

Clasificación de EMG a través de Índices Lineales y No Lineales por medio de Redes Neuronales Artificiales

M. E. Rodríguez García, G. Dorantes Méndez, M. O. Mendoza Gutiérrez
Facultad de Ciencias, Universidad Autónoma de San Luis Potosí
Av. Salvador Nava s/n, Zona Universitaria, San Luis Potosí, S.L.P. 78290 México
E-mail: emiliano7474@gmail.com

Resumen—En este trabajo se extrajeron índices lineales y no lineales de la señal de electromiografía (EMG) como: el Valor Cuadrático Medio (RMS), el Valor Medio Absoluto (MAV), la Integral, la Integral Cuadrada Simple (SSI) y la Entropía Aproximada (ApEn). La señal de EMG fue adquirida del músculo flexor radial del carpo y del músculo extensor de los dedos durante tres maniobras de flexión y extensión de la muñeca, considerando la máxima contracción voluntaria (MVC), el 50% de la MVC, y movimientos pasivos. Con los índices extraídos se diseñaron dos redes neuronales artificiales para clasificar flexión-extensión y flexión-extensión-relajación. Los resultados de desempeño de clasificación de las dos redes mostraron porcentajes de eficiencia de 91.4% y 94.7%, respectivamente, lo que implica que las redes neuronales tuvieron un buen desempeño con los índices lineales y no lineales extraídos de la señal de EMG.

Palabras clave—Clasificación de movimientos, electromiografía, red neuronal artificial.

I. INTRODUCCIÓN

El análisis de la señal eléctrica de los músculos, EMG, ha sido abordado en una variedad de estudios con la finalidad de extraer características, modelar la señal y reconocer patrones; y de esta forma diferenciar entre varios estados del músculo, así como la diferenciación entre tipos de movimientos. Sin embargo, la selección de características o índices que representen adecuadamente el estado del músculo es un tema aún en discusión y desarrollo, ya que la señal puede ser caracterizada de formas distintas. Una aplicación de la caracterización de la señal de EMG es el control de dispositivos de rehabilitación o prótesis robóticas [1]. Dentro de este contexto, la selección adecuada de características y su correcta clasificación permitirán una estimación precisa del estado del músculo y una correcta utilización y control de la prótesis.

El conjunto deseable de características utilizadas para lograr una buena clasificación de los diferentes estados de la señal de EMG debe estimar de la mejor forma posible dicho estado, además de tener una gran separabilidad en el espacio de características de EMG. Existen estudios en los que se utilizan como discriminantes para la clasificación índices clásicos de la señal de EMG, tales como la integral del valor absoluto, la varianza y los cruces por cero. Zardoshti-Kermani y Wheeler utilizaron estos índices y el histograma de EMG para obtener una clasificación adecuada con el método de "K-Nearest Neighbor" utilizando dos canales de adquisición de EMG,

además de observar una disminución del error agregando a su vector de características los coeficientes de un modelo auto-regresivo [2]. Las desventajas de utilizar este método son que requiere un costo computacional elevado y tiene un tiempo de ejecución largo [2], [3]. Otras características utilizadas para análisis en el dominio del tiempo son la amplitud de Willison, el valor absoluto medio, la pendiente del valor absoluto medio, la longitud de onda, los cambios de signo en la pendiente y el valor cuadrático medio. Mientras que en el dominio de la frecuencia se utiliza la transformada wavelet, la cual es una herramienta útil para el análisis local de señales no estacionarias y de transición rápida [4]; y la función de densidad de potencia espectral, la cual indica cómo se distribuye la potencia total de la señal analizada sobre el espectro de frecuencia [5].

La utilización de algunos de estos índices, en específico, el valor absoluto medio, la longitud de onda, los cambios de signo en la pendiente y los cruces por cero, junto con un análisis discriminante lineal ha permitido diferenciar señales de EMG de manera adecuada, con la desventaja que el análisis requiere ventanas de tiempo relativamente grandes, aproximadamente 4 segundos, antes de poder tomar una decisión, lo que ocasionaría un retraso en la clasificación [6] y problemas de implementación para control en tiempo real.

En cuanto a la clasificación de EMG se han utilizado diferentes métodos los cuales incluyen clasificadores Bayesianos, funciones discriminantes no-lineales, lógica difusa y redes neuronales [3]. Las redes neuronales tienen la ventaja de tener su estructura distribuida en paralelo y la habilidad para aprender y por lo tanto generalizar, es decir, producir salidas razonables para entradas que no fueron usadas durante el entrenamiento. En este trabajo se propone la clasificación por medio de una red neuronal utilizando un conjunto de características clásicas de la señal de EMG en el dominio del tiempo, con la adición de una medida no lineal, la entropía aproximada (ApEn), con el objetivo de diferenciar entre los movimientos de flexión, extensión y el estado de relajación, contemplando como futura aplicación el control de una prótesis de miembro superior.

II. METODOLOGÍA

A. Adquisición de la señal de EMG

La adquisición de la señal de EMG se realizó con el sistema Biopac MP36® a una frecuencia de muestreo de 1 kHz con un arreglo de electrodos bipolar. Las señales de EMG se obtuvieron de 30 sujetos de ambos sexos, 14 hombres y 16 mujeres, con una edad media de 23.1 ± 2.9 años. Los electrodos fueron colocados en el músculo flexor radial del carpo (músculo flexor) y el músculo extensor de los dedos (músculo extensor), como se muestra en la Fig. 1, mientras que el electrodo de referencia se colocó en el codo.

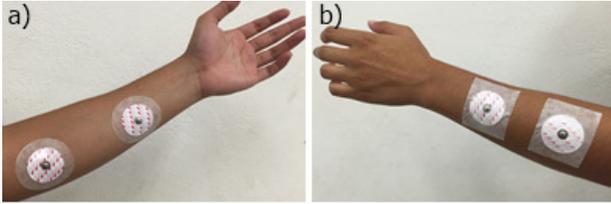


Fig. 1: . Colocación bipolar de electrodos del músculo flexor (a) y músculo extensor (b).

El protocolo de adquisición de los datos consistió en la realización de tres maniobras. Durante la primer maniobra se instruyó a los sujetos para realizar contracciones máximas voluntarias (MVC); en la segunda maniobra se realizaron contracciones con una amplitud aproximada al 50% de la MVC de cada sujeto; y finalmente en la tercer maniobra se realizaron movimientos simples (pasivos) de flexión y extensión, es decir, sin realizar fuerza activa. En las tres maniobras se realizaron 3 flexiones de muñeca y posteriormente 3 extensiones de muñeca. Se utilizaron estas maniobras ya que se cubre un amplio rango de posibles movimientos realizados por los sujetos, tales como los realizados cotidianamente. Cada contracción realizada en las maniobras tuvo una duración de 5 segundos mientras que entre cada una de las contracciones existió un periodo de relajación de 10 segundos.

B. Procesamiento de la señal de EMG

La señal de EMG adquirida fue filtrada en la ventana de 20 a 500 Hz para eliminar posibles alteraciones existentes en la señal registrada. Posteriormente la señal fue rectificad y normalizada digitalmente; la normalización fue respecto al valor máximo registrado en cada sujeto, eliminando de esta forma la dependencia de la amplitud máxima de todos los registros. Además, las señales de EMG correspondientes a cada contracción muscular con duración de 5 segundos fueron divididas en ventanas temporales de un segundo con un traslape de 0.25 segundos.

La caracterización de la señal de EMG se realizó utilizando los índices característicos de: RMS, MAV, Integral, SSI y ApEn; estos índices y sus respectivas fórmulas se muestran en la Tabla I. La ApEn es un índice no lineal que expresa la semejanza que existe entre dos segmentos, con base en dos parámetros: el primero es la longitud m que tendrá cada segmento, mientras que el segundo es el umbral de similitud

r , el cual determinará si un segmento es similar a otro sólo si el umbral r no es superado por la resta del valor absoluto de los dos segmentos a comparar. Esto es útil para poder diferenciar si un segmento de la señal de EMG es parte de un evento de contracción muscular o de reposo. Para este trabajo se consideró una longitud fija $m = 2$, mientras que el valor de r es de 0.1 veces la desviación estándar de una muestra de contracción muscular, ya sea flexión o extensión, o una etapa de relajación, dependiendo de la maniobra evaluada. Con estos parámetros establecidos se calcula C_m , la cual es la media de la cantidad de patrones de longitud m que son similares (dependiendo de r) a cada uno de los demás patrones dentro de la muestra (el número total de patrones es N/m , donde N es la cantidad de datos en la muestra) y C_{m+1} , el cual se calcula de manera similar a C_m siendo la única diferencia la longitud de los segmentos, la cual será de $m + 1$. De esta forma se puede establecer si los segmentos dentro de una muestra son similares o no [7].

TABLA I: Índices obtenidos de la señal de EMG

Índice	Fórmula
Valor Cuadrático Medio (RMS)	$\sqrt{\frac{\sum x_i^2}{N}}$
Valor Absoluto Medio (MAV)	$\frac{\sum x_i}{N}$
Integral	$\sum x_i$
Integral Cuadrática Simple (SSI)	$\sum x_i^2$
Entropía Aproximada (ApEn)	$\ln\left(\frac{C_m}{C_{m+1}}\right)$

Notación: x_i es el valor de la señal rectificad y normalizada de EMG, N es la cantidad de datos que se tienen por muestra, C_x es la media de la cantidad de patrones de longitud x que son similares a cada uno de los patrones dentro de la muestra.

C. Clasificación de movimientos

Se seleccionó una red neuronal artificial (RNA) con la finalidad de clasificar entre movimientos de flexión, extensión y relajación, utilizando un vector de características que contiene los índices previamente establecidos. La arquitectura de la RNA se determinó de acuerdo a pruebas realizadas con varias configuraciones, seleccionando la red con el menor error cuadrático medio (MSE).

Se implementaron dos RNA: la primera red (R1) considerando la clasificación entre flexión y extensión, y la segunda red (R2) considerando 3 clases: flexión, extensión y relajación. Ambas redes fueron entrenadas con las maniobras previamente descritas. La arquitectura seleccionada fue de 20 neuronas en la capa de entrada, 10 neuronas en la capa oculta y en la capa de salida 2 y 3 neuronas para R1 y R2, respectivamente, utilizando una función de transferencia tangencial sigmoidea. El entrenamiento de la RNA fue de tipo supervisado, el cual consiste en presentar un conjunto de entrenamiento a la RNA, encontrar la salida de la red y ajustar los pesos sinápticos para que la salida actual se aproxime a

las etiquetas deseadas y definidas a priori. Los vectores de entrenamiento se presentaron de forma aleatoria a la RNA. La asignación de etiquetas a los vectores de características consistió en determinar cada ventana temporal como flexión, extensión o relajación.

El entrenamiento de la RNA se realizó utilizando MATLAB® a través del algoritmo de aprendizaje de retro-propagación, los valores de los pesos y el sesgo se actualizaron de acuerdo a la optimización de Levenberg-Marquardt y se utilizó una función de aprendizaje de gradiente descendente con momento. El entrenamiento se llevó a cabo durante 100 o menos épocas de acuerdo al error alcanzado y el desempeño de la RNA fue evaluado con el MSE, con base a la curva de aprendizaje. Mientras que la asignación de los valores de la salida de la RNA a las clases se realizó a través de un umbral. Los vectores de características que generaron un valor de salida fuera de este umbral fueron descartados y por lo tanto, no se asignaron a ninguna clase.

Para detener el entrenamiento y el ajuste de pesos sinápticos de la RNA no existe un criterio bien definido. En este trabajo se utilizó el método donde se dividen los datos disponibles en tres subconjuntos para brindar una mejor generalización. Los tres subconjuntos son entrenamiento, validación y prueba. El subconjunto de entrenamiento es usado para calcular el gradiente y actualizar los pesos y términos de sesgo de la RNA. En el subconjunto de validación se monitorea el error alcanzado durante el proceso de entrenamiento, que normalmente decrece durante la fase inicial de entrenamiento; el clasificador se entrena hasta que el error del subconjunto de validación alcanza un mínimo. Sin embargo, cuando la red comienza a sobre ajustar los datos, el error con el conjunto de validación comenzará a incrementarse. Si esto sucede para un número específico de iteraciones, se sugiere detener el entrenamiento [8]. El conjunto total de vectores de características se dividió aleatoriamente en tres subconjuntos: entrenamiento (80 % de los datos), validación (10 %) y prueba (10 %).

Los datos de entrada para las etapas de entrenamiento, prueba y validación de la red consisten en una matriz de diez renglones donde cada columna pertenece únicamente a una clase, ya sea flexión, extensión o relajación. En los primeros 5 renglones se encuentran los 5 índices adquiridos pertenecientes al músculo flexor y en los últimos 5 están los índices que pertenecen al músculo extensor con el siguiente orden: RMS, MAV, Integral, SSI y ApEn. El tamaño de la matriz de vectores de características para R1 fue de 10×3240 y para R2 fue de 10×4860 . Los vectores se encontraban permutados para que el entrenamiento tuviera un mejor desempeño. La red R1 fue entrenada para obtener a la salida (1,0) en el caso de flexión y (0,1) en el caso de extensión y para la red R2 se consideró la salida (1,0,0) como flexión, (0,1,0) como relajación y (0,0,1) para extensión, dichos valores establecidos como el caso ideal. Para ambas redes se consideró un umbral de 0.2.

Para evaluar el desempeño de las RNA implementadas se obtuvo el porcentaje de error considerando las ventanas temporales que se clasificaron de manera incorrecta y las que no se lograron clasificar. Además, se obtuvo la curva ROC (Receiver

Operating Characteristic) y la matriz de confusión para evaluar el desempeño de la red R2. Para cada clase, ROC aplica umbrales dentro del intervalo de 0 y 1 a las salidas. Para cada umbral se calculan dos valores, los cuales son la proporción de positivos verdaderos y la de falsos positivos. Mientras la curva obtenida de cada una de las clases tenga una proporción mayor de valores verdaderos positivos se considera que la clasificación de esa clase obtuvo resultados favorables [9]. La matriz de confusión es apropiada para métodos de clasificación en los cuales valores específicos pueden ser asignados a una sola clase y en los que las medidas de precisión están basadas en la proporción de datos correctamente clasificados, ya que muestra la cantidad de ventanas temporales clasificadas correcta e incorrectamente [10].

III. RESULTADOS

La Fig. 2 y la Fig. 3 muestran las curvas de aprendizaje durante el entrenamiento de R1 y R2, respectivamente. En ambos casos, se presenta el MSE alcanzado, además del comportamiento de los conjuntos de validación y prueba. El entrenamiento de R1 se llevó a cabo hasta la época 21 alcanzando un MSE de 0.0095, mientras que el de R2 se realizó hasta la época 40 logrando un MSE de 0.0064.

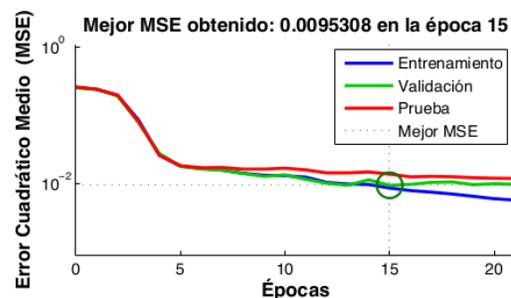


Fig. 2: Curva de aprendizaje del entrenamiento de R1.

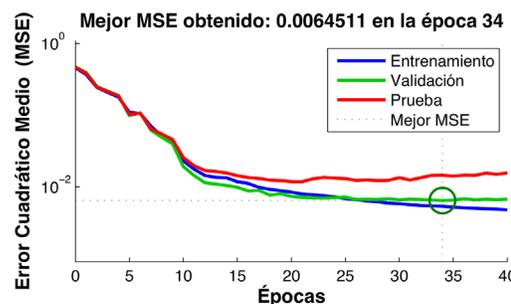


Fig. 3: Curva de aprendizaje del entrenamiento de R2.

Al calcular los errores de clasificación de R1 con el conjunto de prueba se obtuvo un valor del 7.4% y 9.9% para las clases de flexión y extensión respectivamente, generando una tasa de error del 8.6%. En la Fig. 4 se observan las salidas obtenidas de R1 con el conjunto de prueba.

La curva ROC de la etapa de prueba de R2 se muestra en la Fig. 5a, donde se puede apreciar que las curvas correspondientes a cada clase tienen valores elevados de verdaderos

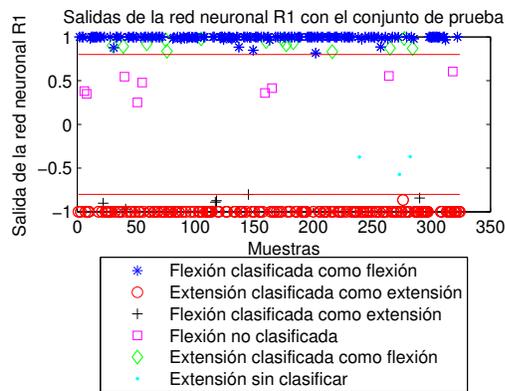


Fig. 4: Salidas de R1 con el conjunto de prueba.

positivos y valores bajos de falsos positivos, lo que significa que R2 tiene una eficiencia apropiada. El error obtenido fue de 8.6%, 0% y 7.4% en las clases de flexión, relajación y extensión, respectivamente, generando una tasa de error de 5.3%. La gráfica de difusión obtenida de R2 en la etapa de prueba se muestra en la Fig. 5b.

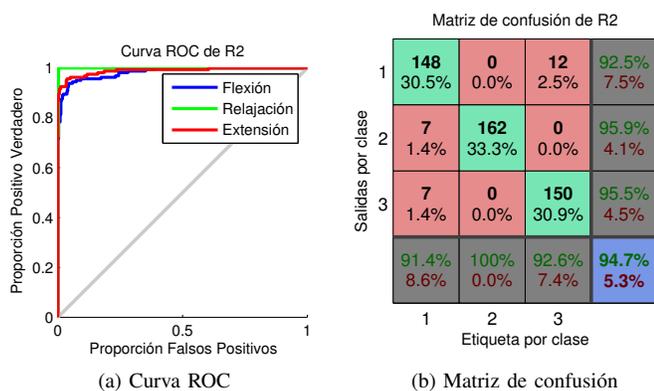


Fig. 5: Resultados obtenidos para R2.

IV. DISCUSIÓN Y CONCLUSIÓN

Los entrenamientos de las redes consiguieron un MSE en su desempeño de 0.0095 y 0.0064 de R1 y R2, respectivamente, los cuales son errores bajos. Estos valores muestran que las redes tuvieron un entrenamiento apropiado y además que son capaces de realizar clasificaciones adecuadas.

Durante la etapa de prueba, R1 mostró una buena eficacia ya que obtuvo una tasa de error de 8.6%, lo que significa que clasificó correctamente más del 91% de las ventanas temporales presentadas durante esta etapa. R2 logró un mejor resultado al obtener una tasa de error de 5.3% durante esta etapa. Estos resultados muestran un buen desempeño por parte de las dos redes neuronales.

La curva ROC de R2 mostró que las 3 clases obtienen resultados correctos en la mayoría de las ventanas temporales al obtener una proporción mucho mayor de valores positivos

verdaderos en comparación con los falsos positivos. Mientras que la matriz de confusión de R2 mostró que cada una de las clases lograron una clasificación correcta mayor al 91% y en promedio la eficiencia de la red fue del 94.7%.

Para probar la eficiencia de las redes neuronales propuestas, se evaluó el desempeño de una tercer red neuronal (R3) con las mismas clases que R2 y entrenada con las maniobras de MVC y del 50% de la MVC, dicha red fue probada con los datos de la maniobra de movimientos simples, los cuales son totalmente ajenos al entrenamiento. Los resultados obtenidos por medio de la matriz de confusión de R3 muestran una eficiencia del 92.8%, el cual es un buen desempeño considerando que son datos de movimientos no incluidos en el entrenamiento; esto supone que R1 y R2 serán capaces de clasificar correctamente movimientos cotidianos, ya que estos se encuentran dentro del rango de entrenamiento recibido.

En conclusión, la combinación de índices lineales y no lineales para caracterizar la señal de EMG provenientes de dos músculos resultó ser adecuada para lograr diferenciar entre flexión, extensión y relajación a través de las RNA propuestas, ambas con un buen desempeño. Por lo tanto, dicha clasificación sería adecuada para la aplicación propuesta del control de una prótesis mioeléctrica de miembro superior. Como perspectivas del trabajo se encuentra el incorporar un número mayor de músculos que generen una gama mayor de movimientos, con la finalidad de caracterizarlos de forma que el control de la prótesis sea más fino, además de evaluar el desempeño de la red con el método de validación cruzada y realizar la comparación con otros clasificadores como máquinas de soporte vectorial y redes neuronales con entrenamiento no supervisado.

REFERENCIAS

- [1] R. Chowdhury, M.B.I. Reaz, M.A. Ali, et.al. (2013, septiembre), *Surface Electromyography Signal Processing and Classification Techniques*, Sensors [Open Access]. Disponible en www.mdpi.com/journal/sensors.
- [2] M. Zardoshti-Kermani, B. Wheeler, *EMG Feature Evaluation for Movement Control of Upper Extremity Prostheses*, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 1995, vol. 3, no. 4, pp. 305-311.
- [3] F. Chan, Y. Yang, F. Lam, et.al., *Fuzzy EMG Classification for Prosthesis Control*, IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 8, no. 3, pp. 305-311, 2000.
- [4] M. Reaz, M. Hussain, F. Mohd-Yasin (2006, Marzo), *Techniques of EMG signal analysis: detection, processing, classification and applications*. Biological Procedures Online [Open Access]. Volúmen 8, pp. 11-35. Disponible en www.biologicalprocedures.com
- [5] A. Barreto, S. Scargle, M. Adjouadi, *A Practical EMG-based Human-computer Interface for Users with Motor Disabilities*, Journal of Rehabilitation Research and Development, vol. 37, no. 1, pp. 53-64, 2000.
- [6] G. Li, T. Kuiken, *EMG Pattern Recognition Control of Multifunctional Prostheses by Transradial Amputees*, 31st Annual International Conference of the IEEE EMBS, Minneapolis, Minnesota, USA, 2009.
- [7] S. Pincus, *Approximate Entropy as a Measure of System Complexity*, Proceedings of the National Academy of Sciences of the United States of America, vol. 88, no. 6, p. 297-301, 1991.
- [8] R. Duda, M. Hart, D. Store, *Pattern Classification*, Wiley-Interscience Publication, 2001, pp. 483-485.
- [9] K. Woods, K. Bowyer, *Generating ROC Curves for Artificial Neural Networks*, IEEE Transactions on medical imaging, vol. 16, no. 3, pp.329-337, 1997.
- [10] H. Lewis, M. Brown, *A Generalized Confusion Matrix for Assessing Area Estimates from Remotely Sensed Data*, Int. J. Remote Sensing, vol. 22, no. 16, pp.3223-3235, 2001.