

Clasificación de gestos de la mano basado en polinomios Anidados por medio de EMG

Classification of hand gestures based on nested polynomials by means of EMG

E. Valdés-Rincón ^{a,*}, O.A. Domínguez-Ramírez ^b, L.R. Lechuga-Gutiérrez ^c

^aEscuela Preparatoria Número 3, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

^bCentro de Investigación en Tecnologías de Información y Sistemas, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

^cCRIP, CONACYT, Ciudad de México, México

Resumen

En el documento se presenta una clasificación de diferentes tipos de gestos de la mano por medio de señales mioeléctricas (EMG), las cuales serán procesadas por un filtro tipo Kernel Gaussiano, para su posterior clasificación utilizando del método de Polinomios Anidados. Se tiene como resultados del proceso de clasificación la correcta identificación de un solo gesto, así como la clasificación de múltiples gestos a la vez. Luego de tener los resultados de la clasificación podrán ser implementados en diversas aplicaciones posteriormente.

Palabras Clave: Biomecánica, electromiografía, procesamiento de señales mioeléctricas, algoritmos de clasificación.

Abstract

The document presents a classification of different types of hand gestures by means of myoelectric signals (EMG), which will be processed by a Kernel Gaussian type filter, for subsequent classification using the Nested Polynomials method. The results of the classification process are the correct identification of a single gesture, as well as the classification of multiple gestures at the same time. After having the results of the classification, they can be implemented in various applications later.

Keywords: Biomechanics, electromyography, myoelectric signal processing, classification algorithms.

1. Introducción

Se ha estudiado la obtención de las señales mioeléctricas (EMG) relacionadas con el miembro superior por medio de diferentes dispositivos, uno de ellos es el brazalete de control de gestos MYO. Por medio de los gestos preestablecidos del brazalete se ha controlado robots manipuladores para tareas dentro de su espacio de trabajo (de los Santos Bojórquez, 2015). Algunos estudios enlazan las señales EMG con exoesqueletos de articulaciones (Campoverde and Nacipucha, 2016) o el miembro completo (Villeda et al., 2013) para la fácil movilidad del miembro superior. Otras aplicaciones tienen que ver con el desarrollo de prótesis de la mano para la representación de movimientos e implantación en pacientes con amputación como en (Villamil and Sanchez, 2018), (Miguel et al., 2016) y (J..Brazeiro et al., 2015). Por otro lado, se cuenta con estudios relacionados con el procesamiento y caracterización de las

señales EMG para una posterior manipulación de diferentes dispositivos como en (J..Brazeiro et al., 2015), (Guachamin, 2017) y (Gutiérrez et al., 2018). Se han aplicado otras implementaciones para detección de gestos nuevos como en (Chimal, 2017); los cuales son utilizados en algunos dispositivos robóticos. El objetivo de esta investigación es validar un proceso de filtrado e identificar una clasificación que permitan la correcta caracterización de diferentes gestos de la mano. De esta forma, se realice la aplicación de un filtro compuesto por una función Kernel Gaussiana como el aplicado en (A.Mohammed et al., 2011) para las señales EMG obtenidas por medio del brazalete de control de gestos Myo, para su posterior clasificación por medio del método de Polinomios Anidados como herramienta de caracterización de gestos. Se logró validar la utilización de una función Kernel Gaussiana como filtro de señales EMG, así como resultados favorables en la clasificación de gestos al identificar uno o múltiples gestos en una secuencia, siendo la base

*Autor para correspondencia: elizabeth.valdez@uaeh.edu.mx

Correo electrónico: elizabeth.valdez@uaeh.edu.mx (Elizabeth Valdés-Rincón), omar@uaeh.edu.mx (Omar Arturo Domínguez-Ramírez), luis.lechuga@conacyt.mx (Luis Rey Lechuga-Gutiérrez).

Historial del manuscrito: recibido el 08/11/2022, última versión-revisada recibida el 08/11/2022, aceptado el 09/11/2022, publicado el 11/11/2022. **DOI:** <https://doi.org/10.29057/icbi.v10iEspecial5.10204>



para futuras aplicaciones de dichas señales. Además, se sienta la base de un proceso que permite caracterización de aspectos de las señales EMG.

2. Marco teórico

Se presenta información teórica importante para el desarrollo de la investigación realizada, misma que permite dar un panorama de lo realizado durante la misma.

2.1. Filtro Kernel Gausseano

Las señales mioeléctricas (EMG) empleadas durante las pruebas de caracterización se someten a un proceso de filtrado, mismo que se realizó por medio de una función Kernel Gaussiana (A.Mohemmed et al., 2011). A continuación, se presenta una serie de definiciones para la construcción del filtro empleado.

Definición: Sea $I \in [0, N] \subset \mathbb{Z}$ y $\Theta(I)$ una función Heaviside. La **función Kernel Gaussiana** $\alpha : [0, N] \rightarrow \mathbb{R}$ esta descrita por:

$$\alpha(I) = \frac{Ie^{1-I/T_s}}{T_s} \Theta(I) \quad (1)$$

donde $\alpha_{max} = \alpha(T_s)$. Con T_s tal que $T_s \ll N$. Además $\alpha(I)$ cumple

$$\lim_{I \rightarrow \infty} \alpha(I) = 0$$

Definición: Sea $I \in [0, N] \subset \mathbb{Z}$, $F(k) \in \mathbb{R}$ el valor de una señal en el instante k y $|F(k)|$ el valor absoluto de la función $F(k)$ con $k = 0, 1, 2, \dots, N$. Se define a la función $\beta(I)$ como:

$$\beta(I) = |F(k)|\alpha(I) \quad (2)$$

con $\beta_{max} = \beta(T_s) = |F(k)|$.

Definición: Sea $\alpha(I)$ la función Kernel Gaussiana, $\{F(k)\} \subset \mathbb{R}$ el conjunto de valores de una señal F y $|F(k)|$ valor absoluto de $F(k)$ con $k = 0, 1, 2, \dots, N$. La familia de $\beta(I)$ esta descrita por:

$$\begin{aligned} \beta(0) &= |F(0)|\alpha(k) \\ \beta(1) &= |F(1)|\alpha(k-1) \\ \beta(2) &= |F(2)|\alpha(k-2) \\ \beta(3) &= |F(3)|\alpha(k-3) \\ &\vdots \\ \beta(N) &= |F(N)|\alpha(k-N) \end{aligned} \quad (3)$$

Para la implementación del filtro se aplica la superposición de las funciones $\beta(I)$ con $I = 0, 1, 2, \dots, N$ representada por (4). La señal obtenida con la función SB es la sometida al proceso de clasificación.

$$SB = \sum_{i=1}^N \beta(i) \quad (4)$$

El valor absoluto de la función $F(k)$ en la familia de $\beta(I)$ permite no perder información durante el filtrado; esto debido a que la señal final es una suma de funciones cuya amplitud es directamente proporcional al valor recibido por el sensor, al contar con valores con amplitud negativa produciría una interpretación errónea de SB .

2.2. Polinomios Anidados

La clasificación se basa en el método de Polinomios Anidados, mismas que se ajusta para múltiples dimensiones por una función polinomial con un conjunto de parámetros. Iniciando con la descripción del proceso de ajuste en una dimensión. Dado un conjunto de datos (x_i, y_i) con $\{x, y\} \in \mathbb{R}$, se desea encontrar una función $y = p(x)$ que mejor se aproxime a esos datos; ahora se propone un polinomio de grado n de la forma:

$$p(x) = a_0 + a_1x + a_2x^2 + a_3x^3 + \dots + a_nx^n \quad (5)$$

Una vez establecido el polinomio se determinan sus parámetros minimizando una función de costo, la cual se propone con la forma:

$$C = \sum_{i=0}^m (f(x_i) - y_i)^2 / 2 \quad (6)$$

$$C = \sum_{i=0}^m (a_0 + a_1x_i + a_2x_i^2 + a_3x_i^3 + \dots + a_nx_i^n - y_i)^2 / 2 \quad (7)$$

Derivando parcialmente a C para obtener la tasa de cambio de la función de costo con respecto a cada una de las variables $(a_0, a_1, a_2, a_3, \dots, a_n)$:

$$\begin{aligned} \frac{\partial C}{\partial a_0} &= \sum_{i=0}^m (f(x_i) - y_i) \cdot 1 \\ \frac{\partial C}{\partial a_1} &= \sum_{i=0}^m (f(x_i) - y_i) \cdot x_i \\ &\vdots \\ \frac{\partial C}{\partial a_n} &= \sum_{i=0}^m (f(x_i) - y_i) \cdot x_i^n \end{aligned} \quad (8)$$

Obteniendo un sistema de $n + 1$ ecuaciones, con $n + 1$ incógnitas. Y proponiendo:

$$\begin{aligned} c_k &= x_0^k + x_1^k + x_2^k + x_3^k + \dots + x_n^k \\ &\text{con } (k = 0, \dots, 2n) \\ t_k &= x_0^k y_0 + x_1^k y_1 + x_2^k y_2 + x_3^k y_3 + \dots + x_n^k y_n \\ &\text{con } (k = 0, \dots, n) \end{aligned} \quad (9)$$

así el sistema de $n + 1$ ecuaciones

$$\begin{aligned} a_0c_0 + a_1c_1 + a_2c_2 + \dots + a_n c_n &= t_0 \\ a_1c_1 + a_2c_2 + a_3c_3 + \dots + a_{n+1}c_{n+1} &= t_1 \\ a_2c_2 + a_3c_3 + a_4c_4 + \dots + a_{n+2}c_{n+2} &= t_2 \\ &\vdots \\ a_n c_n + a_{n+1}c_{n+1} + a_{n+2}c_{n+2} + \dots + a_{2n}c_{2n} &= t_n \end{aligned} \quad (10)$$

representa el sistema de ecuaciones matricial:

$$\begin{bmatrix} c_0 & c_1 & c_2 & \dots & c_n \\ c_1 & c_2 & c_3 & \dots & c_{n+1} \\ c_2 & c_3 & c_4 & \dots & c_{n+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ c_n & c_{n+1} & c_{n+2} & \dots & c_{2n} \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix} = \begin{bmatrix} t_0 \\ t_1 \\ t_2 \\ \vdots \\ t_n \end{bmatrix} \quad (11)$$

representando el arreglo de forma matricial:

$$Ck_{[n \times n]} A_{[n \times 1]} = Tk_{[n \times 1]} \quad (12)$$

donde Ck es la matriz de los coeficientes, en la que intervienen todos los n -parámetros de la variable x , Tk es la columna de términos constantes que contiene las salidas deseadas, y A

la columna de las incógnitas constantes a encontrar. Si el determinante de Ck no es nulo, existe una matriz inversa Ck^{-1} ; resolviendo el sistema de ecuaciones:

$$A = Ck^{-1}Tk \quad (13)$$

Para extender de una dimensión a las dimensiones d , cada conjunto de soluciones ($A_{[n \times 1]}$) se propone como un vector fila en una matriz de Vandermonde en modo n -dimensional (matriz de Vandermonde anidada), es decir, para un campo escalar d -dimensional (con un polinomio de grado n para cada dimensión), la matriz polinomial anidada asociada es:

$$MV = \begin{pmatrix} p_{y1} \cdot 1 & p_{y1} \cdot x_1 & p_{y1} \cdot x_1^2 & \cdots & p_{y1} \cdot x_1^n \\ p_{y2} \cdot 1 & p_{y2} \cdot x_2 & p_{y2} \cdot x_2^2 & \cdots & p_{y2} \cdot x_2^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ p_{yk} \cdot 1 & p_{yk} \cdot x_k & p_{yk} \cdot x_k^2 & \cdots & p_{yk} \cdot x_k^n \end{pmatrix} \quad (14)$$

donde k es el k -ésimo conjunto de entradas, p_{yi} es el i -ésimo vector de la matriz de Vandermonde para la entrada y , es decir:

$$p_{yi} = \begin{bmatrix} p_{zi} \cdot 1 & p_{zi} \cdot y_i & p_{zi} \cdot y_i^2 & \cdots & p_{zi} \cdot y_i^n \end{bmatrix} \quad (15)$$

para lo cual p_{zi} representa el i -ésimo vector de la matriz de Vandermonde de la dimensión z , así sucesivamente hasta terminar con las m dimensiones. Una vez completa la matriz de Vandermonde m -dimensional, se puede aplicar el método de mínimos cuadrados recursivo para resolver el sistema de ecuaciones.

Para evaluar la arquitectura de los polinomios anidados, se recomienda utilizar el método n -dimensional de Horner extendido a polinomios anidados, la razón de esto es que, al anidar ecuaciones, la información se pierde porque la solución de los polinomios de dimensiones más profundas alimenta polinomios de capas superiores perdiendo información por el redondeo que realiza el software, provocando una acumulación del error que a su vez provoca que la solución diverja de la real.

El algoritmo de Horner trata de evaluar un polinomio de la forma más eficiente; si se tiene la ecuación:

$$p_x = a_n x^n + a_{n-1} x^{n-1} + \cdots + a_1 x + a_0 \quad (16)$$

La forma más eficiente de evaluar un polinomio según el método de Horner es:

$$H(x, \bar{a}) = (((a_n x + a_{n-1})x + a_{n-2})x + \cdots + a_1 x) + a_0 \quad (17)$$

Dado que el concepto de polinomios anidados hace que a_i sea un nuevo polinomio. Para la primera dimensión se tendrá $n + 1$ polinomios, donde n es el grado del polinomio de la primera dimensión; así sucesivamente para las dimensiones posteriores. Se puede proponer una expresión general, por ejemplo para tres dimensiones (x, y, z), como:

$$p(x, y, z) = H(H(H(z, \bar{a}), y), x) \quad (18)$$

Con \bar{a} como el vector de constantes que resuelven el polinomio anidado.

3. Clasificación de gestos de la mano

Establecida la parte teórica para la clasificación de las señales EMG que se implementará, proseguiremos con la clasi-

ficación de gestos de la mano por medio del método de polinomios anidados. Para el proceso es importante considerar la calibración del electromiógrafo de superficie el brazalete de control de gestos Myo.

3.1. Calibración del electromiógrafo de superficie Myo

Considerando la biomecánica del miembro superior se establece el posicionamiento de la interfaz Myo; de tal forma que se estandarice su ubicación sobre el antebrazo para los experimentos. La pulsera Myo se coloca en el antebrazo aproximadamente a tres centímetros de la articulación del codo Y se alinea el icono del brazalete con el dedo pulgar [observar en la figura (1)].



Figura 1: Colocación de la pulsera Myo en el antebrazo.



Figura 2: Orden de los sensores de la interfaz Myo (Anillo et al., 2017)

La relación de las columnas de la matriz guardada con respecto a los ocho sensores en la estructura de la pulsera se muestra de forma física en la Figura (2). Con base a la colocación planteada se relacionan los músculos implicados en cada uno de los sensores en la Tabla (1); los cuales se encuentran asignados en una forma aproximada, esto debido a que las señales EMG tomadas por el brazalete de control de gesto Myo son superficiales. Es muy importante que el orden de los sensores sea respetado para todas las pruebas de clasificación de gestos de la mano.

Tabla 1: Músculos relacionados con los sensores EMG.

Sensor	Músculo
Sensor 1	Branquiorradiar
Sensor 2	Branquiorradiar
Sensor 3	Flexor superficial de los dedos
Sensor 4	Flexor radial Plonador
Sensor 5	Cubital Posterior
Sensor 6	Extensor de los dedos
Sensor 7	Aductor de la mano
Sensor 8	Branquiorradiar

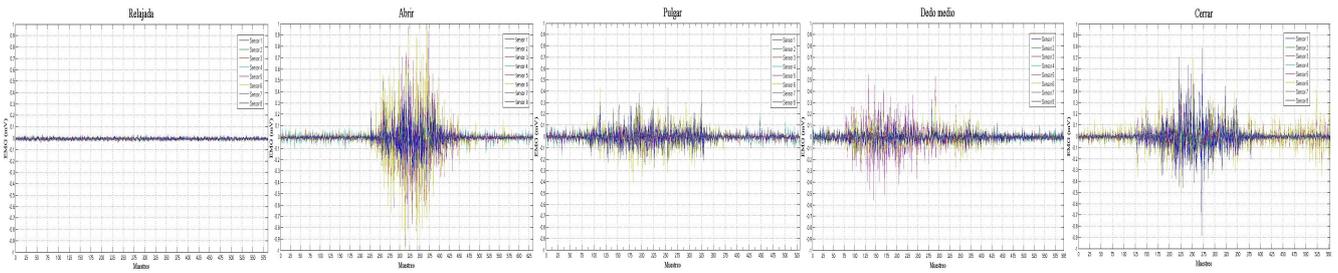


Figura 4: Señales EMG de los 8 sensores para los gestos relajada, abierta, dedo medio , pulgar y cerrada.



Figura 3: Gestos de la mano.

3.2. Descripción de gestos para pruebas experimentales

Los gestos o acciones considerados para la toma de muestras se observan en la figura (3); los cuales son mano relajada, mano abierta, dedo medio, dedo pulgar y mano cerrada (puño). La mano relajada será considerada como la referencia del miembro superior sin una actividad de movimiento cuyos datos permitan establecer un umbral para el resto de acciones. A continuación, se da una descripción de los gestos:

- **Mano relajada:** se considera la mano relajada si se encuentra sin realizar ningún tipo de movimiento o esfuerzo, permitiendo tomarla como referencia para identificar los momentos en los cuales los músculos no estén haciendo algún otro gesto.
- **Mano abierta:** en este gesto la mano se encuentra completamente abierta, sin hacer sobre esfuerzos al momento de abrirla.
- **Dedo medio:** la mano una vez cerrada se extenderá el dedo medio, de tal forma que se encuentra alineado con el antebrazo sin generar sobre esfuerzos.
- **Dedo pulgar:** con la mano cerrada se extenderá el dedo pulgar, de tal forma que se encuentra perpendicular al resto de puño sin generar sobre esfuerzos.
- **Mano cerrada:** consiste en cerrar la mano en forma de puño sin generar sobre esfuerzo los músculos para cerrar la mano.

Establecidos los gestos para la toma de muestras, se procede a la obtención de las señales por medio de la plataforma de MATLAB. Una vez obtenida la información se prosigue al proceso de filtrado basado en la función Kernel Gaussiana de las señales obtenidas (figura (4)) para su posterior clasificación.

3.3. Procesamiento de las señales EMG

El filtro establecido con la función Kernel Gaussiana es aplicado por separado a cada uno de los ocho sensores mieléctricos en cada gesto obteniendo ocho señales filtradas. El resultado de la señal procesada de una de las muestras, para cada gesto, bajo el filtro se observa en la figura(5).

Ahora bien, como se mencionó la mano relajada nos permite establecer un umbral de comparación para que en los datos no se consideren los momentos en que los músculos no se encuentren trabajando; la figura (6) muestra un ejemplo de dicha depuración para cada uno de los cuatro gestos restantes. Se logró observar que los máximos se mantienen; además, de que el mínimo pasa a ser el valor del umbral que se establece. Se nota que secciones donde la función es creciente significa que en instantes anteriores al actual se cuenta con actividad, mientras que en las secciones decrecientes implica que la actividad disminuyó o fue nula. Una vez filtradas las señales mioeléctricas obtenidas de la interfaz Myo para cada gesto se realiza la clasificación basada en el método de polinomios anidados para uno y múltiples gestos.

4. Clasificación de un solo gesto

Para la clasificación de un gesto basado en el método de polinomios anidados debe hacerse la construcción de la matriz de correlación para el entrenamiento de los polinomios que permitirán relacionar un sensor S_i (con $i = 1, 2, \dots, 8$) con sus sensores adyacentes. Las ecuaciones se construirán con relación a la dimensión que se desee, esta dimensión determina el

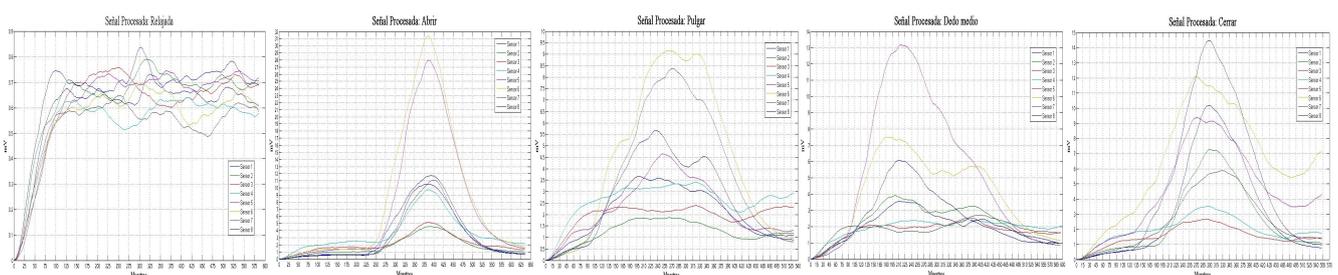


Figura 5: Señal procesada para los ocho sensores de los gestos relajada , abierta , pulgar y cerrada.

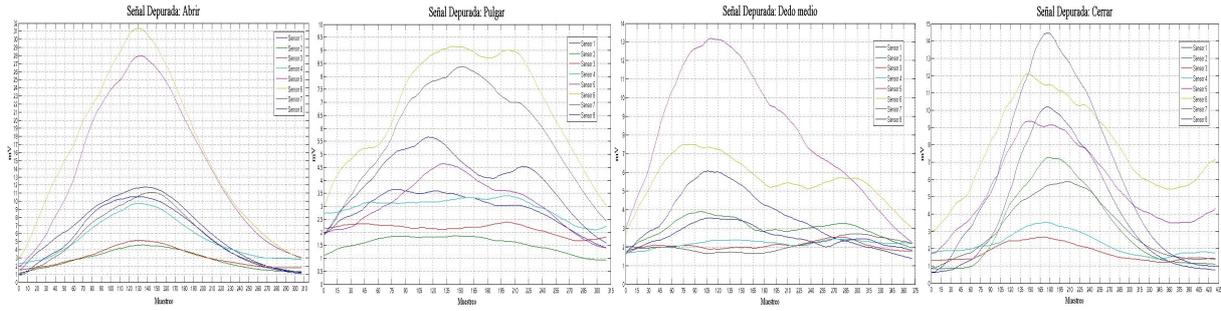


Figura 6: Señal procesada con un umbral para los ocho sensores de los gestos abierta, dedo medio, pulgar y cerrada.

parámetro n del algoritmo, mientras que el grado del polinomio anidado será destacado por $m - 1$. De esta forma se tiene una dimensión $n = 4$ para los resultados que se presentan en la sección actual. Por lo tanto, la estructura de la matriz de correlación para el entrenamiento MCE_i en el sensor S_i está dada en (19):

$$MC_i = [S_{i-2}, S_{i-1}, S_{i+1}, S_{i+2}, S_i] \quad (19)$$

Las matrices MC_i de cada sensor S_i se ingresan al algoritmo de entrenamiento de los polinomios anidados para la obtención de los coeficientes del polinomio resultante para la clasificación del gesto. Donde los datos de entrada son los valores filtrados de los sensores adyacentes al sensores S_i dados por $(S_{i-2}, S_{i-1}, S_{i+1}, S_{i+2})$ y la salida es el valor filtrado de los sensores S_i . De forma desarrollada se obtiene un polinomio dado en (20):

$$P(S_i) = a_0 + a_1S_{i+2} + a_2S_{i+1} + a_3S_{i+1}S_{i+2} + a_4S_{i-1} + a_5S_{i-1}S_{i+2} + a_6S_{i-1}S_{i+1} + a_7S_{i-1}S_{i+1}S_{i+2} + a_8S_{i-2} + a_9S_{i-2}S_{i+2} + a_{10}S_{i-2}S_{i+1} + a_{11}S_{i-2}S_{i+1}S_{i+2} + a_{12}S_{i-2}S_{i-1} + a_{13}S_{i-2}S_{i-1}S_{i+2} + a_{14}S_{i-2}S_{i-1}S_{i+1} + a_{15}S_{i-2}S_{i-1}S_{i+1}S_{i+2} \quad (20)$$

Posteriormente, se crean las matrices de correlación para la evaluación ME_i , las cuales son como en (21):

$$ME_i = [S_{i-2}, S_{i-1}, S_{i+1}, S_{i+2}] \quad (21)$$

Para los resultados que se mostraran a continuación se entrenó el algoritmo de los polinomios anidados con 4 conjuntos de pruebas diferentes, donde se considera una dimensión $n = 4$ y polinomios anidados de grado uno, que tendrán forma desarrollada como en (20) para cada sensor S_i . De donde se obtuvieron los coeficientes para cada sensor mostrados en la Tabla 2.

Al algoritmo de evaluación de los polinomios anidados se ingresaron datos de tres pruebas diferentes entre las cuales una coincide con el gesto entrenado previamente. La figura (7) muestra los resultados de la evaluación para cada uno de los sensores, donde se puede observar de color azul el entrenamiento del polinomio anidado, mientras que de diferente color los gestos evaluados. Se logra observar que en 6 de 8 sensores el polinomio tiene el menor error con respecto a la señal procesada en el transcurso del gesto con el cual fue entrenado el polinomio anidado. Con todo esto, se logra concluir que el algoritmo de los polinomios anidados con la señal procesada nos

permite clasificar un gesto de la mano. Por lo cual, se da paso a la clasificación de múltiples gestos dentro del mismo algoritmo.

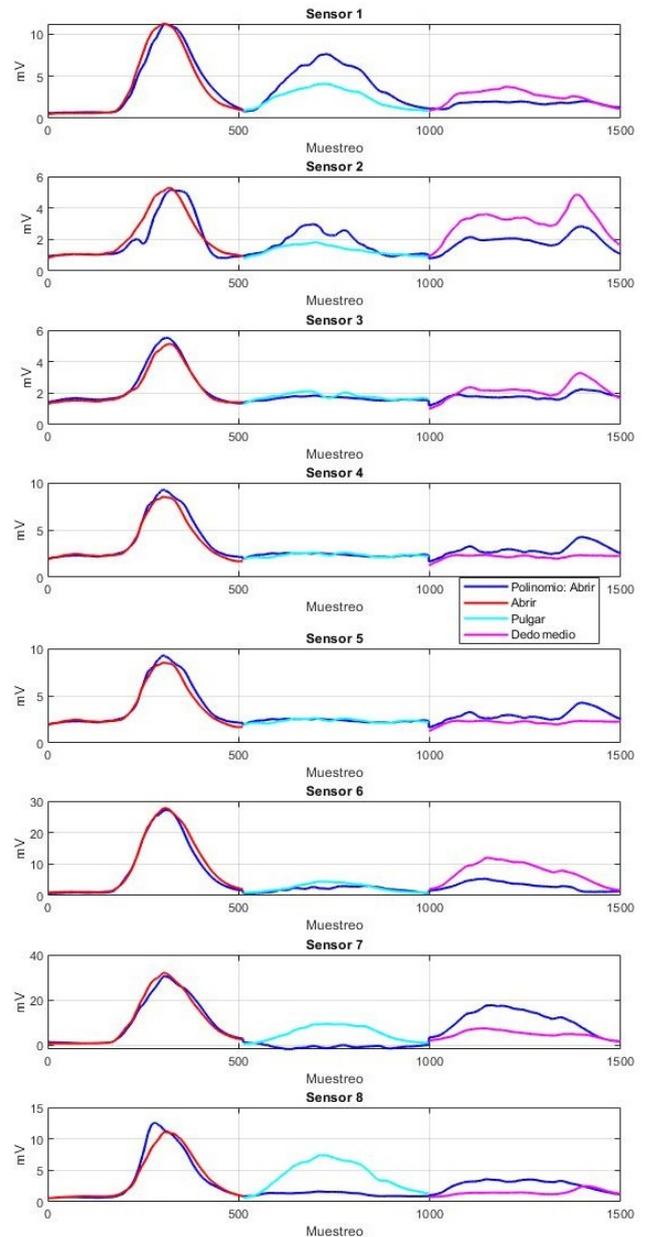


Figura 7: Evaluación de polinomios anidados para un gesto .

Tabla 2: Coeficientes de los polinomios anidados para cada sensor.

a_i	S_1	S_2	S_3	S_4	S_5	S_6	S_7	S_8
a_0	0.0007	0.0061	0.0002	-0.0003	0.0021	0.0022	-0.0005	-0.0005
a_1	-0.0047	0.0612	-0.0052	-0.0023	-0.0156	-0.0242	0.0105	0.0211
a_2	-0.0099	-0.1190	0.0010	0.0042	0.0325	-0.0744	0.0081	-0.0079
a_3	0.1014	0.3138	0.0059	0.0123	-0.1044	0.0977	-0.2931	0.1158
a_4	0.0182	-0.0056	0.0022	0.0038	-0.0877	0.0386	0.0053	0.0098
a_5	-0.0215	-0.2508	-0.0306	-0.2315	0.8230	-0.1831	0.0989	-0.3100
a_6	-0.1205	0.0821	0.0146	0.0536	-0.6695	0.4212	-0.1746	0.0272
a_7	-0.4916	-0.2497	-0.0072	0.1908	-0.4453	0.3118	0.6352	0.0120
a_8	-0.0174	-0.0785	-0.0111	0.0062	-0.0481	-0.0191	-0.0018	0.0021
a_9	0.0898	-0.5458	0.3035	0.2364	0.0709	0.3627	-0.0533	-0.0702
a_{10}	0.0858	1.3174	-0.0961	-0.2039	0.2586	0.6596	0.1024	0.0576
a_{11}	-0.3443	-0.4877	0.1339	-0.0300	0.3576	-3.7086	0.7066	-0.2634
a_{12}	-0.0146	0.2245	0.0086	-0.0022	0.9047	-0.5173	-0.0161	-0.0755
a_{13}	0.6485	1.3872	-0.2707	1.2336	-1.1555	2.4975	-0.3453	1.8248
a_{14}	0.6516	-2.2665	0.1755	0.3624	-2.1296	-0.5645	0.5804	-0.0157
a_{15}	0.8108	1.3726	0.9261	-0.0623	3.0289	1.6229	-0.3223	-0.3869

5. Clasificación de múltiples gestos

Para la clasificación de múltiples gestos se implementa un proceso parecido al utilizado para un gesto con variaciones de las matrices de correlación y la forma de evaluación. Se establece un conjunto de cuatro gestos (abrir, pulgar, dedo medio, cerrar) con cuatro pruebas diferentes cada uno. Para la clasificación se consideraron polinomios anidados de primer grado, así como una dimensión $n = 6$; con esto las matrices de correlación para el entrenamiento estarán dadas por (22).

$$MC_i = [S_{i-3}, S_{i-2}, S_{i-1}, S_{i+1}, S_{i+2}, S_{i+3}, S_i] \quad (22)$$

Se crea una matriz de correlación para cada sensor en cada uno de los gestos, teniendo 8 matrices por cada gesto. Estas ocho matrices entran al algoritmo de entrenamiento de los polinomios anidados, de lo cual se obtienen los coeficientes de los 64 términos para el polinomio anidado desarrollado de cada gesto; obteniendo 4 polinomios anidados diferentes. Posteriormente, se construyen las matrices de correlación para la evaluación de la forma (23) de cada uno de los sensores, se evalúan 4 gestos diferentes, de los cuales ningún dato es de los datos de entrenamiento. Teniendo así que cada matriz de correlación

para la evaluación contiene información de cuatro gestos diferentes.

$$ME_i = [S_{i-3}, S_{i-2}, S_{i-1}, S_{i+1}, S_{i+2}, S_{i+3}] \quad (23)$$

El conjunto de datos de cada sensor se somete al entrenamiento en los diferentes gestos. De lo anterior, se tiene una matriz de salida de 4×8 para cada muestra, se desarrolla una interpolación lineal que nos permite darle peso a los sensores con mayor actividad en cada instante; con lo cual, la matriz de salida se multiplica por la interpolación para de esta forma tener una matriz de 4×1 donde nos dará el valor para cada gesto en ese instante. De los valores de esta última matriz se logra obtener el mínimo en cada instante; mismo que representara el gesto que corresponde en ese instante, teniendo de esta forma los resultados mostrados en la figura (8) donde el gesto de abrir equivale al nivel 1, pulgar al 2, dedo medio al 3 y cerrar al 4. Como se logra observar existen instantes en los cuales la señal no coincide con la sección del gesto que le corresponde, esto se debe a que los músculos del antebrazo donde se toman las señales EMG están relacionados a diferentes actividades con un comportamiento muy similar.

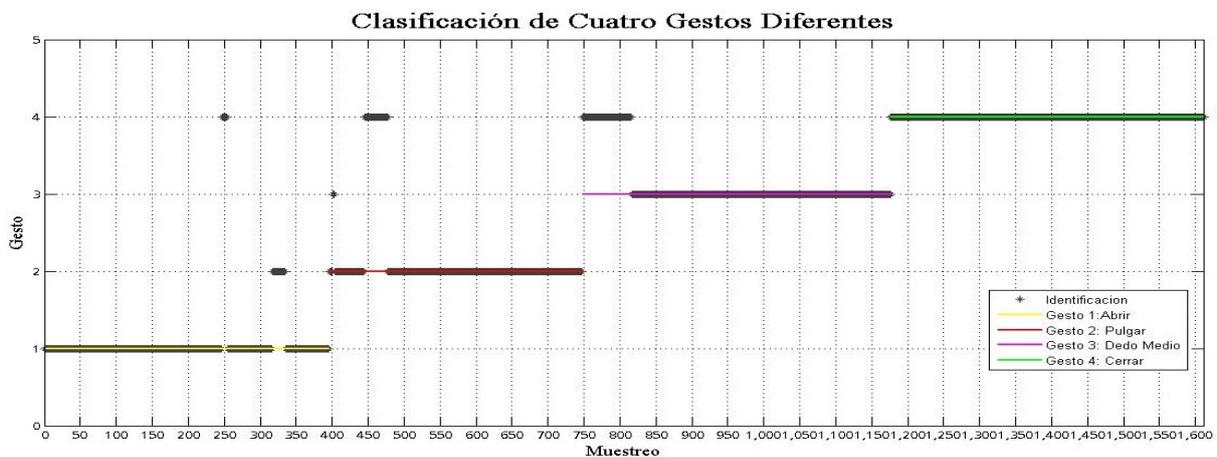


Figura 8: Evaluación de polinomios anidados para cuatro gestos. Abrir=1, pulgar=2, dedo medio=3 y cerrar=4.

6. Conclusiones

Al clasificar gestos, tanto el filtrado de señales como el entrenamiento del polinomio anidado se realizó fuera de línea, de igual manera la clasificación para uno y múltiples gestos se realiza de esta forma.

Con lo cual se puede concluir que el filtro propuesto permite que los datos de las señales EMG relacionadas a la actividad muscular al realizar una acción sean considerados sin la pérdida de información en el proceso. Además, el algoritmo de polinomios anidados definido con sus respectivas matrices de correlación para entrenamiento y evaluación funcionó favorablemente para la clasificación de un gesto, así como múltiples gestos con la consideración de seleccionar el polinomio que mejor describa cada uno de los gestos. Dicho proceso de clasificación es posible su mejoramiento al ingresar un número mayor de pruebas de entrenamiento, aunque esto implica un mayor costo computacional.

Referencias

- A.Mohammed, Shliebs, S., Matsuda, S., and Kasabov, N. (2011). Method for training a spiking neuron to associate input-output spike trains. *Engineering Applications of Neural Networks, Springer Berlin Heidelberg*, pages 219–228.
- Anillo, A. S., Lorente, L. E. M., and Rojas, M. D. B. (2017). Matriz de electrodos de emg para detección de intención de movimiento de la mano. In de Madrid, U. C. I., editor, *Trabajo Recepcional*. Escuela Politécnica Superior de Leganés, España.
- Campoverde, C. I. M. and Nacipucha, J. M. N. (2016). Diseño e implementación de un prototipo de exoesqueleto destinado a la rehabilitación de codo. In *Trabajo recepcional*. Universidad de Cuenca, Cuenca, Ecuador.
- Chimal, I. B. (2017). Desarrollo de una api para el dispositivo myo. In *Tesis de maestría*. Universidad Veracruzana, Xalapa, Ver., Méx.
- de los Santos Bojórquez, H. R. (2015). Control de robots manipuladores con señales mioeléctricas. In *Tesis de especialidad*. Centro de Ingeniería y Desarrollo Industrial, Santiago de Querétaro, Qro., Méx.
- Guachamin, J. Z. (2017). Implementación de un sistema de clasificación de gestos del brazo humano utilizando myo armband para mano a distancia de un brazo robótico de 3gdl. Escuela Politécnica Nacional, Quito, Ecuador.
- Gutierrez, L. R. L., Rodríguez, J. L., and Carrochano, E. B. (2018). Spike quaternion neural networks control for a hand prosthesis. *2018 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, [En línea]:1–6.
- J..Brazzeiro, Petraccia, S., and Valdés, M. (2015). Mano controlada por señales musculares. In *Memoria de proyecto*. Universidad de la República, Montevideo, Uruguay.
- Miguel, A. M., Pérez, S. A. V., Merlin, E. G., Montiel, M. A., and E. Lugo, R. M. L. (2016). Control de movimiento de una mano robótica mediante señales electromiográficas. In *Memorias XXXIX del Congreso Nacional de Ingeniería Biomédica*, pages 73–76. Nombre de la editorial, Mérida, Yuc., Méx.
- Villamil, D. C. A. and Sanchez, F. D. B. (2018). Sistema de conexión inalámbrica entre un brazalete myo y una prótesis de miembro superior por medio de bluetooth de baja energía. Universidad Distrital Francisco José de Caldas, Bogotá, Colombia.
- Villeda, A. L., Sanchez, F. J. R., Ramírez, O. A. D., and Vega, V. P. (2013). 'robotic design of an upper limb exoskeleton for motion analysis and rehabilitation of paediatric neuromuscular disorders. *Converging Clinical and Engi. Research, Springer Berlin Heidelberg*, pages 265–269.