	0.16	0.67	0.00	0.04	0.96	0.00	0.17	0.83
	Sujeto M1						Sujeto M2						Sujeto M3					
	Entrenamiento			Validación			Entrenamiento			Validación			Entrenamiento			Validación		
	D1	D2	D3	D1	D2	D3	D1	D2	D3	D1	D2	D3	D1	D2	D3	D1	D2	D3
D1	1.00	0.00	0.00	1.00	0.00	0.00	0.60	0.20	0.20	0.67	0.16	0.16	0.96	0.00	0.04	1.00	0.00	0.00
D2	0.00	0.95	0.05	0.17	0.83	0.00	0.13	0.87	0.00	0.00	1.00	0.00	0.00	0.85	0.15	0.00	0.67	0.33
D3	0.00	0.00	1.00	0.33	0.00	0.67	0.27	0.09	0.64	0.40	0.00	0.60	0.14	0.05	0.81	0.00	0.17	0.83

En la tabla 29 se muestran el promedio de clasificación correcta para cada clase, D₁, D₂ y D₃. La clase D₃ es principalmente asignada de manera incorrecta a la clase D₂. La baja exactitud en la clasificación de D₃, se puede atribuir a que los índices de reconocimiento más pequeños se deben a la mala clasificación de los movimientos D₃, que son asignados a la clase D₁ con tasa de error del 40% para el participante M2.

Tabla 29. Exactitud de la clasificación de las clases.

Clase	Exactitud promedio global (%)
D ₁	91.77
D ₂	91.66
D ₃	76.66

4.3.2. Flexibilidad

Los resultados muestran que las características del TD difieren entre los participantes. Sin embargo, el clasificador LDA fue capaz de adaptarse a señales sEMG provenientes de diferentes participantes y superar las fluctuaciones en la amplitud de la señal ME provocadas por el ruido del entorno. Además, no obstante que las posiciones de la mano parecen muy

similares en la ubicación mecánica y por tanto, el clasificador pudiera no ser capaz de identificar correctamente los movimientos de la mano, la estructura de las señales ME fue fiable para la asignación apropiada, manteniéndose una tasa de error tolerable.

4.3.3. Interpretación de los resultados

A continuación se resaltan los aspectos importantes al aplicar la metodología y del proceso de clasificación de las señales sEMG usando el clasificador LDA.

- ❖ En la etapa de entrenamiento inicialmente se incluyeron las cuarenta características del TD, posteriormente se observó que esta cantidad de variables afectó la etapa de validación. Los porcentajes de acierto logrados en la etapa de validación fueron bajos, situándose aproximadamente en un 53%.
- ❖ La reducción de dimensionalidad se usó para seleccionar las características TD. Los porcentajes de acierto logrados con las muestras de entrenamiento disminuyeron alrededor de un 9% tras desarrollarse el procedimiento de selección de características TD; en contraparte, se observó un impacto favorable y significativo en la correcta asignación obtenida con las muestras de validación, siendo en general valores aceptables.
- ❖ Las características TD discriminantes predominantes en esta investigación son Willison amplitud y longitud de onda, representadas por la letra W y WL respectivamente.
- ❖ No existe un canal único que discrimine a las señales ME de todos los participantes. Se tienen combinaciones de canales según el individuo analizado.
- ❖ Las características TD discriminantes y los canales que se seleccionaron fueron específicos para cada participante.

- ❖ El participante F1 solamente requirió de tres variables para la clasificación de sus señales sEMG. La mayor cantidad de variables necesarias para la clasificación fue para M1.
- ❖ Los participantes F1, F2 y F3, mujeres, tienen mejores porcentajes de acierto en la clasificación al compararse con los hombres participantes M1, M2, y M3. Una posible explicación a este hecho, puede ser la cantidad de fibras musculares, grasa debajo de la piel y el grosor de la misma que, en general, suele ser diferente entre hombres y mujeres. Se propone realizar otro experimento para confirmar en esta investigación, si las muestras de las señales sEMG de mujeres tienen mejores índices de clasificación que los hombres.
- ❖ El clasificador, después de la etapa de selección de características discriminantes, corrigió favorablemente su desempeño.

Los resultados de la clasificación permiten afirmar que los porcentajes de éxito de la clasificación para los participantes fueron superiores en la segunda ejecución del proceso de entrenamiento, lo cual demuestra que la mejora observada en el comportamiento del clasificador es atribuible a la reducción de la dimensionalidad. El conjunto de datos de validación tiene la función de verificar la capacidad predictiva de las características TD, lo que ayudó a evaluar si los vectores patrones poseían capacidad de predicción en los datos.

En la señal sEMG capturada, el número de características TD puede considerarse muy grande, debido a esto, surgió la necesidad de reducir la dimensionalidad de los datos de entrada. La reducción de características redujo el sobreajuste porque evitó la redundancia al tratar con características TD altamente correlacionadas y eliminó las variables que no aportan información significativa. Disminuir el sobreajuste contribuyó a la disminución de la complejidad del proceso de clasificación e incrementó el desempeño del clasificador.

En resumen, la interpretación de los resultados de la clasificación de los movimientos de los dedos de la mano al sujetar esferas con diámetro diferente usando señales sEMG en un escenario estructurado, es que el clasificador LDA reconoció las tres posiciones de los dedos, lo que a su vez implicó, la identificación de las pequeñas variaciones en el movimiento de los dedos de la mano.

4.4. Resultados adicionales de la clasificación LDA para sujeción de cinco esferas

Un esquema de experimentación adicional se investigó para conocer si es posible clasificar los movimientos de los dedos de la mano al agarrar cinco esferas diferentes aplicando LDA. La preparación, el diseño y la realización del experimento se ejecutaron tal como se describieron en las secciones 4.1.1 a la 4.1.6. La figura 29 muestra las esferas $D_1=5.715$, $D_2=6.985$, $D_3=7.7978$, $D_4=9.0678$ y $D_5=10$ cm de diámetro, utilizadas en experimento. El tamaño de la muestra fue 30 repeticiones $\times$ 5 esferas, 150 observaciones.



Figura 29. Cinco esferas del experimento adicional.

Los resultados de la clasificación de los movimientos para las cinco esferas, presentaron un error de clasificación aproximado del 63%. En la figura 30 se muestran los cinco centroides sobrepuestos, a pesar de haber aplicado la reducción de dimensionalidad.




Figura 30. LDA no separa apropiadamente las cinco clases.

Con la finalidad de afrontar este problema, el conjunto de datos se separó en dos sub-problemas tal que, las señales correspondientes a las esferas D₁, D₃ y D₅ se analizaron como el primer grupo de interés. Las esferas restantes, D₂ y D₄, se consideraron otro problema, formando el segundo grupo de estudio. Los resultados de la clasificación bajo este enfoque, alcanzaron tasas del 9% y 18.18% de éxito obtenidos en la etapa de validación del primero y segundo grupo respectivamente. La tabla 30 muestra las matrices de confusión de los grupos.

Tabla 30. Matrices de confusión del experimento adicional.

Primer grupo							Segundo grupo				
Sample	Train			Test			Sample	Train		Test	
	D1	D3	D5	D1	D3	D5		D2	D4	D2	D4
D1	0.90	0.10	0.00	1.00	0.00	0.00	D2	0.78	0.22	0.80	0.20
D3	0.00	0.90	0.10	0.00	0.83	0.16	D4	0.29	0.71	0.16	0.84
D5	0.10	0.13	0.77	0	0	1					

La figura 31 muestra la separación de los centroides D₁, D₃ y D₅ correspondientes al primer grupo y D₂ y D₄ del segundo grupo, al aplicar LDA.




Figura 31. LDA para el primero (izquierda) y segundo (derecha) grupo de esferas.

Hasta el momento, se investigan los métodos de clasificación que puedan combinar la información del grupo uno y dos para establecer un conjunto de criterios de clasificación secuenciales. Existen métodos de aprendizaje por multclasificadores que mantiene un conjunto de descriptores y predice combinando estos ya sea por votación simple o ponderada, o bien seleccionando la descripción más relevante. Un ejemplo de método de aprendizaje por multclasificadores es el algoritmo de ensamblaje (en inglés *ensemble algorithm*) que actualmente se estudia para implementarlo con las señales sEMG del experimento de las cinco esferas.

5. Conclusiones

En este trabajo de investigación se realizó el reconocimiento de patrones de las señales sEMG de tres movimientos de los dedos de la mano. Se diseñó el experimento que especificó la cantidad de participantes, el tamaño de muestra y los músculos del antebrazo seleccionados para la colocación de los sensores. Se trató la importancia de analizar cuál es el número y la colocación de electrodos más conveniente para este problema. A la vez, el efecto de la captura y procesamiento de la señal en la interpretación de los datos. La intención es obtener conclusiones correctas a partir de los datos de sEMG. Una vez capturada la señal, se realizó la tarea de preparar la señal para extraer la información necesaria para generar las características del TD. Las características basadas en estadísticos temporales se evaluaron rápidamente y se obtuvieron de cada segmento de tiempo para crear el conjunto de características que representó los vectores patrones de la señal. Se corroboró que las consideraciones respecto a la estacionalidad de la señal ME son adecuadas en movimiento de corta duración como los analizados. En la etapa de entrenamiento se incluyeron inicialmente cuarenta características del TD, las cuales no pudieron clasificar correctamente las muestras de validación. La razón fue que la cantidad de características provocó el problema de la dimensionalidad. Para la reducción de la dimensionalidad se procedió a ingresar nuevamente la matriz que contiene las muestras de entrenamiento y la matriz con las muestras de validación, pero en esta ocasión, combinaciones de características se evaluaron en el clasificador LDA. El clasificador LDA aumentó el número de aciertos con la selección de características TD.

Algunos factores deseados en el reconocimiento de patrones estadísticos son el obtener pocas características discriminantes, que puedan dividir el espacio en regiones de decisión simples; un clasificador fácil de entrenar y características estables con baja sensibilidad al ruido u otros errores, entre otros. En aplicaciones prácticas se requiere un clasificador que se desempeñe lo suficientemente rápido en tiempo real; usar reducida capacidad de memoria del procesador y aplicar pocos pasos en el procesamiento, tal como actúa el LDA. Los obstáculos en el análisis de la señal ME se han superado a través del desarrollo de sensores inalámbricos de rango de operación amplio, técnicas de procesamiento de señales y algoritmos de cálculo; aún persisten problemas en el estudio señales ME, principalmente por

la naturaleza del fenómeno analizado. Los procesadores actuales adquirieron y filtran señales en tiempo real empleando paquetería cada vez más portátil. El modelado por computadora y el software están facilitando el conocimiento acerca de la señal ME. El reconocimiento de patrones y máquinas de aprendizaje estiman la predicción de los movimientos y la actividad muscular. La EMG se puede utilizar de forma más fiable y a un costo aceptable, por lo que es factible en un mayor número de aplicaciones. Los investigadores continúan laborando para reducir los elementos que afectan el registro fidedigno de la señal EMG. La EMG ha dejado de ser una técnica para constituirse como un conjunto científico fundamentado en los métodos experimentales del estudio del movimiento humano. Los estudios pioneros para comprender la contracción muscular y las iniciativas del proyecto SENIAM fueron las bases para esta transición.

El propósito del trabajo de tesis fue demostrar que era posible establecer la relación de la posición de los dedos de la mano en un escenario estructurado con el diámetro de la esfera. Incluso con las perturbaciones en el ambiente fue viable extraer la información contenida en la señal ME para categorizar e identificar la intención de los movimientos de la mano humana al sujetar la esfera, explotando las características TD y el reconocimiento de patrones estadísticos. Las características del TD empleadas en el estudio hicieron una representación apropiada de la señal sEMG compleja y no estacionaria, a un nivel de contracción muscular muy bajo. Las medias multivariante están espacialmente separadas, lo que significa que las características TD extraídas proyectan una identificación del movimiento.

Los estudios de clasificación de los movimientos de los dedos de la mano analizan posiciones o gestos de la mano claramente diferentes, movimientos de agarre de objetos de uso común (lápiz, herramientas, etc.); otros estudios analizan la flexión de los dedos en un entorno no estructurado. Una diferencia importante en este trabajo respecto a investigaciones encontradas en el estado del arte, es el enfoque que se ha empleado, reconocer posiciones de los dedos con una pequeña variación del gesto o movimiento de los dedos provocado por un objeto con geometría esférica. Asimismo, se usaron únicamente características de TD, en vez de alguna combinación de característica TD y de frecuencia; no se requirió procesamiento de señales adicional. La investigación efectuada permitirá el procesamiento

de las señales ME para propósitos de diseño de sistemas de control ME. Actualmente está en curso en el laboratorio la realización de experimentos adicionales para adquisición de las señales ME aplicando la metodología experimental descrita en este documento. El conjunto de dichas señales formará una base de datos, siendo una contribución importante para las investigaciones relativas al reconocimiento de patrones de agarres o sujeción de objetos con la mano, control de prótesis de la mano e interacción hombre máquina.

El trabajo a futuro está enfocado a la búsqueda de los algoritmos de ensamblaje o de un método de multclasificación para analizar las señales sEMG de las cinco clases de movimientos de la mano al sujetar el mismo número de esferas con diámetros diferentes, cuyos resultados preliminares fueron presentados.

Referencias

- [1] E. Alpaydm. *Introduction to Machine Learning*, The MIT Press, 2nd ed., 2010.
- [2] A. H. Al-Timemy, G. Bugmann, J. Escudero and N. Outram, “Classification of Finger Movements for the Dexterous Hand Prosthesis Control with Surface Electromyography,” *IEEE Journal of Biomedical and Health Informatics*, vol. 17, no. 3, pp. 608-618, May 2013.
- [3] M. J. Anderson, T. J. Willis, “Canonical analysis of principal coordinates: a useful method of constrained ordination for ecology”, *Ecology*, vol. 84, pp. 511-525, 2003.
- [4] P.K Artemiadis, K.J. Kyriakopoulos, “EMG based control of a robot arm using low-dimensional embeddings”, *IEEE Trans. Robotics*, vol. 26 no. 2, pp. 393-398. 2010
- [5] J.V. Basmajian and C.J. De Luca. *Muscles Alive: Their Function Revealed by Electromyography*. Williams Wilkins, Baltimore, 1985.
- [6] J. A. Camarena, *Notas de Reconocimiento de Patrones*, Facultad de Ingeniería Eléctrica, Univ. Michoacana de San Nicolas de Hgo., Marzo de 2009.
- [7] C. M. Cuadras, *Nuevos Métodos de Análisis Multivariante*, CMC Editions, Barcelona, 2014.
- [8] M. De Cáceres, F. Oliva, X. Font, “On relational possibilistic clustering”, *Pattern Recognition*, 39, 2010-2024, 2006.
- [9] C. J. De Luca, *A Practicum on the Use of Surface EMG Signals in Movement Sciences*, Delsys Inc, 2008.
- [10] C. J. De Luca, *Electromyography. Encyclopedia of Medical Devices and Instrumentation*, J. G. Webster, Ed. John Wiley Publisher, 2006.
- [11] C. J. De Luca, “*Surface Electromyography: Detection and Recording*”, Technical Report, Delsys. 2002.
- [12] C. J. De Luca, “The Use of Surface Electromyography in Biomechanics”, *Journal of Applied Biomechanics*, Human Kinetics Publishers, Inc., vol. 13, pp. 135-163, 1997.
- [13] G. De Luca, “*Fundamental Concepts in EMG Signal Acquisition*”, Technical Report, Delsys. Rev.2.1, March 2003.

- [14] P. A. Devijver and J. Kittler. *Pattern Recognition: A Statistical Approach*, 1st. ed. Prentice Hall, 1982.
- [15] L. Dipietro, A. Sabatini and P. Dario, “A survey of glove-based systems and their applications,” *IEEE Transactions on Systems, Man, And Cybernetics—Part C: Applications and Reviews*, vol. 38, no. 4, pp. 461–482, July 2008.
- [16] R. Drake, A. W. Vogl, y A. W. M Mitchell, *Gray Anatomía para estudiantes*, 2a. ed. Español. España: Elsevier, S.L., 2010.
- [17] R. O. Duda, P. E. Hart, D. G. Stork. *Pattern Classification*, 2nd ed., Wiley Interscience, 2000.
- [18] K. Englehart and B. Hudgins, “A Robust, Real-Time Control Scheme for Multifunction Myoelectric Control,” *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 7, pp. 848 – 854, July 2003.
- [19] K. Englehart, B. Hudgins and P. Parker, “A Wavelet Based Continuous Classification Scheme for Multifunction Myoelectric Control,” *IEEE Transactions on Biomedical Engineering*, vol. 48, no. 3, pp. 302-311, March 2001.
- [20] K. Englehart, B. Hudgins, P.A. Parker and M. Stevenson, “Classification of the myoelectric signal using time-frequency based representations,” *Medical Engineering & Physics*, vol. 21, issues 6–7, pp. 431–438, July 1999.
- [21] R. M. Enoka, *Neuromechanical basis of kinesiology*. Champaign, IL: Human Kinetics, 1994.
- [22] K. Fukunaga, *Introduction to statistical pattern recognition*, 2nd ed., Academic Press, 1990.
- [23] T. Hastie, R. Tibshirani and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed., Springer.
- [24] N. Hogan and R. W. Mann, “Myoelectric signal processing: optimal estimation applied to electromyography-part I: derivation of the optimal myoprocessor,” *IEEE Transactions on Biomedical Engineering*, vol. BME-27, no. 7, pp. 382-395, July 1980.
- [25] B. Hudgins, P. Parker and R. N. Scott, “A New Strategy for Multifunction Myoelectric Control,” *IEEE Transactions on Biomedical Engineering*, vol. 40, No.1, January 1993.

- [26] A. K. Jain, R.P.W. Duin and J. Mao, "Statistical pattern recognition: A review," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, no 1, pp. 4-37, January 2000.
- [27] *JMP® 11 Multivariate Methods*. Cary, NC: SAS Institute Inc. 2013.
- [28] R. A. Johnson and D. W. Wichern, *Applied multivariate statistical analysis*, 5th ed., Prentice-Hall, Inc., 2002.
- [29] Z. Ju and H. Liu, "Human Hand Motion Analysis with Multisensory Information," *IEEE/ASME Transactions on Mechatronics*, vol.19, no.2, pp.456-466, April 2014.
- [30] R. Merletti and H. Hermens, "Detection and conditioning of the surface EMG signal," in *Electromyography: Physiology, Engineering and Noninvasive Applications*, R Merletti and P. Parker, Ed., New Jersey: John Wiley & Sons, pp. 107-128, 2004.
- [31] E. Micheli-Tzanakou. "Supervised and Unsupervised Pattern Recognition: Feature Extraction and Computational Intelligence," in *Industrial Electronics Series*, J. D. Irwin, Ed. CRC Press LLC, 2000.
- [32] D.C. Montgomery, *Design and Analysis of Experiments*. John Wiley & Sons, Inc. Eighth edition. 2013
- [33] E. Muñoz, O. H. Paruma y F. Florez. "Aplicaciones de las señales mioeléctricas para el control de interfaces hombre-máquina", Universidad del Cauca, Popayán, Reporte técnico, 2003.
- [34] B. A. Myers. "A Brief History of Human Computer Interaction Technology," *ACM interactions*, vol. 5, no. 2, pp. 44-54, March 1998.
- [35] M. A. Oskoei and H. Hu. "Myoelectric control systems: A survey", *Elsevier: Biomedical Signal Processing and Control*, vol. 2, issue 4, pp. 275-294, October 2007.
- [36] P. A. Parker, K. B. Englehart, and B. S. Hudgins, "Control of Powered Upper Limb Prostheses," in *Electromyography: Physiology, Engineering and Noninvasive Applications*, R Merletti and P. Parker, Ed., New Jersey: John Wiley & Sons, pp. 453 – 475, 2004.
- [37] J. J. Pascual, *Rehabilitación de la mano*, La Habana: Editorial Ciencias Médicas, 2010.

- [38] A. Phinyomark, H. Hu, P. Phukpattaranont, C. Limsakul, "Application of Linear Discriminant Analysis in Dimensionality Reduction for Hand Motion Classification", *Measurement Science Review*, vol. 12, no. 3, pp. 82-89, 2012.
- [39] L. A. Rivera y G. N. DeSouza. "Recognizing hand movements from a single sEMG sensor using guided under-determined source signal separation," in *IEEE International Conference on Rehabilitation Robotics Rehab*, Week Zurich, ETH Zurich Science City, Switzerland, June 29 - July 1, 2011.
- [40] T. Saponas, D. Tan, D. Morris, R. Balakrishnan, J. Turner, and J. Landay, "Enabling always-available input with muscle-computer interfaces," in *Proc. 22nd Annu. ACM Symp. User Interface Softw. Technol.*, pp. 167–176, 2009.
- [41] C. Sapsanis, G. Georgoulas, A. Tzes, y D. Lymberopoulos "Improving EMG based Classification of basic hand movements using EMD," in *35th Annual International Conference of the IEEE EMBS*, Osaka, Japan, pp. 5754- 5757, July 2013.
- [42] P. Singh. "Empirical Modelling and Classification of Surface Electromyogram". Ph.D. dissertation, RMIT University, Melbourne, Australia, 2010.
- [43] X. Tang, Y. Liu, C. Lv, and D. Sun, "Hand motion classification using a multi-channel surface electromyography sensor," *Sensors*, vol. 12, no. 2, pp. 1130–1147, 2012.
- [44] F. V. G. Tenore, A. Ramos, A. Fahmy, S. Acharya, R. Etienne-Cummings and N. V. Thakor, "Decoding of Individuated Finger Movements Using Surface Electromyography", *IEEE Transactions on Biomedical Engineering*, vol. 56, no. 5, pp. 1427-1434, May 2009.
- [45] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 2nd. ed. San Diego: Academic Press, an imprint of Elsevier, 2003.
- [46] G. A. Thibodeau y K. T. Patton. *Anatomía y Fisiología*. 13era. ed. Ed. España: Elsevier, S.A.
- [47] A. R. Webb, *Statistical Pattern Recognition*, 2nd ed., John Wiley & Sons, Ltd., 2002.
- [48] S. Xiang, F. Nie, C. Zhang, "Learning a Mahalanobis distance metric for data clustering and classification", *Pattern Recognition*, Elsevier Ltd., vol. 41 pp. 3600 - 3612, 2008.

- [49] M Zardoshti-Kermani, B.C. Wheeler, K. Badie and R.M. Hashemi, "EMG feature evaluation for movement control of upper extremity prostheses." *IEEE Trans Rehab Eng*, 3:324, 1995.
- [50] D. Zhang, X. Chen, S. Li, P. Hu, and X. Zhu, "Emg controlled multifunctional prosthetic hand: Preliminary clinical study and experimental demonstration," in *Proc. IEEE Int. Conf. Robot. Autom.*, pp. 4670–4675, 2011.
- [51] M. Zecca, S. Micera, M. Carrozza, and P. Dario, "Control of multifunctional prosthetic hands by processing the electromyographic signal," *Crit. Rev. Biomed. Eng.*, vol. 30, pp. 459–485, 2002.
- [52] <http://www.seniam.org>

Productividad académica



<http://upaep.mx/micrositios/coloquios/coloquio2016/>



Revista Electrónica de Ingeniería y Aplicación - REIA. ISSN: 2448-6817

http://www.iteshu.edu.mx/reia/descargables/revista_reia_16.pdf

Torres et al. (2016), 1 (2) 7-12

Clasificación de Movimientos de la Mano a partir de Señales Mieléctricas Superficiales usando Características del Dominio del Tiempo.

Guadalupe A. Torres¹, Víctor H. Benítez²

¹Posgrado de Ingeniería Mecatrónica, ²Departamento de Ingeniería Industrial, ¹Universidad Popular Autónoma del Estado de Puebla, ²Universidad de Sonora.

¹Calle 21 Sur 1103, Santiago, Barrio de Santiago, Puebla, Pue, México, ²Blvd. Luis Encinas y Rosales S/N, Centro, Hermosillo, Sonora, México, atorres@industrial.uson.mx

Resumen— En este trabajo se establece la clasificación de los movimientos de las manos que varían en posiciones mecánicas específicas, el enfoque consiste en distinguir varias posiciones de la mano ante variaciones mecánicas. Una posición específica de la mano se realiza con ayuda de un objeto geométrico dentro de una variación de parámetros controlados. Se colocan electrodos en cinco músculos en el antebrazo de seis sujetos sanos que sujetan esferas. Un vector de características en el dominio del tiempo (TD) es la entrada al análisis discriminante lineal (LDA). Se demuestra que es posible categorizar cada movimiento mediante características del TD, las cuales proporcionan una representación efectiva para la clasificación. La membresía de las señales mieléctricas (MES) registradas se asignó a una clase de movimiento de las manos. Estos resultados serán de potencial utilidad para el análisis de movimiento de la mano humana, teniendo aplicación potencial en mano robótica e interacción hombre-máquina.

Abstract— In this paper the classification of hand motions that vary in specific mechanical positions is proposed, the approach consist in distinguish several hand positions with mechanical variation. A specific hand position is performance with help of a geometrical object within a controlled parameter variation. Hand natural motions are collected by placing electrodes on five muscles on the forearm of six healthy subjects who fasten spheres into a controlled environment. A feature vector approach in time domain (TD) is given as input to a linear discriminant analysis (LDA) module used as statistical pattern classifier. We show that it is possible to categorize each motion, that is, TD features based provide an effective representation for classification, indicating the membership of myoelectric signals (MES) collected to a hand positions class. These results will be useful for human hand motion analysis and has potential applications especially in robotic hand and human-computer interaction (HCI).

Palabras clave — Electromiografía, Mahalanobis, Reconocimiento de Patrones Estadístico.


I. INTRODUCCIÓN

La información proporcionada por las señales mieléctricas (MES) ha sido ampliamente utilizado para la clasificación del movimiento humano en los últimos años. MES son la manifestación eléctrica de la activación neuromuscular asociada con la contracción muscular. La naturaleza de MES tiene una influencia por su capacidad como una señal de control, siendo utilizada como señal de referencia para el control de dispositivos de asistencia para la restauración de la función de la mano humana [1], [2]. Casi todos los enfoques en el pasado han utilizado la señal mieléctrica recogida durante contracciones en el estado estable y esta señal, sobre todo aleatoria, se ha caracterizado por sus propiedades estadísticas [3]. Se requiere una identificación eficaz de los movimientos humanos para comandar interfaz hombre-máquina; MES son el medios para lograr esto, ya que reflejan la intención del movimiento. El reconocimiento de patrones estadístico se enfoca en las propiedades estadísticas de los patrones, un modelo para un patrón puede ser un único conjunto específico de características, a pesar que el patrón detectado haya sido perturbado por alguna forma de ruido aleatorio [4].

Investigaciones que presentan estudios con respecto al rendimiento de los sistemas de control usando como entrada la señal electromiográfica (EMG) se tiene en [5], donde se desarrolla un esquema de control basado en un conjunto de simples estadísticas del dominio del tiempo y un clasificador de red neuronal artificial, capaz de clasificar cuatro tipos de movimiento de las extremidades superiores con MES adquiridas del músculo bíceps y tríceps. En referencia [6] se demostró que el uso de cuatro canales colocados en músculos flexores y extensores de la muñeca ofrece suficiente información para la clasificación continua de señales EMG superficiales. El conjunto de características consistió en estadísticas del TD, que se ingresan al clasificador LDA. El trabajo en [7], consistió en analizar la efectividad de diferentes configuraciones de electrodos en el rendimiento



ISBN: 978-1-5090-2560-2



Finger Movements Classification from Grasping Spherical Objects with Surface Electromyography using Time Domain Based Features

Guadalupe A. Torres

Ingeniería Mecatrónica
Universidad Popular Autónoma del Estado de Puebla
Puebla, Mexico.

Victor H. Benitez

Ingeniería Industrial
Universidad de Sonora
Hermosillo, Mexico.

Abstract—In this paper the classification of fingers gestures that vary in specific mechanical positions is proposed, which consist in distinguish several finger positions with very low mechanical variation. A new approach is presented that is different to the state of the art methods for the classification of fingers movements that have traditionally, focused on very well distinguished gestures from each other. Myoelectric signals (MES) reflect the intention of the movement according to the diameter of the sphere sustained is the objective of the present study. Natural motions are collected by placing electrodes on five muscles on the forearm of six healthy subjects, while performing spherical fastenings. A time domain (TD) feature vector is given as inputs to a linear discriminant analysis (LDA) module. LDA is used as statistical pattern classifier. We show that there exist significant relationship between muscle signals and fingers positions. Therefore, it is possible to categorize each class of finger position, that is, TD feature based provide an effective representation for classification. LDA achieve the assignment of the membership of a MES collected to one fingers position class, which is defined by the diameter of sphere. These results will be useful for analysis of movement of the human hand to improve control of robotic prosthetic hand and man-machine interfaces.

Keywords— myoelectric signal, statistical pattern recognition, classification, linear discriminant analysis.

I. INTRODUCTION

MES associated with limb motions has been widely used for classification of human movement in the last years. These are the electrical manifestation of the neuromuscular activation linked with a contracting muscle; signals are time and force dependent, whose amplitude varies in a random nature above and below the zero value [1]. The nature of MES has an important impact on its faculties as a command signal, being widely used as a reference signal to control assistive devices [2]. Many studies have used MES collected during steady-state contractions and aleatory component has been highlighted by its statistical attributes [3]. An effective identification of human movements is required to command man-machine interface; MES are the able via of achieving this due to they reflect motion intention. TD features arranged on statistical properties of patterns, allow statistical pattern recognition. A model for a pattern vector may be a specific set of features, despite the actual sensed pattern has been affected by random noise [4].

A pattern is represented by a set of attributes, viewed as a d -dimensional feature vector. Usually, attributes are numerical representation of MES and TD features are one kind of representation that facilitate its statistical analysis. To identify a MES belonging to a predefined class, decision frontiers between pattern classes are established. Those boundaries are set using concepts of statistical decision theory. A typical recognition module is operated in two stages: training and validation [5].

A particular muscular movement generates a MES pattern, thereby feature vector pattern is movement dependent [6]. At present, it has not been possible to obtain a single parameter to appropriately reflect the characteristics of MES measured. Because of this, a set of characteristics should be chosen as input to a stage of pattern classification. Ideally, is desired a set of features that takes out enough information from MES to recognize dissimilar types of finger movement [7]. Therefore, TD characteristics are more effective due to they takes a smaller dimension vector and homogenize the variance within class [8]. Aforementioned investigations indicate the effectiveness of feature selection stage; it is crucial for a reliable classification and a way to improve the accuracy of the classification of MES patterns [8]. An agreement that can be established from such studies is that, even if a capable classifier may deliver a notable classification, feature selection is critical to overall performance [3]. Research related to the issue of classification of finger and hand movements taking advantage of MES, have conducted experiments consisting in hand gestures and fastening objects of common use, achieving high rates in classification results. However, in this study, our approach consists in classifying the mechanical position of fingers based in grasping spherical objects that differ in diameter, that is, its shape is constant. It is expected that moderate changes in finger position are such that, muscle contraction, though slight, achieves an amplitude variation of specific MES. If this take place, it could be distinguish a discriminant features vector.

This paper is organized as follows: in section 2, a description of statistical method LDA is introduced. The methodology to obtain the data sets is presented in section 3. In section 4, several traditional TD features selected to estimate the extracted feature vectors are exhibited. Experimental setup



<http://www.mecamex.org/congreso-nacional>