

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE MONTERREY

CAMPUS MONTERREY

PROGRAMA DE GRADUADOS EN TECNOLOGÍAS DE
INFORMACIÓN Y ELECTRÓNICA



DISEÑO DE UN SISTEMA DE RECONOCIMIENTO DE
MOVIMIENTOS CON UN CUANTIFICADOR MENOR A 12 BITS,
UTILIZANDO SEÑALES EMG Y REDES NEURONALES.

TESIS

Documento presentado para el cumplimiento de los requisitos necesarios
para obtener el grado de Maestro en Ciencias en Ingeniería Electrónica,
con especialidad en Sistemas Electrónicos.

José Alfonso Sánchez de Lucio

Monterrey, N.L., Septiembre 2007

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS SUPERIORES DE MONTERREY

CAMPUS MONTERREY

PROGRAMA DE GRADUADOS EN TECNOLOGÍAS DE INFORMACIÓN Y ELECTRÓNICA

Los miembros del comité de tesis recomendamos que la presente tesis de José Alfonso Sánchez de Lucio sea aceptada como requisito parcial para obtener el grado académico de Maestro en Ciencias de Ingeniería Electrónica, con especialidad en Sistemas Electrónicos.

Comité de Tesis

M.C. Artemio Aguilar Coutiño
Asesor

Dr. Graciano Dieck Assad
Sinodal

Dr. José Ramón Rodríguez Cruz
Sinodal

Dr. Graciano Dieck Assad
Director del Programa de Graduados.
Septiembre de 2007

Dedicatoria

A mi Padre, por todo el apoyo y las oportunidades que me has dado, siempre voy a seguir tu ejemplo de trabajar muy duro. A mi Madre, por que siempre me has apoyado aún cuando no estas de acuerdo, sin ti mi maestría no hubiera sido posible. A Cristina, por que siempre has sido mi hermana mayor y te has preocupado por mi a tu manera, gracias por todo Cris. A Zaira, gracias por tu apoyo y por que gracias a ti, la maestría paso de algo bueno a algo muy bueno y muy bonito. A ustedes cuatro les dedico esta tesis, espero les guste.

Agradecimientos

Gracias a las personas con las cuales tuve la oportunidad de convivir estos últimos dos años. Gracias a la maestría tuve la oportunidad de conocerlos y eso se agradece, gracias a Roberto Enrique Magaña Rodríguez, Francisco Javier Martínez Baltodano, Jorge Alberto León Castelán, Carlos Barrera Suárez y a Greysell Ramos Aguilar. Gracias a las personas fuera de la maestría que me han apoyado, gracias a Luis Lauro Gonzáles Heredia, Juan Raúl López Morales, Luis Ramón Peraza Rodríguez, Emilia Jazmin Caballero Ruíz, Cynthia Pamela Luna Cruz, Edgar Gerardo Pérez Flores y a Edgar Iván Gordillo Cortázar. Gracias a la gente de antaño que aunque los vi poco, fue un gusto compartir mi tesis con ustedes, gracias a Arturo Martínez López, Reynaldo Felix Salido, Eduardo Alonso Bonilla Andujo, Hector Daniel Santillanes Chapa, Jesús Aguila Gómez, Alberto Martínez Lopéz, Alfredo Castro Velasco, Alejandro Castro, Luis Gerardo Reyes Vega y Alexandre Ricardo Avelar Porres. Gracias a toda la gente que me apoyo y ayudo en el desarrollo de esta tesis.

Resumen

Los sistemas de reconocimiento de movimientos son utilizados hoy día en aplicaciones como prótesis y apuntadores. Cada día se avanza más en las diferentes áreas de investigación de estas aplicaciones, las investigaciones permiten que cada día sea más fácil implementar sistemas de control que reconocen movimientos y con ello facilitar el uso de los mismos. Los sistemas de reconocimiento de movimientos utilizan señales electromiográficas (EMG) como señales de control, las señales EMG se generan a partir de contracciones musculares. Las señales EMG se digitalizan para poder procesarlas y determinar a que movimiento pertenecen, esto con ayuda del modelado en el tiempo. Las señales EMG se pueden considerar como señales estacionarias y pueden ser modeladas como procesos AR, los parámetros obtenidos del modelado sirven para generar los patrones característicos que identifican a los movimientos. La relación patrón-movimiento se lleva a cabo por medio de una red neuronal, que se entrena para que desarrolle la relación, una vez que se tiene la red entrenada está es capaz de reconocer los movimientos mediante los patrones generados a partir de los parámetros AR. El objetivo de esta tesis es demostrar que se puede mejorar la digitalización de las señales EMG para un sistema de reconocimiento con las características anteriores, la forma de mejorarlo es demostrando que las señales pueden ser cuantificadas con una cantidad menor de bits que la que se utiliza generalmente en la mayoría de los sistemas. Para llevar a cabo el objetivo se diseña un sistema de reconocimiento de movimientos capaz de reconocer cuatro movimientos cualquiera, donde se evalúa el desempeño con diferentes cuantificadores.

Índice general

Índice general	I
Índice de figuras	III
Índice de tablas	V
1. Introducción	1
1.1. Definición del problema	4
1.2. Antecedentes	5
1.3. Hipótesis	8
1.4. Objetivos	8
1.5. Organización	9
2. Marco Teórico	10
2.1. Generación de Movimientos	10
2.2. Predicción Lineal	12
2.2.1. Predicción hacia adelante	12
2.2.2. Predicción hacia adelante-Filtro de error	15
2.2.3. Algoritmo de Levinson-Durbin	16
2.3. Funcionamiento de una red neuronal	18
2.3.1. Aprendizaje en una red neuronal	20
3. Simulación de señales EMG	23
3.1. Introducción	23
3.2. Modelado de señales EMG	26
3.2.1. Modelado como un proceso AR	26
3.3. Simulación de señales EMG	34
3.3.1. Simulación como un proceso AR	34
3.3.2. Añadiendo características de las señales EMG reales a las señales simuladas	37
4. Cuantificador de señales EMG	41
4.1. Introducción	41
4.2. Cuantificación uniforme de una señal EMG	42

5. Identificando patrones de señales EMG	47
5.1. Introducción	47
5.2. Determinando el patrón de una señal EMG	49
6. Reconocimiento de movimientos	54
6.1. Introducción	54
6.2. Creando una red neuronal	55
6.3. Preparando datos para entrenar una red	56
6.4. Entrenamiento de una red neuronal	57
7. Sistema de reconocimiento de Movimientos	62
7.1. Introducción	62
7.2. Características del sistema	63
7.2.1. Adquisición de las señales EMG	63
7.2.2. Conversión A/D	65
7.2.3. Procesamiento de la señal EMG	65
7.2.4. Reconocimiento de movimientos	67
7.3. Metodología de las pruebas	67
7.4. Primer experimento	69
7.4.1. Reconocimiento de movimientos	69
7.5. Segundo experimento	70
7.5.1. Reconocimiento de movimientos	70
7.6. Tamaño de palabra en el sistema	71
8. Conclusiones	72
Bibliografía	74

Índice de figuras

1.1.	Rangos de frecuencia y voltaje para algunos biopotenciales [30].	2
1.2.	Señales EMG correspondientes a un mismo movimiento.	3
1.3.	Diagrama a bloques de un sistema de reconocimiento de movimientos. . .	3
1.4.	Sistema de reconocimiento de movimientos, sin la etapa de la red neuronal.	7
2.1.	Proceso para generar un movimiento [19].	11
2.2.	Unidad motora compuesta por el axón que transmite la información y las fibras donde se encuentra la unión neuromuscular.	11
2.3.	Filtro predictor hacia adelante de un paso [10].	13
2.4.	Relación entre un filtro predictor y un filtro predictor de error. [10].	16
2.5.	Filtro predictor de error [10].	16
2.6.	Modelo no lineal de una neurona [8].	19
2.7.	Estructura de una red neuronal de tres capas [8].	19
2.8.	Diagrama del aprendizaje de una red neuronal [8].	21
3.1.	Modelo estocástico [10].	24
3.2.	Filtro Generador de un proceso AR [10].	27
3.3.	Señal EMG [7].	28
3.4.	Señal EMG modelada.	29
3.5.	Funciones parciales de autocorrelación para una señal modelada como un proceso AR de orden 4 y la señal EMG original.	30
3.6.	Funciones de autocorrelación para una señal modelada como proceso AR de orden 4 y la señal EMG original.	30
3.7.	Función de autocorrelación de los residuos del modelado AR de la señal EMG original.	31
3.8.	Comparación entre los patrones obtenidos.	33
3.9.	Proceso AR que simula una señal EMG.	37
3.10.	Parámetros AR de señales que representan un movimiento en común. . . .	38
3.11.	Señal EMG simulada con características de una señal EMG real.	39
3.12.	Señal EMG modelada.	40
4.1.	Explicación gráfica de resolución y rango, relación entre la resolución y el ruido de adquisición.	42
4.2.	Diagrama a bloques de la adquisición de una señal EMG superficial. . . .	43

4.3. Cuantificador para una aplicación que utiliza un valor de amplitud y ruido de adquisición definidos.	44
4.4. Señal EMG real [3].	45
4.5. Señal cuantificada con 12 bits usando un cuantificador uniforme.	46
4.6. Señal cuantificada con 5 bits usando un cuantificador uniforme.	46
5.1. Filtro predictor de error del cual se obtienen los parámetros de un proceso AR [10].	48
5.2. Generación de patrones en un sistema de reconocimiento de movimientos con dos canales.	49
5.3. Parámetros AR relacionados con una señal EMG.	50
5.4. Parámetros AR de las señales EMG provenientes de los canales del sistema.	51
5.5. Ensamble de los parámetros AR obtenidos de las señales en los canales para formar el patrón correspondiente a algún movimiento.	52
5.6. Patrones que representan diversas señales generadas a partir de un mismo movimiento.	53
5.7. Patrones que representan diversas señales generadas a partir de movimientos diferentes.	53
6.1. Estructura de la red neuronal utilizada para el reconocimiento de movimientos.	57
6.2. Entrenamiento de una red neuronal, degradación del error de entrenamiento (MSE).	60
6.3. De izquierda a derecha y de arriba hacia abajo: regresión lineal del movimiento 1, regresión lineal del movimiento 2, regresión lineal del movimiento 3 y regresión lineal del movimiento 4.	61
7.1. Sistema de reconocimiento de movimientos a implementar.	63
7.2. Parámetros AR base para crear 4 movimientos diferentes.	64
7.3. Parámetros AR para varias muestras de un mismo movimiento.	65
7.4. Parámetros AR de las muestras de cada movimiento con sus centroides.	66

Índice de tablas

3.1. Conjunto de parámetros AR que caracterizan y sirven para modelar la señal de la Figura 3.3.	32
3.2. Parámetros de un proceso AR para simular una señal EMG.	36
5.1. Parámetros AR en las particiones de la señal en la Figura 5.3.	50
6.1. Lotes de patrones y “targets” para entrenar una red neuronal.	58
7.1. Resultado de las pruebas para el primer experimento.	69
7.2. Resultado de las pruebas para el segundo experimento.	70
7.3. Desempeño del sistema para diferentes tamaños de palabra y un cuantificador de 8 bits.	71
7.4. Desempeño del sistema para diferentes tamaños de palabra y un cuantificador de 12 bits.	71

Capítulo 1

Introducción

Los órganos de los seres vivos generan señales eléctricas cuando realizan sus funciones. Estas señales son conocidas como biopotenciales y se caracterizan por ser señales de muy bajo voltaje que pueden ser registradas a través de electrodos y de un sistema de adquisición adecuado. Analizando los registros de los biopotenciales es posible identificar las funciones de dichos órganos de acuerdo a las características de las señales. Los registros de biopotenciales reciben un nombre característico dependiendo del órgano que lo origina, aquellos generados a partir de las señales del corazón se conocen como *electrocardiogramas* (ECG), los generados por las señales de los músculos como *electromiogramas* (EMG), los generados por las señales del cerebro como *electroencefalogramas* (EEG) y los generados por las señales de los ojos como *electrooculogramas* (EOG).

En la Figura 1.1 se presentan los rangos de frecuencia y voltaje de diversos biopotenciales. Conocer estos rangos es de gran ayuda para caracterizar el sistema de adquisición usado para registrar el biopotencial deseado.

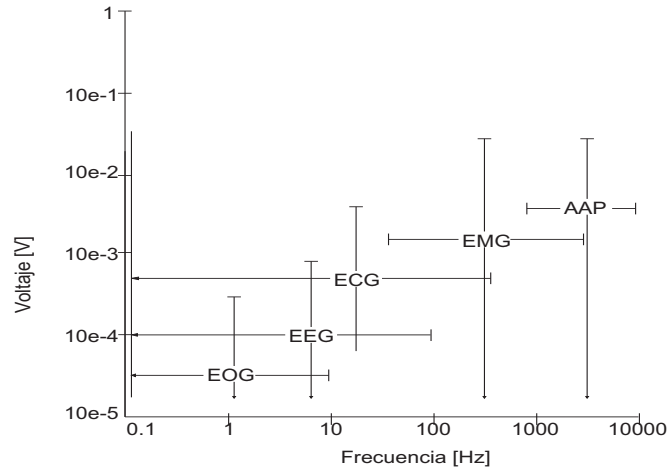


Figura 1.1: Rangos de frecuencia y voltaje para algunos biopotenciales [30].

En este trabajo se propone un sistema de reconocimiento de movimientos en base a las señales generadas por los músculos del cuerpo, por lo cual el objeto de análisis son las señales electromiográficas (EMG). Las señales electromiográficas han sido ampliamente utilizadas en la observación de la actividad muscular y como puntos de referencia para el control de prótesis y apuntadores. El diseño de aplicaciones que utilizan señales EMG abarca áreas como instrumentación [24][23], estadística [18][21] y redes neuronales [29][15], por mencionar algunas. Cada una de las áreas de investigación en las que se utilizan señales EMG presentan problemas característicos, que en la mayoría de los casos siguen siendo investigados.

El control de prótesis y apuntadores depende de la relación entre un movimiento y algo que lo identifique [26][17][14][3][28], la señal EMG generada y el patrón correspondiente a esa señal. El problema principal en el reconocimiento de una señal EMG es que la señal generada por el músculo no es siempre igual, aún cuando ésta se genere a partir del mismo movimiento (ver figura 1.2), lo que dificulta la obtención de un patrón específico para cada movimiento.




Figura 1.2: Señales EMG correspondientes a un mismo movimiento.

Una señal EMG puede ser considerada como débilmente estacionaria [11], ya que la señal mantiene su primer y segundo momento estadístico para cualquier muestra de la misma, cuando dichas muestras son de un tamaño dado [11]. Es posible modelar las señales EMG como un proceso estacionario siempre y cuando éstas se puedan considerar como señales débilmente estacionarias. Si la señal EMG puede ser modelada como un proceso estacionario los parámetros del modelo serán el patrón característico de la señal modelada. Los movimientos se pueden identificar entre otros por medio de los patrones formados con los parámetros de las señales modeladas, ya que éstos se pueden discriminar dependiendo del movimiento del cual se obtuvieron.

Lo anterior es la base para el diseño de un sistema de reconocimiento de movimientos utilizando señales EMG. El sistema se puede entender mejor a través de la Figura 1.3, donde se pueden observar 4 bloques que corresponden a cada una de las funciones que el sistema lleva a cabo para poder reconocer los movimientos mediante el análisis de señales EMG. El primer bloque representa la señal EMG que sirve de entrada al sistema, el movimiento que se desea reconocer. El bloque A/D es la etapa de digitalización de la señal de entrada. En el tercer bloque se procesa la información para encontrar el patrón característico de la señal de entrada discreta. En la etapa de reconocimiento (Red neuronal) se determina si el movimiento correspondiente a la señal EMG de entrada se encuentra dentro de los movimientos que se pueden identificar, si esto ocurre se determina a que movimiento pertenece.




Figura 1.3: Diagrama a bloques de un sistema de reconocimiento de movimientos.

El objetivo de la presente tesis es analizar los efectos que tiene la digitalización en el desempeño del sistema, cómo afecta al sistema el cambio de niveles en el cuantificador. En la mayoría de los casos se utiliza una cantidad de niveles fija de 4096 niveles.

1.1. Definición del problema

Como se mencionó en la introducción, los sistemas de reconocimiento siguen siendo investigados, aunque algunas variables de estos no. Cada bloque se encuentra delimitado de acuerdo a variables que dependen de las características del sistema, entre estas variables se encuentran: la frecuencia de muestreo de la señal EMG, el número de bits en el cuantificador y la cantidad de parámetros AR que se utilizan para formar los patrones, por mencionar algunas. Cada una de las variables produce un efecto en el desempeño del sistema, que se traduce en el porcentaje de reconocimiento satisfactorio de movimientos.

El bloque de digitalización contiene variables que se consideran fijas en la mayoría de los sistemas de reconocimiento, las variables manipulables de acuerdo al resultado que se espera obtener son la frecuencia de muestreo de la señal EMG y la cantidad de niveles en el cuantificador. La frecuencia de muestreo se considera fija en base al teorema de muestreo de *Nyquist*, donde la frecuencia más alta para una señal EMG es la armónica más alta que se encuentra aproximadamente en $450Hz$ [19]. Los niveles en el cuantificador se eligen en base a una deducción menos sólida que la anterior, en el hecho que el ruido de adquisición es aproximadamente $1\mu V_{RMS}$, el ruido de adquisición es aquel generado por la electrónica analógica con la cual se obtienen las señales EMG. Si se supone que el ruido de adquisición se conoce, entonces se diseña el cuantificador para que la resolución (el tamaño de los niveles) sea un poco menor que la amplitud del ruido, resultando en 4096 niveles [19].

Manejar cierta cantidad de bits en el cuantificador del sistema implica cierto tiempo de procesamiento del convertidor, así como un costo económico relacionado con la cantidad de bits. El tiempo de procesamiento de un sistema de reconocimiento aumenta en cierta medida de acuerdo al número de bits del cuantificador, esto debido a los niveles del mismo. El costo depende de la velocidad y el número de bits del mismo, si se toman dos cuantificadores con la misma velocidad pero con diferente cantidad de bits, 12 y 8 bits por ejemplo, se tiene que el precio del cuantificador de 12 bits es 60% mayor que el costo del cuantificador de 8 bits, aproximadamente. Cuando se produce un sistema a gran escala, es importante considerar el tiempo de respuesta de la aplicación y reducir costos de producción.

Los sistemas de reconocimiento actuales utilizan un bloque de conversión análogo-digital de 12 bits [1][29][15]. En aplicaciones médicas se puede considerar necesaria tal cantidad de bits por la precisión requerida. Un sistema de reconocimiento de movimientos basado en el uso de redes neuronales y en el modelado de la señal como un proceso estacionario, no debe necesitar tal cantidad de bits, ya que el patrón que identifica a los movimientos se genera en base a los parámetros del modelado, donde lo que importa es la discriminación de los parámetros y no la exactitud de éstos. La discriminación permite reconocer los parámetros de acuerdo a un rango en el que se pueden encontrar estos, no tienen que ser necesariamente iguales. Entre menor cantidad de bits tenga el sistema los parámetros correspondientes a un movimiento tenderán a variar mas con respecto a otra muestra del mismo movimiento.

El ruido en el bloque de adquisición de un sistema de reconocimiento de movimientos se puede suponer como ruido con una distribución Gaussiana [20], la cual es la distribución de un proceso estacionario. Los parámetros dependen de la característica estacionaria del proceso, si a este proceso se le suma un proceso estacionario o débilmente estacionario, entonces se obtiene un proceso que sigue siendo estacionario o débilmente estacionario. Bajo la suposición anterior los parámetros obtenidos se verán afectados en igual medida y los patrones característicos de diversos movimientos se verán afectados en igual forma, manteniendo la discriminación de movimientos.

En este trabajo se pretende demostrar que es posible disminuir la cantidad de bits en el bloque de conversión análogo-digital, para poder utilizar un cuantificador con un menor número de niveles, lo que se traduce en un menor tiempo de procesamiento y reducción de costos.

1.2. Antecedentes

Las investigaciones relacionadas con aplicaciones que utilizan sistemas de reconocimiento de señales EMG tienen distintos objetivos, como son la adquisición de la señal EMG [23][18], el modelado de la señal EMG [11][25][18][21][4][21], los métodos para obtener los patrones característicos de los movimientos [22] y los algoritmos para el reconocimiento de movimientos [13]. Cada una de las áreas de investigación relacionadas con sistemas de reconocimiento de movimientos, manejan diversas variables que se encargan de caracterizar y definir cada sistema.

Las investigaciones relacionadas con la adquisición de las señales EMG se encargan de determinar los valores correspondientes al número de sensores utilizados para obtener la señal, a las frecuencias de corte de los filtros que eliminan algunas componentes de la señal adquirida, a la ganancia del amplificador que determina la amplitud de la señal, a la frecuencia de muestreo de la señal y a los niveles del cuantificador utilizado para digitalizar la señal. Estas investigaciones han arrojado información suficiente para determinar el valor de las variables, por lo que se conoce que el número de sensores utilizados depende del movimiento a obtener, las frecuencias de corte de una señal EMG se obtienen mediante el rango de las señales (Figura 1.1) [30], la ganancia del amplificador depende de la aplicación [19], la frecuencia de muestreo es el doble de la armónica más alta en las señales EMG [19] y la cantidad de bits utilizados en el cuantificador deben ser suficientes para que la resolución sea un poco menor al ruido de adquisición [19].

La señal EMG puede ser modelada conforme al tiempo o en frecuencia, en esta tesis el modelado se trabajará en relación al tiempo. El modelado en tiempo toma como base la característica estacionaria de la señal, gracias a las investigaciones se sabe que la señal EMG se puede considerar como débilmente estacionaria (WSS) para muestras de un tamaño dado [11][25]. En base a que se demuestra que la señal EMG es estacionaria, entonces ésta puede ser modelada como si fuera un proceso estacionario. Para modelar la señal EMG comúnmente se usa el modelado AR (*autorregresivo*) [11] y el modelado ARIMA (*autorregresivo con integración de medias móviles*). Las variables a considerar son el modelado que se utilizará, el tamaño de las muestras [11] y el orden del modelado [11].

Los patrones correspondientes a los movimientos a identificar se generan mediante los parámetros obtenidos en el modelado de la señal. Los parámetros AR adquiridos de un mismo movimiento no serán siempre iguales. Sin embargo, si éstos se utilizan para formar un patrón, la forma del patrón siempre será la misma. La variación en los parámetros AR de un mismo movimiento depende de diversos factores como el ruido de adquisición, el ruido de cuantificación y el algoritmo utilizado para obtener los parámetros. Algunas investigaciones han demostrado que los parámetros pueden ser adquiridos mediante el uso de filtros adaptables o mediante predicción lineal. El uso de filtros RLS [22] provoca menor varianza en los parámetros a costa del aumento en el procesamiento, mientras que la predicción lineal necesita menos procesamiento y arroja una varianza aceptable, alrededor de .06 como máximo [13]. Una vez que se tienen los parámetros se forma el patrón, las investigaciones realizadas [29][15] proponen tomar 3 o 4 parámetros de cada uno de los canales por los cuales se adquieren las señales EMG, el ensamble de éstos es el patrón característico de los movimientos. Esta información se puede analizar mejor con ayuda de la Figura 1.4. En la Figura 1.4 se tiene que “ n ” es la cantidad de parámetros usados de cada canal para generar los patrones, mientras que “ m ” es el número total de parámetros obtenidos en cada canal.

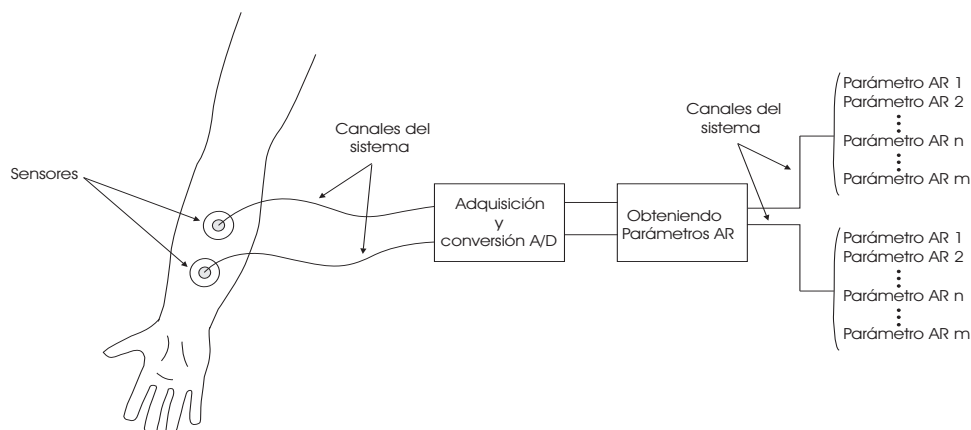


Figura 1.4: Sistema de reconocimiento de movimientos, sin la etapa de la red neuronal.

El reconocimiento de movimientos se puede realizar satisfactoriamente aprovechando la capacidad de aprendizaje de redes neuronales [29][15][1]. Las redes neuronales se entrenan en base a los parámetros AR de las señales EMG. Es posible realizar la discriminación de movimientos utilizando los parámetros del modelado, ya que la forma de éstos se mantiene cuando se concatenan para formar un patrón. Las investigaciones mencionadas [29][15][1] determinan la estructura de la red neuronal de acuerdo a las características del sistema de adquisición. La estructura de las redes neuronales utilizadas para el reconocimiento de movimientos son estructuras de 3 capas, donde la cantidad de neuronas en cada capa depende de los sensores utilizados y de la cantidad de parámetros AR con los cuales se forman los patrones característicos [29][15].

Las investigaciones mencionadas en esta sección son la base para la implementación de algunos sistemas de reconocimiento de movimientos. Esta teoría servirá para cumplir los objetivos establecidos en la siguiente sección, la hipótesis propuesta en esta tesis.

1.3. Hipótesis

La mayoría de los sistemas de reconocimiento de movimientos generados a partir de señales EMG, que utilizan parámetros AR para formar los patrones correspondientes a los movimientos y redes neuronales para identificar dichos patrones, cuentan con un cuantificador de 12 bits en la etapa de digitalización. La cantidad de bits en el cuantificador afecta directamente el comportamiento de la señal cuantificada. El comportamiento y los parámetros AR de una señal digitalizada con un cuantificador de 12 bits, son muy parecidos a los de la señal sin digitalizar. Es posible reducir la cantidad de bits en el cuantificador y aún así tener un buen desempeño en el sistema. Al reducir la cantidad de bits se espera que baje la varianza de los patrones, lo que puede generar confusión al momento de identificar la semejanza entre los patrones de los diferentes movimientos. Es importante demostrar que aún con un cuantificador menor de 12 bits se puede mantener un buen desempeño, inclusive igual que con un cuantificador de 12 bits, desempeño en el sentido de que tan bien se reconocen los movimientos en el sistema.

1.4. Objetivos

El objetivo principal de esta tesis es demostrar que se puede reducir la cantidad de bits en la etapa de digitalización de un sistema de reconocimiento de movimientos, donde el sistema se basa en el modelado AR de la señal EMG y el uso de redes neuronales. Para poder demostrar la hipótesis de la tesis es necesario desarrollar etapas previas, como son la simulación de una señal EMG, la digitalización de esa señal, el modelado de la señal digitalizada para obtener los patrones correspondientes a los movimientos, para finalmente implementar una red neuronal que identifique los movimientos simulados.

El registro de señales para movimientos específicos no corresponde al tema de esta tesis, por lo que el primer paso es simular señales EMG para los movimientos que el sistema reconocerá, en este trabajo se simularán cuatro movimientos. El segundo paso es digitalizar las señales EMG simuladas, con esto se podrá evaluar los efectos que tiene un cuantificador en el desempeño del sistema al momento de variar la cantidad de niveles. El tercer paso consiste en obtener los patrones correspondientes a las señales digitalizadas, ya que estos serán la base para el funcionamiento de la red neuronal. Finalmente, se implementará una red neuronal que, en base a los parámetros AR de las señales cuantificadas, sea capaz de reconocer los 4 movimientos simulados.

1.5. Organización

La información contenida en esta tesis se presenta de la siguiente manera:

- Capítulo 2 (Marco Teórico): Se proporciona información necesaria para comprender los tópicos relacionados con el sistema de reconocimiento de movimientos.
- Capítulo 3 (Simulación de señales EMG): Descripción del modelado de una señal EMG con el que es posible simular las señales que servirán de entrada al sistema de reconocimiento de movimientos.
- Capítulo 4 (Cuantificador de señales EMG): Se explica el proceso para cuantificar una señal EMG.
- Capítulo 5 (Identificando patrones de señales EMG): Se explica el proceso para obtener los parámetros AR que servirán como patrones característicos de las señales EMG.
- Capítulo 6 (Reconocimiento de movimientos): Descripción del proceso para utilizar una red neuronal en el reconocimiento de movimientos de acuerdo a la información proporcionada por la señal EMG.
- Capítulo 7 (Sistema de reconocimiento de movimientos): Implementación del sistema de reconocimiento mediante simulaciones. Se muestran diversas pruebas del sistema, cada una de las pruebas tiene como variante el cambio en los niveles del cuantificador.
- Capítulo 8 (Conclusiones): Análisis de la información obtenida en las pruebas.

Capítulo 2

Marco Teórico

2.1. Generación de Movimientos

La generación de un movimiento implica la contracción o expansión de las fibras pertenecientes a los músculos involucrados, estas contracciones se presentan gracias a una pequeña corriente eléctrica que pasa a través de las fibras. El movimiento se genera ya que a la *unión neuromuscular* de cada músculo relacionado con el movimiento le llega una señal en forma de corriente eléctrica, la cual origina un cambio de potencial en la *membrana muscular* que se descarga mediante las fibras que la componen, provocando la contracción de las fibras. La unión neuromuscular es la zona del músculo donde se recibe la información del cerebro. El potencial generado en la membrana muscular se conoce como *señal electromiográfica* (EMG). En la Figura 2.1 se muestra gráficamente la generación de un movimiento.

Las señales del cerebro que le dicen a un músculo que debe contraer sus fibras para generar un movimiento son recibidas por una *motoneurona*, y transmitidas a las fibras mediante un *axón*. A la unión de una motoneurona con un conjunto de fibras pertenecientes a un músculo se le conoce como *unidad motora*, los movimientos se generan mediante la contracción de las fibras contenidas en varias unidades motoras. La estructura de una unidad motora se presenta en la Figura 2.2.




Figura 2.1: Proceso para generar un movimiento [19].




Figura 2.2: Unidad motora compuesta por el axón que transmite la información y las fibras donde se encuentra la unión neuromuscular.

2.2. Predicción Lineal

La predicción lineal se utiliza en el desarrollo de esta tesis como una herramienta necesaria en el modelado y en la simulación de señales EMG (capítulo 3). En esta sección se presentan las bases para entender la predicción lineal, cómo se puede llevar a cabo y la herramienta que permite calcular los parámetros necesarios para la predicción.

Un problema en el análisis de señales en el dominio del tiempo es la predicción de los valores futuros de un proceso estacionario, discreto y estocástico. La predicción del proceso se lleva a cabo a partir de los valores pasados del mismo. Es decir que se tiene una serie en el dominio del tiempo, $u(n), u(n-1), \dots, u(n-M)$; donde los valores representan $(M+1)$ muestras de un proceso que incluye el tiempo n . La predicción de un valor de estas muestras se puede dar a partir de las muestras anteriores, si se quiere estimar $u(n)$ se utilizan las muestras $u(n-1), u(n-2), \dots, u(n-M)$.

Usando la notación de Haykin [10] se tiene que U_{n-1} es el espacio dimensional- M constituido por las muestras $u(n-1), u(n-2), \dots, u(n-M)$, y se tiene que $\hat{u}(n|U_{n-1})$ denota el valor a predecir. Cuando se predice el valor $u(n)$ a partir de las muestras anteriores se le conoce con el nombre de *predicción hacia adelante*, cuando la predicción se realiza con las muestras $u(n), u(n-1), \dots, u(n-M+1)$ para encontrar el valor de $u(n-M)$ se le conoce como *predicción hacia atrás*.

2.2.1. Predicción hacia adelante

La Figura 2.3 consiste de un filtro lineal transversal con M coeficientes $w_{f,1}, w_{f,2}, \dots, w_{f,M}$ y valores presentes de entrada $u(n-1), u(n-2), \dots, u(n-M)$. Se asume que los valores presentes de entrada son tomados de un proceso estocástico *ampliamente estacionario (WSS)* con media cero. Además se asume que los coeficientes están optimizados con el criterio del *mínimo error cuadrado (MSE)*, de acuerdo a la teoría de los filtros *Wiener* [10], el valor a predecir se obtiene a partir de la ecuación 2.1.

$$\hat{u}(n|U_{n-1}) = \sum_{k=1}^M w_{f,k}^* u(n-k) \quad (2.1)$$

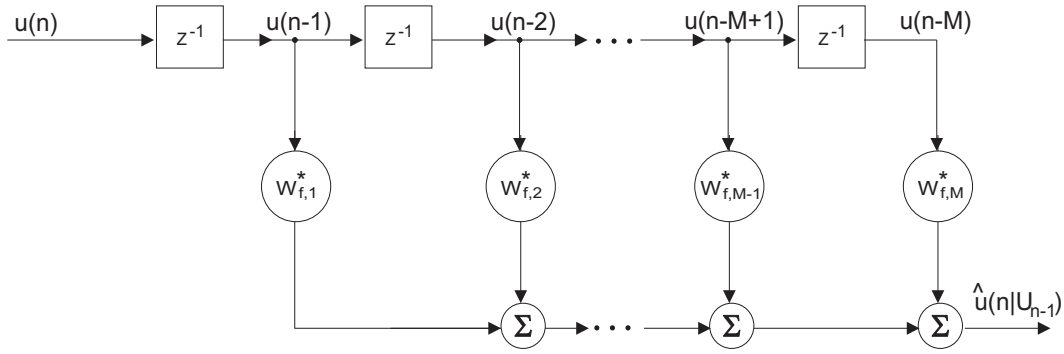


Figura 2.3: Filtro predictor hacia adelante de un paso [10].

La respuesta deseada $d(n)$ es igual a $u(n)$, que representa la muestra actual de la entrada al proceso en el tiempo n [10], ecuación 2.2. La predicción del error hacia adelante es igual a la diferencia entre la entrada $u(n)$ y el valor que se predijo $\hat{u}(n|U_{n-1})$. De acuerdo a la notación de Haykin [10] se denota la predicción de error hacia adelante por $f_M(n)$, ecuación 2.3.

$$d(n) = u(n) \quad (2.2)$$

$$f_M(n) = u(n) - \hat{u}(n|U_{n-1}) \quad (2.3)$$

El subíndice M en la ecuación 2.3 representa el orden del predictor, definido como *el número de unidades de retraso necesarias para almacenar el conjunto de muestras usadas para la predicción* [10]. Con los valores presentes de entrada se asume que se tiene media cero, el error de predicción hacia adelante $f_M(n)$ también tendrá media cero. El error de predicción calculado a partir del error mínimo cuadrado (MSE) se representa por medio de P_M , ecuación 2.4; la cual tendrá una varianza igual a la del filtro predictor de error [10].

$$P_M = E[|f_M(n)|^2]; \quad \text{para toda } n \quad (2.4)$$

Tomando de nuevo la notación de Haykin se tiene que \mathbf{w}_f denota el vector de coeficientes de dimensión $M \times 1$ del predictor hacia adelante de la Figura 2.3, en forma expandida se tiene:

$$\mathbf{w}_f = [w_{f,1}, w_{f,2}, \dots, w_{f,M}]^T \quad (2.5)$$

Los coeficientes se pueden obtener a través de las ecuaciones de *Wiener-Hopf*, ecuación 2.6, donde se tiene que \mathbf{R} representa la *matriz de correlación* $M \times M$ de los valores presentes de entrada, $u(n), u(n-1), \dots, u(n-M+1)$ en un filtro transversal, \mathbf{w}_o representa el vector $M \times 1$ de coeficientes óptimos del filtro transversal, óptimo en el sentido del mínimo error cuadrado *MSE* [10]; por ultimo \mathbf{r} representa el vector $M \times 1$ de *cross correlación* entre los valores presentes de entrada del filtro y la respuesta deseada $d(n)$.

$$\begin{aligned}\mathbf{R}\mathbf{w}_o &= \mathbf{r} \\ \mathbf{w}_o &= \mathbf{R}^{-1}\mathbf{r}\end{aligned}\quad (2.6)$$

Otro parámetro importante a calcular es el error mínimo de predicción cuadrado P_M , ya que se usa para determinar el error que existe entre la muestra original y la que se obtuvo mediante la predicción, para de esa forma determinar la validez del valor que se predijo. Para calcular P_M se necesita la varianza del proceso $u(n)$.

$$\begin{aligned}\mathbf{R} &= E[\mathbf{u}(n-1)\mathbf{u}(n-1)^H] \\ &= \begin{vmatrix} r(0) & r(1) & \dots & r(M-1) \\ r^*(1) & r(0) & \dots & r(M-2) \\ \vdots & \vdots & \ddots & \vdots \\ r^*(M-1) & r^*(M-2) & \dots & r(0) \end{vmatrix}\end{aligned}\quad (2.7)$$

La ecuación 2.7 representa la matriz de correlación \mathbf{R} . El vector de valores presentes de entrada $u(n-1)$ de tamaño $M \times 1$ se presenta en la ecuación 2.8. Otro término necesario para la solución de las ecuaciones 2.6 es el vector de *cross correlación* \mathbf{r} , la forma para obtenerlo se presenta en la ecuación 2.9.

$$\mathbf{u}(n-1) = [u(n-1), u(n-2), \dots, u(n-M)]^T \quad (2.8)$$

$$\begin{aligned}\mathbf{r} &= E[\mathbf{u}(n-1)u^*(n)] \\ &= \begin{vmatrix} r^*(1) \\ r^*(2) \\ \vdots \\ r^*(M) \end{vmatrix} = \begin{vmatrix} r^*(-1) \\ r^*(-2) \\ \vdots \\ r^*(-M) \end{vmatrix}\end{aligned}\quad (2.9)$$

2.2.2. Predicción hacia adelante-Filtro de error

En la Figura 2.3 se observa el filtro de predicción hacia adelante, el cual consiste de M retrasos y M coeficientes, $w_{f,1}, w_{f,2}, \dots, w_{f,M}$. El filtro de la Figura 2.3 tiene como entrada las muestras $u(n-1), u(n-2), \dots, u(n-M)$, con las cuales el filtro tiene como salida el valor predicho de $u(n)$, la predicción lineal para obtener $u(n)$ se presenta en la ecuación 2.1. El error en el valor predicho para la muestra $u(n)$ se presenta en la ecuación 2.10 [10], donde $u(n)$ es la respuesta esperada a la salida del filtro.

$$f_M(n) = u(n) - \sum_{k=1}^M w_{f,k}^* u(n-k) \quad (2.10)$$

Para simplificar la ecuación 2.10 se tiene que $a_{M,k}$, $k = 0, 1, \dots, M$; denota los coeficientes de un filtro transversal, que se encuentran relacionados con los coeficientes del filtro predictor hacia adelante, la relación se presenta en la ecuación 2.11. Si se utiliza la relación de la ecuación 2.11 en la ecuación 2.10 se tiene una forma simplificada de ésta, la cual se presenta en la ecuación 2.12.

$$a_{M,k} = \begin{cases} 1, & k = 0 \\ -w_{f,k}, & k = 1, 2, \dots, M \end{cases} \quad (2.11)$$

$$f_M(n) = \sum_{k=0}^M a_{M,k}^* u(n-k) \quad (2.12)$$

El filtro predictor de error hacia adelante se puede observar en la Figura 2.5, el cual tiene como entrada el conjunto de muestras $u(n), u(n-1), \dots, u(n-M)$ para producir el error de predicción hacia adelante $f_M(n)$, la salida del filtro. La relación presentada en la ecuación 2.9 es la relación entre un filtro predictor hacia adelante con un filtro predictor de error hacia adelante, Figuras 2.3 y 2.5 respectivamente. La relación entre los filtros se presenta gráficamente en la figura 2.4.




Figura 2.4: Relación entre un filtro predictor y un filtro predictor de error. [10].

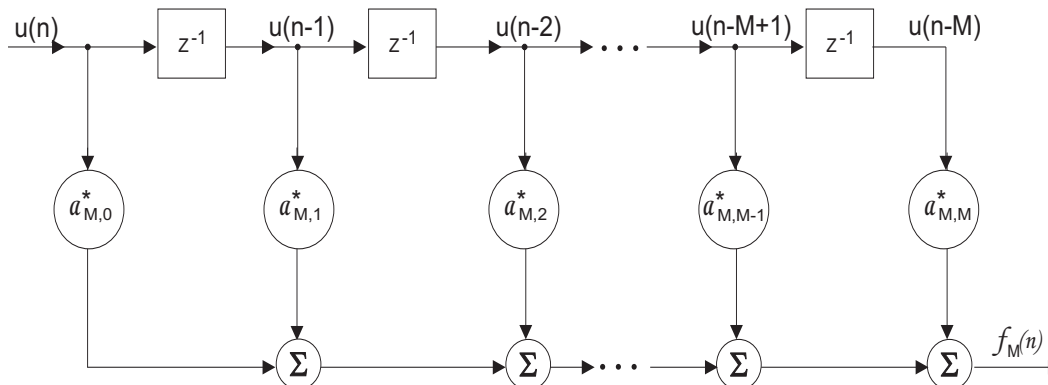


Figura 2.5: Filtro predictor de error [10].

2.2.3. Algoritmo de Levinson-Durbin

El algoritmo de *Levinson-Durbin* es un método directo que sirve para calcular los coeficientes de un filtro predictor de error, así como la potencia del error de predicción. El método es recursivo y utiliza estructuras *Toeplitz* de la matriz de correlación de los valores presentes de entrada del filtro, esto con el fin de resolver las ecuaciones de *Wiener-Hopf*. Mediante el algoritmo se calculan los coeficientes de un filtro predictor de error de orden m , el cálculo se lleva a cabo mediante la solución de las ecuaciones de *Wiener-Hopf* para un filtro predictor de error de orden $m - 1$, para $m = 1, 2, \dots, M$, donde M es el orden final de los filtros. Para desarrollar el algoritmo se utiliza tanto la predicción hacia adelante como la predicción hacia atrás, en este trabajo se utilizará la primera.

Para desarrollar el algoritmo de *Levinson-Durbin* se utiliza la predicción hacia adelante, donde los coeficientes del filtro predictor de error de orden m se representan mediante el vector \mathbf{a}_m de dimensiones $(m + 1) \times 1$. En la ecuación 2.13 se presenta la forma en la que se actualiza el vector de coeficientes del filtro predictor de error, donde k_m es una constante [10]. La versión escalar de la actualización de los coeficientes del filtro predictor de error se presenta en la ecuación 2.14, en esta tesis se utilizara la ecuación 2.13.

$$\mathbf{a}_m = \begin{bmatrix} \mathbf{a}_{m-1} \\ 0 \end{bmatrix} + k_m \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^* \end{bmatrix} \quad (2.13)$$

$$a_{m,l} = a_{m-1,l} + k_m a_{m-1,-l}^* \quad l = 0, 1, \dots, m. \quad (2.14)$$

La forma de obtener el error de predicción es multiplicando la ecuación 2.13 con la matriz de correlación, en ambos lados de la ecuación [10]. El producto se representa en la ecuación 2.15, donde P_{m-1} es la potencia del error predicho para el filtro, $\mathbf{0}_m$ es el vector nulo de dimensiones $(m - 1) \times 1$, k_m es una constante [10] y Δ_{m-1} se define en la ecuación 2.16.

$$\begin{bmatrix} P_m \\ \mathbf{0}_m \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \mathbf{0}_{m-1} \\ \Delta_{m-1} \end{bmatrix} + k_m \begin{bmatrix} \Delta_{m-1}^* \\ \mathbf{0}_{m-1} \\ P_{m-1} \end{bmatrix} \quad (2.15)$$

$$\Delta_{m-1} = \sum_{l=0}^{m-1} r(l-m) a_{m-1,l} \quad (2.16)$$

El algoritmo de *Levinson-Durbin* permite calcular los coeficientes del filtro predictor de error y el error de predicción de dos maneras diferentes. La primera forma supone el conocimiento explícito de la función de autocorrelación de las entradas del proceso, se necesita tener conocimiento de los valores de la función de autocorrelación para los los “lags” $0, 1, \dots, M$ ($r(0), r(1), \dots, r(M)$); donde M representa el orden del filtro. En la ecuación 2.17 se presenta la forma de obtener los “lags” de la función de autocorrelación. La segunda forma o método para realizar los cálculos es teniendo conocimiento explícito de los coeficientes de reflexión k_1, k_2, \dots, k_M y la función de autocorrelación para el “lag” cero, $r(0)$. El algoritmo en el segundo método necesita las relaciones presentadas en la ecuación 2.18.

$$\hat{r}(k) = \frac{1}{N} \sum_{n=1+k}^N u(n)u^*(n-k), \quad k = 0, 1, \dots, M \quad (2.17)$$

En el primer método presentado para desarrollar el algoritmo de *Levinson-Durbin* se tiene el seguimiento de las iteraciones de la siguiente forma: en la primera iteración del algoritmo recursivo, que inicia con $m = 0$, se tiene $P_0 = r(0)$ y $\Delta_0 = r^*(1)$, además $a_{m,0}$ es la unidad para cada valor de m , y $a_{m,k}$ es cero para toda $k > m$, los cálculos terminan cuando $m = M$ para las ecuaciones 2.13 y la 2.15. Los resultados estimados del filtro predictor de error, los *coeficientes* y la *potencia del error de predicción*, se obtienen con este procedimiento, también se le conoce como *Estimadores Yule Walker* [10].

$$\begin{aligned} a_{m,k} &= a_{m-1,k} + k_m a_{m-1,m-k}^*, & k = 0, 1, \dots, m \\ P_m &= P_{m-1}(1 - |k_m|^2) \end{aligned} \quad (2.18)$$

Para el segundo método se tiene el seguimiento del algoritmo de la siguiente forma: el algoritmo inicia en $m = 0$ y se detiene cuando el orden alcanza el valor final M , para las ecuaciones presentadas en la ecuación 2.18. La información presentada de este algoritmo se baso en el libro del doctor Haykin [10].

2.3. Funcionamiento de una red neuronal

Las redes neuronales tienen la habilidad de aprender a través del ambiente que las rodea, y mejorar su desempeño a través del aprendizaje. Una red neuronal aprende de su ambiente mediante un proceso interactivo que ajusta los coeficientes de la red, así como el corrimiento de los mismos. Los coeficientes reciben el nombre de “*synaptic weights*”, mientras que al corrimiento se le conoce como “*bias*”. Los ajustes en los parámetros de la red son la forma en la que se lleva acabo el aprendizaje, que en realidad se refiere a que la red tiene la capacidad de adaptar sus parámetros de acuerdo al ambiente en el que es utilizada.

Los componentes principales en la estructura de una red neuronal son las capas y las neuronas, las capas son las etapas que tiene una red neuronal, las neuronas por otro lado son las que componen a las capas, Figura 2.7. En la Figura 2.6 se observa el modelo no lineal correspondiente a una neurona. En el modelo se observan los parámetros de la neurona que son los “*sinaptic weights*” para la neurona “*K*”, la *función de activación* que se encarga de definir la salida de la neurona y el corrimiento que se tiene en los coeficientes de la neurona (“*bias*”). El aprendizaje

en una red se lleva a cabo mediante el ajuste de los parámetros de cada una de las neuronas que componen las capas de una red neuronal.

La definición de aprendizaje aplicada a una red neuronal es la siguiente [8]: *Aprendizaje es un proceso mediante el cual los parámetros libres de una red neuronal son adaptados a través de un proceso de estimulación, afectado directamente por el ambiente en el cual la red es utilizada. El tipo de aprendizaje es determinado de acuerdo a la forma en la que los parámetros cambian sus valores.*

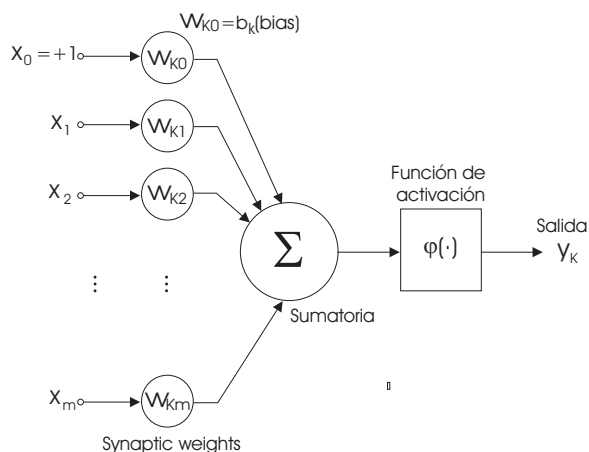


Figura 2.6: Modelo no lineal de una neurona [8].

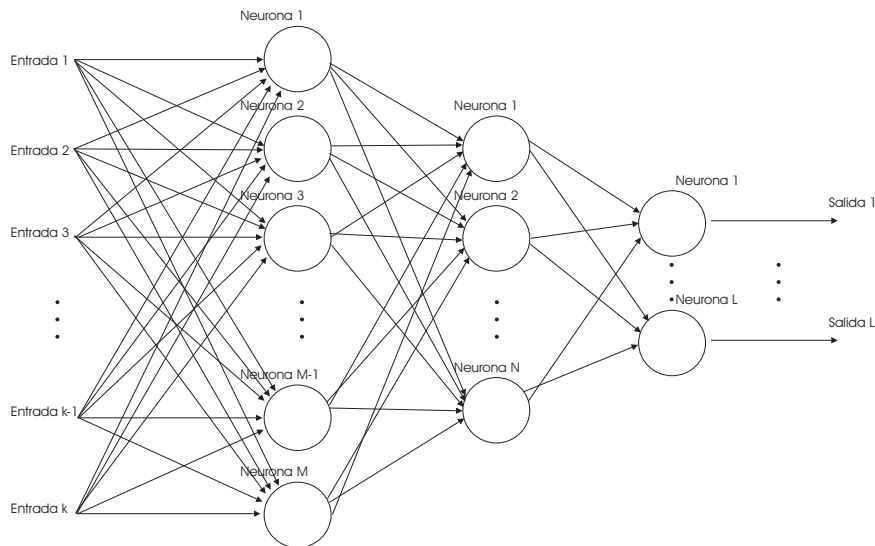


Figura 2.7: Estructura de una red neuronal de tres capas [8].

2.3.1. Aprendizaje en una red neuronal

El aprendizaje de una red neuronal se puede llevar a cabo de dos formas diferentes, de forma supervisada y de forma no supervisada; en esta tesis sólo se ocupará la primera. El aprendizaje supervisado, Figura 2.8, puede ser generalizado en términos matemáticos [8]. El modelo del aprendizaje se encuentra constituido por los siguientes términos [8]:

- Ambiente: El ambiente es estacionario, donde se le proporciona a la red un vector \mathbf{x} con una función de distribución acumulada $F_x(x)$, que no cambia pero que no se conoce.
- Maestro: El maestro provee la respuesta deseada d , para cada vector de entrada \mathbf{x} que recibe la red del ambiente; de acuerdo con la función de distribución acumulada $F_x(x|d)$ que no cambia y tampoco se conoce. La respuesta deseada d y el vector de entrada \mathbf{x} se relacionan mediante $d = f(\mathbf{x}, v)$; donde v es un término de ruido, el cual le permite al maestro ser ruidoso.
- Máquina de aprendizaje (Algoritmo): La máquina de aprendizaje (Red neuronal) es capaz de implementar un mapeo del conjunto entrada - salida descrito mediante $y = F(\mathbf{x}, \mathbf{w})$, donde y es la respuesta producida por la máquina de aprendizaje en respuesta a la entrada \mathbf{x} , mientras que \mathbf{w} es un conjunto de parámetros libres (“*synaptic weights*”) seleccionados desde el espacio de parámetros W .

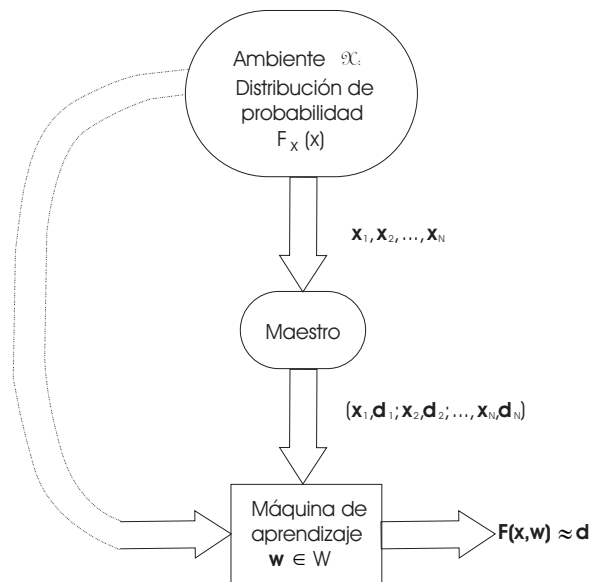


Figura 2.8: Diagrama del aprendizaje de una red neuronal [8].

El problema del aprendizaje supervisado se centra en seleccionar la función particular $F(x, w)$ que se aproxime a la respuesta deseada en forma óptima, por óptima se refiere al sentido estadístico [8]. La selección se basa en el conjunto de N pruebas para el entrenamiento de la red, donde éstas son idénticamente distribuidas e independientes, la ecuación 2.19 representa el entrenamiento de una red neuronal [8], donde \mathbf{x}_i son los vectores de entrada a la red, los cuales sirven para su entrenamiento, d_i es la respuesta deseada para cada vector \mathbf{x} al entrenar la red.

$$T = \{(\mathbf{x}_i, d_i)\}_{i=1}^N \quad (2.19)$$

Cada una de las pruebas para el entrenamiento toma un vector de datos y un vector de respuesta deseada de T , con una función de distribución acumulativa conjunta $F_{\mathbf{x}, D}(\mathbf{x}, d)$, donde se sabe que es constante pero no se conoce. El problema radica, en base al entrenamiento, en construir una máquina capaz de tener una buena aproximación del sistema a la respuesta deseada, en encontrar la función $F(x, w)$ que tenga la mejor aproximación a la función deseada $f(x)$.

La medida de discrepancia o pérdidas entre la señal deseada d , para el vector de entrada \mathbf{x} ; y la respuesta actual del sistema $F(\mathbf{x}, \mathbf{w})$, se denota como $L(d, F(\mathbf{x}, \mathbf{w}))$. Una definición popular para la pérdida $L(d, F(\mathbf{x}, \mathbf{w}))$ es mediante la *función de pérdida cuadrática* [8], definida como la distancia al cuadrado entre $d = f(x)$ y la aproximación $F(\mathbf{x}, \mathbf{w})$, como se muestra en la ecuación 2.20.

$$L(d, F(\mathbf{x}, \mathbf{w})) = (d - F(\mathbf{x}, \mathbf{w}))^2 \quad (2.20)$$

El valor esperado de las pérdidas es definido como el *riesgo funcional* [8], ecuación 2.21. El objetivo del aprendizaje supervisado es minimizar la función de costo $R(\mathbf{w})$, sobre la clase de funciones de aproximación $\{F(\mathbf{x}, \mathbf{w}), \mathbf{w} \in W\}$. En el aprendizaje supervisado la única información disponible se encuentra en el conjunto de información de entrenamiento T , por lo tanto la minimización depende por completo del entrenamiento de la red, cuando el *riesgo funcional* disminuye. Las pérdidas L disminuyen y se tiene un mejor desempeño en el aprendizaje de la red cuando la función $F(\mathbf{x}, \mathbf{w})$ se optimiza.

$$R(\mathbf{w}) = \int L(d, F(\mathbf{x}, \mathbf{w})) dF_{\mathbf{x}, D}(\mathbf{x}, d) \quad (2.21)$$

Capítulo 3

Simulación de señales EMG

3.1. Introducción

En este capítulo se presenta la generación de señales EMG mediante la simulación de un proceso con las mismas características que las señales EMG. Es posible generar señales pertenecientes a diferentes movimientos simulando distintas señales EMG, basándose en el modelado de las mismas. En este capítulo se presenta el modelado de señales EMG mediante procesos AR y la simulación de señales EMG utilizando el modelado AR.

El análisis del comportamiento de una señal en el tiempo se realiza mediante el modelado de la misma, a través del cual se obtienen los parámetros que la caracterizan. Dependiendo del modelo utilizado se obtienen diversos parámetros que describen a la señal. Debido a la naturaleza de las señales EMG, éstas se pueden considerar como estacionarias (débilmente estacionarias) ya que sus primeros dos momentos estadísticos se mantienen para cualquier intervalo de la señal [11]. El hecho de conocer los momentos estadísticos de la señal EMG hace posible su modelado.

Las señales se clasifican dependiendo de su característica estacionaria, estrictamente estacionarias, ampliamente estacionarias o no estacionarias. Las señales en las cuales se mantienen todos sus momentos estadísticos en todos los intervalos, en intervalos del mismo tamaño, se les conoce como señales *estrictamente estacionarias (ESS)* y aquellas en las que únicamente se mantienen sus dos primeros momentos se les conoce como *estacionarias en el sentido amplio (WSS)*. Para las señales EMG no todos sus momentos se mantienen, no de forma estricta o de forma amplia, pero cuando se divide la señal en particiones de un tamaño dado (entre 300 y 400 ms) [11] y se analizan como señales independientes, se tiene que sus momentos se mantienen; a estas señales se les conoce como *débilmente estacionarias* [11], procesos *WSS*.

Los *procesos estocásticos* ó *procesos aleatorios* son procesos cuya salida no se puede predecir, sin embargo se conoce el comportamiento de la señal bajo las leyes de la probabilidad. Los valores de una señal EMG no se pueden predecir, sin embargo sí se conocen sus primeros dos momentos estadísticos [11]. Tanto los procesos estocásticos como los procesos aleatorios pueden ser modelados de acuerdo a la idea de que una serie en el tiempo $u(n)$, consiste en observaciones altamente correlacionadas que pueden ser generadas aplicando una serie estadística independiente de “*shoks*” a un filtro lineal [10]. Los “*shoks*” son variables aleatorias tomadas de una distribución fija, ejemplo de ésta es la *distribución Gaussiana*.




Figura 3.1: Modelo estocástico [10].

En la Figura 3.1 la señal $v(n)$ representa la serie de “*shoks*” independientes que sirven de entrada al sistema, la señal $u(n)$ es el proceso estocástico generado. Existen diversos modelos para representar un proceso estocástico, dentro de los más conocidos [10] se encuentran el *Modelo autorregresivo (AR)*, el *Modelo de medias móviles (MA)* y el *Modelo autorregresivo de medias móviles (ARMA)*.

$$u(n) + a_1^*u(n-1) + \dots + a_M^*u(n-M) = v(n) \quad (3.1)$$

$$u(n) = v(n) + b_1^*v(n-1) + \dots + b_K^*v(n-K) \quad (3.2)$$

$$\begin{aligned} u(n) + a_1^*u(n-1) + \dots + a_M^*u(n-M) \\ = v(n) + b_1^*v(n-1) + \dots + b_K^*v(n-K) \end{aligned} \quad (3.3)$$

Las ecuaciones anteriores muestran el modelo de los procesos estocásticos mencionados. La ecuación 3.1 representa el modelo AR, donde los coeficientes a_k son los parámetros del modelo, los coeficientes b_k son los parámetros del modelo MA (ecuación 3.2) y el conjunto de coeficientes a_k y b_k son los parámetros del modelo ARMA (ecuación 3.4). Los parámetros determinan el comportamiento del proceso. Un proceso estacionario es considerado un proceso estocástico y puede ser modelado con alguna de las ecuaciones anteriores, o con otro modelo pueda representar dicho proceso.

Cada modelo se encuentra caracterizado de acuerdo al comportamiento de su función de autocorrelación y sus funciones parciales de autocorrelación, si el comportamiento de éstas, tanto del proceso original como del proceso modelado son iguales, entonces se puede asumir que probablemente es un buen modelado [11]. Es posible determinar que un modelo es adecuado para un proceso a través los residuos. Los residuos son el error entre la señal que se desea y la que se obtiene mediante el modelado, la ecuación 3.4 muestra como obtener los residuos. Para que el modelado sea considerado adecuado los residuos deben tener media cero, varianza constante y no deben de encontrarse correlacionados [11].

$$\omega_k = y_k - \sum_{i=1}^p a_i y_{k-1} \quad (3.4)$$

La ecuación 3.4 muestra la fórmula para obtener los residuos, donde y_k es el valor de la señal EMG deseada, $\sum_{i=1}^p a_i y_{k-1}$ es el valor de la señal obtenida mediante el modelado, a_i son los parámetros AR con los que se modelo la señal y p es el orden del modelado [11].

3.2. Modelado de señales EMG

Los modelos en el tiempo aceptados para modelar señales EMG son todos aquellos que trabajan bajo el supuesto que la señal es un proceso estocástico y estacionario. La Doctora *Hefftner* cita en su investigación [11] diversos trabajos para encontrar la mejor aproximación, entre éstos se encuentran aquellos que modelan la señal como un modelo “*autorregresivo*” [6][2][27] y como un modelo “*autorregresivo con integración de medias móviles*” (*ARIMA*) [25]. El Doctor *Makhoul* [16] menciona que si un proceso puede ser clasificado como *débilmente estacionario*, entonces puede ser modelado como un proceso *AR*. El modelado de la señal EMG en esta tesis será realizado tomando en cuenta la observación anterior.

3.2.1. Modelado como un proceso AR

Si se tiene un proceso que se quiere modelar en el tiempo mediante un modelado AR, entonces es necesario obtener los parámetros del modelo a partir del proceso. Para el caso del modelo AR (ecuación 3.1) se obtienen los parámetros a_k . La cantidad de parámetros del modelo AR para el caso de las señales EMG dependen de dos variables, una relacionada con las particiones que componen a la señal y otra relacionada con el orden del modelado a utilizar. Las particiones de la señal EMG son necesarias para el modelado ya que únicamente se consideran como señales débilmente estacionarias aquellas señales con duración entre $300ms$ y $400ms$ [11], por lo tanto hay que tomar particiones de la señal EMG del mismo tamaño. El modelo adecuado para la señal EMG es aquel de 4^{to} orden [11]. Los parámetros de cada una de las particiones se pueden obtener con ayuda de diversas herramientas, sin embargo en este caso se obtendrán con ayuda de las ecuaciones de *Yule Walker*, ecuación 2.17, el algoritmo de *Levinson-Durbin*.

El modelado de la señal EMG permite obtener los parámetros que la caracterizan, pero además también permite reproducir la señal EMG, una señal con las mismas características estadísticas. Los parámetros AR del proceso modelado sirven para generar la estructura de un filtro digital, o filtro generador, donde dichos parámetros son los coeficientes del filtro. En la Figura 3.2 se tiene un filtro generador donde los coeficientes a_k representan los coeficientes de un proceso AR modelado. La señal $u(n)$ es el proceso generado cuando se tiene como entrada al sistema una señal $v(n)$, que en este caso es un proceso gaussiano con media cero. La señal $u(n)$ es un proceso AR generado a partir del modelado de una partición de la señal EMG. Cuando se modela la señal también se debe definir la desviación estándar de cada una de las particiones establecidas $\sigma(n)$, ya que cada partición $u(n)$ se genera por medio de un proceso gaussiano $v(n)$ con una $\sigma(n)$ dada, esta determinara la amplitud de la señal $u(n)$ generada.

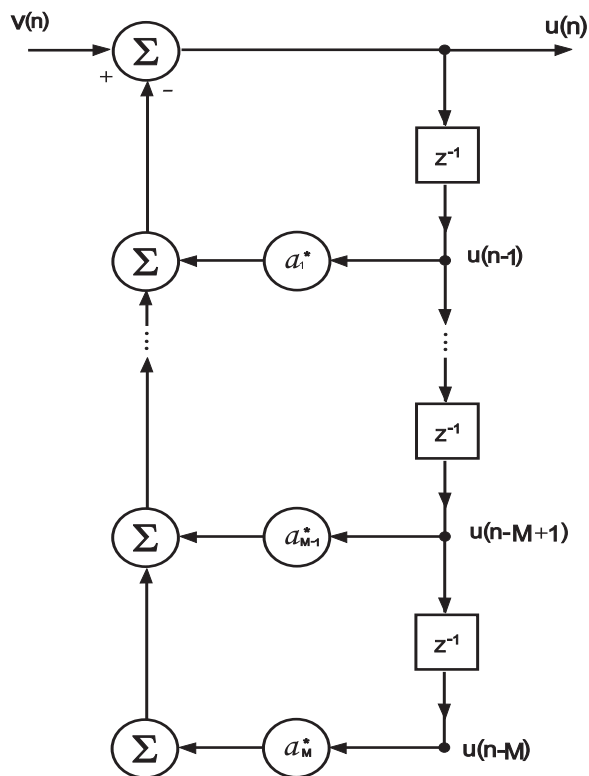


Figura 3.2: Filtro Generador de un proceso AR [10].

A partir de lo presentado hasta el momento sobre el modelado de señales EMG mediante procesos AR, se puede concluir que se deben obtener 4 coeficientes [1] del modelo AR y la $\sigma(n)$ para cada partición, con estos parámetros se puede generar cada una de las particiones que componen la señal a modelar. Una vez que se modelan y se generan todas las particiones se concatenan para obtener como resultado una señal que posea las mismas características estadísticas que la señal EMG original.

La Figura 3.3 muestra una señal *electromiográfica* (EMG) [7] con características específicas. La señal debe ser modelada para comprender sus características, para esto es necesario modelar la señal mediante el modelado AR. El primer paso es obtener los coeficientes necesarios para formar los filtros generadores de cuarto orden. Dependiendo de la duración de la señal a modelar se tendrán “n” conjuntos de parámetros del proceso AR, donde cada conjunto modelará una partición de la señal EMG original. Una vez modeladas las particiones, éstas se concatenan para obtener el modelado de la señal EMG total.




Figura 3.3: Señal EMG [7].

La Tabla 3.1 muestra el conjunto de parámetros obtenidos para cada una de las particiones de la señal EMG [7] para el modelado AR, también muestra la σ de cada partición. Una vez que se obtienen los parámetros es posible reproducir la señal a través de un proceso AR, modelando cada partición con ayuda de un filtro generador (Figura 3.2). La salida del filtro es un proceso AR con características parecidas a la señal EMG original, Figura 3.3, que es el proceso generado por la ecuación 3.5.

$$\begin{aligned}
 u(n) + a_1^* u(n-1) + a_2^* u(n-2) \dots & \quad (3.5) \\
 + a_3^* u(n-3) + a_4^* u(n-4) = v(n) &
 \end{aligned}$$

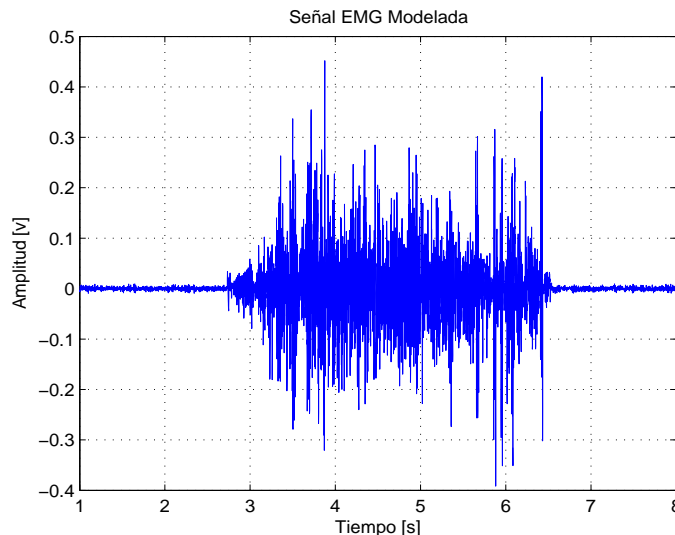


Figura 3.4: Señal EMG modelada.

En la Figura 3.4 se observa que la señal modelada no tiene la misma forma que la señal original mostrada en la Figura 3.3, con lo cual se puede inferir que no fue modelada correctamente. Sin embargo, al momento de analizar sus términos estadísticos se puede observar lo contrario. Como se menciona en la introducción: *“Si los residuos del modelado de la señal EMG tienen como características un valor esperado igual a cero, varianza constante y no se encuentran correlacionados, entonces se puede asegurar que el modelado fue correcto”*, con ello se tiene que para poder emitir un juicio acerca del modelado se tendrá que analizar el comportamiento de los residuos. Una comparación que no justifica el modelado, pero que da una idea si éste es correcto, es el comportamiento de las funciones de autocorrelación y las funciones parciales de autocorrelación, la señal modelada debe mostrar funciones parecidas a las originales.

La Figura 3.5 muestra la comparación entre las funciones parciales de autocorrelación de la señal EMG y la señal modelada. La Figura 3.6 muestra la comparación entre las funciones de autocorrelación de ambas señales.

Si se obtienen los residuos de la señal simulada y se observan sus características, se puede observar que éstos cumplen con las cualidades de un buen modelado. Es decir que poseen un valor esperado igual a 0, una varianza constante y su función de autocorrelación no se encuentra correlacionada, como se puede observar en la Figura 3.7. Entonces se puede concluir que el modelado AR de la señal EMG original es adecuado [11].

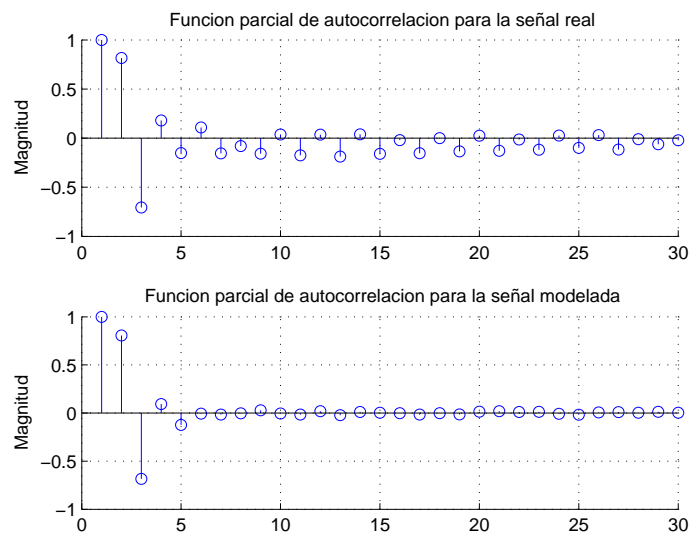


Figura 3.5: Funciones parciales de autocorrelación para una señal modelada como un proceso AR de orden 4 y la señal EMG original.

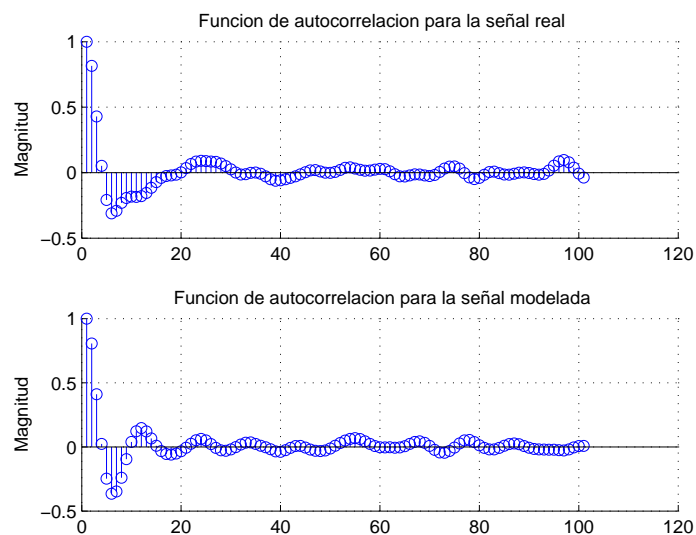


Figura 3.6: Funciones de autocorrelación para una señal modelada como proceso AR de orden 4 y la señal EMG original.




Figura 3.7: Función de autocorrelación de los residuos del modelado AR de la señal EMG original.

Tabla 3.1: Conjunto de parámetros AR que caracterizan y sirven para modelar la señal de la Figura 3.3.

a_1	a_2	a_3	a_4	σ
-1.16	0.31	0.11	0.09	0.00
-1.11	0.36	0.06	0.13	0.00
-1.18	0.36	0.08	0.12	0.00
-1.17	0.43	-0.02	0.13	0.00
-1.25	0.58	-0.13	0.20	0.00
-1.21	0.46	0.00	0.10	0.00
-1.23	0.57	-0.29	0.15	0.00
-1.46	1.14	-0.62	0.27	0.01
-1.82	1.69	-0.98	0.32	0.02
-1.65	1.22	-0.47	0.16	0.03
-1.54	0.99	-0.23	0.04	0.05
-1.34	0.87	-0.24	0.08	0.05
-1.46	1.04	-0.41	0.21	0.04
-1.32	0.83	-0.35	0.24	0.04
-1.32	0.75	-0.15	0.10	0.04
-1.42	0.99	-0.37	0.20	0.03
-1.38	0.80	-0.12	0.05	0.03
-1.48	0.99	-0.34	0.12	0.03
-1.77	1.43	-0.62	0.20	0.03
-1.73	1.32	-0.52	0.16	0.03
-1.68	1.25	-0.53	0.19	0.02
-1.26	0.55	-0.20	0.21	0.00
-1.20	0.28	0.22	0.02	0.00
-1.27	0.44	0.06	0.09	0.00
-1.21	0.42	-0.01	0.14	0.00
-1.24	0.42	0.07	0.08	0.00

Otra forma de comparar qué tan bien es modelada la señal, es obteniendo los coeficientes de la señal modelada y comparándolos con los coeficientes de la señal original. En la Figura 3.8 se puede apreciar que el modelado de la señal conserva el patrón de la señal original. Los patrones se forman a través de los parámetros AR de acuerdo a lo presentado en la introducción, lo que demuestra que el modelado de la señal mediante un proceso AR sirve para sistemas de reconocimiento de movimientos, donde los coeficientes sirven como patrón característico de los mismos.




Figura 3.8: Comparación entre los patrones obtenidos.

3.3. Simulación de señales EMG

La simulación de una señal EMG se basa en la definición del término modelo: “El termino modelo se usa para cualquier hipótesis que puede ser aplicada para explicar o describir las leyes ocultas que se supone gobiernan o generan información física de interés”, [10]. Si se conoce el modelo que es capaz de representar a las señales EMG, entonces se pueden generar diversas señales que presenten el mismo comportamiento. De esta forma es que se lleva a cabo la simulación de señales electromiográficas.

Cualquier modelo que sea capaz de representar al biopotencial muscular sirve para la generación de señales EMG. Como se vio en el apartado anterior existen dos modelos que cumplen con las expectativas, el modelo *autorregresivo* y el modelo *autorregresivo con la integración de medias móviles*. Debido a que ya se comprobó que los movimientos pueden ser caracterizados por el modelo AR, será éste el que sirva para la simulación de las señales EMG.

3.3.1. Simulación como un proceso AR

La simulación de una señal EMG se hace por partes, simulando cada una de las particiones que la componen. Cada partición tendrá una duración entre $300ms$ y $400ms$ [11]. Para simular cada una de las particiones se necesita un conjunto de parámetros $\{a_1, a_2, \dots, a_k\}$, 4 en este caso; y la σ del proceso gaussiano $v(n)$ que servirá de entrada al filtro generador, esto se aprecia mejor en la Figura 3.2. Una vez simuladas todas las particiones se concatenan para obtener la señal EMG final, el proceso de simulación es parecido al modelado de una señal EMG.

Es posible simular movimientos específicos siempre y cuando se conozcan sus coeficientes y la desviación estándar de éstos. También se pueden simular señales que no representen movimiento alguno, pero que tienen un comportamiento parecido a las señales EMG, con lo cual se pueden suponer movimientos que no existen. También se pueden simular movimientos diferentes que no sean específicos, en cuyo caso se supone un conjunto de coeficientes y valores de desviación estándar creados para generar las señales que representan a los movimientos.

El problema principal de crear los parámetros del proceso AR para simular una señal EMG radica en definir tanto el conjunto de parámetros del proceso AR como la σ del proceso gaussiano, el cual sirve de entrada para generar cada una de las particiones que componen la señal a simular. En realidad no existe una regla para definir el valor de los parámetros AR, pero dado que el proceso representa el biopotencial muscular en términos estadísticos, los parámetros que generan el proceso no tienen tanta importancia, si se considera que no representan

un movimiento específico. Sin embargo, se debe respetar el hecho de que los coeficientes de una partición generada con un movimiento no varían bruscamente en relación a otra partición generada con otra muestra del mismo movimiento, como se observa en el trabajo de la Doctora Hefftner [12] y en los coeficientes de la Tabla 3.1.

Para ejemplificar la simulación de señales EMG se tienen los dos casos presentados al principio de la sección, el caso de una simulación basada en parámetros reales, que se puede observar en el modelado de la señal EMG; y el caso de la generación de una señal EMG basada en coeficientes creados. En la Tabla 3.2 se presentan los coeficientes creados para la simulación de una señal EMG, los parámetros creados arrojan como resultado la señal mostrada en la Figura 3.9. La varianza del proceso gaussiano se crea mediante un ventaneo de la señal con una varianza constante, la ventana utilizada es la ventana de *Kaiser*, donde ésta cambiara para cada partición de la señal a generar.

En la Tabla 3.2 se observa del lado izquierdo una matriz donde las filas representan los coeficientes de cada una de las particiones que componen la señal EMG a simular, mientras que del lado derecho de la matriz se encuentra un vector que representa la σ del proceso gaussiano, el vector de cada elemento se relaciona con cada una de las particiones, estos son los parámetros que hacen posible el crear una señal EMG. La señal simulada en la Figura 3.9 tiene una duración de $26 \times 300 \text{ ms}$, dado que cada partición tiene una duración de 300 ms y se tienen 26 particiones. La señal generada no se encuentra relacionada con ningún movimiento en particular, solamente es una señal con un comportamiento parecido a una señal EMG, sin embargo gracias a esta característica se puede hacer la representación de un movimiento cualquiera.

Tabla 3.2: Parámetros de un proceso AR para simular una señal EMG.

a_1	a_2	a_3	a_4	σ
-0.07	0.07	0.03	-0.07	0.01
-0.12	0.23	-0.18	0.41	0.02
-0.44	-0.03	-0.29	0.05	0.06
-0.09	0.20	-0.35	0.34	0.11
-0.31	0.05	-0.07	0.32	0.18
-0.09	-0.06	-0.05	0.14	0.28
0.08	-0.03	0.11	0.40	0.39
-0.20	0.35	-0.22	0.20	0.52
0.09	0.01	0.01	0.02	0.65
-0.17	0.20	-0.38	0.34	0.77
0.01	0.10	-0.49	0.35	0.88
0.07	0.10	-0.12	0.18	0.95
-0.30	-0.01	0.10	0.26	0.99
-0.17	0.30	0.06	0.43	0.99
-0.15	0.04	-0.30	0.36	0.95
-0.15	-0.19	-0.10	0.28	0.88
-0.15	-0.14	-0.02	0.21	0.77
0.21	-0.05	-0.07	0.32	0.65
-0.45	-0.01	0.27	0.09	0.52
-0.25	-0.02	-0.08	0.26	0.39
-0.14	0.01	-0.03	-0.13	0.28
-0.35	0.24	-0.04	0.04	0.18
-0.27	-0.24	-0.27	0.34	0.11
-0.01	0.21	-0.13	0.32	0.06
-0.30	0.39	-0.15	0.05	0.02
0.02	-0.10	0.07	0.30	0.01

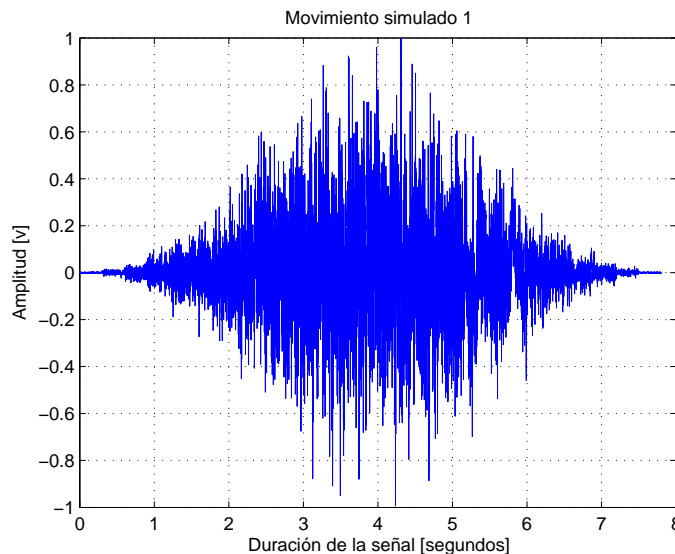


Figura 3.9: Proceso AR que simula una señal EMG.

3.3.2. Añadiendo características de las señales EMG reales a las señales simuladas

Para poder evaluar el desempeño de un sistema de reconocimiento de movimientos no basta con comprobar que las señales EMG simuladas tienen las mismas características estadísticas que las señales reales. Se deben tomar en cuenta otros factores que afectan el comportamiento de las señales EMG, como es el caso del ruido de adquisición, el hecho de que el muestreo en tiempo para las señales EMG es alrededor de 1KHz y que la cantidad óptima de bits para el muestreo en amplitud es de 12.

Las señales EMG reales que se utilizan en sistemas de reconocimiento contienen un ruido aditivo, este ruido proviene del sistema con el cual se registraron las señales. Generalmente este ruido tiene un valor alrededor de $1\mu\text{V}_{RMS}$ [10]. El ruido de adquisición provoca que las características de las señales EMG cambien para señales que son generadas a partir del mismo movimiento. El ruido de adquisición afecta a las señales EMG mostrando una variación de alrededor de .06 en el valor de sus parámetros AR [13][22]. Para el trabajo desarrollado en esta tesis el valor de la variación es de .075. Las señales EMG simuladas en esta tesis contienen el ruido de adquisición. En la Figura 3.10 se pueden apreciar los parámetros de 4 señales simuladas que representan a un mismo movimiento más el ruido de adquisición, donde la variación para los parámetros se encuentra en un rango de $\pm.075$ alrededor de los parámetros originales, muestra 1.




Figura 3.10: Parámetros AR de señales que representan un movimiento en común.

El muestreo en tiempo con el que las señales EMG reales se convierten a discretas, es otro factor que debe ser tomado en cuenta en la simulación de señales EMG. Las señales se simulan mediante un paquete computacional, por ende la señal que se simula ya es discreta. Las señales EMG reales son muestreadas en tiempo a una frecuencia de 1KHz , las señales simuladas entonces deben tener la propiedad de que cada segundo que se simule debe estar compuesto por 1000 elementos que representan a ese segundo, esto dado a la relación $T = 1/fs$, donde fs es la frecuencia de muestreo de las señales EMG reales y T es la duración de las señales EMG. La Figura 3.11 presenta la forma en la que una señal simulada cumple con la característica del muestreo en tiempo, cada segundo de la señal simulada se encuentra compuesto por 1000 elementos. En el lado izquierdo de la Figura 3.11 se tiene la señal EMG simulada, donde el eje “x” representa los elementos que la componen, del lado derecho se observa el eje del tiempo, que mide la duración de la señal.




Figura 3.11: Señal EMG simulada con características de una señal EMG real.

El muestreo en amplitud se mide en base a los parámetros AR con los que se simulan las señales EMG, éstos cambiarán para diferentes cuantificadores. Se sabe que la cantidad de bits óptima para cuantificar señales EMG es de 12, para sistemas de reconocimiento de movimientos [15][1][29]. Si se quiere tomar en cuenta el muestreo en amplitud, se debe respetar el hecho que los parámetros AR deben ser los mismos para la señal simulada y para la señal simulada cuantificada con 12 bits. En la Figura 3.12 se presentan los parámetros AR de una señal EMG simulada y los parámetros AR de la señal cuantificada con diferentes cantidades de bits. En la Figura 3.12 se observa cómo los parámetros AR de la señal simulada y los de la cuantificada con 12 bits son prácticamente idénticos, con lo cual se puede decir que la señal simulada mantiene las características de las señales reales para el muestreo en amplitud.




Figura 3.12: Señal EMG modelada.

Las señales simuladas en este capítulo tienen características estadísticas muy parecidas a las características estadísticas de las señales EMG, además estas señales poseen las características de una señal EMG adquirida mediante un sistema de adquisición superficial. Las señales EMG simuladas en este capítulo se utilizarán para implementar un sistema de reconocimiento de movimientos, donde las señales representan los movimientos que el sistema reconocerá.

Capítulo 4

Cuantificador de señales EMG

4.1. Introducción

El sistema de reconocimiento que se implementará en esta tesis se basa en el procesamiento digital de señales EMG [1][15][29]. La conversión de una señal continua a discreta, o compresión de la señal, se lleva a cabo mediante el uso de cuantificadores. En un sistema de reconocimiento de movimientos esta etapa se utiliza para digitalizar la señal EMG adquirida. Las señales EMG utilizadas en un sistema de reconocimiento deben ser digitalizadas dado que es necesario procesarlas para obtener las características de la señal. Los parámetros AR de una señal EMG son obtenidos mediante el uso de algoritmos que necesitan la señal en forma discreta, tal es el caso del algoritmo de *Levinson-Durbin*.

El cuantificador en un sistema de reconocimiento origina efectos diferentes dependiendo de la cantidad de bits utilizados en la conversión análogo-digital. El principal efecto que se toma en cuenta es la eliminación del ruido de adquisición de la señal EMG [19]. El ruido afectará la digitalización dependiendo de la cantidad de niveles en el cuantificador, es por ello que se diseña el cuantificador para que tenga una resolución un poco menor que el ruido de adquisición [19] (Figura 4.1). Otro efecto que depende de la cantidad de niveles del cuantificador es el comportamiento de la señal, la señal cuantificada tendrá un mayor parecido a la señal continua entre mayor sea la cantidad de bits en el cuantificador.

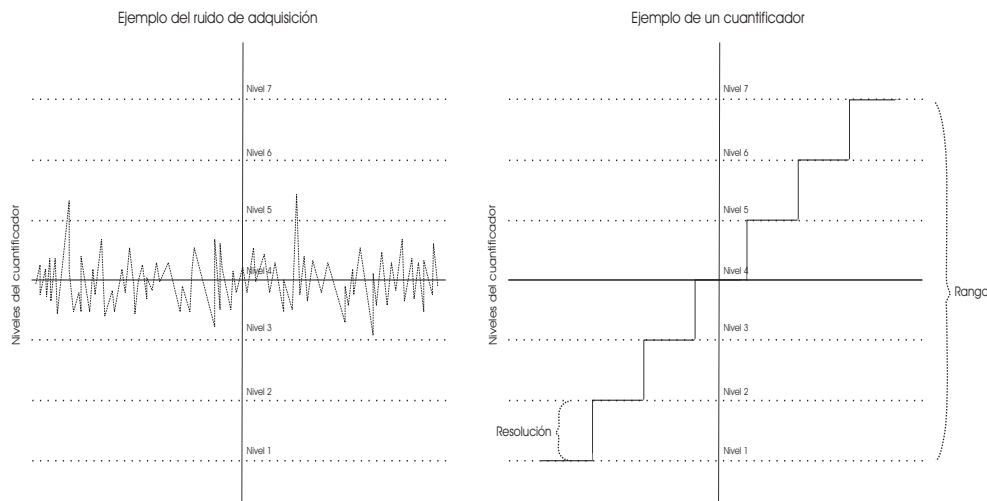


Figura 4.1: Explicación gráfica de resolución y rango, relación entre la resolución y el ruido de adquisición.

Los parámetros AR obtenidos a través de una señal EMG dependen del comportamiento estacionario de la señal, los parámetros se encuentran relacionados con la cantidad de bits en el cuantificador utilizado. La característica estacionaria de una señal cuantificada se define en relación a los momentos de la misma, ya que la cantidad de niveles en el cuantificador afecta el comportamiento de la señal. Dependiendo de la cantidad de niveles usados en el cuantificador se tendrán características de la señal más fieles con respecto a la señal EMG que se está cuantizando, entre más niveles tenga el cuantificador se conservará mejor la característica estacionaria en la señal cuantizada. De acuerdo a lo anterior se tiene que entre mayor sea la cantidad de bits en el cuantificador se podrán reconocer los movimientos con menos probabilidad de error, ya que los patrones característicos de los movimientos serán menos afectados por el ruido de cuantificación [9]. La cuantificación se encuentra relacionada con el desempeño del sistema, en esta sección se explica cómo llevar a cabo la cuantificación de una señal EMG y los efectos que tiene este proceso sobre la señal.

4.2. Cuantificación uniforme de una señal EMG

Para llevar a cabo la digitalización de una señal EMG es necesario muestrear y cuantificar la señal, digitalizar la señal en tiempo y en amplitud. El muestreo en tiempo de la señal EMG se realiza en base al teorema de Nyquist, muestrear al doble de la armónica más alta de la señal, la armónica más alta en señales EMG se encuentra alrededor de los 450Hz . El muestreo en amplitud se realiza mediante un cuantificador [19], donde se tiene que la cantidad de niveles utilizados en los cuantificadores de sistemas de reconocimiento de movimientos generalmente son 2^{12} niveles [15] [5], donde 12 es el número de bits en el cuantificador. Para comprender

la cuantificación de señales EMG se debe tener noción del rango y de la resolución de un cuantificador. En la Figura 4.1 se pueden entender estos conceptos, además se necesita conocer la relación entre niveles y bits, la ecuación 4.1 muestra la relación; donde N es el número de niveles y B es el número de bits en el cuantificador.

$$N = 2^B \quad (4.1)$$

La señal EMG que será cuantificada trae consigo un ruido aditivo, ruido generado por la etapa de adquisición del sistema. La Figura 4.2 muestra los bloques correspondientes a una etapa típica de adquisición de un sistema de reconocimiento de movimientos. El ruido aditivo en la señal EMG es causado por los elementos que componen la etapa de adquisición, por los sensores utilizados para obtener las señales y por los elementos electrónicos necesarios en la etapa.

La base para cuantificar una señal EMG la proporciona el Doctor Merletti [19], proponiendo la cantidad de niveles de un cuantificador para una señal EMG en base a la resolución y al rango: “*En la practica es común el seleccionar la resolución del sistema abajo del nivel del ruido del mismo, y el rango algo arriba del valor pico-pico de la amplitud máxima esperada de la señal que sirve de entrada al cuantificador*”. La resolución se conoce como el tamaño de los escalones o niveles en un cuantificador uniforme. El rango en un cuantificador son los límites de amplitud que el cuantificador es capaz de catalogar, es decir la amplitud máxima y mínima de la señal EMG que el cuantificador reconoce. En la Figura 4.1 se puede apreciar gráficamente el significado de la resolución y el rango.

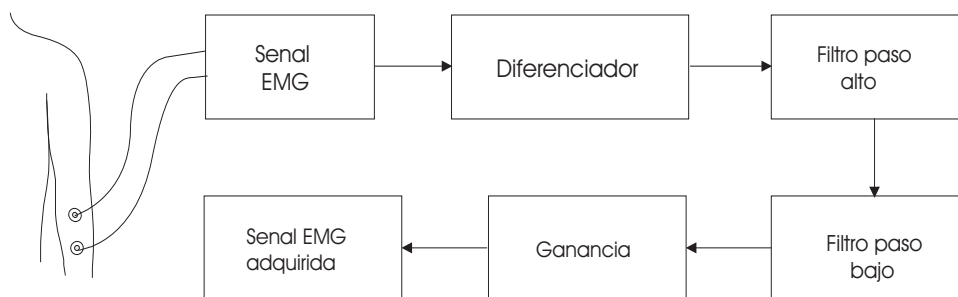


Figura 4.2: Diagrama a bloques de la adquisición de una señal EMG superficial.

La amplitud de la señal EMG que será digitalizada depende de la aplicación y son las características de diseño del amplificador en la etapa de adquisición lo que determinará dicha amplitud. Es decir que el valor pico-pico de la señal EMG adquirida depende de la ganancia del amplificador utilizado en la etapa de adquisición. Los rangos de amplitud de una señal EMG sin amplificar se encuentran entre los μV y los mV , como se observa en la Figura 1.1. El ruido de adquisición depende tanto del material como de la relación señal a ruido de los elementos

electrónicos utilizados en la etapa de adquisición, generalmente se supone que tiene un valor aproximado de $1\mu V_{RMS}$ [19]. En base a lo anterior se puede deducir que la resolución del cuantificador para un sistema de reconocimiento de movimientos debe ser menor a $1\mu V_{RMS}$ y el rango debe ser algo mayor al valor pico-pico de la señal a digitalizar.

Si se supone que la aplicación utiliza una señal con un valor pico-pico de $1V$ y que el ruido de adquisición es alrededor de $1\mu V_{RMS}$, entonces es posible diseñar el cuantificador para la aplicación utilizando los valores anteriores. El cuantificador para el caso anterior tendrá un rango mayor a 2 volts y una resolución menor a $1\mu V_{RMS}$. Tomando en cuenta lo anterior, la resolución del cuantificador se calcula en base al rango, el rango entre el número total de niveles debe dar un valor menor a $1\mu V_{RMS}$. En la Figura 4.3 y en las ecuaciones 4.2 se aprecia la forma de calcular los valores para el rango y la resolución en el cuantificador, donde $V_{EMG_{pp}}$ es el voltaje pico-pico de la señal EMG y B es el número de bits en el cuantificador.

$$\begin{aligned} \text{Rango} &= V_{EMG_{pp}} \\ \text{Resolución} &= \frac{\text{Rango}}{2^B} \end{aligned} \quad (4.2)$$

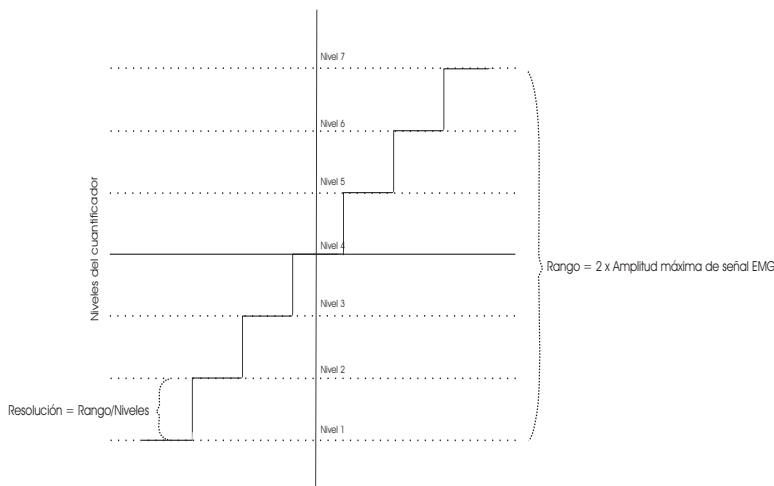


Figura 4.3: Cuantificador para una aplicación que utiliza un valor de amplitud y ruido de adquisición definidos.

Para demostrar el efecto del cuantificador en una señal EMG se cuantificará la señal mostrada en la Figura 4.4. Los cuantificadores utilizados serán dos, uno con 12 bits y otro con 5, ambos cuantificadores tienen el $rango = 3$. El primer cuantificador utilizado tiene una $resolución = 3/2^{12}$ y el segundo tiene una $resolución = 3/2^5$. La Figura 4.5 muestra la señal cuantificada con 12 bits y la Figura 4.6 muestra la cuantificada con 5 bits. En la comparación entre las Figuras 4.5 y 4.6 se puede observar cómo afecta la cuantificación a las señales EMG y cómo cambia el comportamiento de acuerdo a la cantidad de bits utilizados.

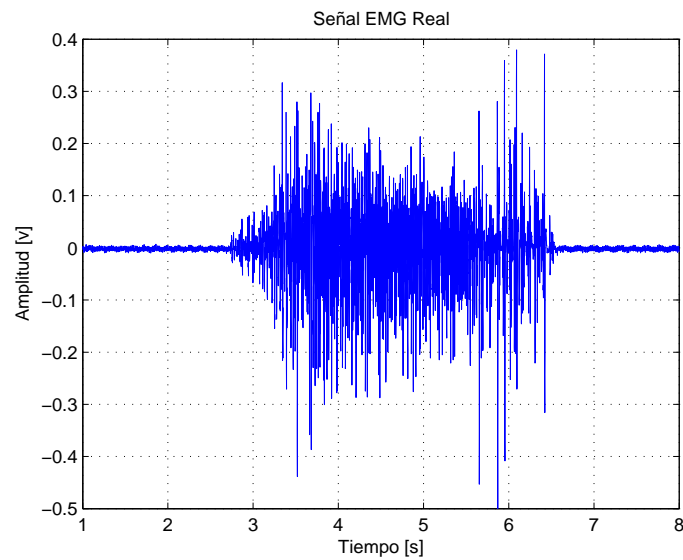


Figura 4.4: Señal EMG real [3].




Figura 4.5: Señal cuantificada con 12 bits usando un cuantificador uniforme.

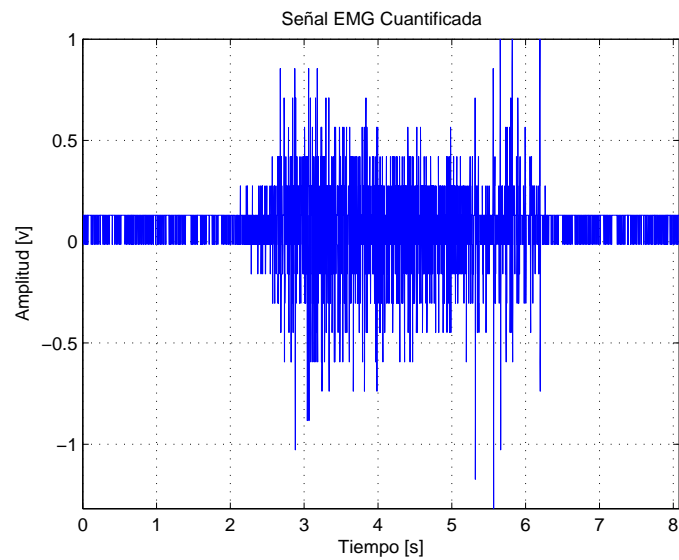


Figura 4.6: Señal cuantificada con 5 bits usando un cuantificador uniforme.

Capítulo 5

Identificando patrones de señales EMG

5.1. Introducción

Un sistema de reconocimiento de movimientos discrimina señales en base a las características que presenta cada una en relación a las señales a identificar. Las características de cada señal pueden ser obtenidas de diversas formas dependiendo de la señal. En el caso de las señales EMG se obtienen a partir del modelado de un proceso AR, el patrón es formado en base a los parámetros obtenidos en dicho proceso. Herramientas como las redes neuronales se encargan de relacionar las señales EMG con sus respectivos patrones y de esta forma llevar a cabo el reconocimiento de movimientos.

Los parámetros AR de una señal EMG son obtenidos en esta tesis con ayuda del algoritmo de *Levinson-Durbin*, el algoritmo es un método para calcular los coeficientes de un filtro predictor de error y el error de predicción mediante las ecuaciones de *Wiener-Hopf*. En la Figura 5.1 se observa un filtro predictor de error donde $u(n)$ es la partición de la señal EMG que se desea modelar, los coeficientes son los parámetros AR que formarán el patrón correspondiente a las señales EMG y el error de predicción se representa como $f_M(n)$, en la figura M representa el orden del filtro. Los parámetros AR se obtienen de cada una de las particiones. Para obtener los parámetros que caracterizan a toda la señal se concatenan los parámetros de cada una de las particiones. El error de predicción representa la desviación estándar en cada una de las particiones de la cual se obtiene, dicho en otras palabras, representa la forma que tendrá en amplitud las particiones que se están modelando.

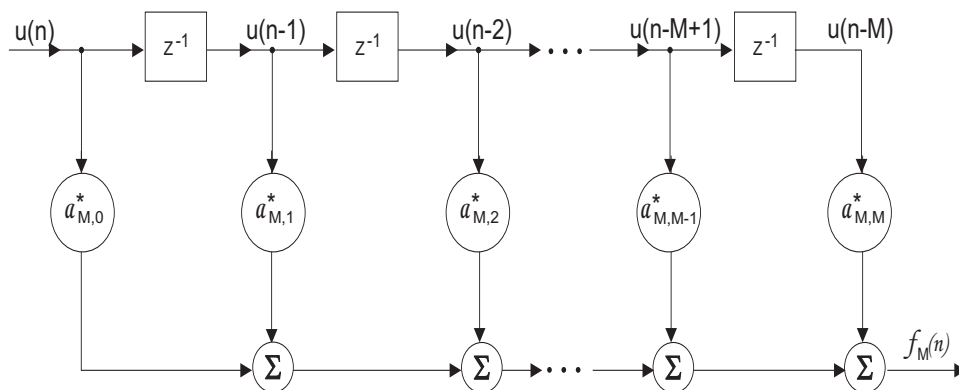


Figura 5.1: Filtro predictor de error del cual se obtienen los parámetros de un proceso AR [10].

Para llevar a cabo la discriminación de movimientos se analizan las señales provenientes de diversos canales para poder llevar a cabo el reconocimiento, Figura 5.2. El patrón que identifica cada movimiento a reconocer depende del conjunto de señales provenientes de los canales, por lo tanto el patrón dependerá de los parámetros del conjunto de señales que representan a un movimiento. Si el sistema tiene dos canales, los parámetros dependerán de las dos señales provenientes de ambos canales. La cantidad de parámetros a tomar, para cada una de las señales, se determina en base al trabajo del Doctor Wang [29]. En dicho trabajo se toman 3 parámetros AR de cada una de las señales provenientes de los canales y al ensamblarlos se obtiene el patrón de los movimientos. En la Figura 5.2 se tiene que n es el número de parámetros AR a obtener de cada una de las señales en los canales para formar el patrón y m es el número total de parámetros que se obtienen en cada una de las señales en los canales.

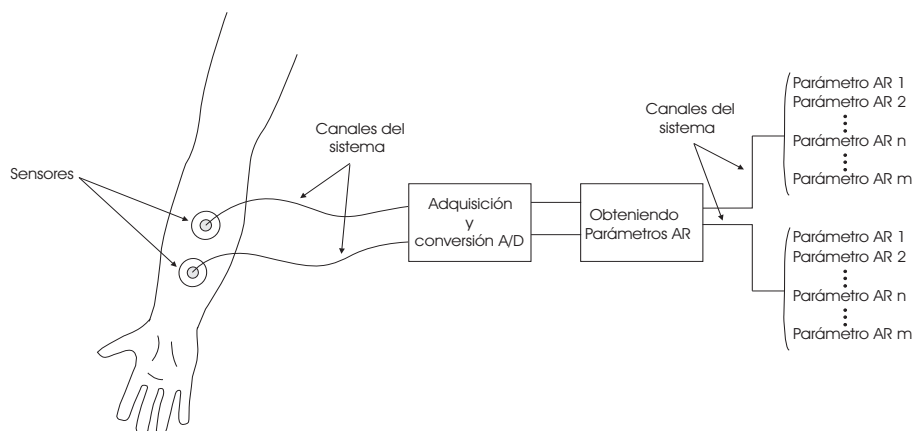


Figura 5.2: Generación de patrones en un sistema de reconocimiento de movimientos con dos canales.

En este capítulo se explicará el procedimiento para obtener los patrones que identifican a cada uno de los diferentes movimientos que el sistema reconocerá. La explicación se centra en dos objetivos, en obtener los parámetros AR de las señales que representan a los movimientos y en formar los patrones con los parámetros AR adquiridos de las señales EMG. Los objetivos a explicar en este capítulo se basan en el trabajo desarrollado por el Doctor Wang [29].

5.2. Determinando el patrón de una señal EMG

Los parámetros AR de una señal EMG se obtienen mediante el algoritmo de *Levinson-Durbin*, para poder utilizar el algoritmo es necesario que la señal EMG sea estacionaria. Las señales EMG se consideran débilmente estacionarias para señales con duración entre 300 y 400 *ms*, si la señal tiene una duración mayor será necesario dividirla en particiones iguales con una duración entre 300 y 400 *ms*. Los parámetros AR de cada una de las particiones se obtienen mediante el algoritmo de Levinson-Durbin, cada partición de la señal debe pasar por un filtro predictor de error de cuarto orden, de acuerdo al modelado propuesto por la Doctora Heffter [11]. De cada partición de las señales EMG se obtienen 4 parámetros AR que permitirán caracterizar las señales [11].

Para esta tesis se determinaron particiones de 300 *ms* de duración, si se tiene una señal EMG con duración de 3s, entonces se tendrán $3/.003$ particiones. Una vez definidas las particiones de la señal EMG se obtienen los parámetros AR de cada una, cuatro parámetros por cada partición. Si se tiene una señal EMG con una duración de 3 segundos, entonces se tendrán $4 \times \frac{3}{.003}$ parámetros AR que caracterizan a la señal EMG, como se observa en la Figura 5.3. Los parámetros AR de cada una de las particiones se muestran en la Tabla 5.1.




Figura 5.3: Parámetros AR relacionados con una señal EMG.

Tabla 5.1: Parámetros AR en las particiones de la señal en la Figura 5.3.

$a_{4,1}$	$a_{4,2}$	$a_{4,3}$	$a_{4,4}$	f_4
-0.14	0.06	0.09	-0.06	0.01
-0.05	-0.20	0.23	0.06	0.09
-0.36	0.08	0.15	-0.02	0.34
-0.39	0.01	-0.09	0.06	0.69
-0.11	-0.12	0.01	0.14	0.96
-0.03	-0.01	0.08	0.28	0.96
-0.28	-0.14	0.10	-0.08	0.69
0.00	0.06	0.15	-0.14	0.34
0.12	-0.15	-0.19	0.20	0.09
-0.20	-0.15	0.14	0.16	0.01

Los patrones que representan los movimientos se generan mediante el ensamble de los parámetros AR obtenidos a través de la señal EMG, las señales en cada uno de los canales del sistema. La cantidad de parámetros AR que se tomarán de cada uno de los canales del sistema depende de la investigación que se tome como base para ello, en este caso se toma el trabajo del Doctor Wang [29] como referencia, el trabajo propone tomar los 3 primeros parámetros AR de cada una de las señales provenientes de los canales. En la Figura 5.6 se observan dos señales EMG provenientes de un sistema con dos canales, como el que se implementará en esta tesis. Las señales representan un movimiento específico mostrado a través del patrón que se forma con los parámetros AR de las señales (Figura 5.6). El patrón que representa el movimiento se forma juntando los 3 primeros parámetros AR obtenidos de cada una de las señales EMG, el patrón se puede observar en la Figura 5.5.

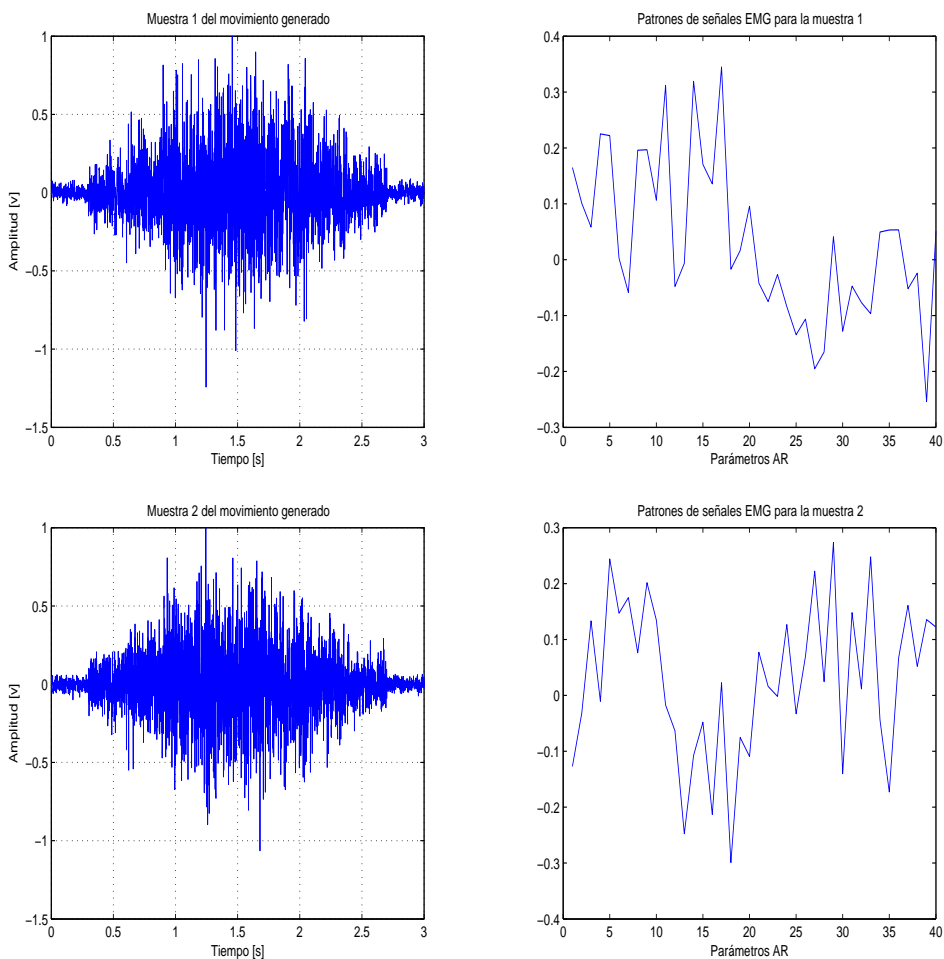


Figura 5.4: Parámetros AR de las señales EMG provenientes de los canales del sistema.

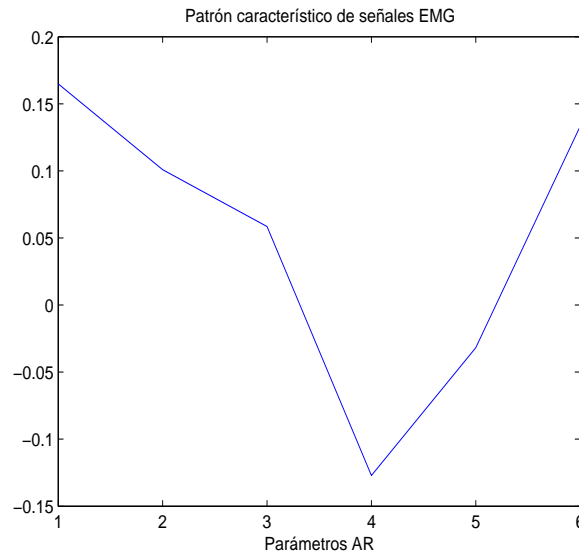


Figura 5.5: Ensamble de los parámetros AR obtenidos de las señales en los canales para formar el patrón correspondiente a algún movimiento.

Los parámetros AR adquiridos de las señales EMG que representan a un mismo movimiento no serán siempre los mismos, debido al ruido que se genera en las etapas anteriores del sistema de reconocimiento de movimientos. El ruido provoca cambios en el comportamiento de las señales EMG. Es posible generar patrones que identifiquen a un movimiento, aunque el valor de los parámetros AR cambien para diversas muestras del mismo, ya que la variación de los parámetros se encuentra dentro de un rango que permite a una herramienta de reconocimiento identificar los patrones. El rango en el que se pueden encontrar depende del ruido en el sistema de reconocimiento, ya que entre mayor sea el ruido más variación tendrán los parámetros. En varias investigaciones [13][12][22] se tiene que la varianza en los parámetros es alrededor de .06. En la Figura 5.6 se observan los patrones formados con muestras de un mismo movimiento y en la Figura 5.7 patrones formados con muestras de diferentes movimientos para una varianza alrededor de .075. En las figuras mencionadas se aprecia como se relacionan los parámetros AR con los movimientos generados.

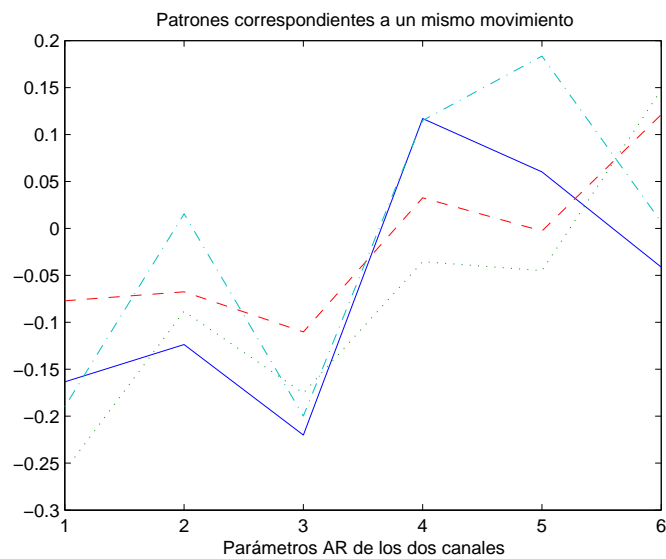


Figura 5.6: Patrones que representan diversas señales generadas a partir de un mismo movimiento.




Figura 5.7: Patrones que representan diversas señales generadas a partir de movimientos diferentes.

Capítulo 6

Reconocimiento de movimientos

6.1. Introducción

Como ya se mencionó, los movimientos son representados a través de las señales EMG para su reconocimiento. Las señales pueden ser caracterizadas para encontrar el patrón representativo a cada uno de los movimientos que se desea identificar. El reconocimiento de movimientos se logra mediante herramientas, como las redes neuronales, que relacionan un patrón con el movimiento del cual se obtuvo [15][29][1]. Las redes neuronales reconocen el movimiento mediante un entrenamiento previo, en el entrenamiento la red aprende a discriminar movimientos de acuerdo al patrón de cada uno. La relación entre el patrón y el movimiento se lleva a cabo gracias a la capacidad de aprendizaje que presentan las redes neuronales.

El entrenamiento de una red neuronal se realiza de dos formas, de forma *supervisada* y de forma *no supervisada*, en este trabajo se utilizará la primera de estas. En el entrenamiento supervisado se le proporciona a la red la información necesaria para que desarrolle la relación entre los patrones y el movimiento, lo que se conoce como el aprendizaje. Para el entrenamiento, existen diversos métodos para presentar la información a la red. Entre éstos se encuentran el *método por lotes* y el *método secuencial*. El método secuencial consiste en enseñarle a la red muestra por muestra las relaciones movimiento-patrón, el método por lotes le presenta todas las muestras movimiento-patrón con las que se entrenara la red a la vez. En este trabajo, la información se le proporcionará a la red mediante el *método por lotes*.

La estructura de la red neuronal que se utilizará para reconocer los movimientos se encuentra relacionada con la etapa de adquisición y la etapa de procesamiento de la señal EMG. Las estructuras que se toman como referencia para este trabajo son estructuras de 3 capas [29][1][15], donde las neuronas en cada una de las capas dependen de varios factores como la cantidad de sensores utilizados, los movimientos a reconocer, la cantidad de canales en el sistema y el número de parámetros AR a tomar de cada señal proveniente de los canales para formar

los patrones. En este trabajo se utilizara como base el trabajo del Doctor Wang [29], el cual presenta una estructura de tres capas, en la primera capa se tiene que las neuronas dependen de la cantidad de parámetros AR, las neuronas de la segunda capa dependen tanto de los parámetros AR como de los sensores y las neuronas en la última capa dependen de la cantidad de movimientos a reconocer. La cantidad de neuronas en cada capa se explicará a lo largo del capítulo.

En este capítulo se describe el diseño de una red neuronal capaz de reconocer movimientos y será la última etapa del sistema presentado en la Figura 1.3. Las bases de la red a implementar se toman del trabajo realizado por el Doctor Wang [29], el cual sirve como referencia para validar el desempeño de la red. La red neuronal tiene como características el uso de señales EMG y de los parámetros AR obtenidos para reconocer los movimientos, además utilizará el algoritmo *Back-Propagation* como algoritmo de aprendizaje, a diferencia del trabajo presentado por el Doctor Wang quien utiliza un algoritmo *delta modificado*. En este capítulo también se presenta la forma de preparar los datos para el entrenamiento de la red y la demostración del reconocimiento de movimientos con la red implementada.

6.2. Creando una red neuronal

La red neuronal que se utilizará en esta tesis depende de dos factores relacionados con la estructura de la misma, las capas y las neuronas que forman la red a implementar. Las capas son el nivel principal de la red, mientras que las neuronas son las unidades fundamentales de la red neuronal, son éstas las que llevan acabo el procesamiento de información y las que modifican sus coeficientes para llevar a cabo el aprendizaje. En base a lo anterior se tiene que la red neuronal a implementar depende de la cantidad de capas que forma a la red y de la cantidad de neuronas que forman a cada una de las capas. La cantidad de capas y de neuronas necesarias en cada capa se explicará a lo largo de esta sección.

La cantidad de capas a utilizar en la red se asignan de acuerdo a investigaciones que proponen el uso de redes con 3 capas [1][15][29]. Por lo tanto, la red a implementar en este trabajo tendrá una estructura de 3 capas. La cantidad de neuronas en cada capa se encuentra relacionada con las etapas de adquisición y procesamiento de las señales EMG. La cantidad de neuronas en la primera capa será igual al producto entre el número de canales en el sistema (N_{can}) y la cantidad de parámetros AR (N_{AR}) a utilizar de cada señal EMG proveniente de los canales. Las neuronas en la segunda capa es igual al producto entre N_{AR} y la cantidad de sensores (N_{transd}) utilizados para adquirir las señales EMG. Por último se tiene que la cantidad de neuronas en la tercera capa es igual a la cantidad de movimientos que se quieren reconocer (N_{Mov}). A continuación se presentan las relaciones para determinar la cantidad de neuronas en cada una de las capas:

$$\begin{aligned} \text{Neuronas en la capa de entrada} &= N_{can} \times N_{AR} \\ \text{Neuronas en la capa oculta} &= N_{AR} \times N_{transd} \\ \text{Neuronas en la capa de salida} &= N_{Mov} \end{aligned}$$

De acuerdo al sistema que se implementará en esta tesis, se tiene que la cantidad de canales es igual a 2 ($N_{can} = 2$), los sensores utilizados para obtener las señales EMG es igual a 2 ($N_{transd} = 2$), la cantidad de parámetros AR a obtener de las señales EMG para generar los patrones es igual a 3 ($N_{AR} = 3$) y la cantidad de movimientos a reconocer es igual a 4 ($N_{Mov} = 4$). Con las características del sistema se puede determinar la cantidad de neuronas para cada una de las capas y con ello tener la estructura de la red que reconocerá los movimientos. Entonces, la estructura se encuentra formada por 3 capas donde la capa de entrada estará formada por 6 neuronas, la capa oculta por 6 neuronas y la capa de salida por 4 neuronas. En la Figura 6.1 se presenta la estructura de la red que se implementará en esta tesis.

6.3. Preparando datos para entrenar una red

La información que se utiliza para entrenar una red neuronal se encuentra clasificada en patrones y “*targets*”. Los patrones son aquellos a través de los cuales se le proporciona a la red las características de los movimientos que deseamos reconocer, en este caso los patrones se encuentran formados por los parámetros AR de las señales EMG. Los “*targets*” son la relación que se establece entre el patrón y el movimiento que representa. Dicha relación es a su vez la representación numérica que se le da al movimiento, para este trabajo se realiza de forma binaria.

La red neuronal será entrenada a través de un aprendizaje supervisado en conjunto con el método por lotes. En el capítulo 5 se explica la forma de obtener

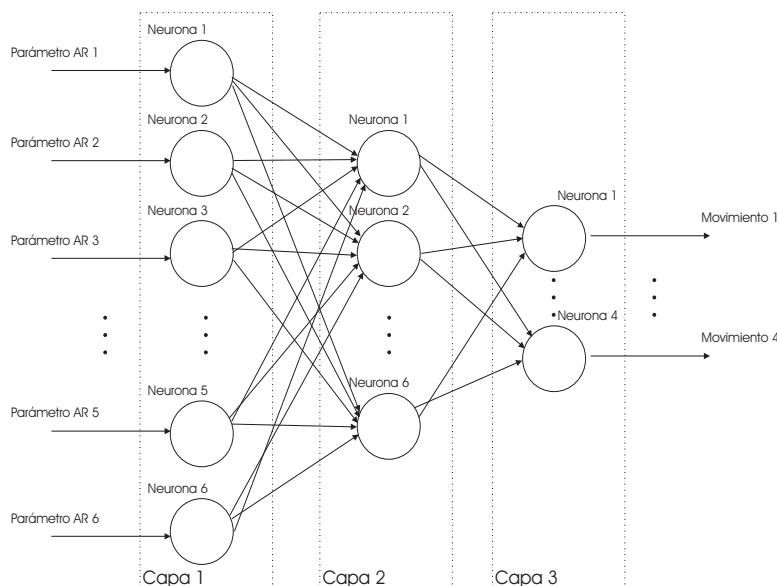


Figura 6.1: Estructura de la red neuronal utilizada para el reconocimiento de movimientos.

los patrones que identifican a los movimientos mediante las señales EMG. Los “targets” se asignan dependiendo del movimiento que se quiera relacionar con los patrones. Si se quieren reconocer 4 movimientos diferentes y se tienen los patrones que identifican a cada uno de éstos, entonces se le debe asignar un valor de “target” a cada uno de los movimientos para que sean identificados.

En la Tabla 6.1 se muestra un pequeño ejemplo de cómo puede ser introducida la información para entrenar una red neuronal mediante el método por lotes. La matriz del lado izquierdo en la Tabla 6.1 es el lote que se encuentra formado por los parámetros correspondientes a tres movimientos diferentes, la matriz del lado derecho es el lote que se encuentra formado por los “targets” correspondientes a los movimientos del lote de patrones. Los patrones se encuentran formados por los parámetros AR de los movimientos, mientras que los “targets” son indicadores binarios que señalan a qué movimiento pertenecen los patrones. El lote de “targets” relaciona los patrones con los tres movimientos diferentes, ubicando el valor unitario en el lote respectivo, la ubicación del indicador determina a que movimiento pertenecen los patrones.

6.4. Entrenamiento de una red neuronal

Es necesario definir ciertas variables para poder realizar el entrenamiento de la red. Entre estas variables se encuentran el número de ciclos, el error mínimo que se espera en el entrenamiento, la cantidad de señales que se utilizarán para entrenar

a_1	a_2	a_3	a_4	a_5	Mov1	Mov2	Mov3
-0.14	0.01	0.34	-0.01	0.16	1.00	0.00	0.00
-0.12	-0.05	-0.07	0.02	0.22	0.00	1.00	0.00
0.07	0.07	0.00	-0.02	0.19	0.00	0.00	1.00
0.04	-0.11	0.10	0.10	0.30	1.00	0.00	0.00
0.02	-0.11	0.09	0.18	0.13	0.00	1.00	0.00
0.01	-0.06	-0.16	0.37	0.01	0.00	0.00	1.00

Tabla 6.1: Lotes de patrones y “targets” para entrenar una red neuronal.

la red y el algoritmo de aprendizaje. El número de ciclos determina la cantidad de iteraciones en las que se evaluará la red para el entrenamiento. De forma que si el error de entrenamiento no disminuye lo suficiente para detener las iteraciones, el número de ciclos sí lo hará. La cantidad de señales que se utilizarán para entrenar la red se refiere al tamaño de los lotes de información que se utilizarán para el entrenamiento, es decir, la cantidad de muestras movimiento-patrón. El algoritmo de aprendizaje es aquel con el cual la red relaciona los patrones con los movimientos.

En el trabajo del doctor Wang [29] no se proporcionan las variables mencionadas en el párrafo anterior, con excepción del algoritmo de aprendizaje, que utiliza un algoritmo *delta modificado*. La red que se implementará para esta tesis no tendrá el mismo desempeño que la obtenida por el Doctor Wang (97%), ya que las variables no serán las mismas en el entrenamiento y el algoritmo de aprendizaje aplicado es diferente; el desempeño se presentara en los capítulos siguientes. El algoritmo que se utilizará será el algoritmo *Back-Propagation*, teniendo en cuenta que el Doctor Wang no menciona qué modificación se llevó a cabo en el algoritmo *Delta*. Los valores que toman las variables para el entrenamiento se muestran a continuación, junto con la estructura de la red que se entrenará:

Capas en la Red neuronal	=	3
Neuronas en capa 1	=	6
Neuronas en capa 2	=	6
Neuronas en capa 3	=	4
Algoritmo de aprendizaje	=	Back-Propagation
Movimientos a reconocer	=	4
Muestras de movimientos	=	500
Porcentaje de muestras para el entrenamiento	=	.8
Ciclos para el entrenamiento	=	100
Mínimo error esperado en el entrenamiento	=	0

El desempeño en el entrenamiento de una red neuronal se puede medir de dos formas, a través del *error en el entrenamiento* o mediante la *regresión lineal* de los movimientos reconocidos por la red entrenada. El error en el entrenamiento puede ser obtenido de diversas formas, en este caso se evaluará mediante el *error mínimo cuadrado (MSE)*, éste tenderá a disminuir dependiendo de las características e iteraciones del entrenamiento. La regresión lineal permite evaluar el desempeño de la red al comparar la salida de una red entrenada con la respuesta deseada, el reconocimiento será mejor entre más se aproxime la regresión lineal a la respuesta deseada. La Figura 6.2 muestra el comportamiento del error de entrenamiento para la red que se está entrenado con las características mencionadas hasta ahora. La Figura 6.3 muestra la regresión lineal para cada una de las respuestas deseadas del sistema, o sea cada uno de los movimientos que se quieren reconocer. En la Figura 6.3 se observa la regresión lineal para los cuatro movimientos, donde las líneas con puntos menos separados representan la relación entre los “*targets*” esperados en las pruebas (A) con los valores de “*targets*” obtenidos (T), el caso ideal se presenta cuando se tiene que $A=T$.

La red puede ser utilizada para reconocer movimientos una vez que ésta haya sido entrenada, aún cuando se le introduzcan señales que la red nunca ha procesado, siempre y cuando éstas pertenezcan a movimientos que la red es capaz de distinguir. El reconocimiento es posible ya que la red identifica las características de los movimientos con los cuales fue entrenada. El desempeño de la red entrenada se explicará a mayor detalle en los capítulos siguientes. Aunque el principal objetivo de la tesis es evaluar el desempeño dependiendo de las características en la etapa de conversión A/D, se ha demostrado que la red implementada en este trabajo es capaz de reconocer cuatro movimientos. El entrenamiento en este caso se realizó para un cuantificador de 12 bits en la etapa de conversión A/D.




Figura 6.2: Entrenamiento de una red neuronal, degradación del error de entrenamiento (MSE).

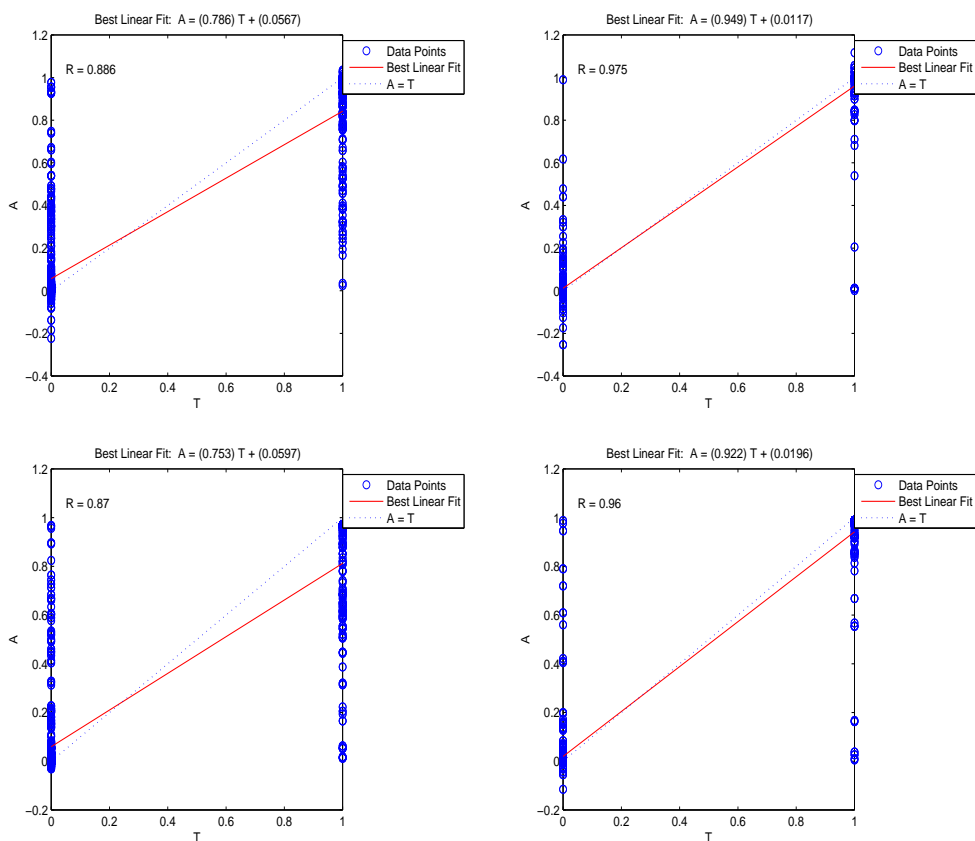


Figura 6.3: De izquierda a derecha y de arriba hacia abajo: regresión lineal del movimiento 1, regresión lineal del movimiento 2, regresión lineal del movimiento 3 y regresión lineal del movimiento 4.

Capítulo 7

Sistema de reconocimiento de Movimientos

7.1. Introducción

En este capítulo se presenta la implementación del sistema de reconocimiento de movimientos con el cual se probará la hipótesis presentada en el capítulo 1, también se presenta la metodología usada para llevar a cabo las pruebas y los resultados. En la sección de metodología se describen las variables de control y las de experimentación usadas para realizar las pruebas. En los resultados se puede evaluar el comportamiento del sistema de acuerdo al reconocimiento correcto de la información.

En la Figura 7.1 se presenta el sistema de reconocimiento que se desea implementar, los números representan cada una de las operaciones que hay que realizar para poder reconocer los movimientos. El número 1 hace referencia a la adquisición de las señales EMG, el 2 a la cuantificación de las señales EMG adquiridas, el 3 presenta los parámetros AR obtenidos de las señales EMG cuantificadas, el 4 el patrón que se forma con los parámetros AR de las señales cuantificadas, el 5 la red neuronal con la cual se reconocerán los movimientos y el 6 al movimiento reconocido por el sistema.

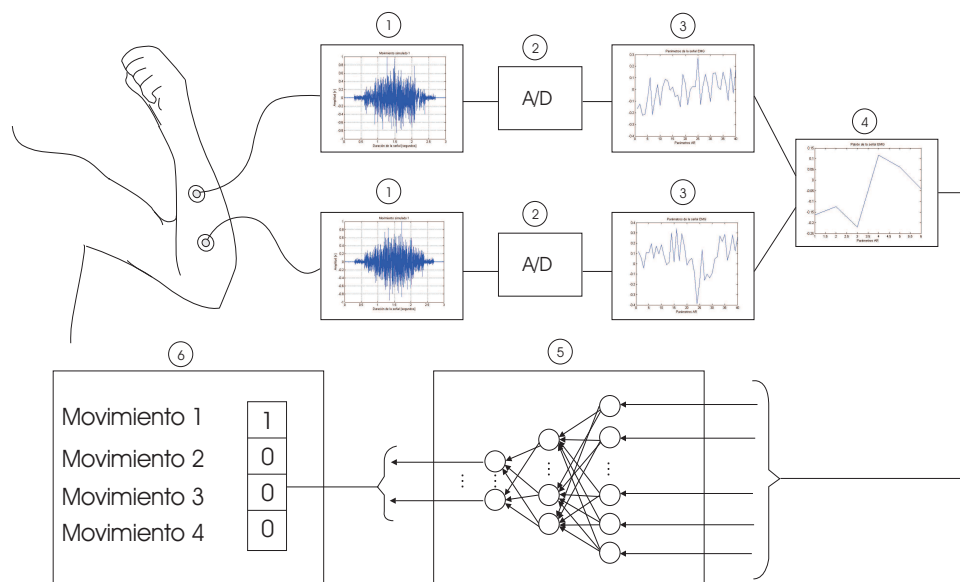


Figura 7.1: Sistema de reconocimiento de movimientos a implementar.

7.2. Características del sistema

7.2.1. Adquisición de las señales EMG

El sistema de reconocimiento de movimientos que se implementará en esta tesis identifica 4 movimientos diferentes, los movimientos están representados por señales EMG simuladas y no por señales adquiridas de los músculos. Las señales EMG simuladas tienen las mismas características que las señales EMG adquiridas mediante dos sensores superficiales. La simulación de movimientos diferentes implica que los parámetros AR que identifican a cada uno de los movimientos serán diferentes. En la Figura 7.2 se presentan los parámetros AR base de cada uno de los movimientos a simular, se conocen por parámetros base a los parámetros característicos que identifican a cada movimiento.




Figura 7.2: Parámetros AR base para crear 4 movimientos diferentes.

Para generar varias muestras de un mismo movimiento necesarias para el entrenamiento de la red neuronal, se requiere variar un poco los parámetros AR correspondientes al movimiento. Esto es para mantener las características del ruido de adquisición que presentan las señales EMG reales. La variación de los parámetros AR es alrededor de .075 con respecto a los parámetros AR base, la varianza en los parámetros se explica en mayor detalle en el capítulo 3. La Figura 7.3 presenta los parámetros AR provenientes de la simulación de varias muestras de un mismo movimiento.




Figura 7.3: Parámetros AR para varias muestras de un mismo movimiento.

Las señales serán transmitidas al bloque de conversión A/D a través de dos canales, donde cada canal transmitirá una señal EMG con la cual es posible identificar el movimiento usando el sistema a implementar, las señales simuladas son solamente la entrada al sistema.

7.2.2. Conversión A/D

La conversión A/D se realiza para las señales EMG provenientes de ambos canales, ya que cada movimiento se encuentra representado por dos señales EMG, como se puede observar en la Figura 7.1. El muestreo en tiempo para las señales EMG simuladas, provenientes de ambos canales, va implícito en la simulación, como se explica en el capítulo 3. El muestreo en amplitud se desarrolla con cuantificadores uniformes con diferente cantidad de bits con el fin de evaluar el desempeño del sistema. Las características de los cuantificadores que se utilizarán para este análisis se explicará a detalle en la sección de metodología.

7.2.3. Procesamiento de la señal EMG

Aunque los parámetros AR de las señales que sirven de entrada al sistema se conocen, se va a suponer lo contrario, ya que el sistema de reconocimiento de movimientos solamente conoce la señal EMG más no sus parámetros. Se deben encontrar los respectivos patrones de los movimientos para que estos sean identificados. En la Figura 7.4 se presentan los patrones de cada movimiento en

un mismo plano, los patrones para todas las muestras simuladas de los diferentes movimientos a reconocer y sus respectivos centroides. En la Figura 7.4 los signos “o” hacen referencia a los parámetros AR que forman los patrones del movimiento 1, los signos “+” el movimiento 2, los signos “ Δ ” el movimiento 3 y los signos “*” el movimiento 4.

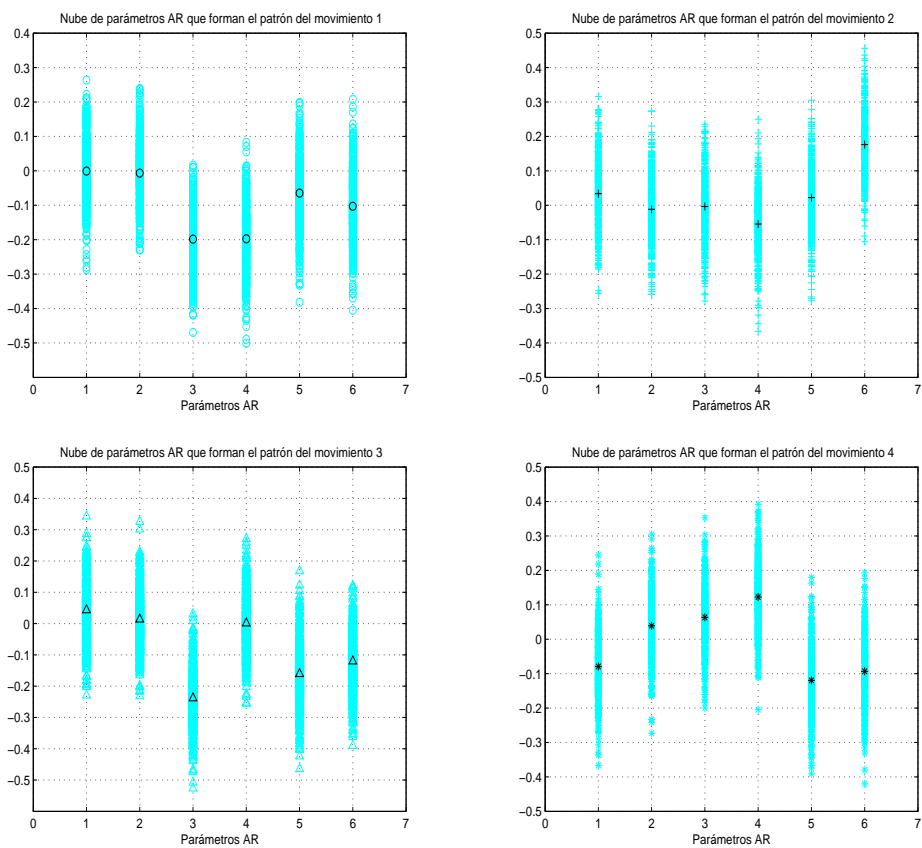


Figura 7.4: Parámetros AR de las muestras de cada movimiento con sus centroides.

7.2.4. Reconocimiento de movimientos

El reconocimiento de movimientos se lleva a cabo mediante la red neuronal diseñada en el capítulo 6. La red neuronal permite relacionar los patrones obtenidos en la etapa del procesamiento de la señal EMG con las señales que sirven de entrada al sistema. El entrenamiento en la red se realiza a partir de varias muestras de los diversos movimientos que la red reconocerá. La red neuronal arroja como salida una palabra binaria de 4 bits, en la palabra binaria únicamente se tendrá un bit con valor igual a 1, los demás serán cero. El reconocimiento del movimiento se realizará dependiendo de la ubicación del bit unitario (Figura 7.1).

7.3. Metodología de las pruebas

Para comprobar la hipótesis se simulará el sistema de reconocimiento de movimientos implementado en la sección anterior, Figura 7.1. Las variables del sistema se dejarán fijas, a excepción del número de bits en el cuantificador que es la variable de experimentación. Con lo anterior se busca analizar el desempeño del sistema a través del porcentaje de reconocimiento correcto para cada cuantificador utilizado. El análisis se lleva a cabo suponiendo diferentes sistemas, cada uno con una cantidad diferente de bits en el cuantificador, las demás etapas de los sistemas serán las mismas para todos.

La cantidad de bits en el cuantificador del sistema cambiará desde 4 hasta 12 bits. La cantidad de bits ideal en cualquier sistema de reconocimiento de movimientos es de 12, mientras que la cantidad mínima de bits con los que se realizan las pruebas depende del efecto que se tiene al cuantificar una señal EMG. De forma que a menor cantidad de bits la señal podría perder su característica estacionaria y no podría ser modelada como un proceso AR, si se modelara aunque la señal no fuera estacionaria los parámetros tendrían un comportamiento inestable.

A continuación se presentan las variables de control del sistema de reconocimiento de movimientos:

Movimientos a reconocer	=	4
Número de canales en el sistema	=	2
Sensores utilizados en la adquisición	=	2
Frecuencia de muestreo de la señal EMG	=	1Khz
Parámetros AR utilizados por canal	=	3
Algoritmo de aprendizaje	=	Back-Propagation
Ciclos en el entrenamiento	=	100
Error mínimo de entrenamiento (MSE)	=	0
Cantidad de capas en la red	=	3
Neuronas en la primera capa	=	6
Neuronas en la segunda capa	=	6
Neuronas en la tercera capa	=	4

Las pruebas del sistema de reconocimiento consisten en dos experimentos, las variables de control que caracterizan al sistema y la variable de experimentación se mantienen para ambos experimentos. Los resultados de los experimentos cambian debido a que los movimientos utilizados serán diferentes en cada uno de éstos. Cada experimento simula un sistema capaz de reconocer 4 movimientos diferentes. Los experimentos realizados se presentan en la siguiente sección.

7.4. Primer experimento

7.4.1. Reconocimiento de movimientos

El objetivo de este experimento es analizar el desempeño del sistema de reconocimiento de movimientos para un entrenamiento previo. El reconocimiento se realiza a través de una red neuronal cuyo entrenamiento se lleva a cabo a partir de 500 muestras de cada movimiento, que son los patrones característicos de éstos. De las muestras de los movimientos se toma el 80 % para el entrenamiento y el 20 % restante para la validación y las pruebas de la red entrenada. El desempeño de la red se mide mediante pruebas realizadas con las muestras de los movimientos separadas para la validación, es decir, el 20 % de las 500 muestras de los movimientos.

El comportamiento de la red permitirá evaluar su desempeño, la red será entrenada 1000 veces para tener una base sólida que justifique su comportamiento. Una vez entrenada la red se obtiene el porcentaje promedio de reconocimientos correctos para tener una métrica confiable del desempeño del sistema. En la Tabla 7.1 se presenta el desempeño del sistema utilizando diferentes cuantificadores uniformes, cada uno de ellos con diferente cantidad de bits. En la Tabla 7.1 también se muestra el error de entrenamiento que se encuentra relacionado con la cantidad de bits en el cuantificador utilizado.

Bits	Porcentaje de reconocimiento	Error en el entrenamiento
4	84.3865	.0544
5	91.4990	.0322
6	92.6900	.0258
7	91.6660	.0271
8	92.1105	.0261
9	92.6605	.0253
10	92.5720	.0252
11	92.6660	.0251
12	94.1710	.0253

Tabla 7.1: Resultado de las pruebas para el primer experimento.

7.5. Segundo experimento

Este experimento se lleva a cabo de la misma forma que el anterior, por lo mismo solamente se presentarán los resultados. Para este experimento se utilizan 4 movimientos diferentes entre si y diferentes a los del experimento anterior. La evaluación del segundo experimento tiene como objetivo respaldar los resultados obtenidos en el primer experimento.

7.5.1. Reconocimiento de movimientos

Bits	Porcentaje de reconocimiento	Error en el entrenamiento
4	84.0850	.0574
5	88.6035	.0435
6	90.1495	.0385
7	90.5920	.0372
8	91.1160	.0364
9	91.0795	.0364
10	90.9695	.0363
11	91.0350	.0362
12	91.0920	.0361

Tabla 7.2: Resultado de las pruebas para el segundo experimento.

7.6. Tamaño de palabra en el sistema

El comportamiento del sistema también se ve afectado por la cantidad de bits que representan a los parámetros AR en la obtención de los patrones de los movimientos, el tamaño de la palabra depende de la herramienta con la que se esté procesando la señal para obtener los parámetros. En la Tabla 7.3 se presenta el desempeño del sistema para casos donde se utilizan diferentes tamaños de palabra que representan a los patrones, el sistema en la Tabla 7.3, es un sistema con un cuantificador de 8 bits. En la Tabla 7.4 se presenta el desempeño del sistema para diferentes tamaños de palabra utilizando un cuantificador de 12 bits. El comportamiento del sistema se compara al analizar el desempeño del mismo para diferentes tamaños de palabra.

Tamaño de la palabra (Bits)	Porcentaje de reconocimiento
2	45.475
4	90.250
6	91.580
8	92.230
10	92.040
12	92.195
16	91.980

Tabla 7.3: Desempeño del sistema para diferentes tamaños de palabra y un cuantificador de 8 bits.

Tamaño de la palabra (Bits)	Porcentaje de reconocimiento
2	48.332
4	91.901
6	94.762
8	94.725
10	94.639
12	94.640
16	94.528

Tabla 7.4: Desempeño del sistema para diferentes tamaños de palabra y un cuantificador de 12 bits.

Capítulo 8

Conclusiones

Los resultados obtenidos en el capítulo anterior, en las pruebas del sistema de reconocimiento implementado, tienen un comportamiento similar para sistemas con cuantificadores entre 8 y 12 bits, mientras que los demás tienden a bajar el desempeño del sistema y el error en el entrenamiento disminuye entre mayor sea la cantidad de bits utilizados en el cuantificador. Para demostrar que los resultados son validos es necesario compararlos con un sistema que se considere valido, en este caso se compara con el sistema que se utilizo de base en está tesis, el trabajo del Doctor Wang [29].

La investigación del Doctor Wang [29] presenta el mismo sistema que el simulado en esta tesis, la diferencia radica en los movimientos identificados, ya que en este trabajo no se lleva a cabo la adquisición de las señales EMG si no la simulación de las mismas. El sistema del Doctor Wang [29] arroja como resultado un porcentaje de reconocimiento del 98.75 % y 95 % para el entrenamiento de la red y la validación, respectivamente; esto para un sistema con un cuantificador de 12 bits. El sistema presentado en esta tesis, para casi las mismas condiciones que el sistema del Doctor Wang [29], da un porcentaje de reconocimiento de movimientos del 92 % al 94 % y un error para el entrenamiento de .02 a .03.

La diferencia en el porcentaje de reconocimiento se debe a las diferencias entre ambos sistemas. Sin embargo, aunque el sistema no presente el mismo porcentaje de reconocimiento que el sistema que sirvió de base [29], el sistema es valido para el tipo de pruebas que se realizaron en el capítulo anterior, ya que no se desea evaluar que tan bueno es el reconocimiento si no como cambia este de acuerdo al cuantificador. El sistema se utilizara para analizar el desempeño del mismo dependiendo del cuantificador uniforme que se utilice en éste, que en la mayoría de las aplicaciones se utilizan 12 bits para la cuantificación, el sistema del Doctor Wang utiliza un cuantificador de 12 bits.

Como se puede apreciar en los resultados del capítulo 7, Tabla 7.1 y Tabla 7.2, se pueden obtener los mismos resultados con diferentes niveles de cuantificación, menores a 12 bits. El porcentaje de reconocimiento se encuentra asociado al cuantificador, pero este se mantiene para cuantificadores entre 8 y 12 bits, para aquellos con menor cantidad se tiene que el desempeño del sistema disminuye. La mejora del desempeño se observa también en el error de entrenamiento arrojado para cada uno de los sistemas con cuantificadores diferentes, si el error de entrenamiento es pequeño se tendrá un mejor desempeño en el sistema [9].

De acuerdo a lo mencionado en este capítulo se puede concluir lo siguiente: *El desempeño en un sistema de reconocimiento de movimientos que utiliza señales EMG para representar los movimientos, parámetros AR de las señales para obtener los patrones y redes neuronales para el reconocimiento; será muy parecido para el uso de cuantificadores que tienen entre 8 y 12 bits. Si se utilizan cuantificadores menores a 12 bits se pueden ahorrar recursos y velocidad de procesamiento, en comparación con los sistemas de 12 bits, con lo cual se comprueba la hipótesis planteada en el primer capítulo de esta tesis.*

Otra conclusión importante es la que se observa en las Tablas 7.3 y 7.4, donde se analizan los efectos en el desempeño del sistema para diferentes tamaños de palabra que representan a los parámetros AR en el sistema, con lo cual se puede concluir lo siguiente: *“El tamaño de palabra óptimo con el cual se puede representar a los parámetros AR para un sistema de reconocimiento de movimientos, es de 6 bits.”*.

Bibliografía

- [1] Ainishet Asres, Huifang Dou, Zhaoying Zhou, Yuli Zhang, and Sencun Zhu. A combination of ar and neural network technique for emg pattern identification. In *18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 63, pp. 561-580,, 1996.
- [2] P. C. Doerschuk, D. E. Gustafson, and A. S. Willsky. Upper extremity limb function discrimination using emg signal analysis. In *IEEE Trans. Biomed. Eng.*, vol. BME-30, pp. 18-28, Jan., 1983.
- [3] Kevin Englehart, Bernard Hudgins, , and Philip Parker. Multifunction control of prostheses using the myoelectric signal. In *Intelligent Systems and Technologies in Rehabilitation Engineering*, 2001.
- [4] Dario Farina, Luca Mesin, Simone Martina, and Roberto Merletti. A surface emg generation model with multilayer cylindrical description of the volume conductor. In *IEEE Transactions on Biomedical Engineering*, VOL. 51, NO. 3, 2004.
- [5] Osamu Fukuda, Jun Arita, and Toshio Tsuji. An emg-controlled omnidirectional pointing device using a hmm-based neural network. In *IEEE*, 2003.
- [6] D. Graupe, K. H. Kohn, A. Kralj, and S. Basseas. Patient controlled electrical stimulation via emg signature discrimination for providing certain paraplegics with primitive walking functions. In *J.Biomed. Eng.*, vol. 5, pp. 220-226, 1983.
- [7] Clinical Biomechanics Research Group. Analysis of electromyographic data. In *University of Brighton*, 2006.
- [8] Simon Haykin. Models of a neuron. In *Neural Networks, a comprehensive foundation.*, 1999.
- [9] Simon Haykin. Modulaci3n por pulsos. In *Sistemas de comunicaci3n.*, 2001.
- [10] Simon Haykin. Stochastic models. In *Adaptive Filter Theory, Fourth Edition*, 2002.

-
- [11] Gisela Hefftner, Walter Zucchini, and George G. Jaros. The electromyogram (emg) as a control signal for functional neuromuscular stimulation -part i: Autoregressive modeling as a means of emg signature discrimination. In *IEEE*, 1988.
- [12] Gisela Hefftner, Walter Zucchini, and George G. Jaros. The electromyogram (emg) as a control signal for functional neuromuscular stimulation -part ii: Practical demonstration of the emg signature discrimination system. In *IEEE*, 1988.
- [13] Wen-Juh Kang, Jiue-Rou Shiu, Cheng-Kung Cheng, Jin-Shin Lai, Hen-Wai Tsao, , and Te-Son Kuo. The application of cepstral coefficients and maximum likelihood method in emg pattern recognition. In *IEEE Transactions on Biomedical Engineering*, Vol. 42, No. 8, 1995.
- [14] Jong-Sung Kim, Hyuk Jeong, and Wookho Son. A new means of hci: Emg-mouse. In *IEEE International Conference on Systems, Man and Cybernetics*, 2004.
- [15] Katsutoshi Kuribayashi, Seiji Shiniizu, Koji Okiniura, and Takao Taniguchi. A discrimination system using neural network for emg-controlled prostheses. In *IEEE/RSJ International Conference on Intelligent Robots and Systems.*, 1993.
- [16] J. Makhoul. Linear prediction: A tutorial review. In *Proc. IEEE*. 63, pp. 561-580,, 1975.
- [17] Yuji Matsumuraa, Minoru Fukumia, Norio Akamatsua, and Kazuhiro Nakaurab. Recognition of wrist emg signal patterns using neural networks. In *Journal of Intelligent Fuzzy Systems, IOS press*, 2004.
- [18] Roberto Merletti, Loredana Lo Conte, Elena Avignone, and Piero Guglielminotti. Modeling of surface myoelectric signals part i: Model implementation. In *IEEE Transactions on Biomedical Engineering*, Vol. 46, No. 7, 1999.
- [19] Roberto Merletti and Philip Parker. Detection and conditioning of the surface signal. In *Electromyography. Physiology, Engineering and Noninvasive Applications 107-123*, 2004.
- [20] Andrea Merlo, Dario Farina, and Roberto Merletti. A fast and reliable technique for muscle activity detection from surface emg signals. In *IEEE Transactions on Biomedical Engineering.*, 2003.
- [21] Luca Mesin and Dario Farina. Simulation of surface emg signals generated by muscle tissues with inhomogeneity due to fiber pinnation. In *IEEE Transactions on Biomedical Engineering*, Vol. 51, No. 9, 2004.

- [22] Seok pil Lee, Jung sub Kim, and Sang hui Park. An enhanced feature extraction algorithm for emg pattern classification. In *IEEE Transactions on Rehabilitation Engineering, Vol. 4, No. 4.*, 1996.
- [23] Zaira Pineda Rico. Diseño de un sistema de control mioeléctrico “manos libres” en tecnología cmos para el encendido automático de una electrolarínge. In *Tesis Maestro en Ciencias en Ingeniería Electrónica con Especialidad en Sistemas Electrónicos Tecnológico de Monterrey, Campus Monterrey.*, 2007.
- [24] Julia Abril Saenz. Diseño de un control mioeléctrico de una electrolarínge. In *Tesis Maestro en Ciencias en Ingeniería Electrónica con Especialidad en Sistemas Electrónicos Tecnológico de Monterrey, Campus Monterrey.*, 2006.
- [25] M. H. Sherif, R. J. Gregor, and J. Lyman. Effects of load on myoelectric signals: The arima representation. In *IEEE Trans. Biomed.*, 1981.
- [26] Ying-Horng Tarn, Gwo-Ching Chang, Jin-Shin Lai, and Te-Son Kuo. Design of the human/computer interface for human with disability - using myoelectric signal controlled. In *Proceedings - 19th International Conference - IEEE/EMBS Oct. 30.*, 1997.
- [27] R. J. Triolo and G. D. Moskowitz. A multichannel time series myoprocessor for robust classification of limb function and estimation of muscle force. In *IEEE Proc. 7th Annu. Conf. Eng. Med. Biol. Soc.*, 265-270, 1985.
- [28] Toshio Tsuj, Osamu Fukuda, Hiroki Shigeyoshi, and Makoto Kaneko. Biomimetic impedance control of an emg-controlled prosthetic hand. In *IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2000.
- [29] Rencheng Wang, Changhua Huang, and Bo Li. A neural network-basaed surface electromyography motion pattern classifier for the control of prostheses. In *19th International Conference - IEEE/EMBS.*, 1997.
- [30] Jhon G. Webster. Amplifiers for other biopotential signals. In *Medical Instrumentation 320-321*, 1997.