



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

**Decodificación de señales mioeléctricas
mediante redes neuronales profundas
para detectar intención de movimiento**

TESIS

Que para obtener el título de
Ingeniero en Mecatrónica

P R E S E N T A

Carlos Omar Mondragón Vázquez

DIRECTOR(A) DE TESIS

Dr. Jesús Esteban Pérez Ortega



Ciudad Universitaria, CDMX, 2018

Índice general

Índice de figuras	III
Índice de tablas	V
1. Introducción	1
1.1. Marco Contextual	1
1.2. Estado del Arte	3
2. Planteamiento del Problema	5
2.1. Justificación	5
2.2. Preguntas	6
2.3. Hipótesis	6
2.4. Objetivos	6
2.5. Meta	6
3. Marco teórico	7
3.1. Electromiografía	7
3.2. Redes neuronales artificiales	9
4. Metodología	13
4.1. Protocolo de ejercicios	14
4.2. Dispositivo de adquisición de datos	15
4.2.1. Sensor de señales mioeléctricas	15
4.2.2. Sensor de velocidad angular	16
4.2.3. Adquisición y almacenamiento de las señales	18
4.2.4. Datos de entrada para la red neuronal	19
4.3. Desarrollo de la red neuronal profunda	20
4.3.1. Arquitectura de la Red	20
4.3.2. Entrenamiento de la red	23
4.3.3. Eficiencia y similitud en la prediccion de la red neuronal	24

5. Resultados	27
5.1. La amplitud de las señales mioeléctricas varía de acuerdo a la persona .	27
5.2. Las señales mioeléctricas varían aunque sea el mismo ejercicio realizado por la misma persona	28
5.3. Las arquitecturas con capas ocultas de 128 neuronas fueron las más eficientes	29
5.4. La mejor eficiencia del set de validación es menor que la del set de entrenamiento	31
5.5. Las predicciones incorrectas no fueron tan alejadas del valor real	33
5.6. Comparación entre todas las arquitecturas con el set de prueba	35
6. Discusión y Conclusiones	41
7. Anexos	45
7.1. Visualización de los pesos obtenidos en la red convolucional	45
7.2. Cuestionario	47
7.3. Documentación de dispositivos ocupados	47
Bibliografía	49

Índice de figuras

1.1. Pirámide demográfica EU y México	2
3.1. Interfaz electrodo-piel	8
3.2. Neurona biológica	9
3.3. Neurona con entrada simple	10
3.4. Neurona con múltiples entradas	11
3.5. Capa de neuronas	11
3.6. Red multicapa	12
4.1. Articulación y velocidad angular de interés	13
4.2. Posiciones de electrodos	17
4.3. Posición IMU	18
4.4. Diagrama de secuencia UML	19
4.5. UML de secuencia: ANNs	22
4.6. red convolucional	22
5.1. Muestra de EMG	29
5.2. Giroscopio y etiquetas	29
5.3. Comparación arquitectura 2	30
5.4. Comparación arquitectura 3	31
5.5. Eficiencia arquitectura 1 del set de entrenamiento VS set de validación .	32
5.6. Eficiencia arquitectura 2 del set de entrenamiento VS set de validación .	33
5.7. Eficiencia y similitud	34
5.8. Predicción y etiquetas	35
5.9. Diagrama de caja	36
7.1. Visualización primera capa	46
7.2. Visualización segunda capa	46

Índice de tablas

3.1. Funciones de Transferencia	10
4.1. Señal de entrada	20
4.2. Etiquetas	21
4.3. Prueba para arquitectura 2	23
4.4. Prueba para arquitectura 3	23
4.5. Set de datos	24
4.6. Similitud	25
5.1. Información de sujetos de prueba	27
5.2. Calidad de la señal mioeléctrica	28
5.3. Entrenamiento: Persona 1	37
5.4. Entrenamiento: Ejercicio B	38
5.5. Entrenamiento: 3 Ejercicios con Persona 1	39
5.6. Entrenamiento: Ejercicio B con todas las personas	39
5.7. Entrenamiento: Todos los datos	40

Introducción

1.1. Marco Contextual

La población de adultos mayores (60 años o más) va en crecimiento año con año, principalmente en países con muy alto índice de desarrollo (Jahan, 2016). En el mundo se tiene actualmente una media de 30.4 años de edad, y hay un 17.28 % de personas mayores de 55 años de edad¹. Mientras que en la Unión Europea, que está constituida en su mayoría por países con un muy alto índice de desarrollo, se tiene una media de 42.9 años (fig.1.1) y hay un 32 % de personas mayores de 55 años de edad². Si observamos la demografía de México, nos damos cuenta que estamos por debajo de la media mundial con 14.73 % de personas mayores de 55 años de edad, pero también podemos observar que en aproximadamente 30 años la forma de la piramide de población cambiará de manera importante.

La población de adultos mayores va en crecimiento y las afecciones en miembros inferiores aumentan con la edad. La enfermedad reumática más frecuente es la artrosis y se da con más frecuencia en las rodillas, para los hombres particularmente en la derecha. Este tipo de enfermedades produce dolor y limita el movimiento de la articulación (Michael et al.). Por lo tanto, es necesario que existan proyectos orientados a esta población. A medida que estas afecciones van avanzando se reduce el número de actividades que este grupo poblacional puede realizar. Esto merma la calidad de vida de las personas, y produce una pérdida en la efectividad que se tiene al laborar.

Un dispositivo que puede servir para reducir el dolor y/o mejorar el funcionamiento de la articulación es la órtesis. Una órtesis se define como “un dispositivo utilizado de manera externa para modificar las características estructurales y/o funcionales del sis-

¹Para la información demográfica del mundo: <https://www.cia.gov/library/publications/resources/the-world-factbook/geos/xx.html>, en la pestaña "People and Society", última verificación: 03/08/2018 15:00

²Para la información demográfica de la Unión Europea: <https://www.cia.gov/library/publications/resources/the-world-factbook/geos/ee.html>, última verificación: 03/08/2018 15:02

1. INTRODUCCIÓN




Figura 1.1: Pirámide Demográfica: Unión Europea y México. Imagen obtenida de *The World Factbook*

tema esquelético y neuromuscular”¹. Las órtesis han permitido que se mejore la calidad de vida de las personas que las usan. Las órtesis pueden ser pasivas o activas y conforme la tecnología va incrementando la utilidad de las órtesis también va en aumento. Las órtesis pasivas se utilizan sin la ayuda de algún dispositivo eléctrico o electrónico, de manera que la asistencia que pueden dar está limitada. Por otro lado, las órtesis activas, además de corregir un problema estructural, tienen la posibilidad de apoyar al movimiento mediante actuadores. Estas últimas necesitan una señal de control que permita manejar su movimiento, generalmente se busca que el movimiento sea tan natural como sea posible. Para este fin, con el desarrollo de nuevos dispositivos electrónicos y la mejora de técnicas para la generación de una señal de control, se ha logrado tener al alcance una gran diversidad de herramientas disponibles. Entre ellas sobresale el uso de señales mioeléctricas por la relación que hay entre estas y la activación del músculo correspondiente, ya que nos indican la intención de movimiento en el instante en el que es observada. Sin embargo, el análisis de esta señal no es sencillo, debido a la naturaleza estocástica de las señales mioeléctricas, estas se tienen que decodificar utilizando técnicas complicadas, capaces de identificar los patrones que las señales siguen y puedan predecir la intención del movimiento. Para esta tarea necesitamos la ayuda de redes neuronales artificiales, las cuales son capaces de identificar patrones en una señal de entrada, y decodificarla en la señal que se requiere.

El uso de las redes neuronales artificiales comenzó a mediados del siglo pasado. Sin embargo, las computadoras no tenían suficiente capacidad de procesamiento para las grandes redes neuronales artificiales, y por tanto no se consideraba viable trabajar con ellas. No fue hasta años recientes que su popularidad volvió a crecer, principalmente por su aplicación en el reconocimiento de voz (Deng et al.). Actualmente hay una comunidad en el área de aprendizaje máquina, que incluye el uso de redes neuronales profundas, en constante crecimiento gracias al costo y accesibilidad de nuevos procesadores que

¹Definición según ISO 8549-1:1989

son capaces de realizar millones de operaciones por segundo.

1.2. Estado del Arte

Recientemente, el desarrollo de interfaces mioeléctricas ha dado resultado en la aparición de robots para rehabilitación como prótesis de mano y exoesqueletos (Park and Lee). Esto ha llevado al desarrollo de métodos cada vez más complejos para la generación de una señal de control para las prótesis o exoesqueletos. Principalmente, los métodos que han generado mejores resultados son los que usan alguna forma de inteligencia artificial en su desarrollo como el diseño de una red neuronal artificial con *wavelet* diseñada por Arveti et al. que discrimina 5 movimientos predeterminados de la mano los cuales con ayuda de un microcontrolador, generan la señal de control para la prótesis de mano.

En este estudio su red tuvo una eficiencia máxima de 96.77%, este estudio fue realizado a solo 2 personas, de las cuales una estaba muy familiarizada con tareas de rehabilitación. Su red fue generada utilizando Matlab, se utilizaron 2 arquitecturas de red con 1 capa oculta, sin ningún procedimiento complejo para evitar la sobrealimentación de la red, se limitaron a probar con varios arreglos de neuronas.

En otro estudio mucho más elaborado, realizado por Park and Lee, de la Universidad de Korea, en el departamento de Ingeniería Cognitiva, se realizó la decodificación de la intención de movimiento para su uso en prótesis de mano, el objetivo fue generar una red capaz de ser usada en múltiples usuarios, que según este mismo artículo, con otras técnicas no se supera el 65% de eficiencia. La arquitectura de su red fue una red neuronal convolucional de 3 capas ocultas, con diferentes arreglos de neuronas en cada capa¹. Utilizaron 6 movimientos de una base de datos disponible a nivel internacional para el desarrollo y comparación de este tipo de pruebas, esta base de datos se llama NINAPRO, la cual contiene información de 27 sujetos realizando 52 tipos de movimientos preestablecidos². El método propuesto mostró una eficiencia de 92%, mayor a cualquier técnica con la que se compararon.

Yan y colaboradores realizaron un artículo de revisión acerca de las estrategias de asistencia para órtesis de miembros inferiores y exoesqueletos (Yan et al., 2015). En esta revisión mencionan que la literatura acerca de los dispositivos para miembros inferiores prolifera debido a una básica pero fundamental tarea: caminar. Los exoesqueletos para pierna son fáciles de diseñar, comparados con su contraparte en los miembros superiores, pero necesitan requerimientos físicos y cognitivos muy particulares. Hay diferentes estrategias de control y enfoques, pero sigue siendo un reto desarrollar una estrategia que provea una asistencia natural y eficiente. En este mismo artículo se mencionan los últimos desarrollos en estrategias de asistencia, dentro de los más estudiados

¹Para más información sobre su arquitectura, por favor ver el artículo de Park and Lee

²Para más información sobre NINAPRO: <http://ninapro.hevs.ch/>, última verificación:

1. INTRODUCCIÓN

están: Control con trayectoria predefinida, Control basado en modelo, Control difuso y Estrategias híbridas.

Específicamente para la rodilla, no hay ninguna estrategia que utilice las señales mioeléctricas al tiempo en el que se desarrolló dicho artículo.

Planteamiento del Problema

Los adultos mayores sufren una pérdida en su calidad de vida debido a afecciones en las articulaciones, por lo que se requiere dar mayor importancia a este grupo poblacional para mejorar su calidad de vida. Además, la población de este grupo va en aumento al igual que su esperanza de vida.

Una manera de recuperar la movilidad en los adultos mayores es con la ayuda de órtesis (Michael et al.). Particularmente se necesitan dispositivos como las órtesis activas de rodilla. Éstas requieren una señal de control para que permitan asistir de manera eficiente a la persona, sin embargo, las estrategias para la generación de esta señal están todavía en desarrollo (Yan et al.). Por lo que este tema requiere atención alrededor del mundo para la aceleración del desarrollo de esta tecnología.

2.1. Justificación

Aunque existen trabajos enfocados en el desarrollo de órtesis activas controladas con una señal mioeléctrica, principalmente se enfocan a miembros superiores del cuerpo humano y se ha prestado poca atención a los miembros inferiores. Aunque funcionalmente los miembros inferiores tienen un movimiento menos preciso, comparado con el de la mano, éstos tienen una carga mucho mayor y deben mantener el equilibrio del sujeto (Yan et al.). Por esto, el desarrollo de un sistema de control no es una tarea simple.

La afección más común en los adultos mayores daña generalmente a los miembros inferiores, especialmente las rodillas (Michael et al.). Esto reduce la calidad de vida y no permite realizar de manera natural tareas tan simples como levantarse o sentarse en una silla. Por otro lado, el crecimiento de los modelos de inteligencia artificial genera nuevas posibilidades para desarrollar estructuras de redes neuronales artificiales, anteriormente inviables, que se podrían aplicar para la decodificación de señales mioeléctricas.

2.2. Preguntas

- ¿Se podrán decodificar las señales mioeléctricas en una señal de control mediante redes neuronales artificiales para su uso en una órtesis de rodilla?
- ¿Se podrá desarrollar una red neuronal artificial capaz de ser utilizada con múltiples usuarios y ejercicios?

2.3. Hipótesis

- Una red neuronal artificial, con una arquitectura adecuada, podrá ser capaz de decodificar de manera eficiente una señal mioeléctrica adquirida digitalmente en una señal de control.
- Una red neuronal profunda será capaz de decodificar la señal mioeléctrica para múltiples usuarios, si es entrenada con grandes cantidades de datos de diferentes personas y diferentes ejercicios.

2.4. Objetivos

Objetivo general: Desarrollar una red neuronal artificial capaz de decodificar la señales mioeléctricas en la flexión y extensión de la rodilla.

Objetivos específicos:

- Implementar un dispositivo capaz de adquirir, adecuar y almacenar datos de diferentes señales mioeléctricas simultáneamente con el valor de la velocidad angular de la articulación de la rodilla.
- Registrar los datos de diferentes sujetos al realizar ejercicios simples de flexión y extensión de la rodilla.
- Desarrollar, mediante el uso de TensorFlow, diferentes estructuras de redes neuronales artificiales y comparar su eficiencia en la decodificación de las señales mioeléctricas.

2.5. Meta

Desarrollar una red neuronal profunda que logre decodificar la señal mioeléctrica en 7 diferentes clases con una eficiencia mayor al 80% utilizando datos de diferentes sujetos experimentales al realizar diferentes ejercicios.

Marco teórico

3.1. Electromiografía

Las fibras musculares están agrupadas y tradicionalmente identificadas por su línea de acción, dirección de la tensión y su origen e inserción. Los axones de las neuronas motoras se ramifican de manera que puedan unirse a la fibra muscular creando sinapsis neuromusculares. Mediante los potenciales de acción de las neuronas motoras se envía una señal a las fibras musculares y se produce así la contracción muscular. La detección de este intercambio de energía es la base de la electromiografía.

Si la contracción de un músculo es sostenida por un periodo largo de tiempo, el músculo empieza a descargarse y la amplitud de la señal se ve reducida. Por lo tanto, la amplitud de la señal mioeléctrica no es igual a la fuerza ([Basmajian and DeLuca](#)).

La energía que es generada por el músculo, al detectarla con los electrodos, se observa en forma de voltaje en el orden de microvolts, lo que hace necesario instrumentos para amplificar esta señal y que pueda ser registrada.

La interfaz entre el electrodo y la piel es un tema delicado [3.1](#). La impedancia de la piel varía en función de la humedad de la piel, el contenido de grasa superficial y la densidad de la capa de células muertas. Generalmente se utiliza un medio electrolítico que provee un colchón entre la superficie del electrodo y la superficie de la piel. Este medio, comúnmente hipersalínico, potencia la señal electromiográfica de la piel. Si no se usa un medio electrolítico, como en el caso de los electrodos secos, la piel eventualmente produce sudor, generando su propio medio electrolítico.

3. MARCO TEÓRICO




Figura 3.1: Interfaz electrodo-piel

Para las señales mioeléctricas, es importante mantener la impedancia de la piel al electrodo lo más baja posible y balanceada entre los dos electrodos. Para propósitos de investigación, se recomienda que sea menor a $10\text{ k}\Omega$ para obtener un buen rechazo al modo común.

Cuando la impedancia es muy alta o está desbalanceada, el modo común es vencido, lo que genera que el ruido afecte a la señal, como lo es el ruido externo de 60 Hz producido por la red eléctrica de la habitación en donde esté el equipo o el mismo ruido interno de otros órganos del cuerpo humano.

Los desbalances pueden ocurrir cuando un electrodo pierde adhesión a la piel, que principalmente ocurre en evaluaciones dinámicas. Los amplificadores pueden tolerar hasta un 20% de discrepancia entre electrodos, valores mayores a 20% generan elevaciones falsas en la amplitud de la señal. Hay otros dos elementos que puede moderar la impedancia de la señal. Uno es el mismo electrodo, en general, el tamaño del electrodo y el material del que está construido. Actualmente la mayoría de los electrodos están hechos de cloruro de plata. El segundo elemento es el cable que existe entre el electrodo y el amplificador, de hecho, el cable es una de las partes más vulnerables del sistema para adquirir la señal mioeléctrica. Usualmente se rompe y tiene que ser remplazado, por lo que se recomienda que cada uno de los cables sea lo más corto posible y que sean inspeccionados con regularidad.

Una vez que la señal se detecta a través de la interfaz electrodo-piel (fig. 3.1), debe ser procesada por el amplificador de instrumentación, el cual amplifica la señal de manera diferencial, por lo que tiene la capacidad de eliminar el ruido mediante el rechazo al modo común ¹.

En el modo diferencial de un amplificador, se necesitan tres electrodos para su funcionamiento, dos electrodos que detectan la señal mioeléctrica, y uno de referencia. Los electrodos de detección son puestos sobre la trayectoria de las fibras musculares, mientras que el electrodo de referencia es colocado en cualquier parte del cuerpo siempre y cuando tenga buen contacto (Criswell), generalmente se pone cerca de la zona de detección por comodidad.

¹(4)

3.2. Redes neuronales artificiales

Las redes neuronales artificiales nacieron en el siglo pasado, mucha investigación importante se realizó en los 80's y 90's. Sin embargo no había grandes desarrollos porque las computadoras no eran lo suficientemente rápidas.

En un principio, las redes neuronales artificiales ANN¹ se basaron en el funcionamiento de una neurona biológica. Las neuronas biológicas tienen un cuerpo, axón y dendritas y pueden comunicarse entre ellas mediante sinapsis (fig. 3.2). El funcionamiento básico de las neuronas biológicas es enviar señales de salida desde su axón mediante potenciales de acción y recibir información de entrada a través de la sinapsis en las dendritas.




Figura 3.2: Esquema simplificado de una neuronas biológica y su contacto de comunicación, la sinapsis

De manera similar a una neurona biológica, una neurona artificial utilizada en las ANN (fig. 3.3) recibe una entrada “p” multiplicada por un peso “w” dado (dendrita), a esto se le suma una compensación “b” (cuerpo) y el resultado es operado con una función de transferencia para obtener la salida “a” (axón). De aquí en adelante las neuronas artificiales serán referidas solo como neuronas.

¹por las siglas en inglés de “Artificial Neural Networks”

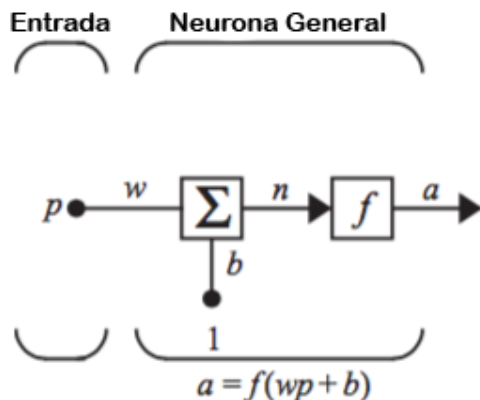


Figura 3.3: Esquema de una neurona artificial con una sola entrada

Las neuronas se activan, o no, dependiendo de una función de transferencia, también llamada función o unidad de activación. Las unidades de activación pueden ser lineales o no lineales y se eligen de manera que satisfagan ciertas características del problema a resolver. Existen muchas unidades de activación disponibles. Para este trabajo se utilizó la función $ReLU^1$ por ser una unidad de activación no lineal (tiene la capacidad de aproximar funciones no lineales) y su facilidad de uso. En la tabla (3.1) se muestra la relación entrada-salida de la función de transferencia junto con su ícono representativo.

Nombre	Relación Entrada-Salida	Ícono
Positive Linear (ReLU)	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$	

Tabla 3.1: Funciones de Transferencia

Típicamente las neuronas tienen más de una sola entrada, cuando estas tienen R entradas, se genera un vector de pesos W correspondientes a cada una de las entradas de la neurona. Se muestra una notación abreviada de una neurona artificial con múltiples entradas en la fig. 3.4

¹por las siglas en inglés de “**R**ectified **L**inear **U**nit”

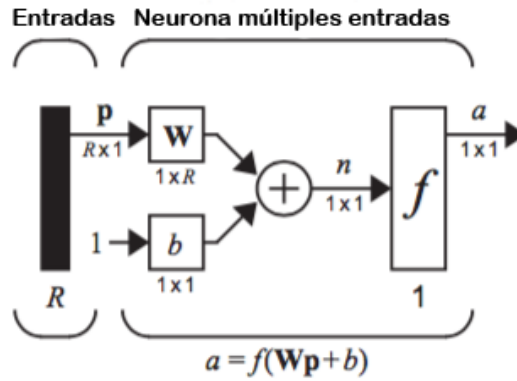


Figura 3.4: Esquema de una neurona con múltiples entradas

Sin embargo, una neurona con muchas entradas puede no ser suficiente y se requieren de más neuronas. Cuando tenemos un arreglo de varias neuronas recibiendo las mismas entradas, este arreglo, recibe el nombre de “capa”. Una capa con S neuronas y R entradas, tiene una matriz de pesos W de tamaño $S \times R$ y a su vez S salidas (fig.3.5).




Figura 3.5: Esquema de una capa de neuronas

La matriz de pesos se puede representar de la siguiente manera:

3. MARCO TEÓRICO

$$W_{m,n} = \begin{pmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,R} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,R} \\ \vdots & \vdots & \ddots & \vdots \\ w_{S,1} & w_{S,2} & \cdots & w_{S,R} \end{pmatrix} \quad (3.1)$$

Conforme la complejidad del problema que se quiere resolver con redes neuronales artificiales va en aumento, se ve la necesidad de incrementar el número de capas que tiene la red. Las redes multicapa son más capaces que las redes de una sola capa, porque pueden encontrar soluciones muy aproximadas a problemas no lineales cuando se usan unidades de activación no lineales. El problema cuando se usan más de 2 capas en la estructura de una ANN es determinar la cantidad de neuronas que se necesitan en las capas intermedias, también llamadas capas ocultas. Actualmente se siguen estudiando maneras de determinar la cantidad de neuronas necesarias en cada capa de la arquitectura (Hagan et al.). Un esquema de una red multicapa se muestra en la fig. 3.6




Figura 3.6: Esquema de una red neuronal multicapa

Metodología

Se pretende decodificar la señal de un conjunto de señales mioeléctricas de la pierna derecha en velocidades angulares que corresponden al comportamiento que tiene la articulación de la rodilla. Esta articulación solo tiene un grado de libertad y dependiendo el sentido del movimiento se divide en: flexión y extensión. La articulación y la velocidad de interés se esquematizan en la fig. 4.1, se entiende por flexión en términos de la velocidad angular como cualquier valor negativo, mientras que extensión se entiende como cualquier valor positivo. En ambos casos, la magnitud indica la rapidez con que se realiza dicho movimiento.




Figura 4.1: Articulación y velocidad angular de interés

4.1. Protocolo de ejercicios

El protocolo de ejercicios fue basado en el manual realizado por [Campbell and Robertson](#), en donde se exponen varios ejercicios orientados a personas mayores para recuperar movilidad y balance en su cuerpo. La serie de ejercicios es pararse y sentarse de una silla de 3 diferentes formas.

La posición de inicio consiste en el sujeto sentado en un silla fija no muy baja, aproximadamente a la altura de las rodillas, con los pies colocados ligeramente detrás de las rodillas. La primer variante del ejercicio consiste en levantarse de la silla de manera natural con los brazos cruzados, y al llegar a la posición de pie volverse a sentar. Este ejercicio se repite tantas veces como sea posible durante 4 minutos. La segunda variante se realiza utilizando una mano de apoyo en uno de los descansabrazos de la silla para levantarse y sentarse sin cambiar la mano de apoyo durante los 4 minutos. La tercer variante se realiza con las 2 manos de apoyo en los descansabrazos. El protocolo completo consiste en realizar las 3 variantes del ejercicio en el siguiente orden:

Ejercicio A Sin apoyo de las manos

Ejercicio B Con apoyo de una mano

Ejercicio C Con apoyo de las dos manos

Se realizó el protocolo de ejercicios a 4 personas que otorgaron su consentimiento oral en el entendido de que ningún dispositivo que se utilizó es de riesgo para su salud, y se informó que de sentirse incomodos o desear terminar la prueba en cualquier momento podían retirarse. También se realizó un cuestionario pequeño acerca de sus hábitos, y se pidió su edad, estatura y peso.

Se colocaron electrodos húmedos en las posiciones indicadas en la [fig.4.2](#), posteriormente se colocaron las IMU¹ como se indica en la [fig.4.3](#) y se conectaron al dispositivo de adquisición. Cabe mencionar que el dispositivo de adquisición es energizado por una pila recargable LiPo de manera que permita libertad de movimiento en la persona realizando la prueba.

Entre cada ejercicio los sujetos tuvieron un descanso de 1 min para evitar el agotamiento. Se registró la calidad de la señal obtenida (ver [tabla 5.2](#) en Resultados).

¹Por sus siglas en inglés *Inertial Measurement Unit*, Unidad de Medición Inercial. Para mas información sobre la IMU que se utilizó: <https://www.sparkfun.com/products/11028>, última verificación: 03/08/2018 20:05

4.2. Dispositivo de adquisición de datos

4.2.1. Sensor de señales mioeléctricas

Para cumplir con el objetivo principal de esta tesis se debe utilizar un dispositivo que tenga la capacidad de digitalizar una señal mioeléctrica. Existen muchos dispositivos comerciales que se pueden utilizar para resolver esta tarea, así como circuitos integrados que, instrumentados de manera adecuada, también pueden servir para el mismo fin. Sin embargo, los dispositivos comerciales para uso de investigación son muy costosos y realizar uno a partir de circuitos integrados llevaría mucho tiempo de desarrollo, lo cual no es el objetivo del presente trabajo. Por lo tanto, la opción fue seleccionar dispositivos comerciales de uso común. Se seleccionó *MyoWare*, desarrollado por *Advancer Technologies* y comercializado por *SparkFun Electronics*, su costo y accesibilidad lo hace un producto adecuado para la presente tesis.

El *MyoWare*¹ cuenta con 4 etapas principalmente:

1. Preamplificación
2. Rectificación
3. Integración
4. Amplificación

Para digitalizar y posteriormente enviar los datos de las señales mioeléctricas de manera digital, se requirió el uso de convertidores de señales analógicas a digitales o ADC². Los circuitos ADC seleccionados envían los datos convertidos digitales por medio del protocolo *I²C*.

Las señales mioeléctricas a registrar deben ser de los grupos musculares relacionados con el movimiento de la rodilla; Éstos, son los siguientes (**Criswell**):

1. Rectus Femoris
2. Vastus Lateralis
3. Gastrocnemius Internus
4. Gastrocnemius Externus
5. Semitendinosus-Biceps femoris
6. Tensor Fasciae Latae
7. Sartorius

¹Para información acerca del dispositivo <https://www.sparkfun.com/products/13723>, última verificación: 03/08/2018 20:11

²Por sus siglas en inglés, *Analog to Digital Converter*

8. Vastus Medialis

De los 8 grupos musculares, los primeros 5 tienen una relación directa con el movimiento de la rodilla los cuales fueron seleccionados para su adquisición y los 3 restantes sirven para estabilizar el movimiento, ubicados a la altura de la cadera, de los cuales solo se seleccionó un músculo, el número 6 *tensor fasciae latae*. De esta manera los primeros 6 grupos musculares de la lista fueron seleccionados y por tanto es necesario registrar 6 señales mioeléctricas de manera simultánea. Se utilizaron 6 *MyoWare* y 2 ADC, ya que cada ADC puede procesar hasta 4 señales. Todos los grupos musculares se seleccionaron con ayuda del libro de [Criswell](#), el cual explica, además de la función que tiene cada grupo muscular, la colocación correcta de los electrodos para detectar la señal mioeléctrica asociada al grupo muscular. En la [fig. 4.2](#) se muestran las posiciones de los electrodos seleccionadas, que se relacionan con el movimiento de flexión y extensión de la rodilla.

4.2.2. Sensor de velocidad angular

Para que la red neuronal artificial pueda realizar la clasificación se necesitan datos etiquetados, es decir, a cada conjunto determinado de datos de las señales mioeléctricas le corresponde una velocidad angular de la articulación. Así la red se entrena con las señales mioeléctricas (señales de entrada) y la velocidad angular (señal de salida). Por lo tanto, es necesario utilizar un sensor de velocidad angular, o giroscopio.

La IMU tiene 2 componentes; un acelerómetro, y un giroscopio. Para uso de este trabajo solo necesitamos el giroscopio que nos brinda la velocidad angular alrededor de uno de los 3 ejes que seleccionemos. Para obtener la velocidad angular referente al ángulo que se muestra en la [fig. 4.1](#) se tiene que hacer una diferencia de las 2 velocidades angulares de los huesos adyacentes a la rodilla ([fig.4.3](#)), por esta razón se necesitan 2 IMU, el valor resultante de la diferencia que hay de los valores obtenidos de la IMU en un instante, es la velocidad angular de la articulación de interés. Las IMU utilizadas envían los datos de manera digital por medio del protocolo *I²C*.




Figura 4.2: Posiciones de los electrodos (a) Semitendinosus-Biceps Femoris, Gastrocnemius Interno, Gastrocnemius Externo (b) Tensor Fasciae Latae, Rectus Femoris, Vastus Lateralis




Figura 4.3: Posición y eje de rotación de la IMU para obtener la velocidad angular de la articulación de interés

4.2.3. Adquisición y almacenamiento de las señales

Es necesario que el dispositivo de adquisición y almacenamiento de datos afecte lo menos posible el movimiento del sujeto y que adquiera con la mayor velocidad y sin interrupción los datos de las 6 señales mioeléctricas así como de los 2 giroscopios. Por tanto, se utilizó el microcontrolador *Raspberry Pi*.

Un aspecto importante cuando se realiza la adquisición de datos es la frecuencia de muestreo. La frecuencia de muestreo es la ventana de tiempo que tiene que pasar antes de que se pueda tomar una muestra. Limitada directamente por la capacidad del hardware, en este caso, el *MyoWare* genera una señal continua y analógica por lo que solo hay 2 elementos que están sujetos a este tiempo de espera; el ADC y la IMU. Estos 2 se comunican por I^2C con el microcontrolador a una velocidad de 400kHz.

La velocidad de adquisición y almacenamiento de 4 muestras consecutivas de la señal mioeléctrica y 1 muestra de la diferencia de los giroscopios fue de 43.48Hz

A partir de la observación, el ciclo para levantarse y sentarse en una silla llevó en promedio 7 s ó 0.14 Hz (ver Resultados), por lo que el ADC y la IMU tienen una adquisición de 310 conjuntos de datos por ciclo. Para tener una referencia, el ciclo de marcha de un humano¹ tiene una cadencia de 100-115 pasos/min, esto quiere decir que, se da 1 paso en 0.6 s ó 1.67 Hz, por lo que el ADC y la IMU tendrían una adquisición de 26 conjuntos de datos por ciclo de marcha.

En la fig.4.4 se muestra un diagrama UML² de secuencia del programa utilizado

¹Para mas información sobre el ciclo de marcha: <http://www.utdallas.edu/atec/midori/Handouts/walkingGraphs.htm>, última verificación: 03/08/2018 21:36

²Por sus siglas en inglés, *Unified Modeling Language*, Lenguaje Unificado de Modelado

para obtener las señales mioeléctricas y los datos del giroscopio. Este programa se desarrolló con *Python*¹ en *Raspberry Pi* utilizando comunicación *I²C* para los 2 ADC y las 2 IMU.

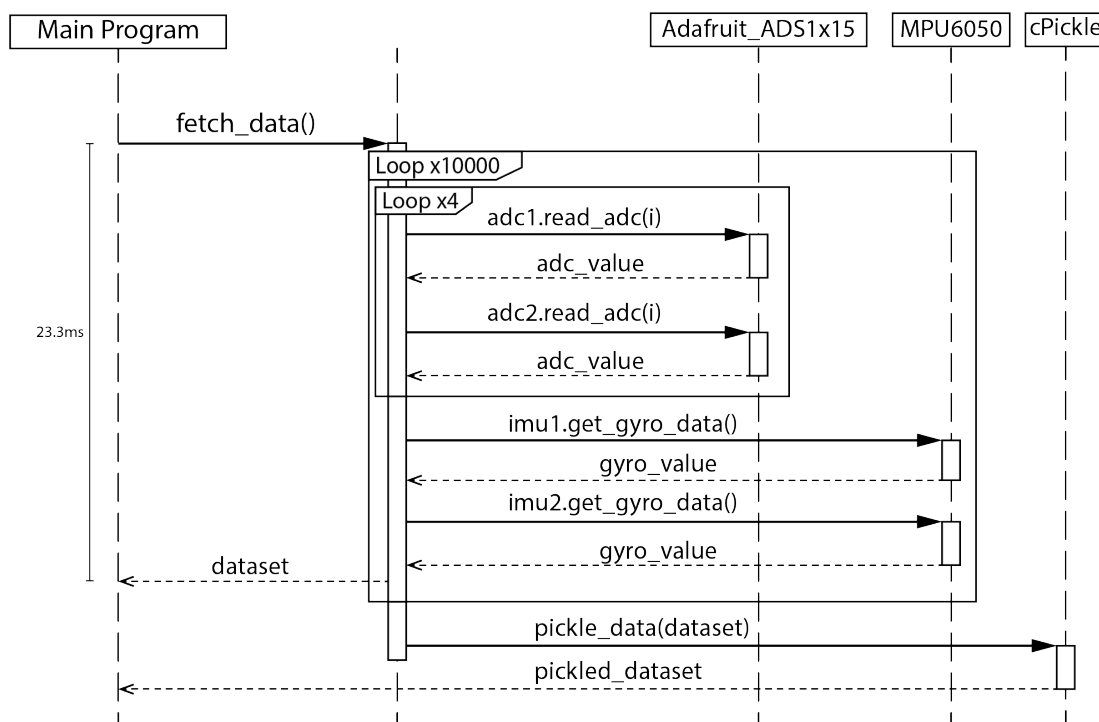


Figura 4.4: Diagrama de secuencia UML del programa de adquisición de datos para *Raspberry Pi*

4.2.4. Datos de entrada para la red neuronal

Los datos almacenados se organizaron de dos diferentes maneras: la primera entrada, llamada Tipo 1, contiene 24 datos de señales mioeléctricas (4 muestras consecutivas por cada grupo muscular) y 1 dato de velocidad angular (diferencia de los dos giroscopios) que corresponde a 1 etiqueta; la segunda entrada, Tipo 2, contiene 96 datos de señales mioeléctricas (16 muestras consecutivas por cada grupo muscular) y 1 dato promedio de 4 datos consecutivos de velocidad angular para generar 1 etiqueta. A continuación se muestra una tabla para mejor visualización.

¹Lenguaje de programación de propósito general, orientado a objetos y de código abierto.

	# señales mioeléctricas	# muestras por señal mioeléctrica	Total de datos por etiqueta
Datos Tipo 1	6	4	24
Datos Tipo 2	6	16	96

Tabla 4.1: Contenido de las señales de entrada a la red

4.3. Desarrollo de la red neuronal profunda

Para el desarrollo de la DNN¹ se normalizaron los datos de entrada para asegurar que nunca se van a obtener valores muy grandes o muy pequeños y tratar de que tengan una media igual o cercana a 0. Para lograr este resultado se aplicó la siguiente fórmula a la señal mioeléctrica donde myo es la señal mioeléctrica, y max es el máximo valor del ADC:

$$\frac{myo - \frac{max}{2}}{\frac{max}{2}} \quad (4.1)$$

De esta manera tenemos valores que oscilan de $[-1, 1]$ y la media es cercana a 0. Esta operación no cambia el contenido de la señal mioeléctrica pero logra que la optimización proceda numéricamente más fácil.

Para la salida de la red neuronal, como ya se había mencionado antes, se necesita codificar la señal del giroscopio en etiquetas. Esto se hizo siguiendo la tabla 4.2

En este punto se tienen todos los elementos necesarios para poder entrenar a la red neuronal. El programa para el entrenamiento se realizó en *Python* utilizando un motor para el desarrollo de *Aprendizaje Máquina* y *Aprendizaje Profundo* llamado *TensorFlow*².

En la fig.4.5 se muestra un diagrama UML de secuencia del programa que se utilizó para el entrenamiento de la red neuronal.

4.3.1. Arquitectura de la Red

Se realizaron los siguientes modelos o arquitecturas de red:

¹Por sus siglas en inglés *Deep Neural Network*, Red Neuronal Profunda

²De código abierto y desarrollado por *Google Brain*, para más información: <https://www.tensorflow.org>, última verificación: 03/08/2018 21:38

Etiqueta	Velocidad Angular [$^{\circ}/s$]
0	$[-110, -75)$
1	$[-75, -45)$
2	$[-45, -15)$
3	$[-15, 15]$
4	$(15, 45]$
5	$(45, 75]$
6	$(75, 110]$

Tabla 4.2: Codificación de las velocidades angulares en etiquetas para su uso en la red neuronal.

1. Clasificador logístico
2. ANN con 1 capa oculta
3. ANN con 2 capas ocultas
4. DNN: Red neuronal convolucional

El clasificador logístico es una red que tiene una sola capa de neuronas con un peso W de dimensiones (m, n) donde m es igual al número de datos de entrada y n es igual al número de datos de salida. La unidad de activación para generar la salida lineal. Es una red simple que servirá como referencia de la eficiencia.

En el caso de las arquitecturas 2 y 3 es necesario determinar un número de neuronas en las capas ocultas. Se realizaron pruebas para determinar el número óptimo de neuronas para cada capa oculta siguiendo la tabla 4.3 para la arquitectura 2 y la tabla 4.4 para la arquitectura 3.

Para la arquitectura 4, se realizaron 2 convoluciones con unidades ReLU como función de transferencia, esto reduce las dimensiones de la ventana de datos a la mitad en el primer paso, y en el segundo paso se reduce a la mitad solo una dimensión de la ventana. a continuación se alimenta a una capa oculta completamente conectada de 32 nodos, y por último se calculan las predicciones. En la fig.4.6 se muestra un diagrama de la estructura de esta red.

4. METODOLOGÍA

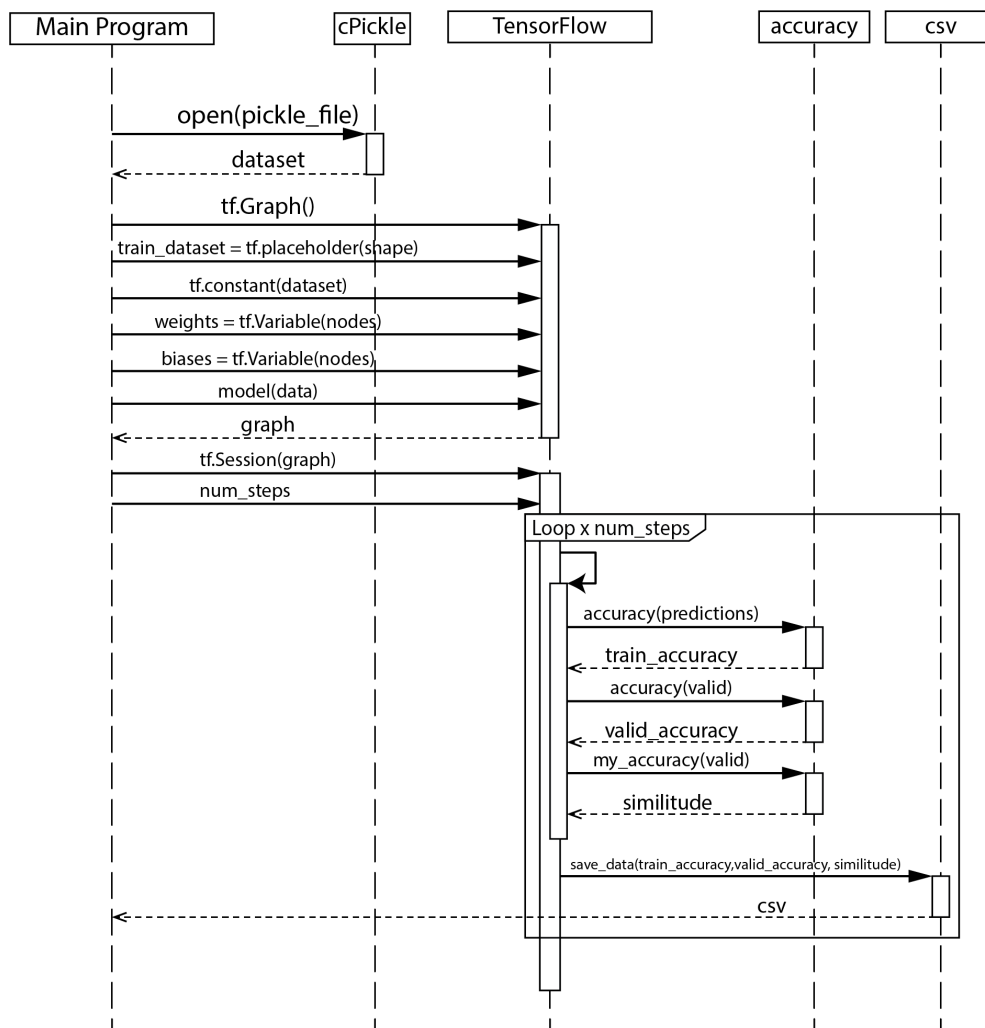


Figura 4.5: UML de secuencia del programa utilizado para el entrenamiento de las ANNs




Figura 4.6: Diagrama de la estructura de la red neuronal convolucional utilizada para la arquitectura 4

Prueba	# de nodos
1	1024
2	512
3	256
✓4	128
5	64
6	32

Tabla 4.3: Valores utilizados en la prueba para la arquitectura 2

Prueba	# de nodos(1)	# de nodos(2)
1	2048	2048
2	2048	1024
3	1024	1024
4	1024	512
✓5	128	128
6	128	32
7	64	32
8	32	32

Tabla 4.4: Valores utilizados en la prueba para la arquitectura 3, (#): número de capa oculta

4.3.2. Entrenamiento de la red

Para entrenar a cada una de las diferentes arquitecturas de red se agruparon los datos de la señal mioeléctrica en 14 diferentes grupos que se muestran en la tabla 4.5. Cada grupo consiste en 3 sets:

Set de entrenamiento Contiene al 85% del grupo. Son los datos que la red recibe iteración tras iteración, y con el cual se van generando los pesos y

4. METODOLOGÍA

bias que eventualmente generan que la red tenga una eficiencia alta.

Set de validación Contiene al 10% del grupo. Son los datos con los que se verifica qué tan eficiente es la red. También es la que se toma en cuenta para hacer modificaciones en los parámetros de la red. Este set de datos no contribuye directamente a los pesos y bias de la red, sino, indirectamente a través de los cambios que hace el investigador a los parámetros.

Set de prueba Contiene al 5% del grupo. Son datos que se mantienen ocultos hasta que se realizan las modificaciones finales. Con este set se calcula una última eficiencia que se considera muy significativa ya que la eficiencia obtenida muestra el comportamiento de la red con datos con los que nunca fue entrenada y el investigador jamás observó.

		Datos Tipo 1	Datos Tipo 2
Persona 1	Ejercicio A	Grupo 1	Grupo 2
	Ejercicio B	Grupo 3	Grupo 4
	Ejercicio C	Grupo 5	Grupo 6
Ejercicio B	Persona 1	Grupo 7	Grupo 8
	Persona 2	Grupo 9	Grupo 10
	Persona 3	Grupo 11	Grupo 12
Todos los datos		Grupo 13	Grupo 14

Tabla 4.5: División de los 14 diferentes grupos de datos

Cada grupo se entrenó independientemente con 500,000 iteraciones, y se anotó el valor máximo de eficiencia y la similitud de predicción que se logró obtener.

4.3.3. Eficiencia y similitud en la predicción de la red neuronal

Para cada grupo de datos la red brinda una respuesta (*predicción*), y ésta es correcta si es la respuesta deseada (*etiqueta*). La eficiencia de la red se define como el porcentaje de respuestas correctas. La eficiencia se calculó para cada uno de los sets de cada grupo (set de entrenamiento, set de validación y set de prueba).

Debido a que los datos etiquetados pertenecen a una escala de medición de intervalo, el hecho de que una predicción no sea correcta no significa que la predicción

sea mala, sino que puede haber quedado cerca del valor de la etiqueta. Por ejemplo, si la red predice que la velocidad angular es de la etiqueta 4, pero en realidad pertenece a la etiqueta 5 (de acuerdo a la tabla 4.2), entonces la predicción es mucho más cercana al valor real que si hubiera predicho que pertenece a la etiqueta 0. Por lo tanto, en esta tesis se propone utilizar una medición de similitud estricta de predicción de la red neuronal: solo son considerados los valores correctamente predichos y los valores de predicción que tengan una diferencia de 1 con respecto a la etiqueta.

La medición de similitud se calcula como $1 - (\text{distancia Euclidiana normalizada})$, en donde la distancia Euclidiana es la diferencia entre el valor de la etiqueta y el valor de la predicción, y luego se normaliza con respecto a la máxima diferencia (que en este caso es de 6). Para el cálculo de la similitud total se realiza el promedio de las similitudes de cada una de las predicciones, considerando cualquier valor con distancia mayor a 1 con el valor de 0 en la similitud. En la tabla 4.6 se muestra un ejemplo para el cálculo de la eficiencia y la similitud total en la predicción.

Etiqueta	Predicción	Diferencia (distancia)	Diferencia normalizada	Similitud
5	6	1	$\frac{1}{6}$	$\frac{5}{6} = 0.83$
5	5	0	$\frac{0}{6}$	$\frac{6}{6} = 1$
3	3	0	$\frac{0}{6}$	$\frac{6}{6} = 1$
4	3	1	$\frac{1}{6}$	$\frac{5}{6} = 0.83$
2	2	0	$\frac{0}{6}$	$\frac{6}{6} = 1$
1	2	1	$\frac{1}{6}$	$\frac{5}{6} = 0.83$
2	2	0	$\frac{0}{6}$	$\frac{6}{6} = 1$
0	2	2	$\frac{2}{6}$	$\frac{4}{6} = 0.67$ ⁰
Eficiencia			$\frac{4}{8} = 50\%$	
Similitud total			$\frac{4+(0.83)(3)}{8} = 81\%$	

Tabla 4.6: Ejemplo para el cálculo de la eficiencia y la similitud de la red

Resultados

5.1. La amplitud de las señales mioeléctricas varía de acuerdo a la persona

Los datos obtenidos del cuestionario que se realizó a las 4 personas se muestran en la tabla 5.1, en donde se puede observar que se registraron datos de dos mujeres y dos hombres jóvenes (entre 18 y 23 años), con diferente estatura y peso y diferentes hábitos de actividad física, en ingerir bebidas alcohólicas y fumar.

#	Sexo	Edad	Estatura	Peso	IMC	Ejercicio	Fuma	Bebe
1	Mujer	22	1.69	80	28	×	×	×
2	Hombre	18	1.70	62	21.5	△	×	△
3	Hombre	23	1.73	73	24.4	△	×	△
4	Mujer	19	1.60	68	26.6	×	△	△

Tabla 5.1: Información obtenida del cuestionario que se realizó, donde #: Número de persona, ○: Mucho, △: Moderadamente, ×: Poco ó Nada

Después de realizar el protocolo de ejercicios, se revisó el registro de las señales electromiográficas de cada una de las personas. En los registros se observó que en algún momento la señal mioeléctrica era tan alta que durante la etapa de amplificación se saturó, y en el registro digital se pierde la forma de la onda de la señal mioeléctrica. En la tabla 5.2 se muestra el resultado que se obtuvo con respecto a la calidad de la señal de los 4 sujetos.

	Ejercicio A	Ejercicio B	Ejercicio C
Persona 1	21.00 %	24.56 %	26.06 %
Persona 2	54.87 %	17.15 %	23.55 %
Persona 3	54.61 %	28.26 %	36.30 %
Persona 4	63.00 %	66.78 %	58.19 %

Tabla 5.2: Se muestra el porcentaje de muestras saturadas o sin respuesta en el total de la prueba correspondiente

Como se observa en la tabla 5.2, solo se logró obtener datos con poca saturación (menor a 30%) para las primeras 3 personas. Por conveniencia se seleccionaron todos los datos de la persona 1 y los datos del Ejercicio B para la Persona 2 y 3.

5.2. Las señales mioeléctricas varían aunque sea el mismo ejercicio realizado por la misma persona

En la fig. 5.1 se muestra una parte del registro de las señales mioeléctricas y la velocidad angular de la persona 1 haciendo el ejercicio A. Se puede observar que, aunque es el mismo ejercicio realizado por la misma persona un solo momento después, las señales mioeléctricas en cada ciclo, de sentarse y levantarse de la silla, son distintas, confirmando la naturaleza estocástica de la señal.

La forma obtenida de la velocidad angular, se comparó para su validación, con un estudio hecho por [Mak et al.¹](#).

¹En este artículo se puede encontrar la cinemática de la rodilla en el movimiento "sit-to-stand"




Figura 5.1: Muestra de una sección de la señal mioeléctrica de la persona 1

En la fig.5.2 se muestra la señal del giroscopio antes y después de ser convertida en etiquetas.




Figura 5.2: Velocidad angular original y convertida en 7 etiquetas para su uso en la ANN

5.3. Las arquitecturas con capas ocultas de 128 neuronas fueron las más eficientes

Para determinar una óptima configuración de la arquitectura 2, se realizaron entrenamientos cambiando el número de neuronas en su capa oculta y determinar cuál genera la mejor eficiencia con los mismos datos del set entrenamiento (fig. 5.3). Se encontró que con la capa oculta de 1,024 nodos la red aprende muy rápido en pocas iteraciones, pero en el largo plazo (después de 15,000 iteraciones) la red con 128 nodos en la capa oculta logra tener mayor eficiencia, por lo tanto esta

5. RESULTADOS

configuración de 128 neuronas en la capa oculta fue considerada la mejor para esta arquitectura.

Lo mismo se realizó para la arquitectura 3 siguiendo la tabla 4.4. En la figura 5.4 se observa que si tienen 1,024 neuronas ambas capas ocultas la eficiencia es mucho menor que si tienen 128 neuronas o menos. La mayor eficiencia se obtuvo al utilizar 128 nodos tanto en la primera como en la segunda capa oculta.

Por lo tanto, para las siguientes comparaciones se utilizó la configuración de 128 neuronas en la capa oculta para la arquitectura 2 y de 128 neuronas tanto para la capa oculta uno como dos para la arquitectura 3.




Figura 5.3: Comparación de similitud para las diferentes configuraciones de la arquitectura 2

5.4 La mejor eficiencia del set de validación es menor que la del set de entrenamiento




Figura 5.4: Comparación de similitud para las diferentes configuraciones de la arquitectura 3

5.4. La mejor eficiencia del set de validación es menor que la del set de entrenamiento

Mientras más iteraciones se realicen la eficiencia va incrementando con el set de entrenamiento, pero esto no significa que la red sea igual de eficiente con datos nuevos (set de validación o set de prueba). Por lo tanto, la siguiente medición de eficiencia se realizó con datos del set de validación en comparación con el set de entrenamiento.

Utilizando la arquitectura 1, en la figura 5.5 se muestra que la eficiencia del set de entrenamiento es un poco mayor a la del set de validación. Sin embargo, ambas incrementan y se mantienen en un valor estable y muy cercano entre las dos. Esta red es muy rápida de entrenar, y difícilmente se va a sobreajustar por la pequeña cantidad de parámetros que tiene.

5. RESULTADOS




Figura 5.5: Comparación entre la eficiencia del set de entrenamiento y el set de validación de la arquitectura 1

Sin embargo, no ocurre lo mismo con la arquitectura 2 (fig. 5.6). Como se puede observar al estar entrenando a la red con la misma información (set de entrenamiento) una y otra vez, llega un momento en el que ésta comienza a “memorizar” la información que está recibiendo mientras se realizan más iteraciones, esto es, mientras la eficiencia del set de entrenamiento va mejorando, la eficiencia del set de validación va disminuyendo. Este fenómeno es conocido como sobreentrenamiento o sobreajuste de la red, que no es deseable cuando se requiere una eficiencia alta en la evaluación con datos nuevos. Este mismo comportamiento ocurre con la arquitectura 3 y 4 (datos no mostrados).




Figura 5.6: Comparación entre la eficiencia del set de entrenamiento y el set de validación de la arquitectura 2

5.5. Las predicciones incorrectas no fueron tan alejadas del valor real

En la figura 5.7 se muestra la eficiencia y la similitud de la predicción de la arquitectura 2 con el set de validación. Mientras la eficiencia nos proporciona el porcentaje de predicciones correctas, la similitud además nos indica si las predicciones incorrectas estuvieron muy cercanas al valor correcto. La eficiencia se encuentra alrededor del 50 %, esto quiere decir que el otro 50 % de las predicciones fueron incorrectas. Si todas las predicciones incorrectas estuvieran muy cercanas al valor correcto, la similitud sería del 91 %. Sin embargo, la similitud se encuentra alrededor del 70 %, lo que quiere decir que cerca de la mitad de las predicciones incorrectas estuvieron muy cercanas al valor correcto.

5. RESULTADOS




Figura 5.7: Gráfica de la eficiencia y la similitud de predicción de la arquitectura 2

Además, en la figura 5.7 se puede observar que la máxima eficiencia y similitud se logra antes de las 50,000 iteraciones y luego comienza a disminuir debido al fenómeno de sobreajuste. Existen varios métodos para evitar el sobreajuste en el entrenamiento, los cuales van más allá del objetivo de este trabajo, y se han utilizado únicamente las redes que mejor eficiencia tuvieron durante todo el entrenamiento.

En la fig.5.8 se muestra una sección de la predicción de la señal utilizando la arquitectura 1 y 4 contra las etiquetas. Se observa como la predicción con la arquitectura 4 se acerca mucho más a la forma de la señal etiquetada del giroscopio que la predicción de la arquitectura 1, y que aunque algunas predicciones no fueron correctas, no están muy alejadas de la etiqueta que le corresponde.




Figura 5.8: Sección de la predicción de la señal (arquitectura 1 y 4) y etiquetas correspondientes.

5.6. Comparación entre todas las arquitecturas con el set de prueba

Teniendo definidos los parámetros para las 4 arquitecturas y tomando en cuenta la mejor red (iteración que mejor eficiencia resultó con los datos del set de validación), se procedió a evaluar el set de prueba (nunca visto por la red neuronal ni utilizado por el investigador para seleccionar la mejor red). En las tablas 5.3, 5.4, 5.5, 5.6 y 5.7 se muestran reunidos todos los resultados que se obtuvieron con los diferentes grupos de datos y de todas las arquitecturas entrenadas hasta 500,000 iteraciones.

- El clasificador logístico obtuvo la eficiencia más baja. Observando las eficiencias obtenidas en la tabla 5.3, podemos notar que para los datos Tipo 1, la arquitectura 1 fue menos eficiente en todos los casos. Pero si observamos la misma tabla para los datos Tipo 2, vemos que la arquitectura 1 para el Ejercicio B fue tan eficiente como la arquitectura 2, e incluso fue mejor que la arquitectura 3 en el entrenamiento del Ejercicio B y C.
- Los datos del Ejercicio C tuvieron mejor similitud en la predicción. En la misma tabla 5.3 se puede observar que la eficiencia es diferente aunque sea la misma persona, pero diferentes ejercicios. Por ejemplo, la similitud para el Ejercicio C fue mayor comparada con la del Ejercicio A y B.

5. RESULTADOS

- La eficiencia depende de la persona. En la tabla 5.4 se muestran las eficiencias obtenidas de 3 personas diferentes realizando el mismo ejercicio. Se puede observar que la eficiencia obtenida para la persona 3 fue mayor en todas las arquitecturas.
- La red convolucional produce la mejor eficiencia con gran variedad de datos. En la tabla 5.5 se muestran los resultados del entrenamiento introduciendo variabilidad al combinar los 3 ejercicios en 1 persona. La arquitectura 4 fue la única que superó el 50 % de eficiencia. En la tabla 5.6 se muestran los resultados del entrenamiento de 3 personas realizando un mismo ejercicio. La única arquitectura que no superó el 50 % de eficiencia fue la 1. La red convolucional fue de nuevo la más eficiente. En la tabla 5.7 se muestran los resultados del entrenamiento tomando en cuenta todos los datos, así aumentando aún más la variabilidad (diferentes ejercicios y diferentes personas). La eficiencia de la arquitectura 1 reduce hasta 40.6 % con una similitud de 59 %, y aunque la cantidad de datos aumente, esta arquitectura no es capaz de incrementar su eficiencia considerablemente. Dentro de las pruebas hechas con los Datos Tipo 2, la arquitectura 4 fue la más eficiente. A pesar de la variabilidad de datos, su eficiencia llegó a 57.5 % y su similitud llegó hasta 75.5 %. A continuación se muestra en la fig.5.9 un diagrama de caja comparando la diferencia entre las eficiencias de las arquitecturas con las que se trabajó. Se usa este diagrama porque al entrenar la red se toma de manera aleatoria segmentos del set de entrenamiento, lo que genera que cada vez que se entrena, la eficiencia no sea la misma a pesar de ser la misma arquitectura.




Figura 5.9: Comparación de eficiencias entre todas las arquitecturas de la presente tesis

Datos	Arquitectura	Ejercicio A		Ejercicio B		Ejercicio C	
		Eficiencia	Similitud	Eficiencia	Similitud	Eficiencia	Similitud
Tipo 1	1	44.6	63.4	50.1	68.7	48.7	69.5
	2	51.9	71.5	52.7	71.5	54	75.2
	3	50	70.4	52.4	71.8	50.4	72.3
	4	51.3	70	53.3	72.2	54.6	76.6
Tipo 2	1	51.2	69.2	53.2	69.9	57.6	71.9
	2	53.6	75.3	53.2	69.9	61.6	79.6
	3	52	73.7	51.6	68.9	53.2	73.5
	4	55.2	74.2	56.8	75.1	64	83

Tabla 5.3: Resultados del entrenamiento para la Persona 1

Tipo de Señal	Arquitectura	Persona 1		Persona 2		Persona 3	
		Eficiencia	Similitud	Eficiencia	Similitud	Eficiencia	Similitud
1	1	50.2	68.5	43.3	60.5	55	70.5
	2	53.8	72.4	49.4	68.9	64.6	81.4
	3	50.9	70.1	46.3	67.1	63.3	81.2
	4	52.9	71	48.9	69.4	65.7	80.7
2	1	52	68.7	51.6	69.9	60	71.3
	2	55.6	73.3	55.6	71.3	65.6	82.6
	3	46.8	65.8	50	70.3	61.2	79.5
	4	57.6	74.3	58	74	70.4	82.7

Tabla 5.4: Resultados del entrenamiento para el ejercicio B

5.6 Comparación entre todas las arquitecturas con el set de prueba

Tipo de Señal	Arquitectura	Eficiencia	Similitud
1	1	42.6	62.3
	2	45.3	66.1
	3	42.6	63
	4	45.7	65.5
2	1	47.2	63.4
	2	48.7	68.1
	3	47.1	66.2
	4	53.9	71.5

Tabla 5.5: Resultados del entrenamiento para todos los ejercicios con la persona 1

Tipo de Señal	Arquitectura	Eficiencia	Similitud
1	1	40.7	57.8
	2	53.6	73.2
	3	53.6	73.2
	4	51.9	72.2
2	1	47.3	62.4
	2	57.2	73
	3	53.6	72.6
	4	60.7	77.4

Tabla 5.6: Resultados del entrenamiento para el ejercicio B con todas las personas

5. RESULTADOS

Tipo de Señal	Arquitectura	Eficiencia	Similitud
1	1	40.6	59.5
	2	51.4	70.7
	3	50.6	70.6
	4	48.2	67.7
2	1	44.6	61.6
	2	54.8	74
	3	51.4	71.2
	4	57.5	75.5

Tabla 5.7: Resultados del entrenamiento para todos los datos.

Discusión y Conclusiones

El tipo de ejercicio que se realiza para el entrenamiento juega un papel importante en la eficiencia final. El ejercicio C como se aprecia en la tabla 5.3 permitió que la eficiencia y similitud en la mayoría de las arquitecturas fueran mayores. Esto se debe a que este ejercicio fue el que menos energía requería de los músculos de la pierna al levantarse y sentarse. Al usar las 2 manos de apoyo para levantarse, una buena parte de la fuerza que se requiere para moverse de la silla se releva en los músculos del brazo, esto genera que la señal mioeléctrica de la pierna tenga menor amplitud y haya menor riesgo de saturar el amplificador, de manera que la red puede entrenarse con una señal sin saturar y en consecuencia la eficiencia es mejor. De manera similar, en la tabla 5.4 se ve que la eficiencia de la persona 3 es mayor comparada con las otras 2. Esto se dio posiblemente porque la persona 3 tiene una actividad física mayor que las demás. Se ha observado que en las personas con músculos acondicionados la señal mioeléctrica tiende a ser de menor amplitud (Criswell) para el mismo tipo de ejercicio que hace una persona con músculos sin acondicionar, por lo que se corre menor riesgo de que el amplificador se sature y por lo mismo, la señal mioeléctrica es registrada con mejor calidad.

En el desarrollo de los modelos o arquitecturas 2 y 3 mientras mayor número de nodos en las capas ocultas tenga una red neuronal, ésta es capaz de "memorizar" mejor la información. Sin embargo, lo que se buscó en la red neuronal fue aprender patrones del set de entrenamiento, con los cuales pueda obtener información, generalizarla y así ser capaz de predecir efectivamente con nueva información. Por esta razón al final solo se comparó la eficiencia de la predicción del set de prueba. Además, la propuesta de esta tesis para medir la similitud de predicción nos indica qué tan alejadas fueron las predicciones incorrectas. En la mayoría de los casos, alrededor de la mitad de las respuestas incorrectas estuvieron muy cerca de ser correctas, llegando a valores del 75.5% de similitud de predicción de datos nuevos de la red neuronal convolucional entrenada con todos los datos de los diferentes ejercicios y las diferentes personas.

La respuesta de la arquitectura 1 en las tablas 5.3 y 5.4 en donde la eficiencia

6. DISCUSIÓN Y CONCLUSIONES

de los datos en algunos casos fue mayor que la arquitectura 3, nos lleva a pensar que la arquitectura 1 podría remplazar el uso de arquitecturas más complejas en ciertos casos. Sin embargo, en la tabla 5.7 nos podemos dar cuenta de que al aumentar la cantidad de ejercicios y al agregar más personas, la arquitectura 1 ya no es tan eficiente. Es con este resultado con el que se puede afirmar que las redes neuronales sobresalen cuando se trata de analizar datos que tienen una variabilidad muy grande.

Se busca que el decodificador de señales mioeléctricas que se está desarrollando se pueda utilizar para una amplia gama de actividades y también pueda utilizarse sin importar las características del usuario. Una arquitectura simple como un clasificador logístico no puede funcionar para este fin, aunque si observamos la eficiencia de nuestra arquitectura más profunda en la señal tipo 1, nos damos cuenta que no logró superar el 50% de eficiencia, lo que nos podría hacer pensar que este tipo de arquitectura tampoco es útil, y en efecto, una red tan profunda como la arquitectura 4 no es capaz de encontrar patrones cuando la información que le damos esta muy limitada. Pero si vemos su desempeño cuando aumentamos la cantidad de datos (señal tipo 2) las cosas cambian.

Las redes neuronales profundas son capaces de decodificar la señal mioeléctrica en una señal de control a pesar de su variabilidad. La metodología que se siguió a lo largo de esta tesis, no solo es exclusiva para su uso en la rodilla, se puede generalizar para cualquier articulación del cuerpo que tenga 1 grado de libertad. Para articulaciones con 2 o más grados de libertad se tiene que cambiar la estructura de la red. Para mejorar la eficiencia de la red neuronal profunda se sugiere en futuros trabajos tomar en consideración los siguientes puntos:

- La señal mioeléctrica al ser tan variable entre persona y persona se tiene que buscar una manera de ajustar los amplificadores para que nunca se saturen y evitar perder información para la red neuronal. Esto se puede lograr incrementando o decrementando la ganancia de manera específica para cada persona, o manteniendo una ganancia pequeña que asegure que no se saturará con ningún individuo, esto además de instalar un ADC de mayor resolución para que la señal pueda ser observable.
- Cuando se trabaja con redes neuronales profundas, la cantidad de datos que ingresa a la red juega un papel importante. Aumentar la cantidad de datos se puede lograr de 2 maneras. La primera es aumentando el número de señales mioeléctricas que correspondan con el movimiento que se quiera decodificar, sin embargo, esta solución es poco viable ya que requiere de más elementos electrónicos. La segunda es aumentando la velocidad de muestreo. Si se tiene un dispositivo que pueda convertir la señal analógica a digital 2, 3 o 4 veces más rápido, esto aumentará la cantidad de datos tantas veces como la velocidad incrementa.
- La condición de la piel en que se pone el electrodo influye directamente en la calidad de la señal mioeléctrica obtenida. Se busca que la impedancia de

los electrodos con la piel sea la misma para cada par, cuando esta difiere la amplitud de la señal obtenida aumenta, lo que genera que el amplificador se pueda saturar fácilmente. Para evitar esto, se puede utilizar una solución conductiva para mejorar la conducción entre el electrodo y la piel, o también se pueden utilizar electrodos secos y permitir que la piel produzca suficiente sudor para que se cree una solución conductiva natural entre la piel y el electrodo. Además de la limpieza necesaria de la piel y la remoción del vello.

- La cantidad de individuos de los que se tome como base la señal mioeléctrica influye en la eficiencia final y permite el desarrollo de una red de uso general. Entre más grande sea el set de entrenamiento, la red tiene menos posibilidad de utilizar el mismo valor 2 veces seguidas, por lo que depende más de la identificación de patrones que de la "memorización" de información.

En este estudio solo se registró la actividad muscular de personas jóvenes (18-23 años), por lo tanto, para que pueda ser extensivo y se pueda lograr la visión de la tesis habrá que realizar registros a diferentes edades y principalmente en adultos mayores. En una investigación que evaluó la viabilidad del uso de señales mioeléctricas en adultos mayores echa por [Tavakolan et al.](#), se encontró que, aunque las señales son en general diferentes, la precisión en su clasificación fué ligeramente menor, por lo que es viable decodificar señales mioeléctricas en adultos mayores. Con esta información se podrá posteriormente desarrollar una órtesis que funcione con este decodificador para ayudar a recuperar la movilidad de adultos mayores con problemas en la articulación de la rodilla.

7.1. Visualización de los pesos obtenidos en la red convolucional

Se muestran a continuación, en forma de imagen, los pesos obtenidos en la primera (fig.7.1) y segunda (fig.7.2) capa de la red convolucional. Se consideró que no es necesaria la visualización de las capas posteriores por que no proporcionan información más relevante.

Los datos de los filtros generados en las convoluciones se almacenan como valores numéricos de punto flotante, poner esa información sin algún procesamiento previo, no nos permite visualizar de manera rápida lo que ocurre en las capas intermedias, por esta razón se decidió hacer un mapa en escala de grises para su fácil visualización.




Figura 7.1: Visualización de los filtros de la primera capa en la red convolucional en forma de imagen




Figura 7.2: Visualización de los filtros de la segunda capa en la red convolucional en forma de imagen

7.2. Cuestionario

El cuestionario que se realizó consta de 5 preguntas:

1. ¿Cuál es tu sexo?
2. ¿Cuál es tu edad?
3. ¿Qué tanto haces ejercicio?
4. ¿Qué tanto fumas?
5. ¿Qué tanto consumes bebidas alcohólicas?

Los valores numéricos: estatura, peso é IMC se obtuvieron y/o calcularon posterior al cuestionario.

7.3. Documentación de dispositivos ocupados

La documentación de los siguientes dispositivos:

1. IMU
2. MyoWare
3. ADC
4. Raspberry Pi

Se puede encontrar en las siguientes páginas web correspondientemente:

1. <https://www.sparkfun.com/products/11028>
2. <https://www.sparkfun.com/products/13723>
3. <https://www.adafruit.com/product/1083>
4. <https://www.raspberrypi.org/products/raspberry-pi-3-model-b/>

Bibliografía

- [1] Arveti, M., Gini, G., and Folgheraiter, M. (2007). Classification of emg signals through wavelet analysis and neural networks for controlling an active hand prosthesis. In *2007 IEEE 10th International Conference on Rehabilitation Robotics*, pages 531–536. [3](#)
- [2] Basmajian, J. and DeLuca, C. (1985). *Muscles Alive*. MD: Williams Wilkins, Baltimore, 5th edition. [7](#)
- [3] Campbell, A. J. and Robertson, M. C. (2003). *Otago Exercise Programme*. Otago Medical School, University of Otago. [14](#)
- [4] Criswell, E., editor (2011). *Crams Introduction to Surface Electromyography*. Jones And Bartlett Publishers, Massachusetts, second edition. [8](#), [15](#), [16](#), [41](#)
- [5] Deng, L., Hinton, G., and Kingsbury, B. (2013). New types of deep neural network learning for speech recognition and related applications: an overview. In *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, pages 8599–8603. [2](#)
- [6] Hagan, M. T., Demuth, H. B., Beale, M. H., and de Jesús, O. (2010). *Neural Network Design*. Martin T. Hagan, Oklahoma, second edition. [12](#)
- [7] Jahan, S. (2016). Human development report 2016. Report, United Nation Development Programme. [1](#)
- [8] Mak, M. K., Levin, O., Mizrahi, J., and Hui-Chan, C. W. (2003). Joint torques during sit-to-stand in healthy subjects and people with parkinson’s disease. *Clinical Biomechanics*, 18(3):197 – 206. [28](#)
- [9] Michael, J. W.-P., Schlüter-Brust, K. U., and Eysel, P. (2010). The epidemiology, etiology, diagnosis, and treatment of osteoarthritis of the knee. *Deutsches Arzteblatt International*, 107(9):152 – 162. [1](#), [5](#)

BIBLIOGRAFÍA

- [10] Park, K. H. and Lee, S. W. (2016). Movement intention decoding based on deep learning for multiuser myoelectric interfaces. In *2016 4th International Winter Conference on Brain-Computer Interface (BCI)*, pages 1–2. [3](#)
- [11] Tavakolan, M., Xiao, Z. G., and Menon, C. (2011). A preliminary investigation assessing the viability of classifying hand postures in seniors. *BioMedical Engineering OnLine*, 10(1):79. [43](#)
- [12] Yan, T., Cempini, M., Oddo, C. M., and Vitiello, N. (2015). Review of assistive strategies in powered lower-limb orthoses and exoskeletons. *Robotics and Autonomous Systems*, 64(Supplement C):120 – 136. [3](#), [5](#)