

Análisis comparativo entre de MAE y RNA en señales de EMG obtenidas para control de una prótesis mano robótica

Comparative analysis between ELM and ANN in EMG signals obtained for the control of a robotic hand prosthesis

Ruthber Rodríguez Serrezuela ^{1*}, Miguel Ángel Tovar Cardozo ², Jeidy Johanna Gómez Montiel ³, Roberto Sagaro Zamora ⁴ y Enrique Maraño Reyes ⁵

¹ Programa de Ingeniería Industrial, Corporación Universitaria del Huila, Corhuila, Colombia

² Programa de Administración Financiera, Corporación Universitaria Minuto de Dios, Uniminuto, Colombia

³ Programa de Administración de Empresas, Corporación Universitaria Minuto de Dios, Uniminuto, Colombia

⁴ Departamento de Mecánica y Diseño (MyD), Tribology Group, Universidad de Oriente, Cuba

⁵ Centro de Estudios de Neurociencias y Procesamiento de Imágenes y Señales, Universidad de Oriente, Cuba

*Autor de correspondencia: ruthber.rodriguez@corhuila.edu.co

RESUMEN– En las últimas décadas, la industria de la robótica está evolucionando de manera exponencial y se pueden hacer robots humanoides, así como de poder realizar las funciones físicas de las personas. Desde este punto de vista, las manos robóticas son vitales para muchas personas que padecen bien sea de una amputación o de alguna enfermedad. El objetivo principal de esta investigación fue clasificar las señales de Electromiografía (EMG) recibidas del brazo humano de personas sanas y luego realizar la aplicación manual con mano robótica en un entorno virtual. Esto es muy importante para comprender y clasificar la estructura geométrica del objeto contenido en aplicaciones de mano robótica. Se investigó el tiempo de clasificación y la relación de precisión entre las Redes Neuronales Artificiales (RNA) y las Maquinas de Aprendizaje Extremo (MAE) utilizados para esta clasificación. Para ello, se extrajeron 10 características y las clasificaciones se probaron utilizando RNA y MAE. Los resultados de clasificación exitosos obtenidos se compararon entre sí y se aplicaron a una mano robótica virtual utilizando el programa V-Rep.

Palabras clave– *Mano robótica, Redes Neuronales Artificiales (RNA); Máquina de aprendizaje extremo (MAE); Señales de EMG*

ABSTRACT– In the last decades, the robotics industry is evolving exponentially and humanoid robots can be made, as well as being able to perform the physical functions of people. From this point of view, robotic hands are vital for many people who suffer from either an amputation or an illness. The main objective of this research was to classify the Electromyography (EMG) signals received from the human arm of healthy people and then perform the manual application with robotic hand in a virtual environment. This is very important to understand and classify the geometric structure of the object contained in robotic hand applications. We investigated the classification time and the precision relationship between the Artificial Neural Networks (ANN) and the Extreme Learning Machines (MAE) used for this classification. For this, 10 characteristics were extracted and the classifications were tested using ELM and ANN. The successful classification results obtained were compared with each other and applied to a virtual robotic hand using the V-Rep program.

Keywords– *Robotic hand, Artificial Neural Networks (ANN); Extreme Learning Machine (ELM); EMG signals*

1. Introducción

Algunas personas se enfrentan a tales problemas congénitos, accidentes laborales en la vida diaria que ocasionan la pérdida de extremidades. La industria de la robótica inteligente ha permitido el desarrollo de robots humanoides que pueden realizar las funciones físicas de las personas. En la actualidad, los brazos y manos robóticas han tenido un notable desarrollo. Las manos

robóticas deben ser capaces de cumplir con algunas habilidades básicas, como el agarre de objetos y la transferencia de un lugar a otro de manera similar a como lo realizan las personas en la vida diaria. La robótica toma importancia para las personas que han perdido su brazo o han nacido sin su brazo. Por ejemplo, en el campo del procesamiento de imágenes, se han trabajado las imágenes de diferentes posiciones de

la mano tomadas por la mano humana y el brazo robótico ha podido realizar estos movimientos rápidamente [1]. En otro estudio, se implementó un sistema de reconocimiento de movimiento de la mano utilizando el sensor Kinect. El movimiento se puede detectar en la aplicación para detectar movimientos de la mano en cualquier dirección, especialmente cuando se toma la dirección de un marcador 3D [2]. Además del procesamiento de imágenes, se han realizado muchas operaciones de procesamiento de señales. En el caso de un procesamiento de señal basado en máquinas de vectores de soporte, se toma la señal EMG de superficie para los movimientos de apertura y cierre de la mano humana y se muestra que esta señal es independiente de la posición del brazo, que se considera adecuada para el control de prótesis activas [3]. En un estudio de dos secciones que investiga el uso de señales electromiográficas (EMG) de la superficie del antebrazo para el control en tiempo real de un brazo robótico, también se proporciona un control de alto nivel [4]. En otro estudio, utilizando datos de señales de EMG, los movimientos básicos de la mano basados en el análisis de señales biomédicas se identificaron y clasificaron utilizando la Descomposición en Modo Empírico (DME) [5]. En este estudio, se extrajeron las características de la señal de EMG tomada del brazo de un hombre que tiene 25 años de edad en [5] y estas características se clasificaron en la Máquina de Aprendizaje Extremo (MAE) y las Redes Neuronales Artificiales (RNA). Los resultados de la clasificación se compararon y se observó que MAE es una mejor opción que RNA. En las siguientes partes de este documento, se explicarán brevemente RNA, MAE y extracción de características, luego se darán los experimentos y los resultados obtenidos. La sección final discutirá los resultados y lo que se puede hacer en el futuro.

2. Materiales y Métodos

En la actualidad, muchas aplicaciones robóticas se están realizando con señales del cuerpo humano. En este estudio, los experimentos se llevaron a cabo mediante el agarre libre y repetido de los diversos elementos necesarios para la identificación de los movimientos de las manos. El fuerza y la velocidad del agarre realizado se deja deliberadamente a la voluntad de la persona. Estos datos se recopilaron utilizando el programa

Labview de National Instruments (NI) a una frecuencia de muestreo de 500Hz. Mediante bandas elásticas y dos electrodos EMG de superficie del antebrazo para recopilar información sobre la activación muscular que se mantiene en el electrodo de referencia central y estas señales se transmitieron a un sistema EMG de dos canales utilizando el sistema EMG de Myoware [5]. Estos electrodos se conectaron a ambos lados del antebrazo y recibieron señales del antebrazo mientras se realizaba el agarre, y estas señales se transfirieron de los electrodos al electrodo de referencia central al que se conectó el electrodo al programa Labview del Instrumento Nacional (NI). Esta transferencia de datos se realizó utilizando el sistema de EMG Myoware. El paciente es un hombre sano de 22 años, al cual se le pidió a que sostenga los objetos con los siguientes seis patrones diferentes de agarre repetidamente Fig 1.

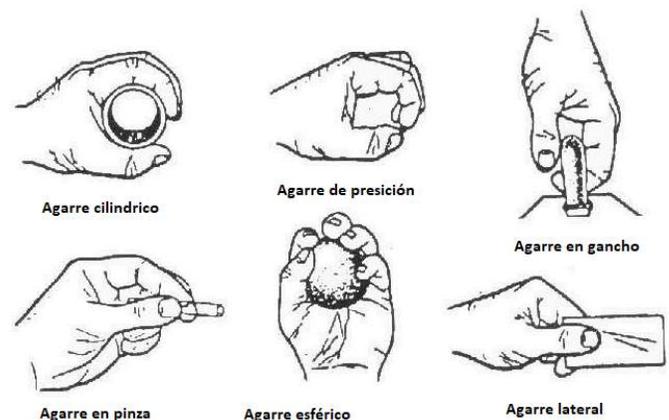


Figura 1. Seis diferentes tipos de agarre.[1]

- Cilíndrico: para sujetar herramientas cilíndricas.
- De presión: para sujetar herramientas pequeñas.
- Gancho: para soportar una carga pesada.
- Pinza: para agarrar con la palma hacia el objeto.
- Esférica: para sujetar herramientas esféricas.
- Lateral: para sujetar objetos delgados y planos.

El experimento consiste en que el sujeto realice 100 veces 6 agarres durante 3 días consecutivos. Por lo tanto, al final de la serie de 3 días, se obtuvieron un total de 1800 agarres que se miden desde canal-1 y canal-2, del dispositivo. Debido a que cada agarre se realiza a intervalos de 5 segundos, se obtienen 2500 piezas de datos para cada operación de agarre, puesto que este programa funciona a una frecuencia de 500Hz [5].

Teniendo en cuenta todo esto, hay 1,800 ciclos que toman 5 segundos y se usan para crear la RNA y el MAE. Por lo tanto, se obtienen 2500 datos en cada ciclo y se incluyen un total de 2500 a 1800 matrices de datos, respectivamente.

2.1 Redes Neuronales Artificiales (RNA)

Uno de los subcampos de la inteligencia artificial son las RNA. A través de las neuronas se realiza el procesamiento de la información. Las neuronas están conectadas entre sí por conexiones ponderadas, como se puede observar en la Fig. 2.

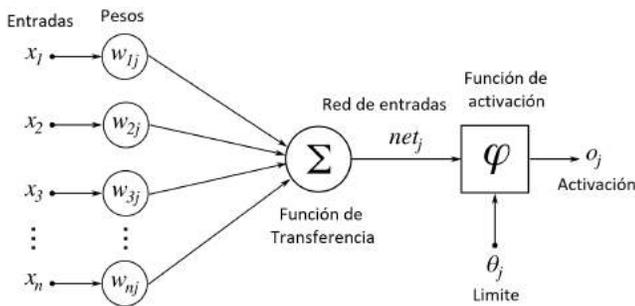


Figura 2. Estructura de una red neuronal artificial.

Una RNA consta de 3 capas básicas. Estas son una entrada, una capa oculta y una capa de salida. Los datos de entrada se aplican directamente a la capa de entrada, de modo que el número de neuronas en la capa de entrada es igual al número de cada muestra de entrada. Luego, estos datos pasan de operaciones como la función de suma, multiplicación y activación que llega a la capa de salida. Finalmente, estos datos se dan directamente a la capa de salida. Se puede utilizar más de una capa oculta en RNA dependiendo de la complejidad de la red. Una capa oculta fue utilizada en nuestro trabajo. La optimización de tipo perceptrón multicapa (PMC) se usa ampliamente en el campo de la optimización de la inteligencia artificial.

Las redes neuronales artificiales de tipo PMC se usaron en este estudio y las funciones de activación utilizadas entre las capas fueron; a) Sigmoidea logarítmico: Logsig b) tan sigmoidea y c) Purelin. Las redes neuronales artificiales pueden recopilar información sobre muestras, hacer generalizaciones y luego decidir sobre esas muestras utilizando información aprendida en comparación con muestras que nunca antes habían visto. Debido a estos aprendizajes y generalizaciones, las redes neuronales

artificiales encuentran una amplia aplicación en muchos campos científicos y demuestran su capacidad para resolver problemas complejos con éxito [6]. En este estudio, la estructura de la RNA consiste en entrada, salida y una capa oculta. Los datos de las señales EMG recopiladas previamente se entregan a la capa de entrada, que luego se actualiza mediante las funciones de activación y se transmite a la capa de salida. Se presenta la estructura básica de RNA en cada círculo se representa una neurona.

2.2 Máquina de Aprendizaje Extremo (MAE)

Una MAE en realidad tiene una estructura de red RNA con una sola capa oculta (ver Fig. 3) y el número de neuronas de capa oculta de MAE estándar suele ser más de 1000 [7]. Los pesos y los umbrales se asignan al azar. Estos pesos no se cambian después. Las operaciones se realizan de acuerdo con los pesos iniciales y los valores de umbral. Las entradas en el MAE son características derivadas de los datos disponibles. Los datos utilizados como salida son también los datos de destino. Dado que los pesos también se asignan al azar, el propósito principal aquí es encontrar el coeficiente Beta. Los coeficientes beta se generan durante la fase del entrenamiento y, a continuación, se utiliza el mismo coeficiente durante la fase de prueba. El inverso generalizado de Moore-Penrose se utiliza para encontrar los coeficientes beta [8]. Como resultado de la obtención de los coeficientes Beta, la red se entrena. Es decir, no hay un cálculo iterativo en el MAE. Por esta razón, tiene una gran ventaja en términos de velocidad del entrenamiento

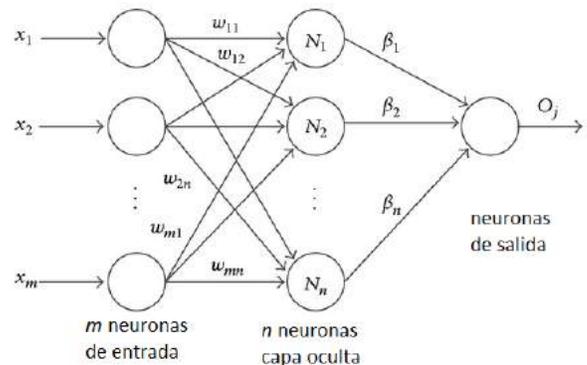


Figura 3. Estructura de una Máquina de Aprendizaje Extremo.

2.3 Extracción de características

Para clasificar los datos recibidos en RNA, es necesario extraer las propiedades de clasificación, y los procedimientos de entrenamiento y prueba se realizan según estas características. En este estudio, se extrajeron un total de 10 características, incluido el dominio del tiempo y la frecuencia. En el dominio del tiempo, se extrajeron cinco características: energía de señal, desviación estándar, promedio absoluto, sesgo y valor de curtosis. Para transferir la señal del dominio del tiempo al dominio de la frecuencia, la densidad espectral de potencia de la señal (DEP) debe obtenerse mediante el método de Welch [9] u otros y, por lo tanto, la señal se puede observar en el dominio de la frecuencia. Luego se extrajeron seis características, incluidos los promedios de esta frecuencia, la desviación estándar, la curtosis asimétrica, la densidad de potencia entre 0-50Hz y 50-250Hz.

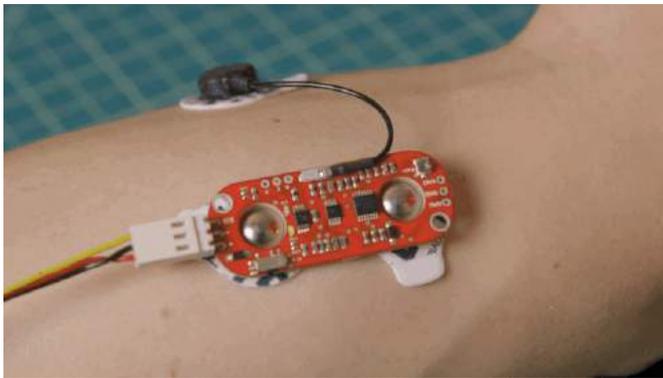


Figura 4. Extracción de las señales mioeléctricas.

2.3 Interfaz gráfica (GUI)

La GUI es una interfaz que permite al usuario interactuar con el programa utilizando objetos visuales (botón, editar texto, texto estático, graficas, etc.) [10]. En este estudio, los valores de precisión de los modelos RNA y MAE se obtuvieron mediante una interfaz y se representaron gráficamente, y la interfaz GUI desarrollada se muestra en la Fig. 5.

La interfaz se desarrolló con la versión de Labview 2018, se instaló en un computador Lenovo, con procesador Intel Core 7i, 8650U Processor (8M Cache, up to 4.20 GHz), Turbo Boost 4.3, con 4.2 GHz, memoria 8 GB de SDRAM DDR4-2133, disco duro de 1 Tb.

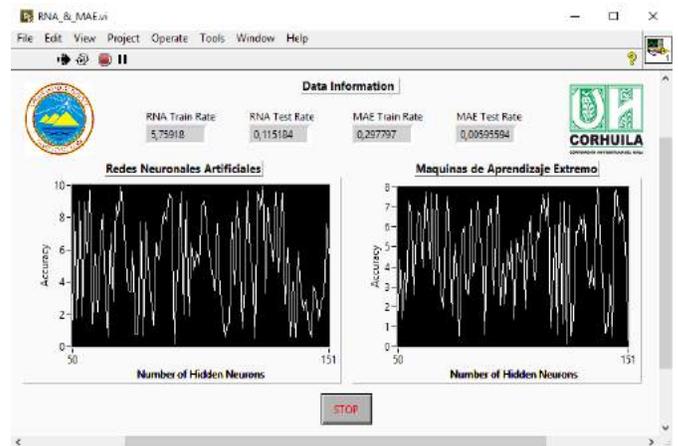


Figura 5. Panel frontal de la interfaz gráfica de usuario diseñada.

2.4 Entrenamiento y Pruebas en RNA y MAE

Las características extraídas de los datos mioeléctricos obtenidos se presentan como datos de entrenamiento y prueba a implementarse en las redes neuronales artificiales (RNA) y las máquinas de aprendizaje extremo (MAE). En esta investigación, el 80% de los datos presentados a RNA y MAE se tomaron como entrenamiento y el 20% como datos de prueba. La clasificación se realiza utilizando las actualizaciones de los valores de sesgo y el peso según el método Newton-Raphson [11] en RNA. Los parámetros RNA se encontraron según la mejor precisión y estos valores de parámetros se registraron en la Tabla I.

Tabla 1. Mejor parámetro de RNA encontrado durante la investigación.

Mejor parámetro de RNA	
Número de neuronas ocultas	7
Número de época	500
Tasa de aprendizaje	0.45
Coefficiente de impulso	0.15

Usando estos valores, se llevaron a cabo 12 procedimientos de entrenamiento y prueba. Como resultado de estas diez pruebas, se tomaron los promedios de los índices de clasificación. Se logró una clasificación con una precisión de entre el 94.00% y el 94.74% como resultado de las pruebas en MAE y el 87.81% -94.85% RNA. La tasa de precisión y el tiempo de entrenamiento se dieron en la Tabla II.

Tabla II. Comparación de RNA, MAE y tasas promedio de precisión.

	RNA			MAE		
	Entrenamiento (%)	Tiempo (%)	Prueba (%)	Entrenamiento (%)	Tiempo (%)	Prueba (%)
1	94.00	5.24	91.03	94.51	0.28	92,65
2	92.12	8.34	86.08	94.27	0.12	92,88
3	94.26	6.30	90.05	94.01	0.20	92,38
4	89.58	5.55	87.08	94.25	0.12	92,57
5	94.74	5.36	94.25	94.50	0.18	92,71
6	91.77	5.35	92.22	94.50	0.12	92,57
7	87.81	5.38	86.78	94.25	0.18	92,45
8	92.02	5.42	84.11	94.74	0.12	92,76
9	89.30	4.84	85.06	94.25	0.17	92,42
10	94.25	5.09	90.34	94.00	0.13	92,57
11	94.85	8.08	91.01	94.51	0.18	92,65
12	88.45	7.32	89.67	94.27	0.14	92,88
Promedio	91.93	6.02	88.97	94.31	0.16	92.61

3. Resultados

Se pueden usar múltiples capas ocultas en una RNA dependiendo de la complejidad del procesamiento. Utilizando dos capas ocultas se obtuvieron los mejores resultados. Así mismo, existen algunos parámetros del sistema que afectan directamente la clasificación en RNA, como lo son la tasa de aprendizaje, el coeficiente de impulso, el número de neuronas ocultas y el número de iteraciones.

Al variar estos parámetros, se pretende reducir el error del sistema al mínimo. En las figuras 6, 7 y 8 muestran gráficamente los valores de precisión obtenidos al cambiar estos valores dentro de un cierto rango para RNA. Podemos observar que en la gráfica de la tasa de precisión según el número de neuronas el porcentaje no sobrepasa el 95%, en un máximo de 12 neuronas ocultas. Así mismo, la mayor tasa de precisión se obtuvo solamente cuando existió el menor número de épocas en la RNA, alcanzando un 97%, valor que concuerda con la literatura según [7], [8].

Las MAE son un método que no depende de la iteración. Es decir, no hay limitación de parámetros en el método MAE, aunque hay muchas limitaciones de parámetros en el método RNA. Por consiguiente, los valores Beta (β) del MAE, se calculan independientemente a partir de la iteración. El número de neuronas ocultas es el factor que afecta el rendimiento en el método MAE. El gráfico de precisión obtenido al cambiar el número de neuronas ocultas dentro de un cierto rango se muestra en la figura 9.

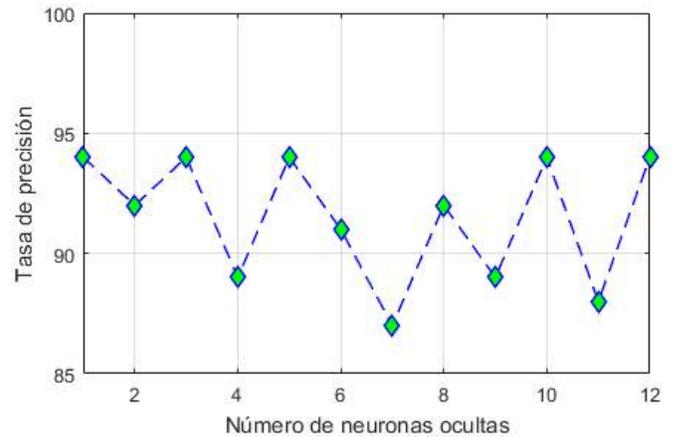


Figura 6. Tasa de precisión según el número de neuronas ocultas.

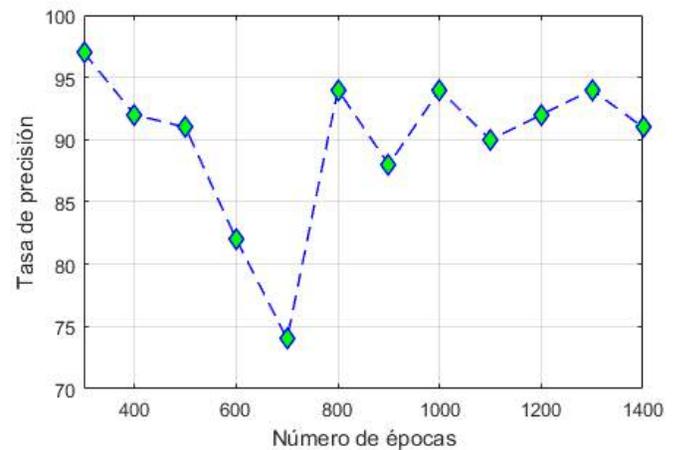


Figura 7. Tasa de precisión según el número de épocas.

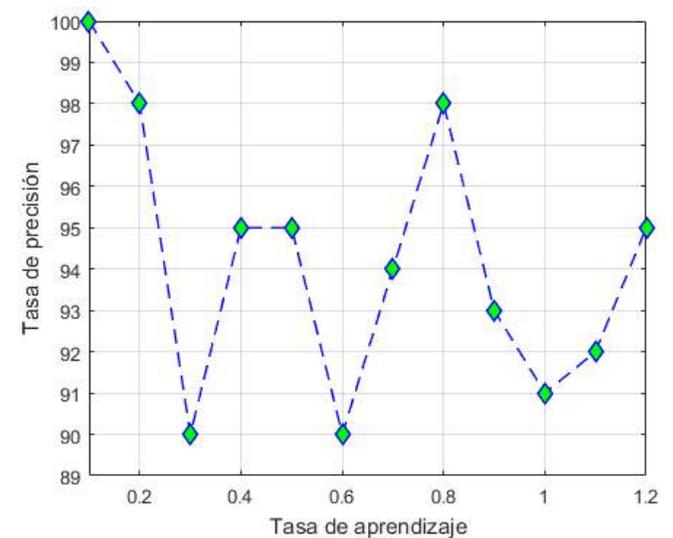


Figura 8. Tasa de precisión según la tasa de aprendizaje.

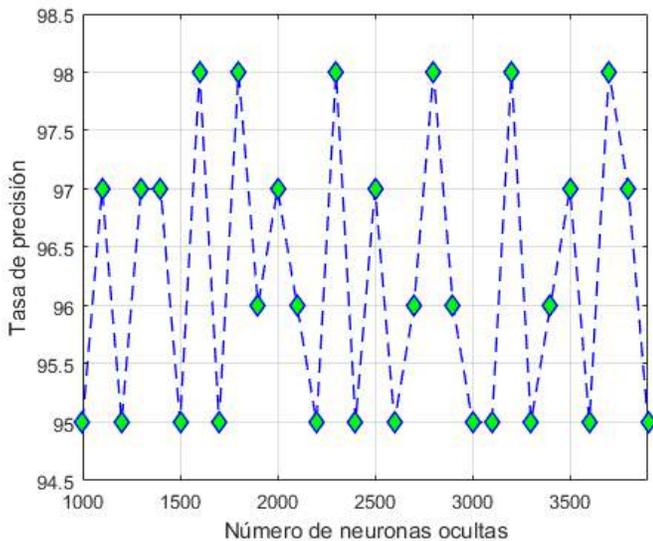


Figura 9. Valores de precisión según el número de neuronas ocultas para MAE.

4. Conclusiones

Los valores de precisión promedio se alcanzan como 94.85% para RNA en el tiempo de cálculo de 8.05 segundos y 94.74% para MAE en el tiempo de cálculo 0.12 segundos. Cuando se toma en cuenta el valor medio y los resultados obtenidos con las 12 pruebas, la varianza de la tasa de precisión de MAE es 0.0479, aunque la varianza de la relación de precisión RNA es 6.6466. Esto sugiere que el MAE será más estable en las respuestas del brazo robótico. También en aplicaciones en tiempo real, el tiempo de reacción del brazo robótico es muy importante. Aquí, la velocidad de aprendizaje de MAE es aproximadamente 67 veces más rápida que la de RNA. Por lo tanto, MAE será más efectivo en aplicaciones en tiempo real. Para concluir, se puede decir que MAE es una mejor opción que RNA en situaciones donde las reacciones son rápidas y precisas.

5. Referencias

[1] Chevtchenko, S. F., Vale, R. F., Macario, V., & Cordeiro, F. R. (2018). A convolutional neural network with feature fusion for real-time hand posture recognition. *Applied Soft Computing*, 73, 748-766.

[2] Mazhar, O., Ramdani, S., Navarro, B., Passama, R., & Cherubini, A. (2018, October). Towards Real-time Physical Human-Robot Interaction using Skeleton Information and Hand Gestures. In 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (pp. 1-6). IEEE.

[3] Wang, J., Ren, H., Chen, W., & Zhang, P. (2015, August). A portable artificial robotic hand controlled by EMG signal using ANN classifier. In 2015 IEEE International Conference on Information and Automation (pp. 2709-2714). IEEE.

[4] Duan, F., Ren, X., & Yang, Y. (2018). A Gesture Recognition System Based on Time Domain Features and Linear Discriminant Analysis. *IEEE Transactions on Cognitive and Developmental Systems*.

[5] Nishad, A., Upadhyay, A., Pachori, R. B., & Acharya, U. R. (2019). Automated classification of hand movements using tunable-Q wavelet transform based filter-bank with surface electromyogram signals. *Future Generation Computer Systems*, 93, 96-110.

[7] Wu, W., Wu, Q. J., Sun, W., Yang, Y., Yuan, X., Zheng, W. L., & Lu, B. L. (2018). A regression method with subnetwork neurons for vigilance estimation using EOG and EEG. *IEEE Transactions on Cognitive and Developmental Systems*.

[8] Huang, G., Huang, G. B., Song, S., & You, K. (2015). Trends in extreme learning machines: A review. *Neural Networks*, 61, 32-48.

[9] Sovilj, D., Eiroola, E., Miche, Y., Björk, K. M., Nian, R., Akusok, A., & Lendasse, A. (2016). Extreme learning machine for missing data using multiple imputations. *Neurocomputing*, 174, 220-231.

[10] Serrezuela, R. R., Trujillo, J. L. A., Delgado, D. R., Benavides, V. K. O., Zamora, R. S., & Reyes, E. M. (2018, September). Diseño e implementación de una prótesis de mano robótica antropomórfica subactuada. In *Memorias de Congresos UTP* (pp. 165-172).

[11] Rojas, J. H. C., Serrezuela, R. R., López, J. A. Q., & Perdomo, K. L. R. (2016). LQR hybrid approach control of a robotic arm two degrees of freedom. *International Journal of Applied Engineering Research*, 11(17), 9221-9228.

[12] Cao, W., Wang, X., Ming, Z., & Gao, J. (2018). A review on neural networks with random weights. *Neurocomputing*, 275, 278-287.