

**Sistema de adquisición de señales eléctricas biológicas para  
detección de intención de movimiento para generar órdenes a un  
manipulador robótico**

**Danna Peña Rodríguez**

**Institución Universitaria Pascual Bravo**

**Facultad de Ingeniería**

**Ingeniería Eléctrica**

**Medellín**

**2023**

**Sistema de adquisición de señales eléctricas biológicas para  
detección de intención de movimiento para generar órdenes a un  
manipulador robótico**

**Danna Peña Rodríguez**

**Trabajo de grado para optar al título de Ingeniería Eléctrica**

**Asesores**

**Mateo Rico García**

**Maestría en Automatización y Control Industrial**

**Gilda Viviana Dávila Durán**

**Maestría en educación**

**Institución Universitaria Pascual Bravo**

**Facultad de Ingeniería**

**Ingeniería Eléctrica**

# Medellín

2023

## Contenido

Lista de ilustraciones .....	4
Resumen .....	5
Abstract .....	7
Glosario .....	8
Introducción .....	9
1. Planteamiento del problema .....	10
1.2 Descripción .....	10
1.3 Formulación .....	11
2. Justificación .....	11
3. Objetivo general .....	12
3.1 Objetivos específicos .....	13
4. Marco teórico .....	13
4.1 Electromiografía (EMG) .....	13
4.2 Métodos de medida señal bioeléctrica .....	15
4.3 Toma de señales bioeléctricas EMG .....	16
4.4 Variabilidad de potencial en bioseñales .....	18
4.5 Electrodo .....	24
4.6 Redes neuronales aplicadas a clasificadores de señal .....	25
4.6.1 Tipos de clasificadores de redes neuronales de señales .....	26
4.6.2 Aplicaciones de las redes neuronales .....	27
5. Metodología .....	27
6. Resultados .....	29
6.1 Herramientas usadas .....	29
6.2 Descripción de la base de datos .....	30
6.3 Entrenamiento de la red neuronal .....	31
6.4 Desempeño en muestras desconocidas .....	33

6.5	Resumen de los resultados .....	34
<b>7.</b>	<b>Conclusiones</b> .....	<b>35</b>
<b>8.</b>	<b>Referencias bibliográficas</b> .....	<b>36</b>

### **Lista de ilustraciones**

<i>Ilustración 1. MUAP registro</i>	_____	15
<i>Ilustración 2. Potencial de acción</i>	_____	20
<i>Ilustración 3. Activación celular</i>	_____	22
<i>Ilustración 4. Distribución de carga en las proximidades de la región activa.</i>	_____	23
<i>Ilustración 5. Superposición de señales EMG.</i>	_____	25
<i>Ilustración 6. Carga de librerías</i>	_____	30
<i>Ilustración 7. Modelo para la ejecución del programa</i>	_____	31
<i>Ilustración 8. Modelo de entrenamiento SVM</i>	_____	32
<i>Ilustración 9. Actividad de red neuronal y métrica de clasificación</i>	_____	33

## **Resumen**

### **Sistema de adquisición de señales eléctricas biológicas para detección de intención de movimiento para generar órdenes a un manipulador robótico**

**Danna Peña Rodríguez**

El presente sistema almacena datos examinados de una población para encontrar parámetros importantes y esenciales en las dinámicas de la mano, específicamente en la intención de movimiento de la parte del cuerpo mencionada. El análisis de clasificación de datos se hace mediante el lenguaje de programación (Python) que encuentra las variaciones más especiales en los datos. Este proceso clasificatorio (SVM) permite mejorar la precisión y eficacia en la detección y procesamiento de señales EMG, lo que puede tener un impacto relevante en la producción y aplicación de prótesis y exoesqueletos robóticos. La utilización de sistemas de inteligencia artificial para el reconocimiento de patrones en señales de EMG permite una mayor exactitud y potencial aplicativo en la tecnología.

El potencial impacto positivo de la tecnología en la industria y en la calidad de vida de las personas es una gran motivación para llevar a cabo un proyecto relacionado con este tema ya que al hacer una importante implementación de este podría relacionar más al ser humano, un ser en una visión bioeléctrica que se relaciona más hacia la ciencia con ventaja en mejoras aplicativas a nuevas herramientas tecnológicas.

Las EMG para intención de movimiento adaptado con inteligencia artificial hacen relevante un modelo de perfeccionamiento que permite mejorar la precisión y eficacia en la detección y procesamiento de señales musculares. Los sistemas de inteligencia artificial pueden ser entrenados para reconocer

patrones específicos en las señales EMG, lo que permite una mayor exactitud en la clasificación de datos y un potencial aplicativo relevante para la producción y aplicación de prótesis y exoesqueletos robóticos.

La utilización de sistemas de inteligencia artificial, en particular las redes neuronales, en el tratamiento de señales bioeléctricas EMG de intención de movimiento pueden tener una marca positiva en la calidad de vida de las personas, ya que los determinantes de proceso de estos sistemas han entregado una evaluación de datos de alta validación.

**Palabras clave:** *Electromiografía, bioseñales, inteligencia artificial, movimiento, validación, algoritmo, programación*

## **Abstract**

The present system stores data examined from a population to find important and essential parameters in the dynamics of the hand, specifically in the movement intention of the mentioned body part. The data classification analysis is done using the programming language (Python) that finds the most special variations in the data. This classification process (SVM) allows to improve the precision and efficiency in the detection and processing of EMG signals, which can have a relevant impact on the production and application of prostheses and robotic exoskeletons. The use of artificial intelligence systems for the recognition of patterns in EMG signals allows greater accuracy and application potential in the technology.

The potential positive impact of technology on the industry and on the quality of life of people is a great motivation to carry out a project related to this topic, since by making an important implementation of this it could relate more to the human being, a Being in a bioelectric vision that is more related to science with an advantage in application improvements to new technological tools.

The EMG for intention of movement adapted with artificial intelligence make relevant an improvement model that allows to improve the precision and efficiency in the detection and processing of muscular signals. Artificial intelligence systems can be trained to recognize specific patterns in EMG signals, allowing for greater accuracy in data classification and relevant

application potential for the production and application of robotic exoskeletons and prostheses.

The use of artificial intelligence systems, in particular neural networks, in the treatment of EMG bioelectric signals of movement intention can have a positive mark on the quality of life of people, since the process determinants of these systems have delivered an evaluation of highly valid data.

**Keywords:** *Electromyography, biosignals, artificial intelligence, movement, validation, algorithm, programming*

## Glosario

**Amplitud de señal:** Se refiere a la cantidad máxima de oscilación de una señal.

**Contracción muscular:** La contracción muscular es un proceso fisiológico que ocurre en los músculos del cuerpo cuando las fibras musculares se acortan y producen tensión.

**Frecuencia:** Es una magnitud física que indica el número de repeticiones de un fenómeno o suceso por unidad de tiempo.

**Inteligencia Artificial:** Es la creación de algoritmos que simulan el comportamiento y parte del pensamiento humano, con un fin aplicativo.

**Potencial de acción:** La transmisión de información y la emisión de una respuesta motivadora por parte de las neuronas y consiste en una onda de descarga eléctrica que se propaga por la membrana celular.

**Señales bioeléctricas:** Señales que emite el cuerpo humano a consecuencia del desplazamiento iónico.

**SVM:** La implementación del algoritmo de Máquinas de Vectores de Soporte (SVM) utilizando el lenguaje de programación Python



## **Introducción**

El estudio de este proyecto está involucrado en la duplicidad de impulsos de movilidad por un sistema de procesamiento de señal electromiográfica para respuestas musculares en intervención modular de la mano y recolección de los datos de la conducción nerviosa, con el procesamiento de estas señales como resultado de las actividades eléctricas y la distribución de cargas se busca generar un algoritmo que analice y automatice el electrodiagnóstico ejecutado y que el control se suministre por inteligencia artificial para que el propósito del proyecto sea un sistema integrado y pueda reproducirse la información en un prototipo articulado que comprenda y gesticule movimientos de esta parte del cuerpo humano.

## **1. Planteamiento del problema**

### **1.2 Descripción**

El desarrollo de este proyecto se enfoca en la transmisión que se ejecuta en la movilidad manual y la generación de información de la actividad eléctrica muscular ante los movimientos rutinarios que se pueden realizar en la mano del cuerpo humano para plantear a través de respuesta las señales determinantes de reflejo e intención que se está en capacidad de accionar los impulsos localizados en el extremo del antebrazo.

Por los impulsos diagnosticados en electrocardiograma de estímulos nerviosos y respuestas musculares se determina las señales de movimiento por medio de la superficie y la reacción de impulso generada de manera física establecida para la mano instigada por medio del análisis de propulsión que en ella misma se ocasiona.

Se destina a proponer un sistema integrado de captación de señales dinámicas de la mano para que se genere una duplicación de información automatizada de las conducciones de electrodiagnóstico obtenido por las señales electromiográficas y la recolección de datos de conducción nerviosa.

### **1.3 Formulación**

¿Cómo plantear un sistema de adquisición de señales bioeléctricas para determinar intenciones de movimiento en la mano?

## **2. Justificación**

La aplicación de la clasificación de inteligencia artificial (IA) a las señales EMG puede brindar varios beneficios, incluida una precisión mejorada, tiempos de procesamiento más rápidos y la capacidad de identificar patrones y tendencias que pueden no ser evidentes para los analistas humanos. Una de las principales ventajas de utilizar la IA para la clasificación de EMG es su capacidad para analizar datos rápidamente, especialmente cuando se trata de grandes cantidades de datos que serían difíciles de analizar manualmente para los seres humanos y llevaría mucho tiempo. Los algoritmos de IA pueden procesar grandes cantidades de datos para identificar patrones y tendencias en las señales EMG, lo que ayuda a identificar los inicios musculares, las contracciones y la fatiga de manera

más precisa y eficiente que los métodos manuales. (Rabin, Kahlon, Mayalet, & Ratnovsky, 2020)

Además, la clasificación IA puede generar resultados más precisos, ya que puede eliminar varias fuentes de error que pueden ocurrir durante la clasificación manual. Por ejemplo, el aprendizaje automático puede identificar cambios más sutiles en las señales EMG que un analista humano puede no notar, lo que proporciona resultados más precisos y consistentes. (Rabin, Kahlon, Mayalet, & Ratnovsky, 2020)

Contar con una clasificación exitosa en IA, se puede obtener información de los datos que antes no podían ver, se pueden identificar patrones complejos y no lineales ocultos dentro de los datos de EMG, lo que puede ayudar a comprender mejor los procesos involucrados en los movimientos musculares.

Por último, a medida que los algoritmos de IA aprenden de los datos que procesan, pueden evolucionar con el tiempo y volverse más precisos lo que lleva a predicciones y clasificaciones más precisas, lo que mejora la calidad de la investigación y permite nuevos avances en el campo del diagnóstico, la rehabilitación y la interacción hombre-máquina basado en EMG. (Rabin, Kahlon, Mayalet, & Ratnovsky, 2020)

Así que el uso de la clasificación de IA para EMG tiene varias ventajas sobre el análisis manual tradicional, como tiempos de procesamiento más rápidos y precisos, que proporciona nuevos conocimientos a un campo de investigación ya rico y una clasificación mejorada con el tiempo a medida que la máquina aprende. (Rabin, Kahlon, Mayalet, & Ratnovsky, 2020)

### **3. Objetivo general**

Proponer un sistema de clasificación de señales eléctricas biológicas para detección de intención de movimiento de la mano humana.

### **3.1 Objetivos específicos**

- Desarrollar algoritmos de detección y segmentación automática de eventos en las señales EMG, como la identificación a contracciones musculares.

- Sugerir un método de extracción de características de señales EMG, como el cálculo de parámetros de frecuencia, amplitud y tiempo, para la examinación de patrones en el aprendizaje de señales.

- Evaluar el desempeño del algoritmo de clasificación de movimientos basado en métricas reconocidas en la comunidad.


## **4. Marco teórico**

### **4.1 Electromiografía (EMG)**

La electromiografía es el estudio de la actividad eléctrica producida por el músculo. El músculo se activa en respuesta a una señal eléctrica que es transmitida por una fibra nerviosa motora (axón) que inerva el músculo. La célula nerviosa motora, su axón y las fibras musculares que inerva forman la unidad básica funcional del sistema muscular, llamada unidad motora. Una vez que la señal eléctrica nerviosa llega a la unión entre el nervio y el músculo, se produce una cantidad de transmisor químico que convierte la señal eléctrica en otra señal que se propaga por toda la fibra muscular. (Martinez, 2011)

En la electromiografía se analiza la actividad eléctrica generada por el músculo. Cada fibra muscular se activa a través de la recepción de un potencial de acción que es transmitido por una fibra nerviosa motora. La unión entre la célula nerviosa motora, su axón y las fibras musculares inervadas por ella se conoce como unidad motora. Cuando el potencial eléctrico alcanza la unión entre el nervio y el músculo, se genera una cantidad de transmisores químicos que convierten el potencial eléctrico en otro potencial que se propaga por toda la fibra muscular.

La electroneurografía de fibra única (SFEMG) y los potenciales de acción de la unidad motora (MUAP) son dos tipos de mediciones clínicas comunes y se utilizan para detectar mal funcionamiento muscular. Los MUAP son el resultado de la suma de distintos potenciales de acción de grupos de fibras musculares que se están contrayendo casi sincronizadamente y su morfología varía dependiendo del tipo de patología muscular que presente el individuo. (Martinez, 2011)



*Ilustración 1. MUAP registro*

Fuente: Extraído de [http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib\\_material/IB\\_T2\\_OCW.pdf](http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib_material/IB_T2_OCW.pdf)

Nota: a) MUAP de un sujeto normal; b) MUAP polifásicos patológicos; c) MUAP al incrementar el nivel de contracción muscular. (RETROALIMENTACIÓN)

## 4.2 Métodos de medida señal bioeléctrica

Las señales eléctricas de la mano se pueden medir utilizando varias técnicas, incluida la electromiografía (EMG) y la tomografía de impedancia eléctrica (EIT). (Wu, jiang, & Demóstenous, 2020)

EMG mide las señales eléctricas generadas por la actividad muscular. Para realizar mediciones de EMG, se colocan electrodos sobre o dentro de la piel que recubre los músculos de interés. Cuando un músculo se contrae o se relaja, produce una señal eléctrica que los electrodos detectan y registran. Estas grabaciones se pueden analizar para proporcionar información sobre la

actividad muscular y el gesto de la mano resultante. (Wu, jiang, & Demóstenous, 2020)

EIT mide los cambios en la impedancia eléctrica a través de una región de interés, que se puede utilizar para determinar los cambios en la distribución de la conductividad eléctrica dentro de la región. Al colocar electrodos alrededor de la mano, EIT puede medir los cambios en la conductividad eléctrica de la mano al realizar diferentes gestos con la mano, que pueden usarse para clasificar los movimientos de la mano. No obstante, los avances tecnológicos han permitido recientemente sistemas rentables, portátiles y fáciles de usar para medir señales manuales eléctricas, que se pueden utilizar para una variedad de aplicaciones, desde control protésico hasta dispositivos de comunicación. (Wu, jiang, & Demóstenous, 2020)

### **4.3 Toma de señales bioeléctricas EMG**

Para tomar señales bioeléctricas de la mano a través de un electromiograma (EMG), se deben colocar electrodos sobre los músculos de interés. Para el caso de la mano, se suele colocar los electrodos en el antebrazo, como una posición de referencia, y cerca de los músculos que se quieren monitorear. Para obtener una señal clara, es importante que los electrodos estén correctamente colocados y que la piel esté limpia y seca. Una vez que se colocan los electrodos, se pueden medir los potenciales eléctricos generados por la contracción de los músculos y así obtener información sobre la actividad muscular. Esta señal se puede utilizar para controlar actuadores, como una prótesis de mano controlada por señales musculares, o para diagnosticar mal funciones musculares. (Castellano, 2017)



Resumen de los requerimientos de señales bioeléctricas según los estándares de la ANSI - AAMI EC11-1991:

Rango Dinámico de Entrada (Input Dynamic Range): +/-5mV de señal y tolerancia para offsets dc de +/-300mV. (Osorio, 2007, pág. 29)

Exactitud en la Ganancia (Gain Accuracy): +/- 5% para selecciones de control de ganancia de 20mm/mV , 10mm/mV y 5mm/mV. (Osorio, 2007, pág. 29)

Error del sistema (System Error): Para señales de entrada limitadas a +/- 5mV y un Slew Rate de 125mV/s, el error máximo permitido es +/-10%. (Osorio, 2007, pág. 29)

Respuesta en la Frecuencia (Frequency Response): Caracterizado relativo a la respuesta de 10Hz de un número de señales de prueba. AHA recomienda un ancho de banda de 0.05Hz a 100Hz (+0.5dB,-3dB). (Osorio, 2007, pág. 29)

Respuesta al pulso (Step Response): El dispositivo debe responder a un impulso de 10mm, con un sobresalto (overshoot) permitido de 10% y una constante de tiempo de decaída  $\geq 3s$  en la medición de los primeros 320ms. (Osorio, 2007, pág. 29)

Impedancia de entrada: Una impedancia de entrada de una sola entrada (single ended) de por lo menos 2Mohms a 10Hz es requerida. (Osorio, 2007, pág. 30)

Corrientes Directas: 0.2mA en todas las conexiones de los electrodos del paciente. (Osorio, 2007, pág. 30)

Ruido del sistema: 40mV cuando todas las entradas están conectadas juntas. (Osorio, 2007, pág. 30)

Los rangos de señales EMG pueden variar según la fuente y el tipo de actividad muscular registrada, pero aquí se presenta una tabla general de rangos de señales EMG en microvoltios ( $\mu\text{V}$ ) para diferentes actividades musculares: (Gillaz, Malanda, Rodríguez Carreño, Rodríguez Falces, & Navallas, 2009)

- Reposo: 0-5  $\mu\text{V}$
- Contraer un músculo levemente: 5-15  $\mu\text{V}$
- Contraer un músculo moderadamente: 15-50  $\mu\text{V}$
- Contraer un músculo intensamente: 50-200  $\mu\text{V}$
- Movimientos voluntarios máximos o isométricos: 200-2000  $\mu\text{V}$

Es importante tener en cuenta que estos son solo rangos generales y que los niveles de señal EMG pueden variar ampliamente según la actividad muscular registrada y las condiciones de medición como la colocación de los electrodos y la interferencia electromagnética. Además, los valores de referencia específicos pueden variar según el equipo, los protocolos de medición y el contexto clínico o de investigación. (Gillaz, Malanda, Rodríguez Carreño, Rodríguez Falces, & Navallas, 2009)

#### **4.4 Variabilidad de potencial en bioseñales**

**Potencial de reposo:** La membrana celular es una delgada capa compuesta de lipoproteínas que generalmente impide la entrada de proteínas e iones en la célula, pero que presenta cierta permeabilidad a iones como el  $\text{Na}^+$ ,  $\text{K}^+$  o  $\text{Cl}^-$ . Esta permeabilidad se debe a la presencia de canales selectivos para cada tipo de ion. Al tener dos medios distintos (el interior y el exterior de la célula) separados por la membrana, se producen

dos flujos de iones a través de la misma. El flujo de difusión ocurre debido a la diferencia de concentración de iones entre los dos medios, y se alcanza un estado estacionario cuando estas concentraciones se igualan. El flujo eléctrico, por otro lado, se produce porque los iones tienen carga eléctrica, y cuando se mueven a través de la membrana generan un potencial eléctrico que se opone al flujo de difusión. Finalmente, estos flujos se estabilizan cuando el flujo de iones que ocurre por difusión se iguala al que ocurre por la diferencia de potencial eléctrico. Este estado estacionario produce un potencial neto entre el interior y el exterior de la célula conocido como potencial de reposo, que se puede calcular usando la ecuación de Nernst, considerando un único tipo de ion. (Martinez, 2011)

**Potencial de acción:** En condiciones normales, cuando no hay excitación, se establece un equilibrio en ambos lados de la membrana celular con un potencial negativo en el interior de la célula, lo que se conoce como potencial de reposo. En este estado, la célula se considera polarizada. (Martinez, 2011)


Cuando se estimula la célula, la membrana experimenta cambios en sus características. La estimulación puede tener diferentes causas. Por ejemplo, en los tejidos de los órganos sensoriales, los canales de la membrana celular están conectados a receptores específicos de energía, lo que provoca la estimulación. En otras membranas, la estimulación se produce debido a cambios en el potencial a través de la membrana. También puede haber una estimulación externa causada por algún tipo de dispositivo artificial. (Martinez, 2011)

Los cambios inducidos por la estimulación alteran la permeabilidad de la membrana a los diferentes iones presentes durante el potencial de reposo. Estos cambios dependen tanto de la intensidad del estímulo (se requiere una amplitud mínima o umbral para que comience el cambio en el estado celular) como del tiempo (las modificaciones en la permeabilidad causadas por la

estimulación cambian a sus valores originales después de cierto tiempo). (Martinez, 2011)

Estas modificaciones descienden principalmente a la permeabilidad del sodio ( $\text{Na}^+$ ) y del potasio ( $\text{K}^+$ ). Después de la estimulación, la permeabilidad al sodio aumenta, lo que hace que la membrana celular permita la entrada de estos iones. Esta entrada masiva de sodio a su vez aumenta la permeabilidad de la membrana, lo que resulta en un efecto de avalancha donde una gran cantidad de iones de sodio entra en la célula, desplazando solo una pequeña proporción de iones de potasio. Como resultado, la célula adquiere una carga positiva (despolarizada) de aproximadamente +20 mV, lo que se conoce como potencial de acción. (Martinez, 2011)

Una vez que se alcanza este nuevo estado de equilibrio, la membrana vuelve a impedir la entrada de nuevas iones. La eliminación de estos iones (proceso de repolarización) está asociada con la dependencia temporal de la nueva permeabilidad de la membrana, que regresa después de cierto tiempo a sus características iniciales ya las concentraciones de reposo. (Martinez, 2011)



*Ilustración 2.* Potencial de acción

Fuente: Extraído de [http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib\\_material/IB\\_T2\\_OCW.pdf](http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib_material/IB_T2_OCW.pdf)

Nota: Gráfica del estímulo de acción en bioseñales.

La **activación celular** se rige por una ley de todo o nada , donde es necesario alcanzar un umbral mínimo para que se produzca el potencial de acción . Una vez que se llega a este umbral, cualquier intensidad adicional en la excitación produce el mismo efecto ya que la célula entra en una fase de inhibición total durante la cual no responde a nuevos estímulos. Esta fase, que coincide con el período de alta duración del potencial de acción, se denomina periodo refractario absoluto (PRA). Debido a que es imposible medir directamente el PRA (requeriría estimulaciones muy fuertes), se mide el periodo refractario efectivo (PRE), que se mide hasta el punto de la pendiente de repolarización en que se puede iniciar un nuevo potencial de acción con un estímulo igual al doble del valor umbral. Durante la fase de repolarización, la célula puede ser estimulada aunque con estímulos más intensos que en la fase de reposo. A este intervalo se le llama periodo refractario relativo (PRR). El tiempo refractario total (TRT) es la suma de estos períodos. La siguiente figura presenta un esquema de estas definiciones para el caso de un potencial de acción de célula cardiaca, en el cual se ha superpuesto la curva intensidad-tiempo de estimulación. Dicha curva muestra un tiempo, al final de la fase de repolarización, durante el cual se puede estimular la célula con intensidades menores al umbral. Este tiempo se conoce como periodo de súper normalidad. (Martinez, 2011)

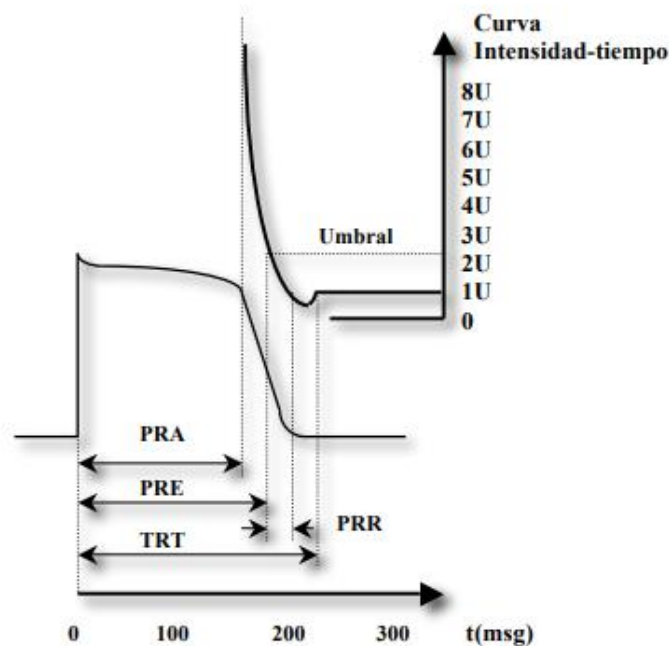


Ilustración 3. Activación celular

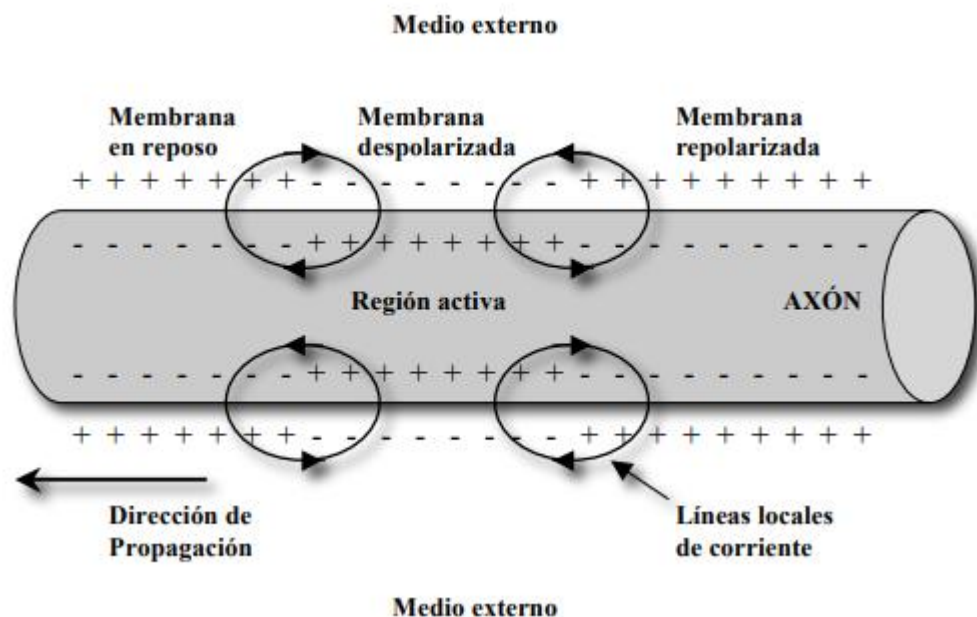
Fuente: Extraído de [http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib\\_material/IB\\_T2\\_OCW.pdf](http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib_material/IB_T2_OCW.pdf)

Nota: Activación celular y refractariedad.

Para analizar cómo se propagan los potenciales de acción a lo largo de las fibras nerviosas, se considera que la región activa (en potencial de acción) en una fibra es mucho menor que la longitud total de la fibra. En un instante determinado, la distribución de carga cerca de la región activa presenta una inversión de polaridad debido a la despolarización de la membrana, mientras que la zona adyacente tiene la membrana repolarizada. La distribución de carga generada genera líneas de corriente que despolarizan las regiones adyacentes y, cuando esta despolarización alcanza el valor umbral y dichas regiones no están en periodo refractario, se convierten en activas. Así, el potencial de acción se propaga a lo largo de la fibra sin atenuación, ya que se regenera constantemente en cada región de la fibra. La membrana de la zona aún no alcanzada por el potencial de acción permanece en estado de

reposo. La figura muestra la distribución de carga y el progreso del potencial de acción a lo largo de la fibra. (Martinez, 2011)

Los vertebrados generalmente tienen neuronas mielinizadas, lo que significa que se recubren los axones con mielina de manera discontinua en intervalos regulares conocidos como nodos de Ranvier. Debido a que la mielina funciona como aislante, los canales iónicos tienden a concentrarse en los nodos de Ranvier. Al estar cubiertas de mielina, las fibras nerviosas reducen las pérdidas de corriente y aumentan sus propiedades de conducción, mejorando su conducción aproximadamente en un factor de 20 con respecto a las no mielinizadas. La conducción se produce mediante la activación secuencial entre nodos y el mecanismo de conducción saltatoria, que se da entre nodos no adyacentes. Por lo tanto, la mielinización de las neuronas es esencial para la transmisión eficiente de señales dentro del sistema nervioso. (Martinez, 2011)



*Ilustración 4.* Distribución de carga en las proximidades de la región activa.

Fuente: Extraído de [http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib\\_material/IB\\_T2\\_OCW.pdf](http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib_material/IB_T2_OCW.pdf)


Nota: Propagación de actividad de potencial de carga en bioseñales.

La rapidez con la que viajan los potenciales de acción es determinada por el tipo de células, y existe un límite máximo de frecuencia debido al periodo refractario. La velocidad varía según el tipo de célula, siendo las fibras nerviosas las más rápidas con velocidades de entre 20 y 140 m/s, mientras que la velocidad en el músculo cardíaco varía entre 0.2 y 0.4 m/s. Para fibras con retardo especial, como en el nodo aurículo-ventricular cardíaco, la velocidad puede ser muy baja, de alrededor de 0.03-0.05 m/s. (Martinez, 2011)

#### **4.5 Electroodos**

La obtención de las señales EMG requiere el uso de tres electrodos: dos se colocan sobre el músculo para medir la diferencia de potencial entre ellos, mientras que el tercero se posiciona en un punto de referencia para medir la señal. Es importante destacar que, al estudiar un músculo, una unidad motora puede activar la contracción de varios músculos simultáneamente para realizar un movimiento específico. Como resultado, la superposición de las señales de activación compone el valor de la señal EMG registrada. Las señales generadas más alejadas del electrodo presentarán menor amplitud en comparación con las señales más cercanas a los electrodos. (Castellano, 2017)





**Ilustración 5.** Superposición de señales EMG.

Fuente: Extraído de [https://rua.ua.es/dspace/bitstream/10045/68351/1/Implementacion\\_y\\_evaluacion\\_de\\_un\\_esquema\\_Lopez\\_Castellanos\\_Jose\\_Mario\\_Porfirio.pdf](https://rua.ua.es/dspace/bitstream/10045/68351/1/Implementacion_y_evaluacion_de_un_esquema_Lopez_Castellanos_Jose_Mario_Porfirio.pdf)

Nota: Propagación de actividad de potencial de carga en bioseñales.

#### **4.6 Redes neuronales aplicadas a clasificadores de señal**

Las redes neuronales son utilizadas comúnmente en la clasificación de señales debido a su capacidad para identificar patrones y relaciones complejas en los datos. En particular, las redes neuronales pueden ser entrenadas con conjuntos de datos de entrenamiento que contienen señales de diferentes clases, lo que les permite aprender a clasificar nuevas señales en una de estas clases. Para utilizar redes neuronales para clasificación de señal, se pueden seguir diferentes enfoques y ajustar diferentes parámetros, como el número de capas ocultas y neuronas en la red, la función de activación y el algoritmo de aprendizaje. (Universidad Nacional Autónoma de México, 2018)

Las redes neuronales pueden ser utilizadas en el aprendizaje y clasificación de señales en EMG. Algunas características importantes a tener en cuenta para este tipo de aplicación incluyen la capacidad de identificar

patrones y relaciones complejas en los datos, el entrenamiento adecuado con conjuntos de datos representativos, la configuración adecuada de parámetros como el número de capas y neuronas en la red, la función de activación y el algoritmo de aprendizaje, y la capacidad de reconocer patrones y relaciones complejas en las señales de entrada. Es importante seleccionar y configurar correctamente el modelo de red neuronal para cada aplicación específica, con el fin de maximizar la calidad de las clasificaciones y minimizar el riesgo de errores. Hay diferentes enfoques para la clasificación de señales en EMG, como utilizar índices lineales y no lineales o utilizar redes neuronales artificiales basadas en diferentes arquitecturas como redes completamente conectadas con capas ocultas, redes convolucionales o redes recurrentes. (Matich, 2001)

Las redes neuronales aplicadas a señales biológicas tienen una gran importancia en la comprensión y análisis de procesos complejos del cuerpo humano. Por ejemplo, en el caso de las señales EMG, las redes neuronales pueden ayudar a identificar patrones específicos de actividad eléctrica muscular que permiten diagnosticar diferentes trastornos neuromusculares y monitorear su progreso. (Universidad Nacional Autónoma de México, 2018)

#### **4.6.1 Tipos de clasificadores de redes neuronales de señales**

Redes Neuronales Convolucionales (CNN, por sus siglas en inglés): estas redes son apropiadas para el análisis de imágenes y se basan en el procesamiento local de la información, con el objetivo de extraer características relevantes de la señal. (Campo, 2021)

Redes Neuronales Recurrentes (RNN, por sus siglas en inglés): estas redes son utilizadas para el procesamiento de señales secuenciales, tales como señales de voz o de vídeo. (Campo, 2021)

Redes Neuronales de retroalimentación (Feedback NN, por sus siglas en inglés): estas redes tienen capacidades de aprendizaje supervisado y no supervisado, y se utilizan en aplicaciones donde la señal de salida se utiliza como retroalimentación para la señal de entrada. (Campo, 2021)

Redes Neuronales de autoorganización (Self-Organizing NN, por sus siglas en inglés): estas redes se utilizan para el análisis de grandes conjuntos de datos, y permiten la identificación de patrones ocultos y no supervisados. (Campo, 2021)

#### **4.6.2 Aplicaciones de las redes neuronales**

Las redes neuronales tienen varias aplicaciones en el procesamiento de señales, incluyendo la caracterización de señales bioeléctricas en el desarrollo de interfaces cerebro-computadora, la aproximación de señales mediante algoritmos Wavenet, el reconocimiento visual en vehículos autónomos, el procesamiento de señales provenientes de sensores en procesadores digitales. En cuanto a otros usos de las redes neuronales, estas también pueden ser utilizadas para modelar sistemas lineales, filtrar ruido de una señal, crear pronósticos económicos y financieros, y ayudar en el control de sistemas de servomecanismo. En resumen, las redes neuronales pueden ser una herramienta útil para la predicción y comprensión de patrones complejos en una variedad de campos. (Basogani, 2008)

### **5. Metodología**

La realización del proyecto en primer lugar se enfatiza a través de una investigación previa y una retroalimentación de las temáticas a desarrollar. Dando como inicio a tomar una muestra para la base de datos en el contexto de la electromiografía (EMG), este tipo de base de datos puede contener muestras de señales EMG recopiladas de diferentes músculos durante diferentes tipos de movimientos o condiciones, también pueden provenir de sujetos sanos o de pacientes con afecciones neuromusculares, y pueden incluir información sobre la edad, el sexo y otros factores relevantes, donde se busca la más óptima para utilización de entrenamiento y validación en los algoritmos de procesamiento de señales y para las técnicas de reconocimiento de patrones con el propósito que en la evaluación de la función muscular y la detección de movimiento, se obtenga un alto índice de precisión. Se ejecuta dicha base de datos de un repositorio confiable encontrado en (Anaconda), donde se obtienen los datos estadísticos de intención de movimiento en una prueba realizada a más de 10.000 sujetos en el cual los movimientos relevantes de estudio cumplen con las etiquetas y condiciones requeridas según su clase (identificación de movimientos de la parte de la mano tomados con un equipo EMG a personas de todas las edades y la relación con respuesta a la velocidad de su movilidad manual).

Los datos se dividieron en conjuntos de caracterización variable y se procedió a la validación de la base de datos en el lenguaje de programación elegido (Python), para empezar a ejecutar un algoritmo de aprendizaje automático en la caracterización de señales EMG entre musculo inactivo y cuando se genera la actividad muscular. El objetivo del algoritmo de aprendizaje automático sería identificar patrones, tendencias y características en las señales EMG que puedan estar relacionadas con una tendencia de movilidad más precisa. Una vez se comprende la información del dataset y se ajusta para su posterior entrenamiento correspondiente de la red neuronal se evalúan los resultados y la información generada por el

programa. De esta manera, se asegura que la red neuronal (SVM) pudiera identificar con precisión las estadísticas de intención de movimiento de la mano, utilizando una arquitectura adecuada.

Una vez que la red neuronal estuvo entrenada, se ajustaron los parámetros para lograr los mejores resultados en el conjunto de validación y prueba. Todo esto se hizo para garantizar una alta precisión en el diseño programado, cumpliendo con los requerimientos descritos y asegurando así un resultado óptimo en la identificación de la intención de movimiento de la mano a partir de la señal EMG.

## **6. Resultados**

### **6.1 Herramientas usadas**

La programación de bioseñales con Inteligencia Artificial en Python, para el procesamiento de bioseñales y la creación de la red neuronal; las bibliotecas más utilizadas son NumPy, SciPy para el procesamiento de señales, matplotlib para la visualización de datos y scikit-learn para el aprendizaje automático y la clasificación de datos, que incluye soporte para SVM (Support Vector Machine) un tipo de modelo automático supervisado utilizado para clasificar datos en dos o más categorías que busca la mejor separación entre las diferentes clases de datos.

Otras herramientas útiles incluyen Jupyter Notebook para la creación y documentación interactiva de código, y Spyder como un entorno de desarrollo integrado (IDE) específico para Python, que proporciona herramientas de depuración y facilita la creación y edición de código.

Then, you need to create a new conda environment with the modules that you want to use with Spyder and include `spyder-kernels` in it. For example, if you want to use `scikit-learn`, open your terminal or the Anaconda prompt on Windows and run the following commands:

```
conda create -n spyder-env -y
conda activate spyder-env
conda install spyder-kernels scikit-learn -y
```

### *Ilustración 6. Carga de librerías*

Fuente: <https://www.spyder-ide.org/>

Gestor de librerías: <https://www.anaconda.com/download>

## **6.2 Descripción de la base de datos**

En cuanto a la base de datos de bioseñales con respecto al tiempo de respuesta, es importante tener en cuenta el tiempo de muestreo, que se refiere al intervalo de tiempo entre cada punto de datos en la señal. La frecuencia de muestreo es el inverso del tiempo de muestreo y representa la cantidad de puntos de datos por segundo. Es crucial que el tiempo de respuesta de la base de datos sea lo suficientemente rápido para garantizar una buena precisión en las mediciones y la eficacia del modelo de IA, sus variables constan de (Class, EMG, time). Las técnicas y análisis predictivos de la base de datos fueron tomadas de un modelo en Git Hub el cual fue un estudio a 10.000 sujetos en la intención de movimiento y el tiempo de reacción en la actividad manual.

La elección de una base de datos de bioseñales de intención de movimiento en lugar de una que module varios movimientos puede tener varios motivos. Uno de ellos es que la captura de datos de intención de movimiento puede ser más específica y, por lo tanto, más efectiva para aplicaciones que involucren el control de prótesis, dispositivos robóticos y otros sistemas de asistencia que requieren una alta precisión en el control del movimiento.

Además, una base de datos de intención de movimiento puede permitir la identificación de patrones específicos en la señal y consecuentemente ayudar en la creación de modelos predictivos y de control. En cambio, en una base de datos de modulación de varios movimientos, puede haber una mayor variabilidad en los datos de la señal, lo que dificulta la identificación de patrones específicos y la creación de modelos precisos.



//

*ustración 7. Modelo para la ejecución del programa*

Fuente: Diseño personal

Nota: Modelo de entrenamiento SVM, para intención de movimiento de la mano

### **6.3 Entrenamiento de la red neuronal**

Las curvas de entrenamiento muestran la evolución del rendimiento de la red neuronal durante el entrenamiento en función de la cantidad de iteraciones o épocas. Estas curvas pueden indicar si la red neuronal está sobreajustando o subajustando, y por lo tanto, ayudar a ajustar los hiperparámetros.

## Modelo SVM con regiones de decision para dos gestos segun EMG,t




Ilustración 8. *Modelo de entrenamiento SVM*

Fuente: Codificación personal de Python

Nota: Modelo de entrenamiento SVM, para intención de movimiento de la mano

Las fronteras de decisión pueden mostrar cómo la red neuronal interpreta la señal de intención de movimiento y cómo clasifica diferentes patrones de la señal en momento de inactividad y en momento de actividad manual respecto al tiempo de respuesta en origen al sujeto. La métrica determinada por el accuracy mide la precisión de la red neuronal en la clasificación correcta de los patrones de la señal de la base de datos en intención de movimiento, esto se refiere a la precisión de la red neuronal en la identificación correcta de la intención de movimiento del usuario para la precisión de movimiento.



Modelo SVM con regiones de decisión para dos gestos segun EMG,t

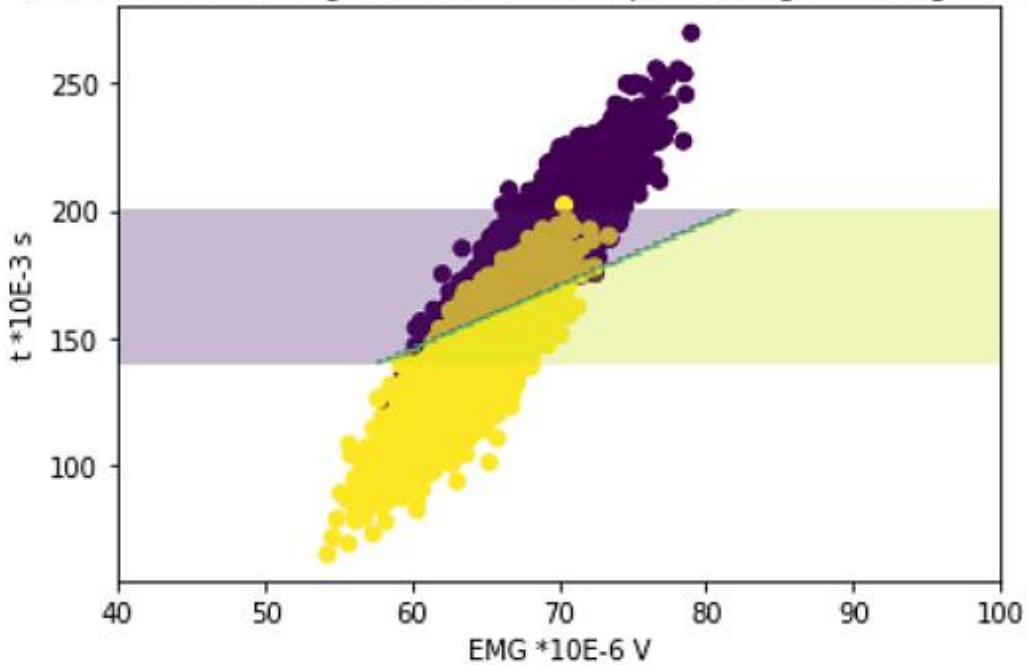


Ilustración 9. Actividad de red neuronal y métrica de clasificación

Fuente: Codificación personal de Python

Nota: Modelo de entrenamiento SVM, para intención de movimiento de la mano

#### 6.4 Desempeño en muestras desconocidas

El sistema de adquisición de señales eléctricas biológicas para detección de intención de movimiento para generar órdenes a un manipulador robótico debería ser capaz de clasificar con precisión nuevas muestras desconocidas ya que la tasa de clasificación correcta alta evidencia la habilidad del modelo para generalizar y clasificar de manera precisa muestras de datos no conocidas previamente. Sin embargo, es importante tener en cuenta que la variabilidad natural de las señales EMG y el ruido en los datos pueden afectar negativamente el rendimiento del modelo en nuevas muestras, como anteriormente menciona este modelo se capacita en alta exactitud

solamente para la intención de movimiento generando mayor eficacia al control de movimiento requerido por dispositivos robóticos, siendo ejecutado por muestreos enormemente numéricos de sujetos y validación de datos por instrumentación limpia y filtrada de la información en las bioseñales implementadas.

En resumen, el entrenamiento de una red neuronal SVM para bioseñales sigue los mismos principios que el entrenamiento de una red neuronal SVM para cualquier tipo de datos. Se necesitan datos de entrenamiento, se divide el conjunto de datos en entrenamiento y prueba, se entrena la red neuronal utilizando un algoritmo de optimización y se evalúa el desempeño del modelo utilizando el conjunto de datos de prueba. Los principales desafíos al entrenar una red neuronal SVM para bioseñales incluyen la selección de características adecuadas, la mitigación del ruido y la selección de los parámetros óptimos.

## **6.5 Resumen de los resultados**

Uno de los principales desafíos al programar bioseñales EMG con inteligencia artificial es lograr una clasificación precisa de las señales de EMG en diferentes categorías de intención de movimiento. La precisión de la clasificación depende de la calidad de los datos de entrenamiento y de la elección de los parámetros para el algoritmo de clasificación utilizado.

Otro desafío importante es la interpretación de los resultados de la clasificación de EMG en el contexto clínico. La precisión de la clasificación no siempre se correlaciona con un movimiento real del sujeto, lo que puede dar lugar a interpretaciones erróneas de los resultados.

Los principales retos al programar bioseñales EMG con inteligencia artificial incluyen lograr una clasificación precisa en diferentes categorías de

intención de movimiento, así como la interpretación correcta de los resultados en un contexto de movilidad con alta precisión. Es importante considerar cuidadosamente la calidad de los datos de entrenamiento y los parámetros del algoritmo de clasificación utilizado para obtener resultados precisos y confiables.

Los resultados son significativos para implementaciones en el campo de las prótesis y la rehabilitación. Por ejemplo, una clasificación precisa de las señales de EMG puede permitir a los pacientes con amputaciones utilizar prótesis controladas por EMG de manera más eficiente, lo que puede mejorar su calidad de vida y reducir su dependencia de terceros. También puede ser útil en la rehabilitación de pacientes con lesiones neuromusculares y mejorar la eficacia de la terapia física. Además, las técnicas de inteligencia artificial utilizadas en el procesamiento de bioseñales EMG para la intención de movimiento pueden ayudar a predecir y gestionar tecnologías sanitarias en el futuro, y esto puede tener importantes implicaciones para la salud humana.

## **7. Conclusiones**

Se determinó que el método de procesamiento implementado, para la elección de clasificación y de la calidad de los datos de entrenamiento utilizados logra un resultado exitoso, donde es esencial que la tasa de clasificación correcta sea alta, lo que indica que el modelo puede generalizar y clasificar con precisión nuevas muestras desconocidas.

Se entrenó un modelo SVM para intención de movilidad que puede permitir una mayor precisión y eficacia en aplicaciones específicas que involucren el control del movimiento, mientras que si fuese adaptado a una base de datos de modulación de varios movimientos puede ser más

adecuada para aplicaciones más generales que no requieran una precisión tan alta.

Se obtuvo un potencial desempeño de respuesta en las curvas de entrenamiento, fronteras de decisión y accuracy para evaluar la eficacia de la red neuronal en la clasificación de patrones de señales de intención de movimiento. La precisión y eficacia en la clasificación de las señales de intención de movimiento generan una buena visión para la implementación en aplicaciones del control de prótesis, dispositivos robóticos y otros sistemas de asistencia que requieren una alta precisión en el control del movimiento.

Para futuras implementaciones se sugiere considerar que para la base de datos sea un estudio realizado en función de varios sujetos, que su implementación debe ser a partir de datos filtrados y lo más limpios de perturbaciones sonoras para la correcta clasificación; si es un diseño implementado a exoesqueleto o manipuladores robóticos se espera a tener en cuenta los datos categóricos que caracterizan la buena modulación del programa.

## **8. Referencias bibliográficas**

Basogani, X. (2008). Obtenido de

[https://ocw.ehu.eus/pluginfile.php/40137/mod\\_resource/content/1/rede\\_s\\_neuro/contenidos/pdf/libro-del-curso.pdf](https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/rede_s_neuro/contenidos/pdf/libro-del-curso.pdf)

Campo, J. L. (2021). *Universidad Politecnica de Madrid*. Obtenido de

[https://oa.upm.es/68673/1/PFC\\_JAVIER\\_LOPEZ\\_INIESTA\\_2021.pdf](https://oa.upm.es/68673/1/PFC_JAVIER_LOPEZ_INIESTA_2021.pdf)

- Castellano, J. M. (2017). *Universidad de Alicante*. Obtenido de [https://rua.ua.es/dspace/bitstream/10045/68351/1/Implementacion\\_y\\_evaluacion\\_de\\_un\\_esqu\\_Lopez\\_Castellanos\\_Jose\\_Mario\\_Porfirio.pdf](https://rua.ua.es/dspace/bitstream/10045/68351/1/Implementacion_y_evaluacion_de_un_esqu_Lopez_Castellanos_Jose_Mario_Porfirio.pdf)
- Gillaz, L., Malanda, A., Rodríguez Carreño, I., Rodríguez Falces, J., & Navallas, J. (2009). *sciELO*. Obtenido de [https://scielo.isciii.es/scielo.php?script=sci\\_arttext&pid=S1137-66272009000600003](https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272009000600003)
- Martinez, J. F. (2011). *Universidad de Valencia* . Obtenido de [http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib\\_material/IB\\_T2\\_OCW.pdf](http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib_material/IB_T2_OCW.pdf)
- Matich, D. J. (2001). Obtenido de [https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monograis/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograis/matich-redesneuronales.pdf)
- Osorio, L. A. (Abril de 2007). Obtenido de <https://core.ac.uk/download/pdf/71394319.pdf>
- Rabin, N., Kahlon, M., Mayalet, S., & Ratnovsky, A. (Julio de 2020). *Science Direct*. Obtenido de <https://www.sciencedirect.com/science/article/abs/pii/S0957417420301068>
- Universidad Nacional Autónoma de México. (2018). Obtenido de [https://virtual.cuautitlan.unam.mx/intar/?page\\_id=977](https://virtual.cuautitlan.unam.mx/intar/?page_id=977)
- Wu, Y., jiang, d., & Demóstenous, A. (Septiembre de 2020). *ieeexplore*. Obtenido de <https://ieeexplore.ieee.org/document/9131824>