

UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA



Profesor Patrocinante:

D.Sc. Esteban Pino Quiroga

Informe de Memoria de Título
para optar al título de:

Ingeniero Civil Biomédico

**Algoritmo de Estimación de Movimientos de los
Dedos de la Mano a Través de un Arreglo de
Sensores de Electromiografía Superficial**

UNIVERSIDAD DE CONCEPCIÓN

Facultad de Ingeniería

Departamento de Ingeniería Eléctrica

Profesor Patrocinante

D.Sc. Esteban Pino Quiroga

Algoritmo de Estimación de Movimientos de los Dedos de la Mano a Través de un Arreglo de Sensores de Electromiografía Superficial

Enrique Ignacio Germany Morrison

Informe de Memoria de Título

para optar al Título de

Ingeniero Civil Biomédico

Marzo 2014

Resumen

La prótesis es la disciplina encargada de generar dispositivos para reemplazar partes del cuerpo que se han perdido por accidentes traumáticos o por problemas congénitos. Desde siglos se han ido desarrollando diversos prototipos de dispositivos y con el paso del tiempo y la integración tecnológica, han aumentado sus grados de destreza y capacidad para asimilar movimientos más completos y naturales.

El control mioeléctrico ha permanecido como el principal método de control a utilizar por diversos desarrolladores a lo largo del mundo, sin embargo, no es suficiente, ya que el funcionamiento muscular es complejo, por lo que herramientas avanzadas son utilizadas para intentar decodificar de buena forma la intención del usuario de la prótesis.

En este trabajo se abarca la aproximación de control mioeléctrico, adoptando un cambio de paradigma desde el control discreto entre clases definidas, decodificadas mediante reconocimiento de patrones, a un mecanismo de estimación continua utilizando funciones de mapeo.

El sistema se compone de dos partes, primero una sección de hardware que realiza la adquisición de datos y segundo, una sección software que realiza la estimación de posición.

La parte de hardware permite de forma simultánea registrar señales de electromiografía (EMG) y de referencia del posicionamiento de los dedos de la mano. Las señales son adquiridas mediante un electromiógrafo de 8 canales y un guante con sensores de flexión respectivamente.

La parte de software debe digitalizar y guardar los datos a modo de utilizarlos en análisis posteriores. Utilizando MATLAB se procesaron las señales y se diseñó e implementó un modelo de redes neuronales artificiales para estimar, desde las señales de EMG, las posiciones de cada dedo de forma independiente. Las señales estimadas se validaron mediante análisis de correlación, con respecto a las señales de referencia del guante.

Los resultados avalan que este método logra de buena forma generar una relación entre la actividad muscular y la posición de cada dedo de forma independiente, lo que otorga mayor libertad de movimientos y no requiere estados discretos que limitan al sistema.



“Creativity is just connecting things. When you ask creative people how they did something, they feel a little guilty because they didn’t really do it, they just saw something. It seemed obvious to them after a while.”

Steve Jobs.

Agradecimientos

El presente trabajo concluye con el apoyo de muchas personas a las cuales quisiera agradecer.

En primer lugar a mis padres, Anita Morrison y Enrique Germany y también a mis hermanos por su apoyo incondicional. Por la formación valórica que me han inculcado, de siempre perseverar y el respaldo económico que me ha permitido desarrollarme como profesional.

A mi profesor tutor D.Sc. Esteban Pino Quiroga por sus consejos y apoyo durante todo el trabajo de memoria.

A los profesores Pablo Aqueveque, Rosa Figueroa, Daniel Sbárbaro, Pamela Guevara, John Atkinson por sus consejos y aportes desde sus propias áreas de interés.

A Alejandro Aguirre por su apoyo e inagotable paciencia en el trabajo de laboratorio.

A Matías Pinto, por su paciencia y ayuda en desarrollar circuitos y modelos de manos robóticas.

A Francesca Saglietto, Benjamin Germany y Rosario Ramos por darme los ánimos de continuar y terminar los trabajos y ayudarme durante todo el proceso de escritura de este documento.

Muchas gracias a todos, ya que sin su apoyo esto no hubiese llegado a término.

Tabla de Contenidos

Índice de figuras	vi
Índice de tablas	viii
Abreviaciones	ix
1. Introducción	1
1.1. Introducción General	1
1.2. Revisión Bibliográfica	4
1.2.1. Introducción	4
1.2.2. Trabajos Previos	4
1.2.3. Anatomía del antebrazo	5
1.2.4. Adquisición y procesamiento	8
1.2.5. Clasificación de señales mioeléctricas	9
1.2.6. Características extraíbles desde EMG	11
1.2.7. Efecto de Cross-Talk.	12
1.3. Discusión	13
1.4. Hipótesis de Trabajo	13
1.5. Objetivos	13
1.5.1. Objetivo General	13
1.5.2. Objetivos Específicos	14
1.6. Alcances y Limitaciones	14
1.7. Metodología	15
2. Hardware de Medición	16
2.1. Electroodos	16
2.2. Electromiógrafo 8 Canales	17
2.2.1. Etapa de Amplificación	17
2.2.2. Etapa de Filtro Pasa Banda	18

2.2.3.	Etapa de Filtro Notch 50 Hz	20
2.2.4.	Etapa de offset para digitalización	20
2.2.5.	Circuito Impreso Módulo EMG	22
2.2.6.	Placa madre del electromiógrafo	23
2.3.	Guante para Medición de Flexión-Extensión de Dedos	26
2.3.1.	Sensores de Flexión	26
2.3.2.	Guante de Adquisición	26
2.4.	Muestreo, Digitalización y Envío Serial	27
3.	Software de Adquisición y Preprocesamiento	28
3.1.	Interfaz Gráfica de Adquisición	28
3.2.	Preprocesamiento	29
4.	Estimación de Posición Mediante RNA	32
4.1.	Introducción	32
4.2.	Redes Neuronales Artificiales	33
4.3.	Resultados	34
5.	Discusiones y Conclusiones	40
5.1.	Discusión	40
5.2.	Conclusiones	40
5.3.	Trabajo Futuro	41
	Bibliografía	42

Índice de figuras

1.	Interfaz músculo electrodo para registro de EMG, adaptado de [3].	2
2.	Señal típica de EMG, en dominio del tiempo.	3
3.	Espectro de frecuencia típico de EMG, adaptado de [3].	3
4.	Músculos y ligamentos del esqueleto de la mano, adaptado de [4]	4
5.	Músculos extensores y flexores de los dedos, adaptado de [7]	6
6.	Proceso de adquisición para EMG, adaptado de [3]	8
7.	Prótesis SmartHand de 16 grados de libertad, adaptado de [13]	10
8.	Tipos de electrodos de superficie, distancias recomendadas y circuitos asociados, adaptado de [10].	12
9.	Esquema de sistema propuesto.	15
10.	Disposición radial de electrodos.	16
11.	Etapas fundamentales para un sistema de adquisición de biopotenciales.	17
12.	Esquemático amplificador de instrumentación INA128PA y seguidor de tensión.	18
13.	Esquemático filtro pasa banda tipo Sallen-Key 4° orden.	19
14.	Simulación de respuesta en frecuencia filtro pasa banda tipo Sallen-Key 4° orden.	19
15.	Esquemático filtro notch 50 Hz tipo Sallen-Key 2° orden.	20
16.	Simulación de respuesta en frecuencia filtro notch 50 Hz tipo Sallen-Key 2° orden.	21
17.	Esquemático del sumador no inversor para adicionar offset regulable.	21
18.	Conector IO módulo EMG.	22
19.	Layout módulo EMG, PCB doble capa (122,2mm * 88,9mm).	22
20.	Fuente dual de alimentación $-9V$ y $+9V$	23
21.	Componentes de la placa madre del electromiógrafo.	24
22.	Layout de placa madre.	25
23.	Dispositivo de adquisición de sEMG ensamblado.	25
24.	Variación de resistencia $15k\Omega - 18k\Omega$ y voltaje del sensor de flexión.	26
25.	Guante para medir Flexión-Extensión de cada dedo de la mano.	27

26.	Interfaz de adquisición de datos en computador.	28
27.	Flexión - Extensión del pulgar.	30
28.	Extracción de características. Ventana de 100 ms. a) RAW EMG, b) IEMG, c) MAV, d) VAR, e) RMS, f) WL.	31
29.	Esquema ilustrativo de la estructura de una red neuronal artificial.	33
30.	Salidas reales y estimadas del conjunto de entrenamiento, $r = 0.940$	35
31.	Histograma de error asociado al conjunto de entrenamiento.	35
32.	Salidas reales y estimadas del conjunto de entrenamiento suavizadas, $r = 0.955$	36
33.	Salidas reales y estimadas del conjunto de prueba, $r = 0.756$	37
34.	Salidas reales y estimadas del conjunto de prueba suavizada, $r = 0.780$	38



Índice de tablas

1.	Listado de los principales músculos del antebrazo y sus funciones en el movimiento de los dedos.	7
2.	Listado con características en el dominio del tiempo	30
3.	Correlación de cada dedo para el conjunto de entrenamiento.	39
4.	Correlación de cada dedo para el conjunto de prueba.	39



Abreviaciones

EMG : Electromiografía.

IEEE : Institute of Electrical and Electronics Engineers (Instituto de Ingenieros Electricos Electrónicos).

IEMG : Integrated Electromyography (Electromiografía Integrada).

LM : Levenberg Marquardt.

MAV : Mean Absolute Value (Valor Absoluto Medio).

MLP : Multi Layer Perceptron (Perceptrón Multi Capa).

PCB : Printed Circuit Board (Circuito Impreso).

RMS : Root Mean Square (Raíz Cuadrática Media).

RNA : Redes Neuronales Artificiales.

sEMG : Electromiografía Superficial.

STFT : Short-Term Fourier Transform (Transformada Corta De Fourier).

VAR : Variance (Varianza).

WL : Wave Length (Largo de Onda).

1 Introducción

1.1. Introducción General

El presente proyecto de memoria de título se enmarca en el contexto del análisis y procesamiento de señales biomédicas, en particular señales mioeléctricas, para obtener información relevante en el ámbito de control de prótesis robóticas.

Desde hace más de 2300 años, existe evidencia de que el ser humano ha intentado recuperar funciones tras perder total o parcialmente parte de miembros inferiores o superiores, acontecimientos que se evidencian con el descubrimiento de un dedo gordo del pie artificial en un cuerpo momificado, fabricado de madera en el Cairo, Egipto.

A través de la historia y con el avance de nuevas tecnologías y materiales, el hombre ha ido perfeccionando los dispositivos prostéticos, utilizando distintas aproximaciones. Desde las primeras prótesis pasivas que sólo abarcaban fines cosméticos y estéticos, pasando luego por dispositivos mecánicos, que mediante movimientos del muñón residual, permiten generar algún grado de movilidad para alguna articulación, como movimiento del codo o apertura/cierre de una pinza. En los últimos años las herramientas computacionales y digitales han impactado de gran manera las soluciones prostéticas. La generación de dispositivos electromecánicos, ha permitido ampliar enormemente los grados de libertad disponibles, con los cuales se ha podido generar movimientos más cercanos a los naturales.

Como menciona Dinesh K Kumar [1], el diseño de interfaces humano-computador es un área de interés en prótesis, donde se busca generar comunicación entre un individuo y un dispositivo robótico de la forma más natural posible. Los músculos corresponden a la fuente de información más utilizada por investigadores y desarrolladores al día de hoy, sin embargo, aproximaciones más novedosas se encuentran investigando directamente el sistema nervioso, a nivel central o periférico. Respecto a la distribución de información y neuro modulación en estos canales, poco se sabe al día de hoy, por lo que esta rama sigue aún en sus inicios.

Este trabajo busca generar un método de adquisición de señal no invasivo, como mencionan

Christian Cipriani et al. [2], cuya información obtenida permita interactuar con dispositivos prostéticos robóticos. Un ejemplo de esto consiste en una mano robótica en la que se pueden controlar la extensión y flexión de cada dedo, permitiendo a un usuario amputado recobrar en parte la funcionalidad de su miembro superior.

Una aproximación no invasiva que resulta natural e intuitiva a utilizar corresponde a la electromiografía de superficie, permitiendo así utilizar electrodos superficiales como interfaz de comunicación entre el músculo del usuario y el sistema prostético. En la Figura 1 se observa la disposición típica de un electrodo sobre la piel, ubicado justo sobre el vientre del músculo. La técnica de electromiografía, permite registrar la actividad eléctrica de los músculos tras su contracción. Esta señal posee valores que son del orden de 0 a $6mV$, un ejemplo de este tipo de señales se puede apreciar en la Figura 2. Respecto a sus características frecuenciales, esta presenta un espectro típico entre los 20 y 150 Hz como se observa en la Figura 3, por lo cual es necesario filtrar la señal eliminando los ruidos de alta y baja frecuencia.




Figura 1: Interfaz músculo electrodo para registro de EMG, adaptado de [3].




Figura 2: Señal típica de EMG, en dominio del tiempo.




Figura 3: Espectro de frecuencia típico de EMG, adaptado de [3].

1.2. Revisión Bibliográfica

1.2.1. Introducción

A continuación se presentan las bases más relevantes de acuerdo a la literatura revisada, entregando una visión de los avances en esta área.

Se abarcan los conceptos anatómicos y fisiológicos del funcionamiento de la mano, y algunos trabajos donde se realizan estudios de las señales mioeléctricas del antebrazo, para obtener información estadística de clasificación y control de interfaces mecánicas.

1.2.2. Trabajos Previos

Se debe comenzar explicando que el movimiento del cuerpo humano es controlado por el sistema nervioso central, el que se comunica con el ente ejecutor – los músculos – mediante las vías nerviosas. La comunicación entre los nervios y los músculos que inervan, se produce en las unidades motoras, las cuales reciben el potencial de acción y provocan la contracción de las fibras musculares que componen el músculo. A su vez, los músculos conectan al sistema esquelético mediante ligamentos y tendones, los responsables de transmitir el movimiento. Lo anterior se observa en la Figura 4.




Figura 4: Músculos y ligamentos del esqueleto de la mano, adaptado de [4]

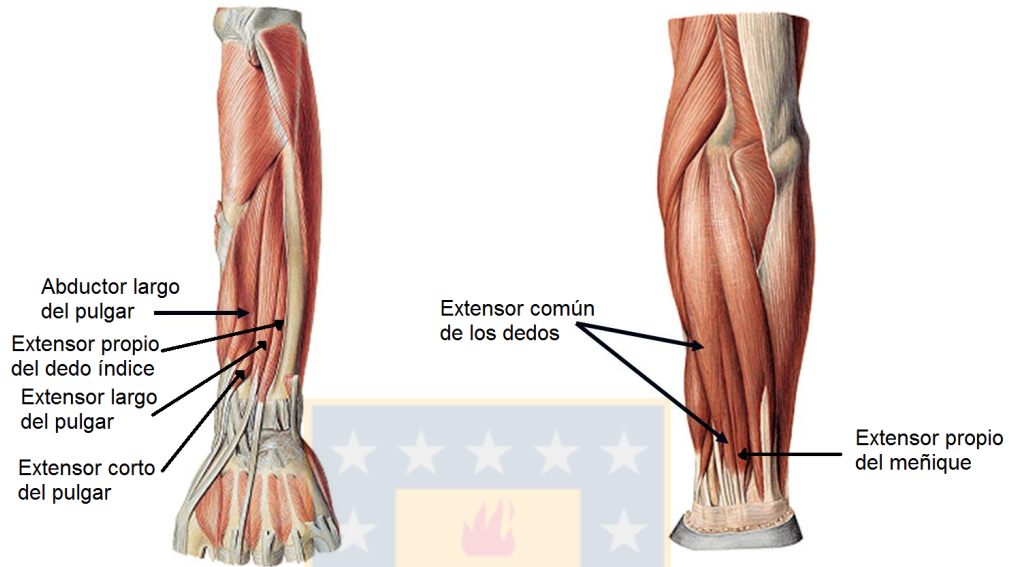
Han surgido diferentes aproximaciones al problema de adquisición de señales para controlar un dispositivo protésico, cada uno haciendo referencia a diversos niveles de adquisición. Primero a nivel muscular mediante electromiografía, que puede ser superficial o profunda. En el caso de electromiografía superficial se tienen por ejemplo los trabajos realizados por T. Scott Saponas et al. [5], en los que logran reconocer movimiento, presión, levantamiento, entre otras características de movimiento de los dedos. Lo anterior demuestra que a nivel de electromiografía superficial se puede utilizar para adquirir información de posicionamiento de los dedos. En el caso de electromiografía profunda, se requiere de electrodos de aguja que atraviesen la piel, lo cual hace impracticable este tipo de adquisición para uso continuo y prolongado, dado las molestias que genera en el paciente. El segundo nivel corresponde a una adquisición directa desde los nervios que inervan los músculos, lo cual obtiene señales con menos ruido producto de que no pasan a través de la piel, sin embargo, se requiere intervención quirúrgica y de electrodos implantables de alta calidad para realizar este tipo de adquisición. Un tercer y último nivel es adquirir los movimientos directamente desde la activación cortical de las señales provenientes de electroencefalografía, sin embargo, este campo es relativamente nuevo y se presentan pocos avances en el área. Esto sumado a la necesidad de cirugía para implantar electrodos en la corteza cerebral, los riesgos asociados y la complejidad en la decodificación de este tipo de señales, hacen inviabilidad este tipo de procedimientos para la adquisición de señales.

Una de las razones para utilizar electromiografía superficial (sEMG) como método de adquisición, es su bajo nivel de invasividad. En el trabajo de Sebastian Meier [6], se establece un procedimiento para obtener señales de sEMG y clasificar los movimientos de los dedos, mediante el entrenamiento de una red neuronal de 3 capas. Este tipo de metodologías se utilizará y explicará más adelante en este trabajo.

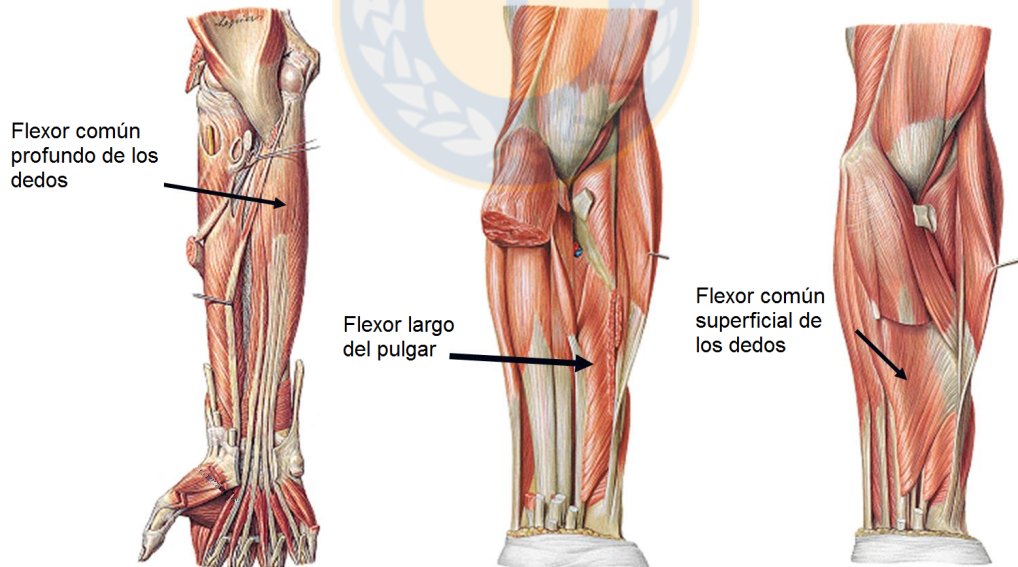
1.2.3. Anatomía del antebrazo

El Dr. Ariel Naveda presenta en su sitio web [7], las características anatómicas del antebrazo con imágenes adaptadas del atlas de anatomía humana Netter [8]. Estas imágenes se presentan

en la Figura 5, donde se observan las posiciones de los músculos involucrados en las funciones de flexión y extensión de los dedos de la mano.



(a) Músculos del grupo posterior del antebrazo.



(b) Músculos del grupo anterior del antebrazo.

Figura 5: Músculos extensores y flexores de los dedos, adaptado de [7]

La Tabla 1 detalla un listado de los músculos relevantes en el movimiento de la mano. De esto se puede obtener la información necesaria para diseñar un mapa de posicionamiento de los electrodos a utilizar en la obtención de las señales, de forma que obtengan información relevante sobre algún movimiento en particular de los dedos de la mano.

Tabla 1: Listado de los principales músculos del antebrazo y sus funciones en el movimiento de los dedos.

Músculo	Función.
Flexor común profundo de los dedos	Flexor de la muñeca, de los metacarpianos y de las terceras falanges sobre las segundas.
Flexor largo del pulgar	Flexor de la segunda falange del pulgar sobre la primera.
Flexor común superficial de los dedos	Flexor las segundas falanges de los dedos sobre la primera.
Abductor largo del pulgar	Abductor del pulgar y de la mano. Extensor de la mano.
Extensor corto del pulgar	Extensor y abductor del pulgar.
Extensor largo del pulgar	Extensor del pulgar.
Extensor propio del dedo índice	Extensor del dedo índice.
Extensor común de los dedos	Extensor de las falanges sobre los metacarpianos y estos sobre el antebrazo.
Extensor propio del meñique	Extensor del dedo meñique.

1.2.4. Adquisición y procesamiento

El proceso de adquisición de biopotenciales, entre los que se encuentra la electromiografía, cuenta con procedimientos bastante estandarizados. Como ilustra Jamal, M. [3], en la Figura 6, la actividad eléctrica del músculo es transformada a un voltaje en los electrodos. Este voltaje es filtrado y amplificado a niveles que puedan ser procesados por circuitos digitales, en donde es digitalizado y enviado a un computador para su procesamiento.

Respecto al procesamiento de los datos, no existe un procedimiento estándar y suele depender de la aplicación. Para utilizar la señal de EMG en dispositivos prostéticos, generalmente se extraen características en el dominio del tiempo o dominio de la frecuencia como se detalla en el capítulo 3.

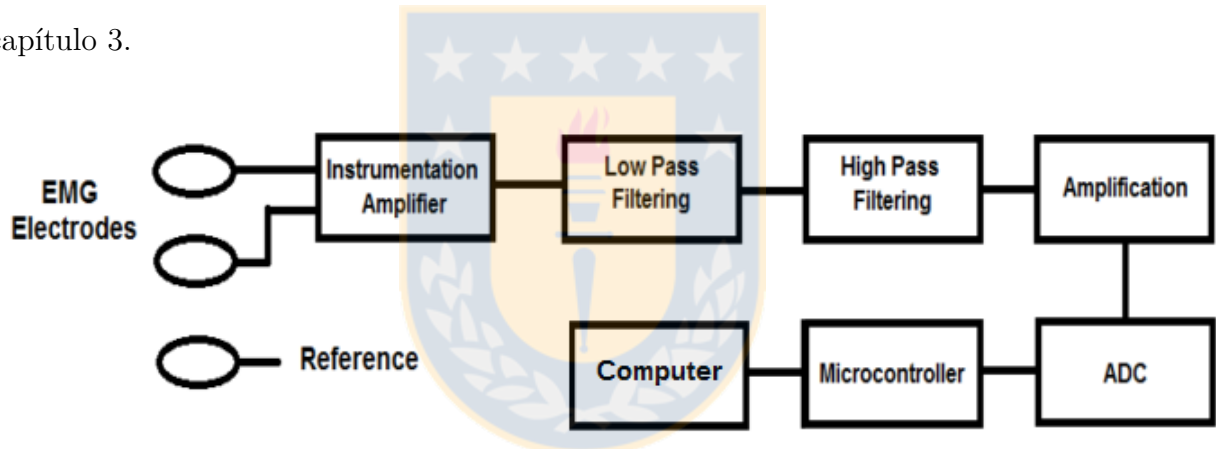


Figura 6: Proceso de adquisición para EMG, adaptado de [3]

1.2.5. Clasificación de señales mioeléctricas

Se plantea en la literatura el control de una mano robótica mediante registros de electromiografía superficial. En su trabajo, Cipriani, C. et al. [2], utilizan como método de clasificación el algoritmo de k-vecinos cercanos, con un parámetro de $k = 8$ vecinos. Los datos mediante los cuales se entrena el clasificador provienen de los canales de electromiografía y de la posición de los dedos, registrados por un guante, el cual tiene sensores en cada una de las articulaciones. Mediante este set de datos se registran diversos movimientos, que luego se relacionan con la señal eléctrica que los genera. El método es capaz, posteriormente, de predecir el movimiento basándose en nuevas mediciones de EMG. En particular es rescatable el posicionamiento y procesamiento de las señales de EMG que utilizan para disminuir el efecto de cross-talk. Dado que trabajaron con pacientes amputados a diferentes niveles, fue imposible estandarizar el posicionamiento de los electrodos, por lo cual la metodología empleada consistió en ubicar cada electrodo sobre el vientre de los músculos mencionados en la Tabla 1, maximizando visualmente la distancia entre los electrodos. El procesamiento empleado para los canales de EMG, consistió en el valor absoluto medio (MAV), de forma de obtener una lectura de la actividad muscular asociada a cada canal.

T. Scott Saponas et al. [5], presentan resultados de clasificación de movimiento y presión ejercida, por los dedos de la mano. La metodología utilizada obtiene señales de electromiografía superficial, provenientes de una banda de 10 sensores, ubicada en forma circular en el antebrazo. Como algoritmo de clasificación, utiliza una máquina de soporte vectorial. Esta es entrenada con muestras de cada clase, las cuales también son definidas en forma discreta. Las clases representan tanto presión leve, como moderada o fuerte, según umbrales definidos y posiciones particulares de los dedos, de acuerdo a información recolectada por un guante de adquisición. Los resultados experimentales demuestran una tasa cercana al 80 % de exactitud para posición y presión de los dedos de la mano.

Meier, S. et al. [6], entregan resultados experimentales para la clasificación de movimientos de dedos de la mano, también mediante una máquina de soporte vectorial. Como método de

obtención de sus señales de EMG, utiliza un arreglo de 8 sensores diferenciales. Estos se ubican sobre diferentes fascículos de fibras musculares del antebrazo. Los sensores utilizados tienen la característica de poseer ganancia ajustable hasta cien mil veces, logrando de esta forma salidas de hasta 4.49 volts. De los resultados experimentales, obtienen que a medida que incrementan la cantidad de clases (gestos) disminuye el porcentaje de clasificación correcta, desde un 98 % aproximadamente para 5 clases a un 91 % aproximadamente para 11 clases.

Antfolk, C. et al. [13], presentan un sistema de control para múltiples grados de libertad, basado en redes neuronales para reconocimiento de patrones, en los que discriminan 7 posiciones. Se cuenta con feedback de presión para los actuadores y con un sistema que ejerce presión sobre el muñón, de forma proporcional a la fuerza ejercida por la mano robótica, uno por cada dedo. La prótesis de mano utilizada corresponde a la SmartHand [18-19], diseñada por los mismos autores, la cual cuenta con 16 grados de libertad, 3 por cada dedo y uno para la oposición del pulgar. Esta prótesis se ilustra en la Figura 7.




Figura 7: Prótesis SmartHand de 16 grados de libertad, adaptado de [13]

En general aproximaciones que utilizan sistemas de clasificación discretas [14] tienen buenos resultados, sin embargo, son extremadamente limitantes en las funciones que se pueden ejercer.

Las metodologías mencionadas anteriormente se basan en un control ON/OFF con la activa-

ción de algún músculo y selección del tipo de agarre mediante otro músculo. Recientemente nos encontramos frente a un cambio de paradigma, que utilizando el potencial de las Redes Neuronales [15], buscan una estimación continua de la flexo-extensión de cada falange, permitiendo así un mayor grado de libertad de movimiento al usuario.

Experimentos en [16] con personas amputadas demuestran que la aplicabilidad de estas técnicas, mediante registros de EMG, son posibles pese a los cambios fisiológicos típicos que estas personas presentan. Para los individuos amputados, estas técnicas que requieren entrenamiento son utilizadas mediante el paradigma de entrenamiento espejo [17]. En este tipo de entrenamiento se le solicita al usuario que haga un mismo movimiento en ambas manos de forma simultánea, mientras se le registra la actividad electromiográfica en la extremidad de amputación. En la extremidad sana se le coloca un guante de adquisición que registra la información mecánica del movimiento de los dedos.

1.2.6. Características extraíbles desde EMG

Se exponen en [9] las bases de la electromiografía, métodos de clasificación y procedimientos para obtener características relevantes en la señal y formar el espacio de características utilizado por el método de clasificación o estimación. Destacan características en el dominio del tiempo, como por ejemplo: valor absoluto medio (MAV), electromiograma integrado, raíz cuadrática media (RMS), largo de onda (WL), etc. Relaciones entre una misma señal o varias señales como el índice de auto-correlación cruzada y coeficiente de correlación. También se pueden obtener algunas características en el dominio de la frecuencia, como por ejemplo: magnitud de poder espectral y transformada corta de Fourier (STFT). Otros procesamientos como la transformada de wavelet y estadísticas de orden superior, también pueden aportar información de la señal dependiendo del método que se utilice.

Como métodos de clasificación se utilizan principalmente métodos de redes neuronales artificiales, como un perceptrón multicapa, y métodos de análisis de discriminantes lineales.

1.2.7. Efecto de Cross-Talk.

El efecto de cross-talk hace referencia a la contaminación de la señal de un canal con la señal de otro. Esto se produce debido a que sus electrodos se encuentran muy cercanos unos a otros. En el trabajo de De Luca, C. [10], se hace énfasis en la separación que se debe considerar entre los electrodos para disminuir este efecto. En la figura 8 se establecen las distancias para las configuraciones de electrodos diferenciales simples y doble diferencial, tanto de barra, como de disco. Se concluye en este trabajo tras diversas pruebas, que para obtener el menor nivel de cross-talk la distancia óptima a utilizar es de 10 mm.

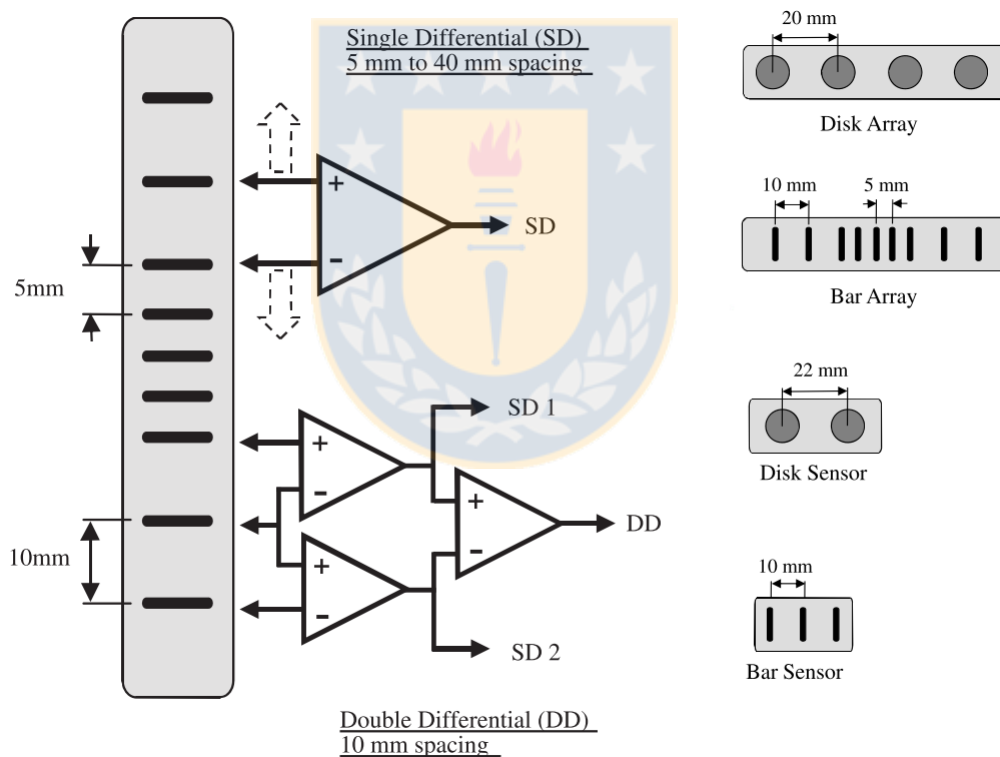


Figura 8: Tipos de electrodos de superficie, distancias recomendadas y circuitos asociados, adaptado de [10].

1.3. Discusión

En la sección anterior se revisó la bibliografía relevante que hace referencia a trabajos similares en el campo de prótesis y rehabilitación. Se identificaron los sensores a utilizar, correspondientes a electrodos de disco en configuración diferencial simple, y el procedimiento para obtener la señal que consiste en electromiografía de superficie, distribuido en 8 canales.

Con los trabajos citados anteriormente se puede ver que es factible realizar la clasificación o estimación de posición, de los dedos de la mano, mediante técnicas no invasivas de electromiografía superficial. Es destacable señalar que en todos los trabajos citados, en los cuales son utilizadas estas técnicas, se han obtenido porcentajes cercanos al 80 % de exactitud.

La literatura muestra que métodos basados en electromiografía superficial, son suficientes después de un buen entrenamiento, para estimar la posición de los dedos en tiempo real. Esto permite establecer que este tipo de metodologías son útiles para el control de prótesis con movimientos diestros.

1.4. Hipótesis de Trabajo

Mediante una interfaz músculo-computador se puede lograr una detección y estimación continua a tiempo real de la posición de cada dedo de la mano.

1.5. Objetivos

1.5.1. Objetivo General

Desarrollar, diseñar e implementar un algoritmo que mediante la adquisición de datos, de electromiografía superficial de los músculos del antebrazo, y la utilización un método de aprendizaje de máquina, como Redes Neuronales Artificiales, permita distinguir el movimiento de los dedos de la mano y estimar su posición flexión-extensión a tiempo real.

1.5.2. Objetivos Específicos

- Desarrollar un dispositivo de EMG, que permita obtener desde un arreglo de electrodos, los distintos canales de electromiografía de los músculos del antebrazo.
- Implementar un guante de sensores de flexión, que permitan medir el grado de flexo-extensión de cada dedo en forma individual.
- Adquirir señales de EMG y del guante, para diversos movimientos de los dedos.
- Diseñar el algoritmo y procesamiento para acondicionar las señales a procesar.
- Diseñar y aplicar una Red Neuronal Artificial, para realizar una función de mapeo entre señal de EMG y posición de flexo-extensión.
- Evaluar el rendimiento del modelo.

1.6. Alcances y Limitaciones

Se establece que el trabajo abarcará desde las etapas de adquisición de señales, pre-procesamiento, generación de un modelo de predicción mediante RNA y estimación posterior de los movimientos de los dedos de la mano. Se establece que el sistema será capaz de entregar señales útiles para el control de una mano robótica, sin embargo, el diseño de la mano protética articulada y su control, quedan fuera del alcance de la actual memoria de título.

1.7. Metodología

Se desarrollará el dispositivo sensor que contará con electrodos diferenciales y con ganancia ajustable, el cual capturará la señal de EMG desde los músculos que realizan flexión y extensión de los dedos. Estos canales de EMG, serán capturados por medio de un microcontrolador, y serán almacenados en un computador para analizar las señales y obtener las transformaciones matemáticas que permitan generar las características a utilizar por el método de estimación. Se crearán conjuntos de entrenamiento de diferentes movimientos, como por ejemplo abrir la mano, cerrar la mano, extender el dedo índice, etc. Con los datos obtenidos se entrenará una red neuronal que permitirá estimar la posición de cada dedo. Luego, adquiriendo señales nuevas, mediante el mismo sistema, se utilizará la red ya entrenada para estimar las posiciones, comparándolas con las obtenidas por el guante de medición y generar índices de similaridad que permitan evaluar el rendimiento de la estimación. Un esquema del sistema propuesto se puede observar en la Figura 9.

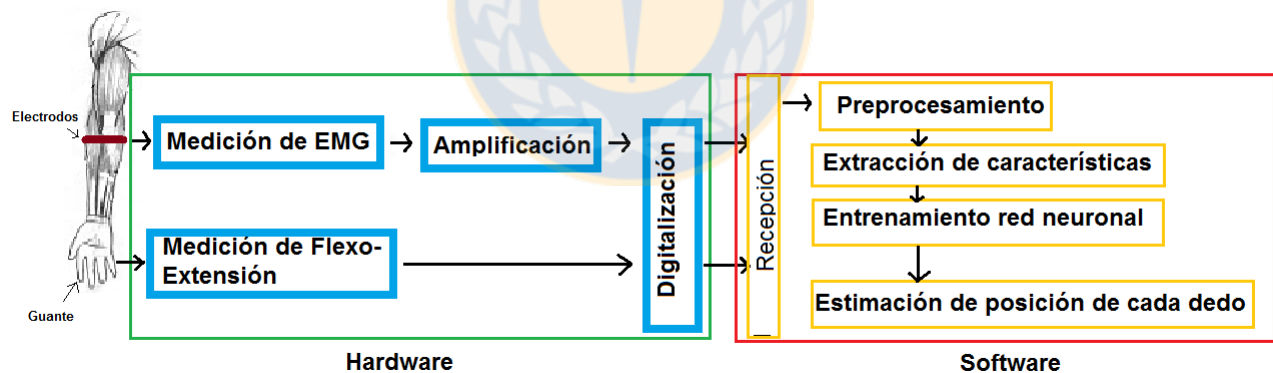


Figura 9: Esquema de sistema propuesto.

2 Hardware de Medición

2.1. Electrodo

Se utilizan 8 pares de electrodos de Ag/Ag-Cl modelo 2228 de 3M® ubicados en forma radial sobre la mitad superior del antebrazo, más un electrodo de referencia en el codo. Esta disposición es adoptada frente a la de mapeo correlativo músculo a músculo, dado que ofrece mayor portabilidad y generalidad a la hora de utilizar el dispositivo. De esta forma se tiene una posición fija donde situar los electrodos, facilitando la adaptación a distintos sujetos sin importar las variantes anatómicas que presenten. Además, dependiendo del grado de amputación que presenten podría darse el caso de que ciertas zonas no estén disponibles, en particular los sectores ubicados en las proximidades de la muñeca. La disposición adoptada se puede apreciar en la figura 10 registrando la actividad muscular de los músculos detallados en la Tabla 1.




Figura 10: Disposición radial de electrodos.

2.2. Electromiógrafo 8 Canales

De acuerdo a los trabajos de Cipriani et al. en [2], la utilización de un arreglo de 8 sensores para registrar datos de sEMG en los músculos del antebrazo, son suficientes para detectar el nivel de activación muscular de los mismos. Dado lo anterior, se trabajó en la construcción de un electromiógrafo de 8 Canales.

El diseño del circuito para la adquisición de sEMG es obtenido del trabajo de un electromiógrafo monocanal desarrollado por Espinoza F. [12], y sigue la metodología estándar de un sistema de adquisición de biopotenciales como se muestra en la Figura 11.

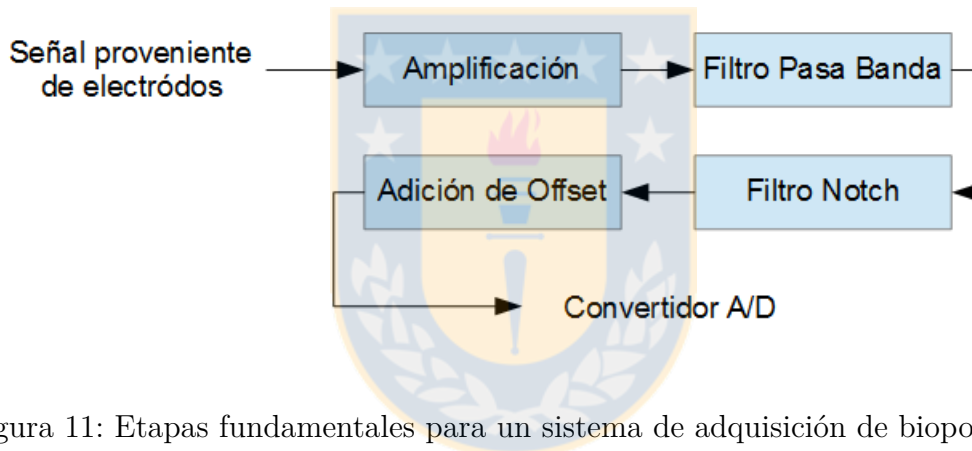


Figura 11: Etapas fundamentales para un sistema de adquisición de biopotenciales.

Mediante la utilización de hardware dedicado, se generan los diferentes canales como múltiples instancias replicadas del circuito de adquisición.

2.2.1. Etapa de Amplificación

Los biopotenciales provenientes de los músculos, dado que se adquieren de forma diferencial mediante un par de electrodos, requieren un amplificador diferencial. Es por esto que se utiliza un amplificador de instrumentación INA128PA, cuya salida se conecta a un seguidor de tensión, para aislarlo de las próximas etapas. En la Figura 12 se ilustra el esquemático.

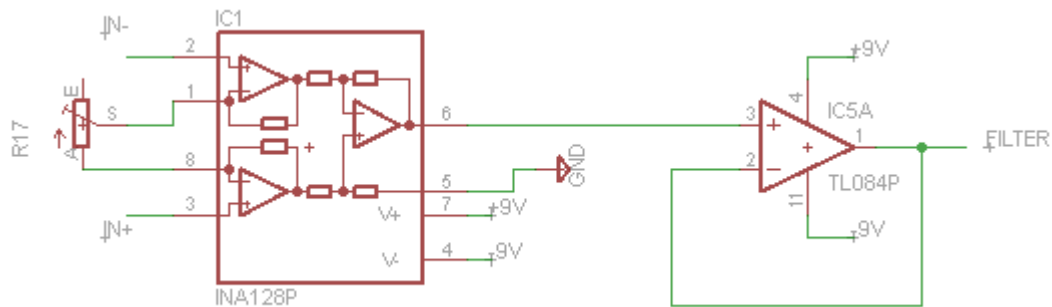


Figura 12: Esquemático amplificador de instrumentación INA128PA y seguidor de tensión.

La ganancia G de un INA128PA está dada por:

$$G = \frac{50k\Omega}{Rg}$$

Siendo $Rg = R17$, donde $R17$ es un trimmer multivuelta de $50k\Omega$, permitiendo ajustar la ganancia entre 1 e ∞ , limitado por la alimentación del integrado. De esta forma se pueden ajustar individualmente las ganancias a modo de que cada canal de EMG ocupe el rango completo de conversión, debido a que las amplitudes de cada canal variarán en amplitud máxima, producto del tamaño de cada músculo y de la profundidad a la que se encuentren.

2.2.2. Etapa de Filtro Pasa Banda

Dadas las características en frecuencia que presenta la señal de sEMG, se utiliza un filtro pasa banda de cuarto orden del tipo Sallen-Key como se aprecia en la Figura 13, para eliminar el ruido de baja y alta frecuencia.

De acuerdo a la simulación de la respuesta en frecuencia de este filtro, como se observa en la Figura 14, se obtiene una banda de amplificación entre los 15 Hz y los 740 Hz, logrando la máxima amplificación entre los 30 Hz y los 550 Hz, con lo cual cumple los criterios especificados para las señales de electromiografía, permitiendo solo señales que se encuentren dentro del espectro típico de la señal de EMG.

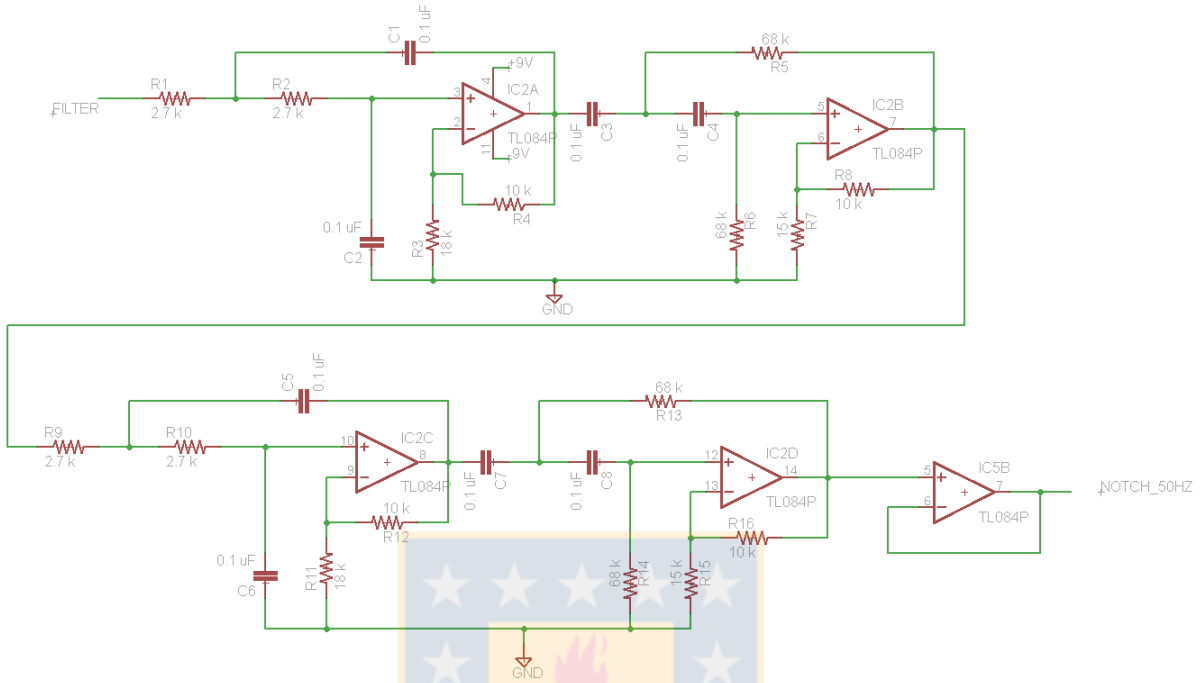


Figura 13: Esquemático filtro pasa banda tipo Sallen-Key 4° orden.

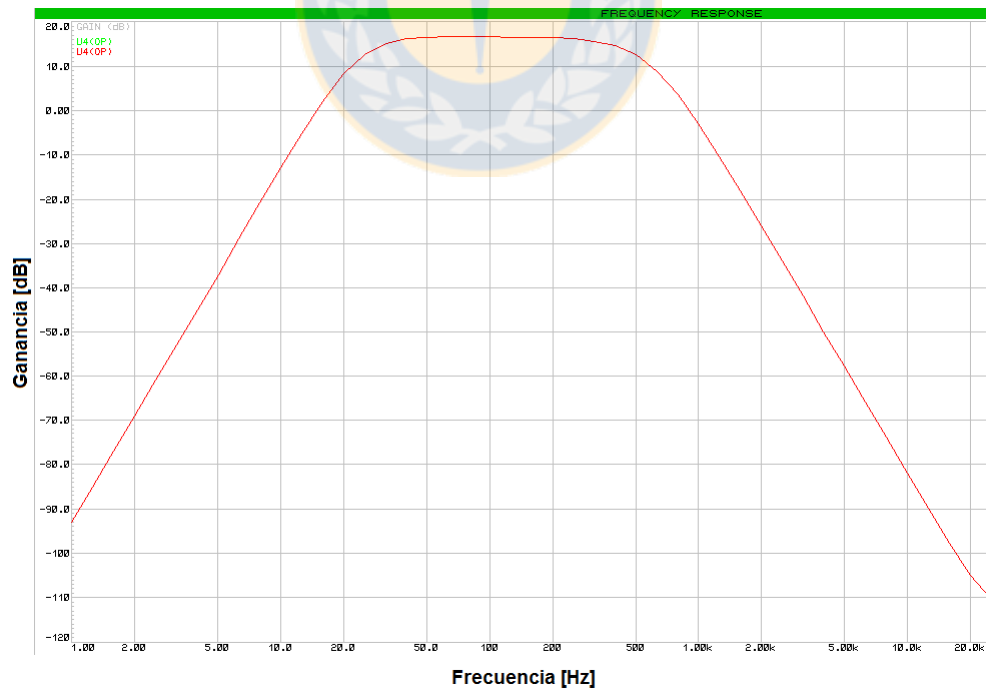


Figura 14: Simulación de respuesta en frecuencia filtro pasa banda tipo Sallen-Key 4° orden.




Figura 15: Esquemático filtro notch 50 Hz tipo Sallen-Key 2° orden.

2.2.3. Etapa de Filtro Notch 50 Hz

La frecuencia de la red eléctrica en el país es de 50 Hz, con lo cual todos los artefactos que nos rodean contaminan de forma inductiva corrientes en circuitos cercanos, por lo que un filtro notch se hace necesario. Se utiliza una topología Sallen-Key de segundo orden como se muestra en la Figura 15.

De acuerdo a la simulación de la respuesta en frecuencia de este filtro, como se observa en la Figura 16, se obtiene una atenuación de -21 dB centrado en la frecuencia de 50 Hz, con lo cual se consigue reducir los errores de medición de la señal de EMG provenientes del ruido de la red eléctrica.

2.2.4. Etapa de offset para digitalización

Dada la naturaleza de la señal de sEMG la señal presenta media nula (en la cual los valores alternan entre valores positivos y negativos), cuya amplitud es determinada por el nivel de activación muscular. A modo de digitalizar esta señal, se requiere ajustar el offset, ya que el convertor A/D trabaja con voltajes entre 0V y 3,3V.

Para agregar un nivel de voltaje constante se adiciona un sumador no-inversor, en el cual




Figura 16: Simulación de respuesta en frecuencia filtro notch 50 Hz tipo Sallen-Key 2° orden.

se suman las señales de sEMG y un voltaje regulable entre $-9V$ y $+9V$ mediante un trimmer multivuelta, a modo de generar una señal centrada en $1,65V$, logrando utilizar la mitad superior del rango de conversión para los valores positivos y la mitad inferior para los valores negativos. El esquemático del circuito se observa en la Figura 17.




Figura 17: Esquemático del sumador no inversor para adicionar offset regulable.




Figura 18: Conector IO módulo EMG.

2.2.5. Circuito Impreso Módulo EMG

Definidas y simuladas todas las partes que componen módulo de amplificación para sEMG, se generó un circuito impreso (PCB) con un conector de 6 pines machos, como se muestra en la Figura 18, módulo que se replica 8 veces para cada uno de los canales de adquisición. La disposición física del circuito se observa en la Figura 19.

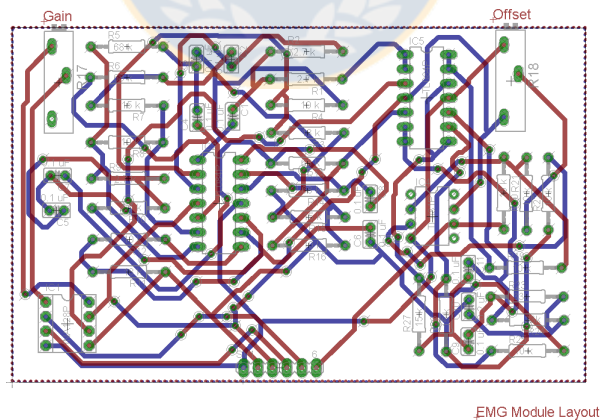





Figura 19: Layout módulo EMG, PCB doble capa ($122,2mm * 88,9mm$).



(a) Conectores de salida de las señales de EMG.



(b) Conectores para las Tarjetas de Condicionamiento de EMG.



(c) Entradas desde los cables de electrodos.

Figura 21: Componentes de la placa madre del electromiógrafo.






Figura 22: Layout de placa madre.

Una vez desarrollados los circuitos impresos, las placas se fabrican utilizando componentes DIL. Con todos los componentes soldados en sus posiciones terminales, se ensambla el equipo como se observa en la Figura 23.



(a) Módulo EMG ensamblado



(b) Equipo de adquisición ensamblado

Figura 23: Dispositivo de adquisición de sEMG ensamblado.

2.3. Guante para Medición de Flexión-Extensión de Dedos

2.3.1. Sensores de Flexión

Para evaluar la posición de los dedos en términos de su flexión-extensión y obtener una medición que permita establecer una relación con las lecturas de sEMG, se construyó un guante con sensores de flexión en cada dedo. Un sensor de flexión corresponde a un dispositivo resistivo variable, cuyo valor varía con el grado de flexión del mismo, como se observa en la Figura 24.

Los sensores utilizados corresponden a los Flex Sensor de Spectra Symbol [20], en su versión de 4,5" [11.48 cm] de largo, tienen un valor nominal de $15k\Omega$ completamente estirados y de $18k\Omega$ en máxima flexión de los dedos (en promedio).

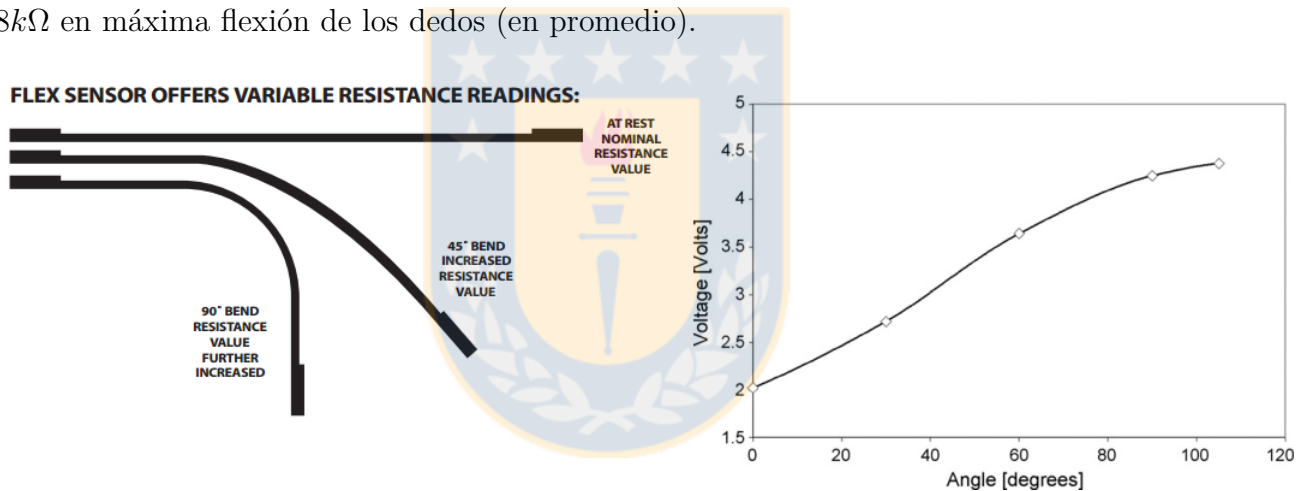


Figura 24: Variación de resistencia $15k\Omega - 18k\Omega$ y voltaje del sensor de flexión.

2.3.2. Guante de Adquisición

Para realizar mediciones del grado de flexión de cada dedo, se posicionó un sensor en cada dedo del guante. Estos sensores fueron conectados a una resistencia fija de $10k\Omega$ formando un divisor de tensión. Dado el funcionamiento de los sensores, el voltaje varía prácticamente de forma lineal con la flexión. El dispositivo ensamblado se puede observar en la Figura 25.



Figura 25: Guante para medir Flexión-Extensión de cada dedo de la mano.

2.4. Muestreo, Digitalización y Envío Serial

Los sistemas de medición, tanto el electromiógrafo como el guante, son conectados a una tarjeta de desarrollo ChipKit Max32 de Digilent Inc [11]. Esta tarjeta posee un cristal de 16kHz, un microprocesador PIC32MX795F y 16 puertas analógicas de entrada-salida.

El equipo de electromiografía es conectado a las primeras 8 entradas (A0-A7) y el guante, a las últimas 5 (A11-A15). El microcontrolador es configurado de forma que muestree en forma de barrido las 13 entradas. Este barrido se realiza cada $1ms$ con lo que se adquiere una tasa de muestreo de 1kHz para todos los canales de adquisición, logrando una buena resolución en frecuencia de los datos. Estos son digitalizados en 10 bits de resolución con lo cual el rango de valores se sitúa entre 0 y 1023. Los 13 datos forman un paquete de datos y son enviados a un computador con una tasa de 500 kbaud.

3 Software de Adquisición y Preprocesamiento

Con el hardware funcionando, se elaboró un programa para computador en lenguaje Python versión 2.7.6, con una interfaz gráfica que permita conectarse al sistema de adquisición, obtener los datos desde la puerta serial y poder guardarlos en archivos de formato “.csv”. Esta interfaz además permite visualizar la señal de sEMG y del guante una vez finalizada la adquisición, a modo de visualizar errores de adquisición. Los datos son posteriormente importados en Matlab, donde se realiza el resto del procedimiento.

3.1. Interfaz Gráfica de Adquisición

En la Figura 26 se puede observar la interfaz de usuario para adquirir datos desde el sistema de medición.

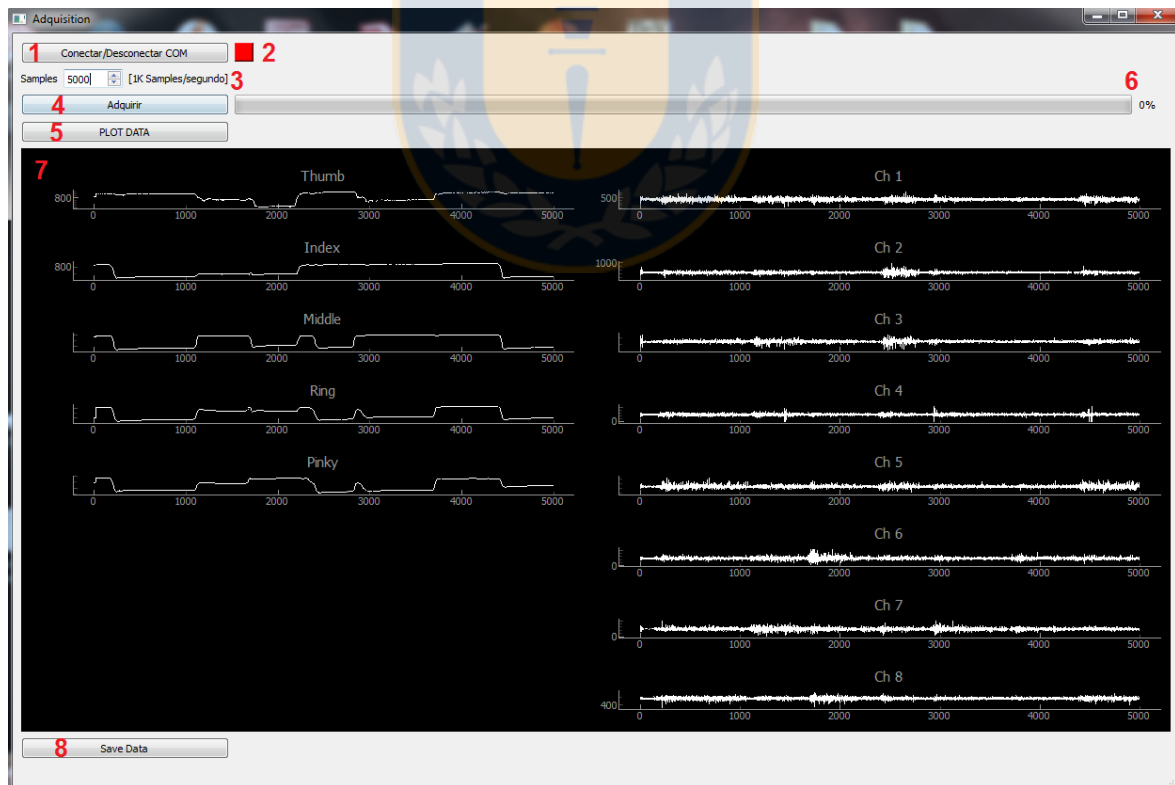


Figura 26: Interfaz de adquisición de datos en computador.

Describiendo la interfaz de usuario numerada en la Figura 26 se tiene:

1. Botón de conexión / desconexión a la puerta serial.
2. Indicador de estado de conexión, Rojo: Desconectado, Verde: Conectado.
3. Cantidad de muestras a recolectar
4. Botón de iniciar la adquisición
5. Botón para graficar datos adquiridos, una vez finalizada la adquisición.
6. Barra de estado indicando porcentaje de progreso de recepción, en base al total de datos solicitados.
7. Visualizador de señales, guante a la izquierda y EMG a la derecha.
8. Botón para guardar los datos adquiridos a un archivo.

3.2. Preprocesamiento

Para realizar procesos de estimación o reconocimiento de patrones es habitual realizar un preprocesado de los datos, asegurando de esta forma que se encuentren en buena condición para los próximos procedimientos. El primer paso corresponde a normalizar cada canal de datos. Este proceso consiste en situar los valores de cada canal en un rango entre 0 y 1, para lo cual se requiere restar a cada valor el mínimo del canal y luego dividir por el máximo. Para los datos adquiridos del guante, el proceso de normalización es el único pre-procesamiento requerido. De esta manera los canales del guante obtienen valor 1 cuando el dedo se encuentre completamente extendido y valor 0 cuando se encuentre completamente flectado. En la Figura 27 se puede apreciar una flexión completa y luego una flexión parcial.




Figura 27: Flexión - Extensión del pulgar.

En cuanto a la señal de sEMG, luego del proceso de normalización descrito anteriormente, es necesario que sea transformada desde su estado natural a alguna característica en el dominio del tiempo. Esto permite obtener información del grado de contracción de los músculos. Luego, se evaluaron diversas características entre las que destacan:

Tabla 2: Listado con características en el dominio del tiempo

Característica en el dominio del tiempo	Expresión matemática
EMG Integrado [IEMG]	$\sum_{n=1}^N x_n $
Valor Absoluto Medio [MAV]	$\frac{1}{N} \sum_{n=1}^N x_n $
Varianza de EMG [VAR]	$\frac{1}{N-1} \sum_{n=1}^N x_n^2 $
Raíz Cuadrática Media [RMS]	$\sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2 }$
Largo de Onda [WL]	$\sum_{n=1}^{N-1} x_{n+1} - x_n $

Para cada una de estas características se seleccionó una ventana de 100 ms, de forma de obtener una buena aproximación de la actividad muscular y a la vez no introducir mucho retardo al sistema actuador. Se realizaron pruebas seleccionando de a una, dos, tres y cuatro de estas características, las cuales conforman un espacio 8, 16, 24 y 32 dimensiones respectivamente, ya que las transformaciones se aplican a cada uno de los 8 canales. Luego, se observó que tomando el valor RMS por sí solo, no se hace necesario adicionar las demás, pues no mejora de forma




Figura 28: Extracción de características. Ventana de 100 ms.
 a) RAW EMG, b) IEMG, c) MAV, d) VAR, e) RMS, f) WL.

significativa los resultados. Esto se explica al comparar el aumento del costo computacional y en el aumento exponencial del tiempo de entrenamiento, con los beneficios en el rendimiento obtenido.

La característica de valor RMS logra entregar una buena estimación, tanto de la actividad contráctil de la musculatura, como de la energía contenida en la contracción. Esto permite conseguir información de la velocidad y magnitud del cambio de posición, además de tener relación con la magnitud de fuerza ejercida en posiciones de agarre. Cabe destacar que las relaciones entre activación muscular y movimiento, no son lineales, por lo que una escala cuadrática como esta permite establecer una mejor relación entre actividad muscular y movimiento de los dedos, logrando diferenciar de mejor forma las zonas de alta actividad contráctil. En la Figura 28 se puede observar un canal de EMG y su representación con las diferentes características, donde el valor RMS obtiene la curva más estable en valor y acentuada en los momentos de contracción.

4 Estimación de Posición Mediante RNA

4.1. Introducción

Ante el creciente desarrollo de dispositivos robóticos, que persiguen recuperar funciones perdidas tras amputaciones, surge la necesidad de generar mecanismos, para obtener las señales de control adecuadas de forma que la persona logre controlar el dispositivo a voluntad. Es el caso de las prótesis de mano robótica, que permiten al usuario sujetar y manipular objetos, en especial aquellas con múltiples grados de libertad.

El control mediante reconocimiento de patrones, se ha vuelto popular en los dispositivos recientes. Este método busca identificar una posición de la mano, de acuerdo a posturas discretas definidas. Esto, si bien ha cobrado adherentes en múltiples prototipos, tiene la limitación de poder generar sólo una finita y restringida variedad de posturas y gestos, restando libertad al usuario.

Un nuevo paradigma surge con mecanismos que logran decodificar la actividad muscular del muñón residual, para identificar la posición que debiese tener el miembro faltante. Esto se ha desarrollado gracias a la aplicabilidad de algoritmos complejos mediante redes neuronales artificiales, que de forma iterativa, logran generar una amplia variedad de funciones lineales y no lineales, logrando ajustar modelos que de forma paramétrica resultarían irrepresentables.

En este trabajo se propone generar una RNA que permita estimar la posición de los dedos (Flexión - Extensión), a partir de señales de electromiografía superficial, obtenidas desde un arreglo de sensores ubicados en la mitad superior del antebrazo. La estimación se lleva a cabo mediante una función de mapeo generada a partir de una sesión de entrenamiento previa, que relaciona datos de entrada con datos de salida de la red, de modo que minimiza el error.

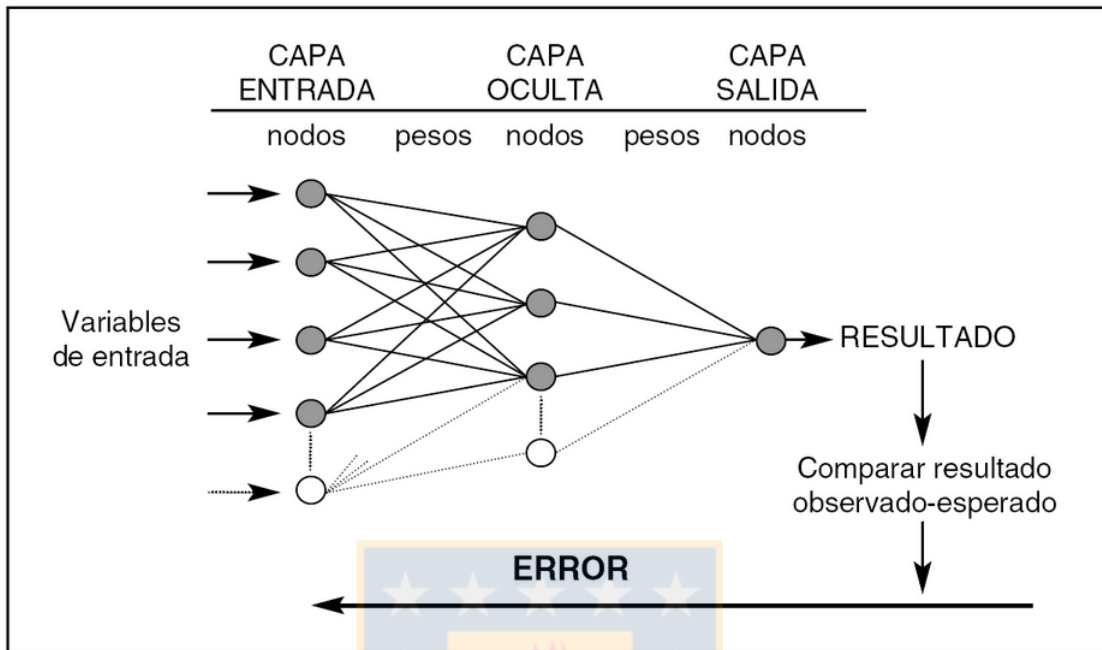


Figura 29: Esquema ilustrativo de la estructura de una red neuronal artificial.

4.2. Redes Neuronales Artificiales

Inspiradas en el sistema nervioso, este tipo de sistemas presenta métodos para establecer relaciones entre variables de entrada y salida de funciones tanto lineales como no lineales, mediante utilización de nodos con funciones sigmoidales y pesos que multiplican al valor de entrada en cada nodo. En la Figura 29 se muestra la disposición estructural de una red.

En el entrenamiento de la RNA, el proceso de aprendizaje funciona de forma iterativa. Esto mediante una ley de adaptación de forma reversa conocida en inglés como “Back Propagation”. Dado los valores de las entradas, se calcula el valor de salida para los nodos terminales y se comparan con la salida esperada. En base al error cuadrático medio se ajustan los pesos desde la última capa hasta la primera de forma proporcional al error y a una tasa de aprendizaje.

$$W_i = W_i + \Delta W_i \quad (1)$$

$$\Delta W_i = \eta(t - o)X_i \quad (2)$$

Para las ecuaciones 1 y 2, W_i es el peso para el nodo i , X_i es la entrada al nodo i , η es la tasa de aprendizaje, t es la salida esperada y o es la salida obtenida.

Utilizando esta lógica de propagación reversa, se hace uso del algoritmo de Levenberg Marquardt (LM) para realizar el entrenamiento, dado que presenta un rápido tiempo de convergencia a soluciones de diferentes índoles. El problema de este método es que requiere una gran cantidad de memoria, debido a que utiliza valores propios e inversión de matrices. Esto hace que no sea conveniente cuando el número de nodos aumenta de forma significativa.

En el caso del sistema propuesto mediante el Neural Network toolbox de MATLAB, se generó una red de 30 neuronas en la capa oculta, 8 neuronas de entrada con los valores RMS de cada canal de EMG y 5 neuronas de salida, para la estimación de posición (flexión extensión) de cada uno de los dedos de la mano. El entrenamiento se realizó con el algoritmo de LM en modo iterativo offline (Batch).

4.3. Resultados

Al sujeto de prueba, con los electrodos y el guante situados en el antebrazo y mano respectivamente, se le solicitó mover los dedos en patrones aleatorios cerrando y abriendo la mano, realizando, diversos movimientos de flexión - extensión con cada uno de los dedos durante este proceso. A través del software de adquisición, se registran 21 conjuntos de datos de entre 5 a 8 segundos de duración. Cada conjunto contiene diferentes movimientos de los dedos, los cuales son utilizados para generar dos conjuntos de aproximadamente 45 segundos, uno para el proceso de entrenamiento de la red neuronal y el otro para validar los resultados de estimación.

Se seleccionan en el primer conjunto de datos, aquellos segmentos que presenten visualmente gran variedad de movimientos. De esta forma se alimenta la red neuronal con datos ricos en información y poca redundancia de movimientos, dando paso al algoritmo iterativo de LM. Tras unos 10 minutos de entrenamiento, en un computador con procesador Intel Core i7 @ 3.5 GHz y 16 GB de ram, la red converge al resultado que se puede apreciar en la Figura 30.

Se obtiene un índice de correlación de 0.940 entre la señal de lectura del guante y la estimación

producida por la RNA. En la Figura 31 se observa la distribución de error que presenta cada dato del conjunto, situando al 90 % de las estimaciones dentro de un rango de error no mayor al 5 % (0.05).

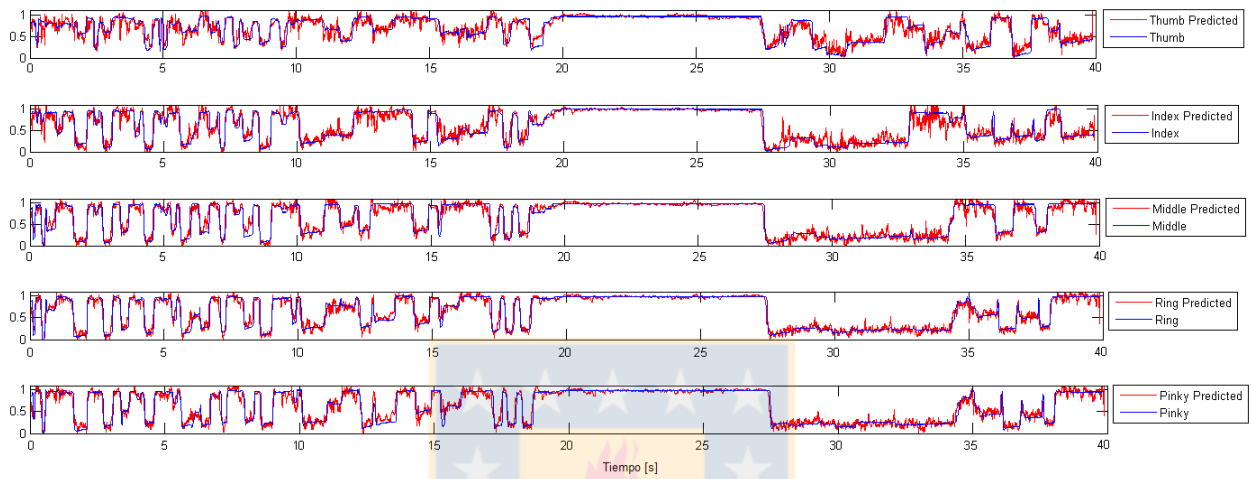


Figura 30: Salidas reales y estimadas del conjunto de entrenamiento, $r = 0.940$.

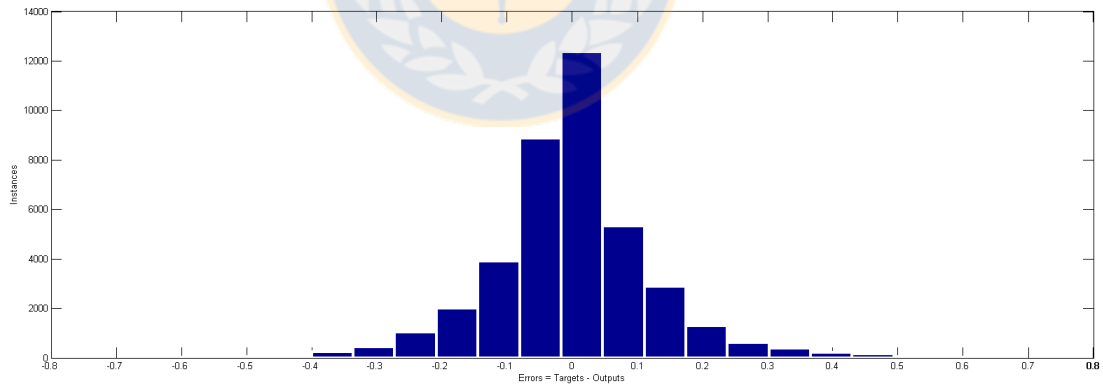


Figura 31: Histograma de error asociado al conjunto de entrenamiento.

Dada la naturaleza de la señal de EMG, su valor RMS presenta alta variación en sus valores, lo cual genera que la estimación proveniente de la red posea también alta variación. Dada esta situación, se plantea realizar un suavizado, promediando las últimas 100 muestras de los valores de salida. El efecto se puede apreciar en la Figura 32, con lo cual, la curva se aproxima más a los valores reales alcanzando un índice de correlación de 0.955.




Figura 32: Salidas reales y estimadas del conjunto de entrenamiento suavizadas, $r = 0.955$.

Utilizando la red neuronal generada, ahora con el segundo set de datos, también de aproximadamente 40 segundos, se obtiene una predicción como se observa en la Figura 33, alcanzando un índice de correlación de 0.756.

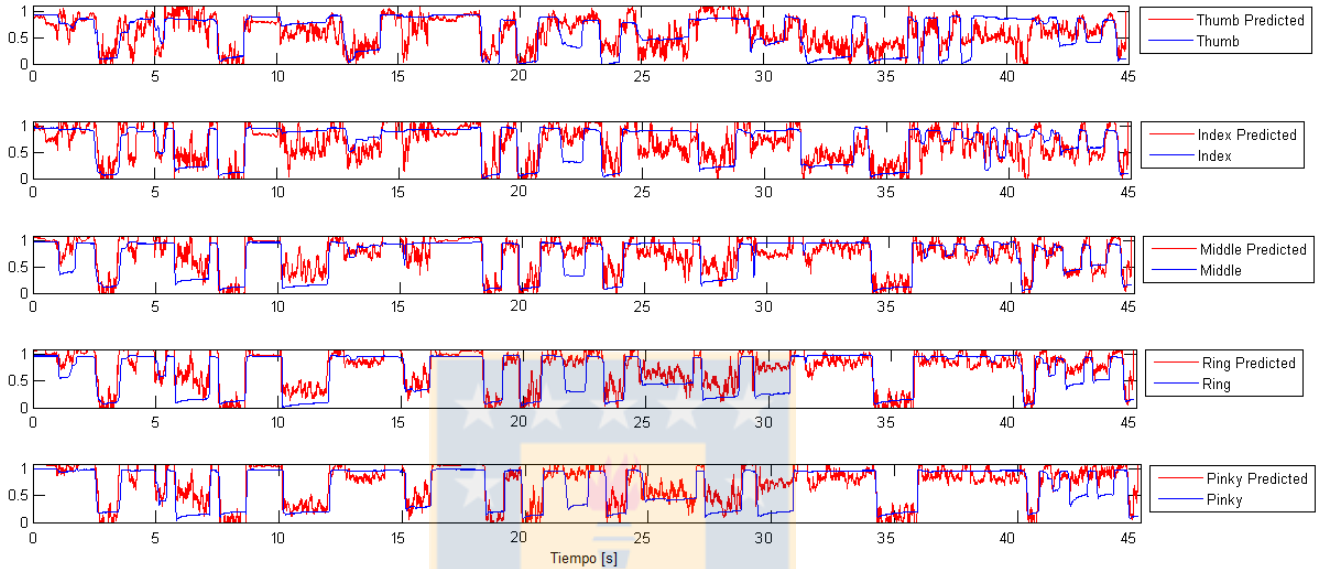


Figura 33: Salidas reales y estimadas del conjunto de prueba, $r = 0.756$.

Realizando ahora el mismo procedimiento de suavizado en esta señal, como se puede apreciar en la Figura 34, se aumenta el índice de correlación a 0.780. Se puede observar que este método logra decodificar de buena forma el movimiento y amplitud de la flexión en cada uno de los dedos. Entre los 35 y 40 segundos se puede ver que la estimación de posición del pulgar, ante movimientos rápidos, no se logra con facilidad. Esto puede ser producto del largo de la ventana de integración para la característica elegida, la cual actúa como filtro pasa bajos. También se pueden notar flexiones que no registran estimación o se registran de forma muy leve, lo que se puede mejorar proporcionando un mayor volumen de datos de entrenamiento a la red.

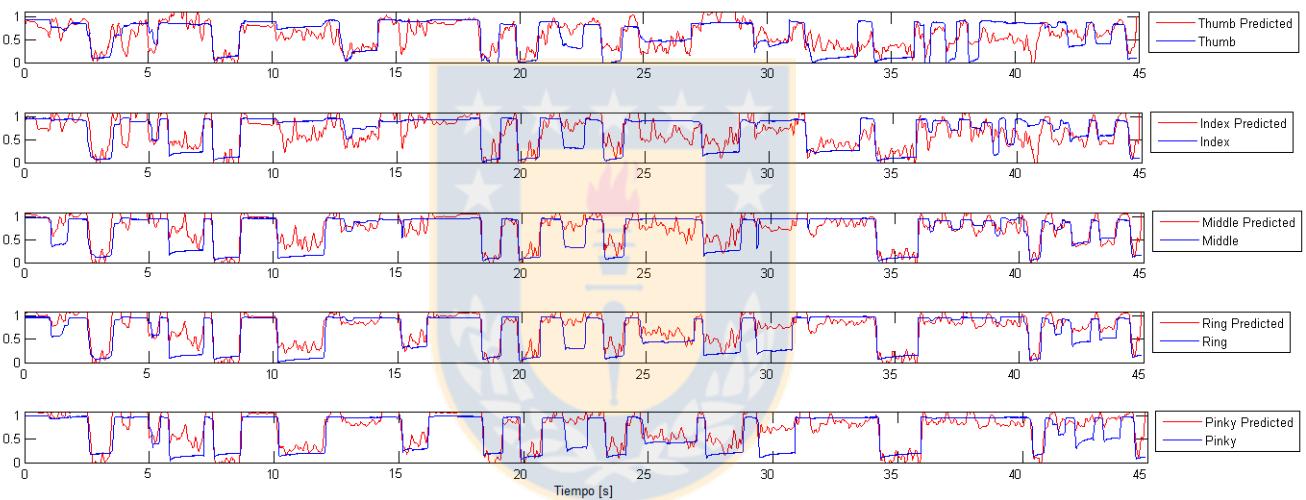


Figura 34: Salidas reales y estimadas del conjunto de prueba suavizada, $r = 0.780$.

En las Tablas 3 y 4 se detallan las correlaciones individuales de cada dedo para cada uno de los casos, con y sin el procedimiento de suavizado. En las cifras se ve de forma clara que las estimaciones no son equivalentes para todos los dedos en cuanto a rendimiento. El pulgar obtiene en todos los casos la peor correlación, el dedo del medio, anular y meñique por su parte desempeñan de la mejor forma y obtienen los valores de correlación mas altos.

Tabla 3: Correlación de cada dedo para el conjunto de entrenamiento.

Dedo	Correlación	Correlación Suavizada (Smooth)
Thumb	0.8971	0.9290
Index	0.9312	0.9517
Middle	0.9531	0.9617
Ring	0.9627	0.9691
Pinky	0.9560	0.9652

Tabla 4: Correlación de cada dedo para el conjunto de prueba.

Dedo	Correlación	Correlación Suavizada (Smooth)
Thumb	0.6801	0.7081
Index	0.6927	0.7224
Middle	0.7870	0.8097
Ring	0.8198	0.8382
Pinky	0.8045	0.8217

5 Discusiones y Conclusiones

5.1. Discusión

De los resultados expuestos anteriormente, se puede decir que obtienen estimaciones bastante cercanas a los establecido en trabajos de otros autores, alcanzando una correlación cercana al 80% entre la posición real del dedo y la estimación mediante sEMG. Es relevante analizar los valores de correlación de cada dedo de forma independiente, donde se aprecia que estos obtienen diferentes porcentajes de exactitud, siendo el pulgar el que obtiene las peores aproximaciones. Este hecho tiene explicación si se contrasta con los grados de libertad que presentan los dedos, teniendo el pulgar mayor libertad de movimiento, lo que genera redundancia de valores al tratar de aproximar su posición con sólo un grado de libertad. Además, el pulgar posee movimientos producto de musculatura que se encuentra en la palma de la mano, los cuales no se registran con los electrodos en el antebrazo, lo que contribuiría también a la disminución de precisión en la estimación.

5.2. Conclusiones

Se desarrolló y construyó el hardware y software necesario para adquirir señales de EMG y de posición de los dedos de la mano. Se diseñó una red neuronal artificial de 3 capas y de 30 neuronas, que se entrenó con los datos recolectados para estimar la posición de los dedos de la mano, utilizando las señales de sEMG como entradas.

De acuerdo a las investigaciones revisadas y al trabajo desarrollado, esta metodología cuenta con capacidad para realizar una buena estimación de la posición de los dedos. Esto demuestra que las señales generadas pueden ser utilizadas como señales de control en un dispositivo prostético.

Se concluye que es posible la estimación de posición mediante técnicas no invasivas, en particular, de electromiografía superficial, para movimientos o gestos de los dedos de la mano. Este método puede ser empleado de forma correcta, aumentando el grado de libertad de acción de

la mano robótica, a diferencia de los enfoques discretos basados en reconocimiento de patrones.

En cuanto a las dificultades encontradas durante el desarrollo de este trabajo, se pueden mencionar algunos problemas al concretar el ensamblado de los circuitos en las PCB. Además, se obtuvieron dificultades durante el proceso de análisis de los datos e interpretación de los resultados con respecto al rendimiento del pulgar como se comentó en la discusión anterior.

5.3. Trabajo Futuro

Como trabajo futuro, se contempla, realizar pruebas con múltiples sujetos tanto sanos como amputados para comprobar empíricamente el rendimiento en distintos escenarios, considerando además los problemas que conllevan las amputaciones, como por ejemplo atrofia muscular.

Se desea también desarrollar un dispositivo protésico robótico de mano, para aplicar el método desarrollado en esta memoria, permitiendo de esta forma continuar mejorando los resultados. Además se agregará mayores características como control de fuerza, otorgando al usuario la capacidad de variar la presión que ejerce al sostener distintos objetos.

Por último, profundizar en estudios de biofeedback para dispositivos protésicos, que permitan entregar al usuario retroalimentación de sentidos, como por ejemplo fuerza y tacto.

Bibliografía

- [1] Dinesh K Kumar, “Robotics to the Rescue: Prosthetic hands help amputees in developing countries”, IEEE BRC “Healthcare for All” conference, March 2013.
- [2] Cipriani, Christian, et al. “Online myoelectric control of a dexterous hand prosthesis by transradial amputees.”, *Neural Systems and Rehabilitation Engineering*, IEEE Transactions on 19.3 (2011): 260-270.
- [3] Jamal, M. Z. “Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis”, *Computational Intelligence in Electromyography Analysis: A Perspective on Current Applications and Future Challenges*.^{ed.} by Ganesh R. Naik (2012): 427-448.
- [4] Ishikawa, K., Toda, M., Sakurazawa, S., Akita, J., Kondo, K., & Nakamura, Y. (2010). “Finger Motion Classification Using Surface-Electromyogram Signals.”, 2010 IEEE/ACIS 9th International Conference on Computer and Information Science, 37–42.
- [5] Saponas, T. Scott, et al. “Demonstrating the feasibility of using forearm electromyography for muscle-computer interfaces.”, *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. ACM, 2008.
- [6] Maier, Sebastian, and Patrick van der Smagt. “Surface EMG suffices to classify the motion of each finger independently.”, *Proceedings of MOVIC 2008, 9th International Conference on Motion and Vibration Control*. 2008.
- [7] Dr. Ariel Naveda, “Anatomía Humana”, Sección de miembro superior, <http://unefaanatomia.blogspot.com/2008/06/musculos-del-miembro-superior.html>, Universidad Nacional Experimental Politécnica de la Fuerza Armada Bolivariana, Visitado Junio del 2013.

- [8] Atlas de Anatomía Humana, 4a Edición. Autor, Frank Henry Netter. Edición, reimpresa. Editor, Elsevier Masson, 2007. ISBN, 8445817590, N° de páginas 548.
- [9] Alexander James Andrews, “Finger Movement Classification Using Forearm EMG Signals”, Master of Science Degree Thesis, Queen’s University, Kingston, Ontario, Canada, Oct. 2008.
- [10] De Luca, Carlo J., et al. “Inter-electrode spacing of surface EMG sensors: Reduction of crosstalk contamination during voluntary contractions.”, *Journal of biomechanics* 45.3 (2012): 555-561.
- [11] Diligent Inc. “Chipkit™ Max32 Board Reference Manual”, Revisión 25 Julio, 2011, <http://www.digilentinc.com/Products/Detail.cfm?Prod=CHIPKIT-MAX32>.
- [12] Espinoza Francisca Marisol, “Sistema de Adquisición de EMG Multifuncional”, Informe de Memoria de Título, Universidad de Concepción, Oct. 2011.
- [13] Antfolk, C., Ctipriani, C., Controzzi, M., Carrozza, M. C., Lindhorg, G., Rosén, B., & Sebelius, F. (2010). Using EMG for real-time prediction of joint angles to control a prosthetic hand equipped with a sensory feedback system. *Journal of Medical and Biological Engineering*, 30(6), 399-405.
- [14] Artemiadis, P. K., & Kyriakopoulos, K. J. (2011). A switching regime model for the EMG-based control of a robot arm. *Systems, Man, and Cybernetics, Part B: Cybernetics*, *IEEE Transactions on*, 41(1), 53-63.
- [15] Nishikawa, D., Yu, W., Yokoi, H., & Kakazu, Y. (1999). EMG prosthetic hand controller using real-time learning method. In *Systems, Man, and Cybernetics, 1999. IEEE SMC'99 Conference Proceedings. 1999 IEEE International Conference on* (Vol. 1, pp. 153-158).

- [16] Ajiboye AB, Weir RF: A heuristic fuzzy logic approach to EMG pattern recognition for multifunctional prosthesis control. *IEEE Trans Neural Syst Rehabilitation Eng* 2005, 13(3):280–291.
- [17] Sebelius, F.C, Rosen, B.N, Lundborg, G.N: Refined myoelectric control in below-elbow amputees using artificial neural networks and a data glove. *JHandSurg* 2005, 30(4):780–789.
- [18] M. Controzzi, C. Cipriani and M. C. Carrozza, “Mechatronic design of a transradial cybernetic hand”, *Proc. of IEEE Int. Conf. on Intelligent Robots and Systems*, 576-581, 2008.
- [19] C. Cipriani, M. Controzzi and M. C. Carrozza, “Progress towards the development of the SmartHand transradial prosthesis.”, *Proc. of IEEE Int. Conf. on Rehabilitation Robotics*, 682-687, 2009.
- [20] Spectra Symbol, “Flex Sensor 4.5” Datasheet”, <http://www.olimex.cl/pdf/Sensors/Flex/FlexSensor.pdf>, Revisión 03 Septiembre 2013.