

ALGORITMO PREDICTIVO DE LA INTENCIÓN DE AGARRES EN UNA PRÓTESIS ROBÓTICA DE MANO IMPRESA EN 3D

*PREDICTIVE ALGORITHM OF GRIP INTENTION ON A 3D
PRINTED ROBOTIC HAND PROSTHESIS*

Lidia Hortencia Rascón Madrigal

Universidad Autónoma de Ciudad Juárez, México

lrascon@uacj.mx

Edgar Eduardo Ramírez Pantaleón

Universidad Autónoma de Ciudad Juárez, México

dgrmrz811@gmail.com

José David Díaz Román

Universidad Autónoma de Ciudad Juárez, México

david.roman@uacj.mx

José Manuel Mejía Muñoz

Universidad Autónoma de Ciudad Juárez, México

jose.mejia@uacj.mx

Ernesto Sifuentes de la Hoya

Universidad Autónoma de Ciudad Juárez, México

esifuent@uacj.mx

Recepción: 14/diciembre/2021

Aceptación: 25/enero/2022

Resumen

Las prótesis mioeléctricas son prótesis eléctricas controladas por señales mioeléctricas, poseen un alto grado de rehabilitación a un mayor costo que las prótesis funcionales. La investigación se enfoca en comparar dos algoritmos de red neuronal artificial para estimar la intención de movimiento de agarre cilíndrico, esférico y mano en reposo a partir de una señal de electromiografía y realizar el movimiento estimado en una prótesis robótica de mano impresa en 3D. Se utilizó el modelo de mano robótica de inmoov, señales de electromiografía registradas mediante dos sensores Myoware®, se extrajeron cuatro características de la señal de electromiografía para evaluarlas en una red neuronal artificial, los resultados de las tres neuronas de salida se analizaron mediante un árbol de decisión, se realizó

un algoritmo para accionar los servomotores mano robótica impresa en 3D. Ésta realizó los agarres de manzanas, pelotas, desarmadores y botellas de agua. Los resultados muestran una especificidad del 95% y sensibilidad del 90% en la arquitectura de red neuronal seleccionada. Las pruebas se realizaron en sujetos sin amputación, los resultados marcan la pauta para integrar más movimientos que pueda realizar la prótesis robótica de mano.

Palabras Clave: Agarre cilíndrico, agarre esférico, intención de movimiento, prótesis mioeléctrica de mano, red neuronal artificial.

Abstract

Myoelectric prostheses are electrical prostheses controlled by myoelectric signals; they have a high degree of rehabilitation at a higher cost than functional prostheses. The research focuses on comparing two artificial neural network algorithms to estimate the intention of cylindrical, spherical hand grip movement and rest hand from an electromyography signal and perform the estimated movement in a 3D printed robotic hand prosthesis. The inmoov robotic hand model was used, electromyography signals were recorded by two Myoware® sensors, four characteristics of the electromyography signal were extracted to be evaluated in an artificial neural network, the results of the three output neurons were analyzed using a tree decision structure, an algorithm was carried out to activate the 3D printed robotic hand servomotors to make the grips of apples, balls, screwdrivers, and water bottles. The results show a specificity of 95% and sensitivity of 90% in the selected neural network architecture. The tests were carried out in subjects without amputation, the results set the tone for integrating more movements that the robotic hand prosthesis can perform.

Keywords: Artificial neural network, cylindrical grip, hand prosthesis, movement intention, spherical grip.

1. Introducción

Las señales electromiográficas superficiales son señales eléctricas producidas por el músculo durante el proceso de contracción y relajación de la mano y son

particularmente útiles para el control de prótesis de mano. Los movimientos y agarres cilíndrico y esférico que realizamos con la mano al tomar una pelota, una manzana o un vaso con agua son actividades cotidianas. En este trabajo se propone estimar la intención de estos agarres mediante dos algoritmos de clasificación.

En [Caesarendra, 2016] presentaron un método de clasificación de ocho movimientos de la mano obtenidos de 15 sujetos. Las señales EMG se clasificaron mediante el Análisis de Componentes Principales (PCA, por sus siglas en inglés) y la aplicación de una red neuronal. Se obtuvieron 16 características con análisis temporales usando el método PCA para mejorar la precisión de la clasificación. Éstas se usaron en la clasificación de la ANN. Los resultados mostraron una precisión de entrenamiento del 85.7% y prueba del 81.2%. En [Iqbal, 2017] presentaron una técnica para clasificar movimientos de mano basado en la descomposición del valor singular (SVD, por sus siglas en inglés), análisis de componentes principales (PCA, por sus siglas en inglés) y el método de clasificación k vecinos cercanos. Los resultados muestran un alta y consistente mediante algoritmos de baja complejidad computacional. En [Abu, 2020] realizaron una clasificación basada en redes neuronales para múltiples gestos de la mano como: (1) Agarre cilíndrico, (2) Supinación (giro a la izquierda), (3) Pronación (Girar a la derecha), (4) Mano en reposo y (5) Mano abierta, las características de la señal EMG utilizadas fueron media del valor absoluto (MAV, por sus siglas en inglés), mediana, longitud de forma de onda (WL, por sus siglas en inglés) y raíz cuadrada media (RMS, por sus siglas en inglés). La Red Neural Artificial (ANN) produjo una precisión del 80% para entrenamiento y prueba para 10 capas de neuronas ocultas. En [Calderón, 2017] presentaron un método para el reconocimiento de patrones de señales de electromiografía (EMG, por sus siglas en inglés); se utilizó una Red Neuronal Artificial (ANN, por sus siglas en inglés) con el método back-propagation porque tienen un elevado índice de éxito usando la menor cantidad de canales. El estudio consistió en hacer una evaluación de 20 muestras de cada uno de los cuatro patrones a analizar (mano relajada/agarre cilíndrico, agarre puntual, aducción del pulgar y extensión del dedo índice). Para la implementación de la ANN se utilizó el paquete Neural Network Toolbox (NNT) del software Matlab, para diseño,

entrenamiento, visualización y simulación interactiva de la red. Los resultados mostraron una tasa de reconocimiento del 95%.

En [Artameeyanant, 2015] se propone una técnica de extracción de características basada en la transformación de señales EMG a una red compleja usando el algoritmo visibilidad de peso, que analiza instantes de tiempo, frecuencia o tiempo/frecuencia; el producto, es utilizado para caracterizar un vector con una Red Neuronal Perceptrón Multicapa (MLPNN, por sus siglas en inglés) para su clasificación. El método propuesto, consiste en segmentar la señal EMG, convertir las señales del dominio del tiempo a la red compleja usando el algoritmo visibilidad de peso y la extracción de características usando métodos estadísticos (boxplots). La eficacia de clasificación fue 94.75%.

En [Gutiérrez, 2017] se desarrolló un algoritmo predictivo para clasificar los agarres de la mano: cilíndrico, esférico y de puño, a partir de una señal EMG. Se utilizó el sistema Myopac junior para la obtención de las señales y el software Matlab para extraer las características: el valor medio absoluto, el número de cruces por cero, el número de cambios de signo de la pendiente y la longitud de onda. Se utilizó un algoritmo basado en la regresión logística y árbol de decisión. Se realizó una validación calculando la especificidad con un promedio del 96.4%, la sensibilidad con 96.09%, el valor predictivo positivo con un porcentaje del 98.34% y el valor predictivo negativo con un porcentaje de 91.75%

El objetivo del trabajo se enfoca en comparar dos algoritmos red neuronal artificial para estimar la intención de movimiento de agarre cilíndrico, esférico y mano en reposo a partir de una señal de electromiografía y realizar el movimiento estimado en una prótesis robótica de mano impresa en 3D. Las pruebas se realizaron en sujetos sin amputación.

2. Métodos

La metodología presenta los pasos detallados para la implementación de la mano mioeléctrica impresa en 3D y el algoritmo basado en red neuronal artificial para estimar la intención de movimiento a partir de las señales EMG. En la figura 1 se ilustra el esquema general de la metodología y se describe cada etapa.





Figura 1 Esquema general de la metodología.

Impresión y ensamble de la mano robótica

El modelo de la mano robótica [inmoov, 2021] se seleccionó de la página www.inmoov.fr. Se utilizó el software SolidWorks Student License 2017 para su visualización y el software Cura 15.04.6 para realizar modificaciones, arreglos al diseño y crear el archivo en código G utilizado por la impresora 3D. Se utilizó la impresora 3D Anycubic 4Max. El prototipo se elaboró con el material PLA. Las falanges se unieron por medio de pernos de 3 mm de espesor para permitir el movimiento natural de una articulación interfalángica figura 2a. Para la simulación de los tendones se empleó hilo de pescar y como accionador de estos hilos se utilizaron servomotores de posición modulados por ancho de pulso (PWM, por sus siglas en inglés); los servomotores MG996R de la empresa Tower Pro se colocaron en el antebrazo de la mano, figura 2b.



a) Ensamble de falanges

b) Servomotores

Figura 2 Ensamble de la mano robótica [inmoov, 2021].

Adquisición de señales EMG

La adquisición de la señal EMG utilizó seis electrodos superficiales Ag/AgCl para cada persona que participo en la recolección de señales para la base de datos. Los electrodos se conectaron a dos sensores Myoware® de la compañía Advance Technology®. El sensor Myoware® se encargó de eliminar el ruido de la señal, amplificar, filtrar y rectificar la señal EMG. La señal EMG obtenida se conectó a la

tarjeta de adquisición de datos DAQ-USB-6009, se desarrolló un programa en LabVIEW 2017 para adquirir la señal EMG durante 10 segundos, a una frecuencia de muestreo de 2 kHz, figura 3.




Figura 3 Diagrama de interfaz entre la señal EMG y la PC.

En los agarres de mano: cilíndrico, esférico y reposo se registraron las señales EMG activas y en reposo de los músculos flexor común superficial de los dedos figura 4a y el músculo extensor común figura 4b, los electrodos fueron posicionados en la parte media de cada músculo.




Figura 4 Colocación de electrodos para músculo flexor y extensor de los dedos.

Protocolo de medida. Para capturar la actividad muscular del agarre esférico, se utilizó una manzana de aproximadamente 10 cm de diámetro y para adquirir la actividad muscular del agarre cilíndrico se utilizó una botella de agua de 600 ml. El protocolo consistió en sentar a la persona en una posición cómoda y capturar una señal con la mano relajada. Posteriormente, se pidió agarrar el objeto con fuerza

durante 10 segundos. Este protocolo se realizó a 5 personas. En una base de datos se almacenaron 20 señales EMG de cada agarre por persona.

ALGORITMO DE INTENSIÓN DE AGARRE MEDIANTE RED NEURONAL

Extracción de características en señal EMG

Se elaboró un algoritmo en Matlab para realizar la extracción de características en el dominio del tiempo reportadas en [Caesarendra, 2016] con buenos resultados. Las señales EMG se analizaron en ventanas de 256 ms con traslapes de 128 ms. Las características fueron: el valor medio absoluto (MAV, por sus siglas en inglés), integral de electromiograma (IEMG), cambios de pendiente (SSC) y longitud de la onda (WL).

El valor medio absoluto es una medida de la señal EMG que permite determinar los niveles de contracción muscular. Se calcula el valor medio absoluto sobre cada segmento i de N muestras de la señal, ecuación 1.

$$MAV = \frac{1}{N} \sum_{K=1}^N |X_k|, \quad i = 1, 2, \dots, I \quad (1)$$

Donde X_k es la K ésima muestra del segmento i e I es el número total de segmentos. La IEMG, que representa la suma de todos los valores de la señal bajo la curva, ecuación 2.

$$IEMG = \sum_{K=1}^N |X_k|, \quad i = 1, 2, \dots, I \quad (2)$$

El cambio de signo de pendiente de la señal proporciona información sobre las propiedades de frecuencia de la señal mediante el conteo del número de veces que la pendiente de la forma de onda cambia de signo. Igualmente requiere de un umbral, para producir los cambios de signo en la pendiente se incrementa según las relaciones en la ecuación 3.

$$\begin{aligned} X_k &> X_k - 1 \quad \text{y} \quad X_k > X_k + 1 \quad \text{o} \\ X_k &< X_k - 1 \quad \text{y} \quad X_k < X_k + 1 \quad \text{y} \\ (|X_k - X_k - 1|) &\geq \text{umbral} \quad \text{o} \quad (|X_k - X_k + 1|) \geq \text{umbral} \end{aligned} \quad (3)$$

Para $k = 1, 2, \dots, N$

La longitud de la forma de onda es la longitud acumulada de la forma de onda sobre el segmento de tiempo y está dada por la sumatoria del valor absoluto de la diferencia de dos muestras consecutivas, ecuación 4.

$$L_o = \sum_{K=1}^N |\Delta X_k|, \quad (4)$$

Donde, $\Delta X_k = X_k - X_{k-1}$ (diferencia entre valores de muestras consecutivas). El valor resultante da una medida de la amplitud de la forma de onda, su frecuencia y duración en un solo parámetro.

Algoritmo de red neuronal artificial y árbol de decisión

La clasificación de los agarres esférico, cilíndrico y reposo se realizó mediante una red neuronal artificial implementada en Matlab. En el desarrollo y entrenamiento de la red neuronal, se utilizaron los vectores de las características, el arreglo matricial se conformó por 7,722 muestras, se utilizaron 99 señales en total (33 de cada agarre a clasificar y reposo), cada señal contenía 78 muestras obtenidas en la extracción de características, se seleccionó el 80% de las muestras para el entrenamiento, 10% para validación y 10% para prueba. La arquitectura de red neuronal constó de una capa oculta con 40 neuronas y una capa de salida de 3 neuronas.

Se comparó una segunda arquitectura de red neuronal se utilizaron las cuatro características de la señal EMG del sensor colocado en el músculo flexor común superficial de los dedos y las cuatro características del sensor colocado en el músculo extensor de los dedos. La arquitectura de red neuronal constó de una capa oculta con 80 neuronas y una capa de salida de 3 neuronas.

Se utilizó un algoritmo basado en árbol de decisión, figura 5, para evaluar el valor de las salidas de la Red Neuronal Artificial, el algoritmo clasifica el agarre solo si algunos de estos tienen una probabilidad más alta que el otro. Se ha numerado cada decisión para facilitar su explicación. En la condición 1, se evaluó la condición de si cilíndrico > esférico ir a condición 3, si no ir a condición 2. La condición 2

compara si esférico > reposo y se clasifica como agarre esférico en caso contrario se clasifica como reposo. La condición 3 compara si cilíndrico > reposo y se clasifica como agarre cilíndrico si no se clasifica como reposo.

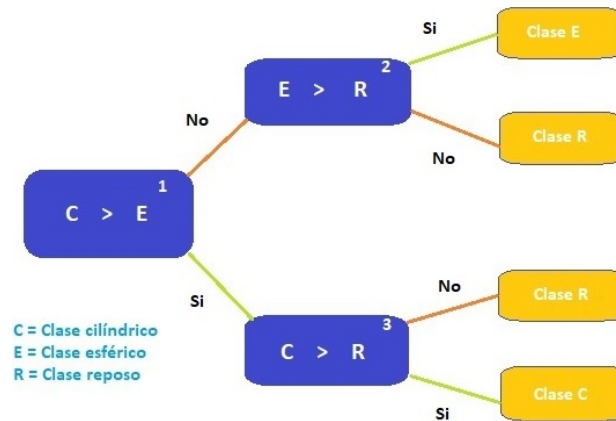


Figura 5 Diagrama de las tres condiciones que forman el árbol de decisión.

Circuito de control para accionar el agarre

El movimiento de la mano robótica se realizó por medio de cinco servomotores alimentados con una fuente de poder externa, se utilizó una placa Arduino UNO, los motores se conectaron en las salidas digitales 3, 5, 6, 10 y 11, se utilizó modulación por ancho de pulso controlar la posición del servomotor y realizar el agarre estimado por la red neuronal en base a la señal EMG adquirida.

Métricas de desempeño de la red neuronal

La validación de la red neuronal calculó la especificidad, sensibilidad, valor predictivo negativo y valor predictivo positivo a los resultados obtenidos en la salida de las redes neuronales. Para estas pruebas fue necesario obtener una matriz con los verdaderos positivos y verdaderos negativos, falsos positivos y falsos negativos. Se calculó la sensibilidad (probabilidad de clasificar correctamente), especificidad (capacidad de clasificar los movimientos fuera del agarre), el valor predictivo positivo (probabilidad de que el algoritmo clasifique un agarre realizado), valor predictivo negativo (probabilidad clasificar un agarre diferente al realizado), ecuaciones 5 a 8 respectivamente.

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad (5)$$

$$\text{Especificidad} = \frac{VN}{VN + FP} \quad (6)$$

$$VPP = \frac{VP}{VP + FP} \quad (7)$$

$$VPN = \frac{VN}{VN + FN} \quad (8)$$

3. Resultados

Ensamble de la mano robótica impresa en 3D

Se imprimieron en material PLA las partes de la mano robótica y se ensamblaron. Se probó su funcionalidad mecánica y se conectaron los servomotores de posición MG996R. Se realizó un programa en LabVIEW para accionar los servomotores mediante la señal PWM a fin de verificar que se realice el agarre cilíndrico, esférico y estado de reposo de la mano robótica.

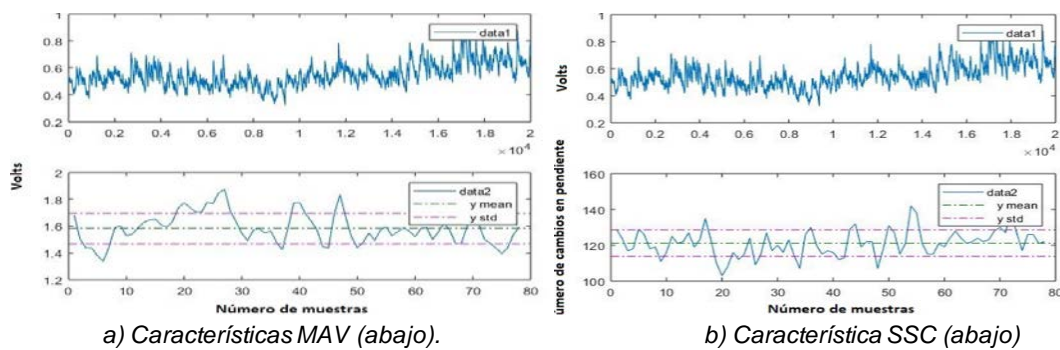
Adquisición de las señales EMG

Se realizó un programa en LabVIEW para adquirir las señales EMG con el método descrito en la sección anterior. La figura 6 muestra 20,000 muestras de la señal EMG del músculo flexor de los dedos para el agarre cilíndrico, registrada durante 10 segundos.

Extracción de las características

La extracción de características: valor medio absoluto (MAV), integral del electromiograma (IEMG), número de cambios de signo de la pendiente (SSC) y longitud de onda (WL) de la señal EMG, se realizó como se describe anteriormente en la sección métodos. Se elaboró un programa en Matlab versión R2017b para leer las señales de la base de datos y calcular las características en la fase de entrenamiento y validación de la red neuronal. En la fase de prueba se leen directamente las señales EMG se obtienen las características y se pasa a la red neuronal. En la figura 6a se muestra una gráfica de la señal activa del músculo flexor

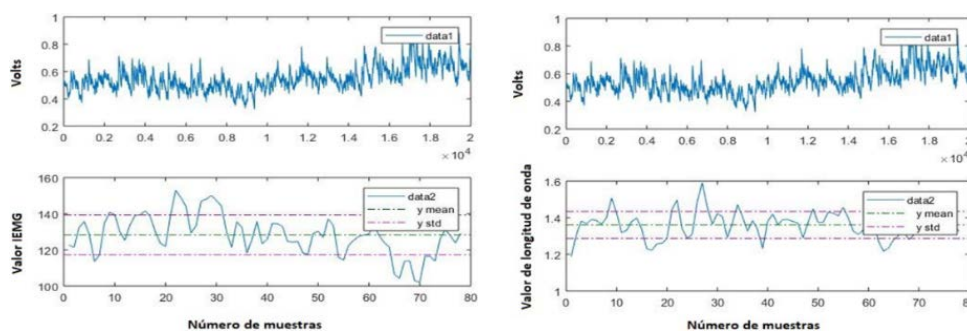
del agarre cilíndrico original y la gráfica de la característica MAV, se obtuvo una media de 1.583 V en el valor absoluto medio (línea verde) y una desviación estándar de ± 0.115 V (líneas moradas). En la figura 6b se observa una gráfica de la señal del músculo flexor de los dedos para el agarre cilíndrico y una gráfica con la característica cambios de signo de la pendiente, se obtuvo una media de 121.2 cambios en la pendiente y una desviación estándar de ± 7.415 cambios en la pendiente. La figura 7a muestra una gráfica de la señal del músculo flexor para el agarre cilíndrico y la característica integral del electromiograma. Se calculó una media de 128.3 y una desviación estándar de ± 10.99 . La figura 7b muestra la señal EMG del músculo flexor de los dedos del agarre cilíndrico, la característica longitud de onda, la media de la longitud de onda de 1.36 y desviación estándar de ± 0.0737 .



a) Características MAV (abajo).

b) Característica SSC (abajo)

Figura 6 Señal EMG, características MAV y SSC.



a) Característica IEMG (abajo)

b) Característica WL (abajo)

Figura 7 Señal EMG, característica IEMG y WL.

Modelo de red neuronal

Para la clasificación de la señal EMG se implementaron dos arquitecturas de red neuronal descritas anteriormente en la sección métodos.

La primera arquitectura está integrada por 4 neuronas de entrada, una capa oculta de 40 neuronas y una capa de salida de 3 neuronas, figura 8. La entrada son los vectores de características extraídas de la señal EMG (MAV; IEMG; SSC; WL) y la salida el vector que representan el agarre esférico, cilíndrico y reposo. Los resultados se muestran en la matriz de confusión, figura 9.




Figura 8 Arquitectura del modelo de red neuronal de 40 neuronas en la capa oculta.



Figura 9 Matriz de confusión arquitectura de red de 40 neuronas en la capa oculta.

La etapa de entrenamiento obtuvo un 83.9, 84.6 y 99.9 para en la clasificación del agarre esférico (clase 1), agarre cilíndrico (clase 2) y el reposo (clase 3) respectivamente. Los resultados la matriz de confusión de validación y prueba se

mantuvieron por encima del 80%. El error obtenido en el entrenamiento, se muestra el gradiente obtenido en la época 30 con un valor de 0.0113.

La segunda arquitectura de red neuronal está integrada por 8 neuronas de entrada, una capa oculta de 80 neuronas y una capa de salida de 3 neuronas, figura 10. La entrada son los vectores de características (MAV; IEMG; SSC; WL) extraídas de la señal EMG del músculo flexor, cuatro características de la señal EMG del músculo extensor y salidas para el agarre esférico, cilíndrico y reposo. La RN se entrenó en 30 épocas con un gradiente del error del 0.0114, la figura 11 muestra la matriz de confusión.




Figura 10 Arquitectura del modelo de red neuronal de 80 neuronas en la capa oculta.



Figura 11 Matriz de confusión de la red neuronal de 80 neuronas en la capa oculta.

Para la etapa de entrenamiento y validación obtuvo valores por encima de 91%, en la etapa de prueba, la clasificación obtuvo 94.1% (clase 1) para el agarre esférico, 93.8% para el agarre cilíndrico y 100% para mano en reposo, mejorando los resultados obtenidos en el primer modelo. Se obtuvo un gradiente de error de 0.0084 hasta la época 49 donde la prueba presentó 6 fallas consecutivas en la prueba de validación.

Circuito de control para accionar el agarre

Los servomotores pueden controlar el ángulo de giro del motor basándose en el ancho del pulso. Un programa en Matlab envía al microcontrolador Arduino UNO la instrucción de ángulo de giro; un valor de 0 para girar a 0° y un valor de 1 para girar a 180°, en la tabla 1 se muestra un ejemplo de los valores enviados al puerto digital para la modulación PWM se utilizó un servomotor extra fijado a la base del dedo medio para afianzar el agarre esférico; el agarre cilíndrico y el estado reposo basto con el control de 5 servomotores. Se utilizó un microcontrolador Arduino Uno para accionar los motores, ver figura 12.




Figura 12 Conexión de los servomotores en la placa Arduino UNO.

Tabla 1 Acción de servomotor para mover los dedos de la mano robótica.

No. Servomotor	Nombre del dedo	Reposo Valor ángulo	Agarre cilíndrico Valor ángulo	Agarre esférico Valor ángulo	Arduino Pin Digital
s	Índice	0.3 54°	1 180°	0.9 162°	D3
s1	Pulgar	0.3 54°	1 180°	0.7 126°	D5
s2	Medio 1	0.4 72°	0.4 72°	0.9 162°	D6

Validación del algoritmo

La validación del algoritmo de la red neuronal se utilizó el 10% de las señales, mismas que no fueron utilizadas en el entrenamiento, ni prueba de la red neuronal. Los datos utilizados fueron señales EMG de agarre cilíndrico, agarre esférico y reposo. En tabla 2 se visualizan los resultados obtenidos por las neuronas de salida de los dos modelos de redes neuronales para la clasificación de agarres. Se observa que los dos modelos de redes no presentan problemas para clasificar la intención del agarre esférico con probabilidades de clasificación por encima del 80%.

Tabla 2 Resultados de la predicción de agarres obtenidos por los dos modelos de red.

Entrada	Red con 40 neuronas ocultas			Red con 80 neuronas ocultas		
	Esférico	Cilíndrico	Reposo	Esférico	Cilíndrico	Reposo
Cil. 1	0.4299	0.5700	0	0.2799	0.7200	0
Cil. 2	0.5072	0.4928	0	0.6623	0.3365	0
Cil. 3	0.3433	0.6567	0	0.7162	0.2837	0.0012
Cil. 4	0.4444	0.5555	0	0.2867	0.7133	0
Cil. 5	0.3755	0.6245	0	0.3715	0.6284	0
Esf. 1	0.9874	0.0126	0	0.9922	0.0076	0
Esf. 2	0.9841	0.0158	0	0.9914	0.0086	0
Esf. 3	0.9863	0.0135	0	0.9627	0.0373	0
Esf. 4	0.9931	0.0066	0	0.9495	0.0498	0
Esf. 5	0.9900	0.0096	0	0.9958	0.0042	0

Los resultados del agarre cilíndrico mostraron que la red con 80 neuronas obtuvo mayores tasas de probabilidad al compararse contra la red con 40 neuronas, sin embargo, la red de 80 neuronas presenta dos fallas en la clasificación del agarre cilíndrico clasificándolo como agarre esférico. En cambio, la red con 40 neuronas ocultas presenta una falla en la clasificación del agarre cilíndrico. Se decidió trabajar con el primer modelo debido a que el objetivo no es evaluar la calidad de predicción de la red neuronal sino escoger la red que presente menos errores, se decidió utilizar un árbol de decisiones para asegurar la simulación del agarre esférico y el agarre cilíndrico sobre la mano robótica.

Se realizó la validación de las dos redes neuronales utilizadas calculando la especificidad, la sensibilidad, el valor predictivo positivo y el valor predictivo negativo de acuerdo con los resultados obtenidos en la predicción de agarres, ver tabla 3.

Tabla 3 Especificidad, sensibilidad, *VPP* y *VPN* de los dos modelos de redes utilizados.

Modelo red	Especificidad	Sensibilidad	<i>VPP</i>	<i>VPN</i>
1	95.02%	90.01%	90.01%	95.02%
2	90.00%	80.03%	80.03%	90.00%

Se observa un porcentaje de especificidad del 95.02% para el modelo uno y un valor de especificidad del 90.00% en el modelo dos, por lo que el modelo uno tiene mejor capacidad de clasificar correctamente cuando no está presente el agarre. La mejor sensibilidad la obtuvo el primer modelo con un valor de 90.01% contra el valor del segundo modelo de 80.03% por lo que el primer modelo tiene mejor capacidad de clasificar el agarre cuando está presente. El segundo modelo presentó valores distintos a los resultados de la matriz de confusión debido a un problema llamado sobre entrenamiento que consiste en que la red funciona excelente para los patrones con los que fue entrenada, pero presenta poca capacidad de reaccionar favorablemente a patrones con los que no fue entrenada.


En la tabla 4 se muestran los resultados que se obtuvieron con la predicción de la red neuronal y la salida obtenida en el árbol de decisión para el control de los servomotores.

Tabla 4 Resultados de prueba de predicción de la red neuronal y del árbol de decisión.

Agarre de entrada en la red	Predicción de red neuronal artificial			Árbol de decisión
	Predicción agarre esférico	Predicción agarre cilíndrico	Predicción Reposo	Salida en actuadores
Cilíndrico 1	0.4299	0.5700	0	Agarre cilíndrico
Cilíndrico 2	0.3433	0.6567	0	Agarre cilíndrico
Cilíndrico 3	0.4444	0.5555	0	Agarre cilíndrico
Esférico 1	0.9863	0.0135	0	Agarre esférico
Esférico 2	0.9931	0.0066	0	Agarre esférico
Esférico 3	0.9900	0.0096	0	Agarre esférico

Finalmente se desarrolló un programa en LabVIEW para adquirir en tiempo real la señal de EMG de un sujeto conectando los electrodos, después de adquirir la señal se calcularon las características (MAV; IEMG; SSC; WL), se alimentaron los vectores de características al modelo 1 de red neuronal, el vector de salida evaluó con el árbol de decisión para finalmente accionar los servomotores que realizan el movimiento en la mano robótica. En la figura 13a se observa la mano robótica

realizando el agarre esférico sobre una manzana. En la figura 13b observa la mano robótica realizando el agarre cilíndrico para sujetar una botella de agua.



a) Agarre esférico

b) Agarre cilíndrico

Figura 13 Funcionalidad de la mano.

4. Discusión

En este trabajo se comparó especificidad de dos modelos de red neuronal para clasificar los agarres de mano: agarre esférico, agarre cilíndrico y mano en reposo. Las señales EMG se obtuvieron utilizando los sensores Myoware en el músculo flexor y extensor del antebrazo, se calcularon las características (MAV; IEMG; SSC; WL), se alimentaron al modelo 1 de red neuronal (descrito en la sección de resultados), los valores de las tres neuronas de salida se evaluaron mediante un el árbol de decisión, cuya salida activa un código para accionar los servomotores y realizar el movimiento en la mano robótica estimado por la red neuronal.

El primer modelo fue compuesto por 4 neuronas en la capa de entrada, 40 neuronas en la capa oculta y 3 neuronas en la capa de salida, obtuvo un gradiente de error de 0.01138. Clasificó el agarre esférico con un valor porcentual del 83.9%, se obtuvo un porcentaje del 84.6% en la clasificación del agarre cilíndrico y un valor de 99.9% en la clasificación del estado de reposo.

El segundo modelo compuesto por 8 neuronas en la capa de entrada, 80 neuronas en la capa oculta y 3 neuronas en la capa de salida obtuvo un gradiente de error de 0.008447. Logró un valor porcentual de clasificación del 92.9% en la predicción del agarre esférico, se obtuvo un porcentaje del 91.7% en la clasificación del agarre cilíndrico y un valor de 100% clasificando el estado de reposo. El segundo modelo obtuvo mejores resultados; sin embargo, al probar con nuevas señales EMG

presentó el problema de sobre entrenamiento, que es la incapacidad de reaccionar favorablemente a patrones con los que no fue entrenada. Se decidió utilizar el primer modelo de red neuronal con un algoritmo de árbol de decisiones debido a los valores de especificidad obtenidos del 95%, sensibilidad 90%, verdaderos positivos 90% contra 90%, 80% y 80% respectivamente del modelo 2.

El primer modelo tiene mejor capacidad de clasificar el agarre cuando está presente una señal EMG desconocida para la red. El segundo modelo presentó valores distintos a los resultados de la matriz de confusión debido a un problema llamado sobre entrenamiento que consiste en que la red funciona excelente para los patrones con los que fue entrenada, pero presenta poca capacidad de reaccionar favorablemente a patrones con los que no fue entrenada. Se cumplió el objetivo al adquirir una señal EMG, clasificarla con un algoritmo de red neuronal y generar el tipo de agarre en una prótesis de mano robótica, aun cuando las pruebas se realizaron en sujetos sanos en esta etapa de la investigación.

5. Conclusiones

El trabajo presentado tiene como objetivo clasificar la señal EMG generada al realizar el agarre cilíndrico, agarre esférico o mano en reposo mediante un algoritmo de estimación de movimiento usando una red neuronal y accionar un conjunto de servomotores en una mano robótica impresa en 3D para realizar el movimiento. Se cumplieron las expectativas debido a que la mano robótica realiza el movimiento estimado por la red neuronal en función de las cuatro características obtenidas de la señal EMG. En un trabajo previo [Gutiérrez, 2017] se trabajó en la clasificación de la intención de movimiento a partir de las señales de EMG, sin llegar a realizar el movimiento en la mano robótica. En una etapa posterior del proyecto se pretenden agregar otros tipos de agarre y características que permitan estimar el movimiento y replicarlo en la prótesis robótica de mano.

6. Bibliografía y Referencias

- [1] Abu M. A., Rosleesham S., Suboh M. Z., Yid M. S., Kornain Z., Fauzani N., (2020). Classification of EMG signal for multiple hand gestures based on

- neural network, *Indonesian Journal of Electrical Engineering and Computer Science*, Vol. 17, No. 1, pp. 256~263, ISSN: 2502-4752, DOI: 10.11591/ijeecs.v17.i1.pp256-263.
- [2] Artameeyanant P., Sultornsanee S., and Chamnongthai K., Classification of electromyogram using weight visibility algorithm with multilayer perceptron neural network, *Proc. 2015-7th Int. Conf. Knowl. Smart Technol. KST 2015*, pp. 190–194, 2015.
- [3] Caesarendra W., Lekson S. U., Mustaqim K. A., Winoto A. R., and Widyotriatmo A., A classification method of hand EMG signals based on principal component analysis and artificial neural network, *2016 Int. Conf. Instrumentation, Control Autom.*, no. 3, pp. 22–27, 2016.
- [4] Calderon Cordova C., Ramirez C., Barros V., Quezada Sarmiento P. A., and Barba Guaman L., EMG signal patterns recognition based on feedforward Artificial Neural Network applied to robotic prosthesis myoelectric control, *FTC 2016 - Proc. Futur. Technol. Conf.*, no. December, pp. 868–875, 2017.
- [5] Guitiérrez A., Desarrollo de un algoritmo predictivo que permite clasificar los agarre: cilíndrico, esférico y de puño, a partir de una señal electromiográfica, *Tesis de la Universidad Autónoma de Ciudad Juárez*, 2017.
- [6] Iqbal O., Fattah S. A. and Zahin S., Hand movement recognition based on singular value decomposition of surface EMG signal, *2017 IEEE Region 10 Humanitarian Technology Conference (R10-HTC)*, 2017, pp. 837-842, doi: 10.1109/R10-HTC.2017.8289085.
- [7] Inmoov, Hand and forarm assembly 3D view, (2021): <http://inmoov.fr/build-yours/hand-and-forarm-assembly-3d-views/>.