

Artículo original

**Redes neuronales y biopotenciales
musculares: Hacia un control más natural
de prótesis mioeléctricas**

**Neural Networks and Muscle Bio-potentials: Towards a
More Natural Control of Myoelectric Prosthetics**

GERSON MOISES NIZAMA SILVA¹

 <https://orcid.org/0009-0003-7478-8291>

TITO LEONCIO CÓRDOVA MIRANDA²

 <https://orcid.org/0000-0001-5060-0221>

Recibido: 4/9/2024

Aceptado: 12/10/2024

Publicado: 23/10/2024

^{1,2}Escuela Profesional de Ingeniería Electrónica, Universidad Privada de Tacna, Tacna, Perú

E-mail: ¹gersonnizama123@gmail.com, ²tilcordova@upt.pe



Resumen

La innovación tecnológica en el control de prótesis mioeléctricas es esencial para mejorar la funcionalidad de personas con discapacidad motora. Este estudio tuvo como objetivo diseñar e implementar un sistema no invasivo de adquisición de señales electromiográficas (EMG) para clasificar los movimientos básicos de miembros superiores utilizando redes neuronales. La metodología experimental incluyó el diseño de hardware, preparación del sujeto y captura de señales EMG en tres estados de la mano (extendida, relajada, y cerrada). Se utilizaron electrodos desechables con gel conductor en los músculos del antebrazo y una tarjeta SichyRay para amplificar y digitalizar señales a 1 kHz y 10 bits. El procesamiento de las señales incluyó filtros pasa altos (5 Hz) y bajos (450 Hz) y la segmentación en ventanas de 200 ms. Se emplearon Google Colab, TensorFlow y Scikit-learn para análisis y clasificación de datos. Se evaluaron tres modelos de redes neuronales: una red secuencial (FNN), una red recurrente con LSTM (RNN) y una red convolucional (CNN), cada uno entrenado durante 50 épocas. La CNN demostró ser el modelo más preciso, con una precisión del 92,69 % y la menor tasa de pérdida (7,31 %), superando a la red secuencial (91,86 %) y la RNN (90,95 %). Estos resultados destacan la superioridad de las redes convolucionales en la clasificación de señales EMG.

Palabras clave: biopotenciales musculares; inteligencia artificial; redes neuronales; señales EMG.

Abstract

Technological innovation in the control of myoelectric prostheses is essential for improving the functionality of people with motor disabilities. This study aimed to design and implement a non-invasive system for acquiring electromyographic (EMG) signals to classify basic upper limb movements using neural networks. The experimental methodology included hardware design, subject preparation, and EMG signal capture in three hand states (extended, relaxed, and closed). Disposable electrodes with conductive gel were placed on the forearm muscles, and a SichyRay board was used to amplify and digitize signals at 1 kHz and 10 bits. Signal processing included high-pass filters (5 Hz), low-pass filters (450 Hz), and segmentation into 200 ms windows. Google Colab, TensorFlow, and Scikit-learn were used for data analysis and classification. Three neural network models were evaluated: a feedforward neural network (FNN), a recurrent network with LSTM (RNN), and a convolutional neural network (CNN), each trained for 50 epochs. The CNN proved to be the most accurate model, with an accuracy of 92.69 % and the lowest loss rate (7.31 %), outperforming the feedforward network (91.86 %) and the RNN (90.95 %). These results highlight the superiority of convolutional networks in EMG signal classification.

Keywords: muscular biopotentials; artificial intelligence; neural networks; EMG signals.



1. Introducción

El desarrollo de tecnologías avanzadas en el campo de las prótesis ha sido una prioridad en la investigación médica y tecnológica desde hace décadas. Estas innovaciones han permitido a personas con discapacidades motoras, especialmente aquellas que han sufrido la pérdida de extremidades, recuperar en gran medida la capacidad de realizar actividades cotidianas (Trent et al., 2020). Las primeras prótesis, que datan de siglos atrás, eran dispositivos mecánicos simples que proporcionaban un soporte básico, pero sin movimiento funcional. Sin embargo, con los avances en ingeniería biomédica, robótica e inteligencia artificial, las prótesis modernas han evolucionado considerablemente, permitiendo a los usuarios realizar movimientos más precisos y naturales (Bates et al., 2020; Childress, 1985; Roche et al., 2014). Su desarrollo es fundamental porque mejora significativamente la calidad de vida de quienes han perdido una extremidad, ya sea por causas congénitas, accidentes o enfermedades. Estas personas, además de enfrentar desafíos físicos, muchas veces experimentan limitaciones psicológicas y sociales. Contar con una prótesis avanzada no solo les permite recuperar funcionalidad, sino también una mayor independencia, facilitando su reintegración en la sociedad y en el entorno laboral (Turner et al., 2022; von Kaeppler et al., 2021). A medida que las tecnologías avanzan, el acceso a prótesis más complejas y eficientes se expande, beneficiando no solo a los individuos en países desarrollados, sino también en regiones con menos recursos, donde históricamente estas tecnologías han sido limitadas.

Sin embargo, a pesar de los avances en el diseño y funcionalidad de estas prótesis, muchos dispositivos actuales todavía enfrentan limitaciones en términos de precisión, accesibilidad y costo. Uno de los avances más importantes en este ámbito ha sido el desarrollo de las prótesis mioeléctricas, que utilizan señales electromiográficas (EMG) para controlar los movimientos. Estas prótesis captan las señales eléctricas generadas por los músculos cuando se contraen, permitiendo que el usuario controle la prótesis de manera más intuitiva. A diferencia de las prótesis mecánicas tradicionales, que requieren acciones físicas o movimientos corporales externos para ser operadas, las prótesis mioeléctricas pueden leer la actividad muscular directamente desde el cuerpo. Este tipo de control facilita un uso más fluido y natural, acercando la funcionalidad de la prótesis a los movimientos naturales de una mano o un brazo humano. Las señales EMG, que son la base de estas prótesis, provienen de la actividad bioeléctrica de los músculos y pueden ser captadas de forma no invasiva mediante electrodos colocados en la superficie de la piel (Chen et al., 2023; Igual et al., 2019; Li, 2011). Pero estas señales, son propensas a interferencias y ruidos, ya que factores como el desplazamiento de los electrodos, la fatiga muscular o incluso el ambiente externo pueden afectar la calidad de las señales capturadas (Chadwell et al., 2016).

Ante estos desafíos, la incorporación de inteligencia artificial (IA) y redes neuronales ha emergido como una solución prometedora para mejorar el rendimiento de las prótesis mioeléctricas. Las redes neuronales, un tipo de modelo computacional inspirado en el funcionamiento del cerebro humano, tienen la capacidad de procesar grandes volúmenes de datos y reconocer patrones complejos. Aplicadas en el campo de la bioingeniería, permiten analizar las señales EMG con una precisión y eficiencia mucho mayores que los métodos tradicionales. Al ser entrenadas con datos de diferentes movimientos, estas redes pueden aprender a predecir qué acción desea realizar el usuario basándose en las señales captadas por los músculos (Jiang et al., 2023; Nayak y Kumar Das, 2020). Por lo tanto, el objetivo del estudio

fue diseñar e implementar un sistema de adquisición de señales EMG no invasivo, capaz de reconocer y clasificar los patrones de biopotenciales musculares mediante redes neuronales.

2. Metodología

2.1. Proceso de preparación, captura y almacenamiento de señales EMG

El diseño se enfocó en la recolección de señales EMG de una persona sana, sin antecedentes de patologías musculoesqueléticas o neuromusculares. Tras obtener el consentimiento informado, el área del antebrazo fue preparada con alcohol isopropílico para reducir la impedancia entre la piel y los electrodos, garantizando la calidad de las señales. Se realizaron pruebas preliminares para asegurar que el participante comprendiera y ejecutara correctamente los movimientos requeridos (mano extendida, mano relajada, mano cerrada), instruyéndolo sobre cómo mantener cada postura. Los electrodos se colocaron en los músculos flexores y extensores del antebrazo, con una separación de 30 mm, usando electrodos desechables con gel conductor (marca 3M) para optimizar la captación de señales mioeléctricas. Los electrodos de potencial se situaron sobre los músculos específicos, y el electrodo de referencia se colocó en una prominencia ósea para reducir interferencias. Durante todo el proceso, se aseguraron las condiciones de seguridad para el sujeto de prueba, siguiendo los protocolos establecidos para estudios con señales biológicas.

La adquisición de señales se realizó mediante la tarjeta SicheyRay, con capacidad de amplificación y digitalización de señales EMG a 1 kHz y 10 bits de resolución. Se capturaron señales durante tres segundos para cada movimiento, repitiendo el proceso en múltiples sesiones para minimizar efectos de fatiga muscular y otras variables externas. Previo a la adquisición, la ganancia de la tarjeta fue ajustada manualmente para evitar distorsiones. Las señales obtenidas se almacenaron en archivos CSV y se procesaron mediante herramientas especializadas (Google Colab, con librerías de Python como TensorFlow y Scikit-learn), lo que facilitó el análisis y clasificación posterior de los datos.

2.2. Procesamiento de datos

El preprocesamiento de las señales EMG implicó la aplicación de filtros digitales para mejorar la calidad de las señales, eliminando interferencias y ruido provenientes de diversas fuentes. Se utilizó un filtro pasa altos con una frecuencia de corte de 5 Hz para suprimir el ruido de baja frecuencia y un filtro pasa bajos de 450 Hz para eliminar interferencias de alta frecuencia. Estos filtros se implementaron utilizando herramientas de procesamiento de señales en Python empleando las librerías SciPy y NumPy. Posteriormente, las señales se segmentaron en ventanas de 200 ms para representar diferentes estados de la mano. A partir de estas ventanas, se extrajeron características clave, como el valor absoluto medio (MAV), la raíz cuadrada media (RMS), la frecuencia media (MNF) y los cruces por cero (ZC). Estas características proporcionaron información valiosa sobre la amplitud, energía, frecuencia dominante y tasa de contracción muscular. Para asegurar un tratamiento equitativo de las características, los datos fueron normalizados, escalando todos los valores a una media de cero y desviación estándar de uno. Además, se realizó un análisis de correlación para identificar las características más relevantes, lo que permitió reducir la dimensionalidad del conjunto de datos y optimizar el proceso de clasificación de los movimientos de la mano.



2.3. Modelado y entrenamiento de redes neuronales

Los datos preprocesados fueron divididos en un conjunto de entrenamiento (80 %) y un conjunto de validación (20 %), asegurando una representación equitativa de los tres estados de la mano en ambas particiones. Se implementaron tres tipos de redes neuronales con arquitecturas específicas. La Red Neuronal Secuencial (Feedforward Neural Network) constaba de una capa de entrada con cuatro neuronas, dos capas ocultas con ocho neuronas cada una, y una capa de salida con tres neuronas, utilizando la función de activación ReLU en las capas ocultas y Softmax en la capa de salida. Se aplicó un dropout del 10 % para evitar el sobreajuste. La Red Neuronal Recurrente (RNN) incluyó una capa LSTM con cuatro unidades para procesar secuencias temporales, seguida de capas densas ocultas y una capa de salida similar a la red secuencial, manteniendo las mismas estrategias de regularización y activación. Por último, la Red Neuronal Convolutiva (CNN) empleó una capa convolutiva inicial, seguida de capas de pooling y densas ocultas para capturar patrones espaciales relevantes. Se utilizó un dropout del 50 % antes de la capa de salida para mejorar la generalización.

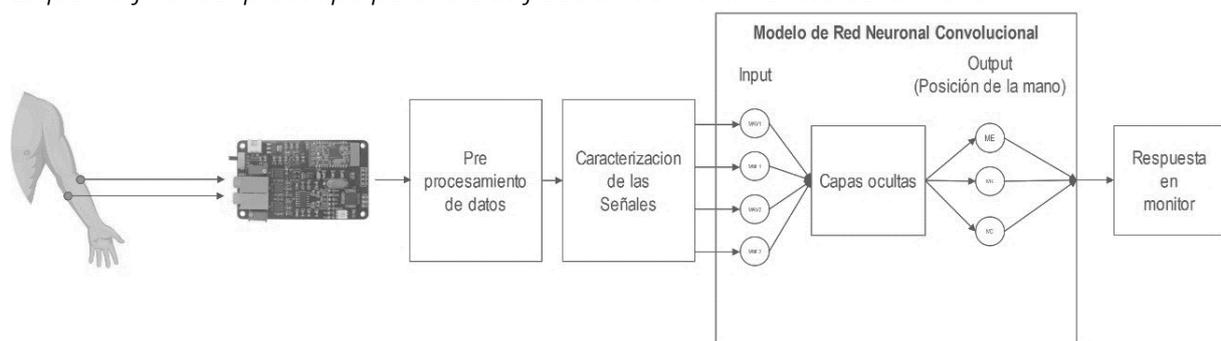
El entrenamiento de cada modelo se llevó a cabo durante 50 épocas, utilizando el optimizador Adam y la función de pérdida Categorical Crossentropy, monitoreando la precisión y la pérdida tanto en los conjuntos de entrenamiento como de validación. Para validar la robustez de los modelos, se realizó una validación cruzada con un conjunto de datos independiente, lo que permitió evaluar su rendimiento con datos no vistos y ajustar los hiperparámetros cuando fue necesario.

2.4. Evaluación y comparación de modelos

Se evaluaron los modelos mediante el análisis de las curvas de aprendizaje, observando la evolución de la precisión y la pérdida a lo largo del entrenamiento. La convergencia adecuada de estas curvas reflejó un buen ajuste de los modelos sin indicios de sobreajuste. Para una evaluación más detallada, se construyeron matrices de confusión que permitieron visualizar las clasificaciones correctas e incorrectas en cada modelo. A partir de estas, se calcularon las métricas de desempeño como precisión, sensibilidad, especificidad y F1-score, lo que proporcionó una evaluación cuantitativa de la eficacia de cada red en la clasificación de los movimientos de la mano. Finalmente, se compararon los resultados obtenidos por los tres modelos y se seleccionó el modelo que presentó el mayor precisión y menor tasa de error en la clasificación de los movimientos.

Figura 1

Esquema final del prototipo para la clasificación de movimientos de la mano



2.5. Implementación y pruebas del prototipo final

El modelo seleccionado se integró en el sistema de adquisición, estableciendo una comunicación en tiempo real entre la tarjeta de adquisición y el algoritmo de clasificación. Se desarrolló una interfaz que permitía visualizar los resultados de la clasificación y verificar el correcto funcionamiento del sistema (Figura 1). Se realizaron pruebas funcionales del prototipo, evaluando su capacidad para clasificar correctamente los movimientos de la mano en tiempo real. Se verificó la estabilidad del sistema y se identificaron posibles mejoras o ajustes necesarios.

3. Resultados

Se evaluaron tres modelos de redes neuronales para la clasificación de los movimientos de la mano a partir de señales mioeléctricas (EMG). Los modelos implementados fueron una red neuronal secuencial, una red neuronal recurrente (RNN) con LSTM, y una red neuronal convolucional (CNN). A continuación, se presentan los resultados obtenidos para cada uno de estos modelos.

3.1. Red Neuronal Secuencial (Feedforward Neural Network)

Esta red, mostró un buen desempeño en la clasificación de los movimientos de la mano, alcanzando una precisión global del 91,86 % y 8,14 % de pérdidas. Este modelo fue capaz de distinguir entre los tres estados de la mano (extendida, relajada y cerrada) con un nivel aceptable de precisión. Sin embargo, se observaron algunas confusiones entre los estados de mano extendida y mano cerrada.

En la curva de aprendizaje mostró una mejora constante en la precisión durante las primeras 30 épocas, estabilizándose en torno al 92 %. La curva de validación también mostró un buen comportamiento, sin signos de sobreajuste o subajuste, lo que sugiere que el modelo logró una adecuada generalización (Figura 2a). En la matriz de confusión normalizadas, el modelo logró clasificar correctamente el 85 % de los casos en los que la mano estaba extendida, aunque hubo un 15 % de estos casos que fueron incorrectamente clasificados como mano cerrada. Para el estado de mano relajada, el modelo alcanzó una precisión del 100 %, lo que indica que este estado fue el más fácil de reconocer por el algoritmo. En cuanto a la mano cerrada, la precisión fue del 88 %, con algunos casos clasificados erróneamente como mano extendida (Figura 2b). En el desempeño general, aunque la red secuencial mostró una buena capacidad de generalización, la confusión entre los estados de mano extendida y cerrada sugiere que las características extraídas de estas señales presentan cierta similitud, lo que afectó la precisión en estos casos.

3.2. Red Neuronal Recurrente (RNN con LSTM)

La red neuronal recurrente, diseñada para capturar dependencias temporales en las señales EMG, mostró un desempeño ligeramente inferior al de la red secuencial, obteniendo una precisión del 90,95 % y 9,05 de pérdidas. Este resultado sugiere que las dependencias temporales en las señales no aportaron mejoras significativas en la clasificación de los movimientos de la mano, aunque el modelo logró captar algunos patrones relevantes.



La curva de aprendizaje de este modelo mostró un comportamiento similar al de la red secuencial, con un incremento gradual en la precisión durante las primeras épocas, alcanzando una estabilización en torno al 90 %. Sin embargo, la mejora en la precisión fue menor, lo que indica que el modelo no fue capaz de aprovechar plenamente las secuencias temporales (Figura 3a). En la matriz de confusión normalizada, el modelo clasificó correctamente el 92 % de los casos en los que la mano estaba extendida, con un 8 % de estos casos clasificados incorrectamente como mano cerrada. En el estado de mano relajada, la precisión fue del 95 %, mientras que, en el estado de mano cerrada la precisión disminuyó al 85 %, con el 14 % de los casos clasificados erróneamente como mano extendida (Figura 3b). En el desempeño general, la red recurrente mostró una mayor confusión entre los estados de mano extendida y cerrada, lo que afectó su precisión global. Esto sugiere que las dependencias temporales en las señales mioeléctricas no fueron suficientes para mejorar significativamente la clasificación en comparación con la red secuencial.

Figura 2

Curva de aprendizaje, pérdidas y matriz de confusión normalizada de FNN

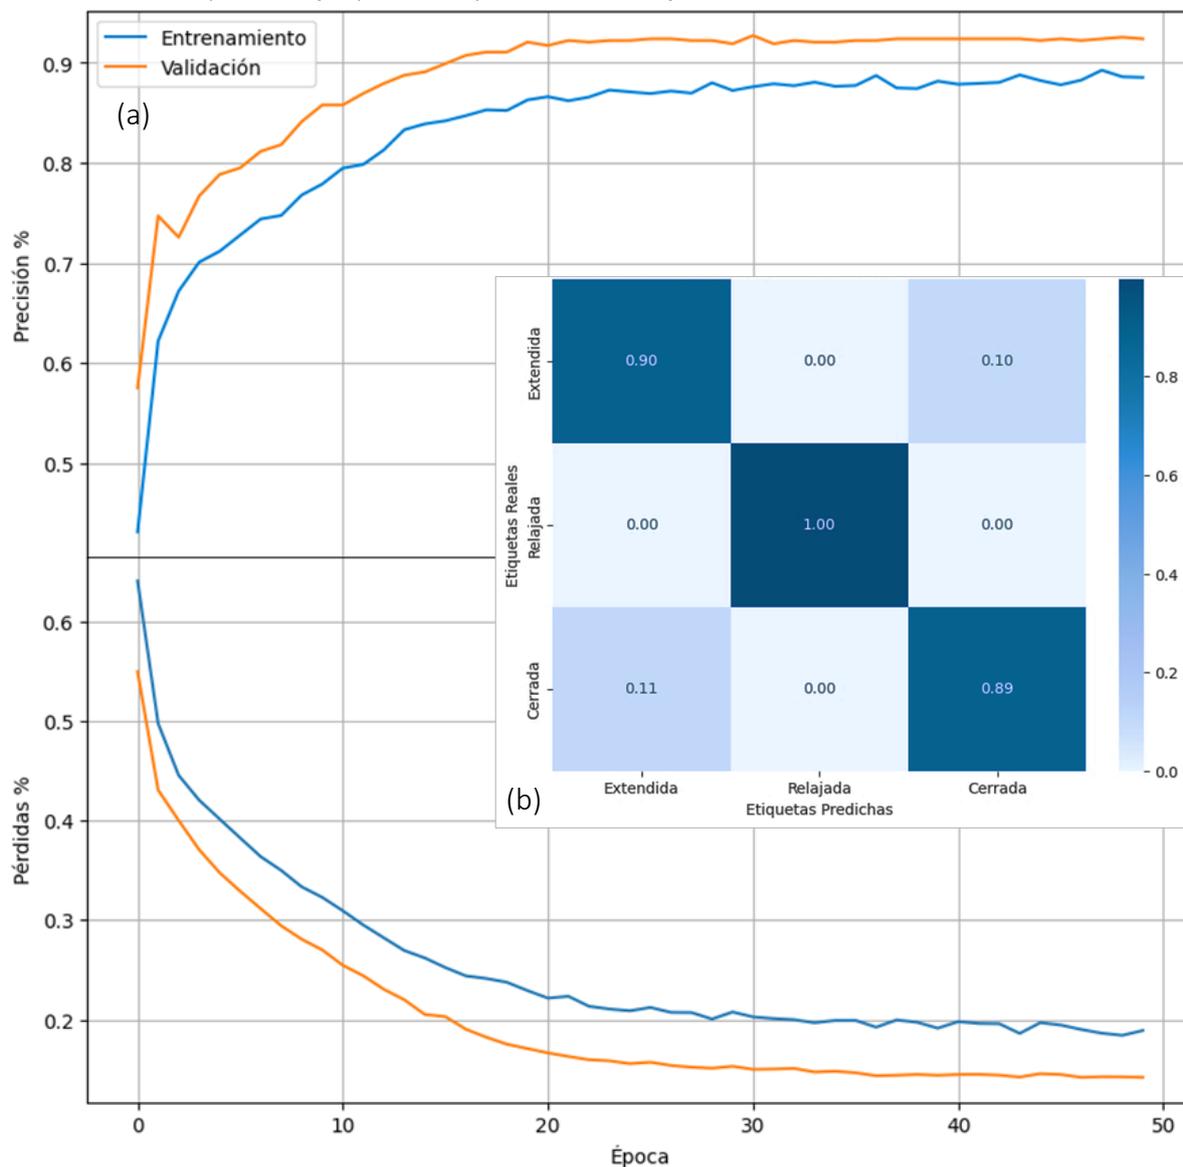
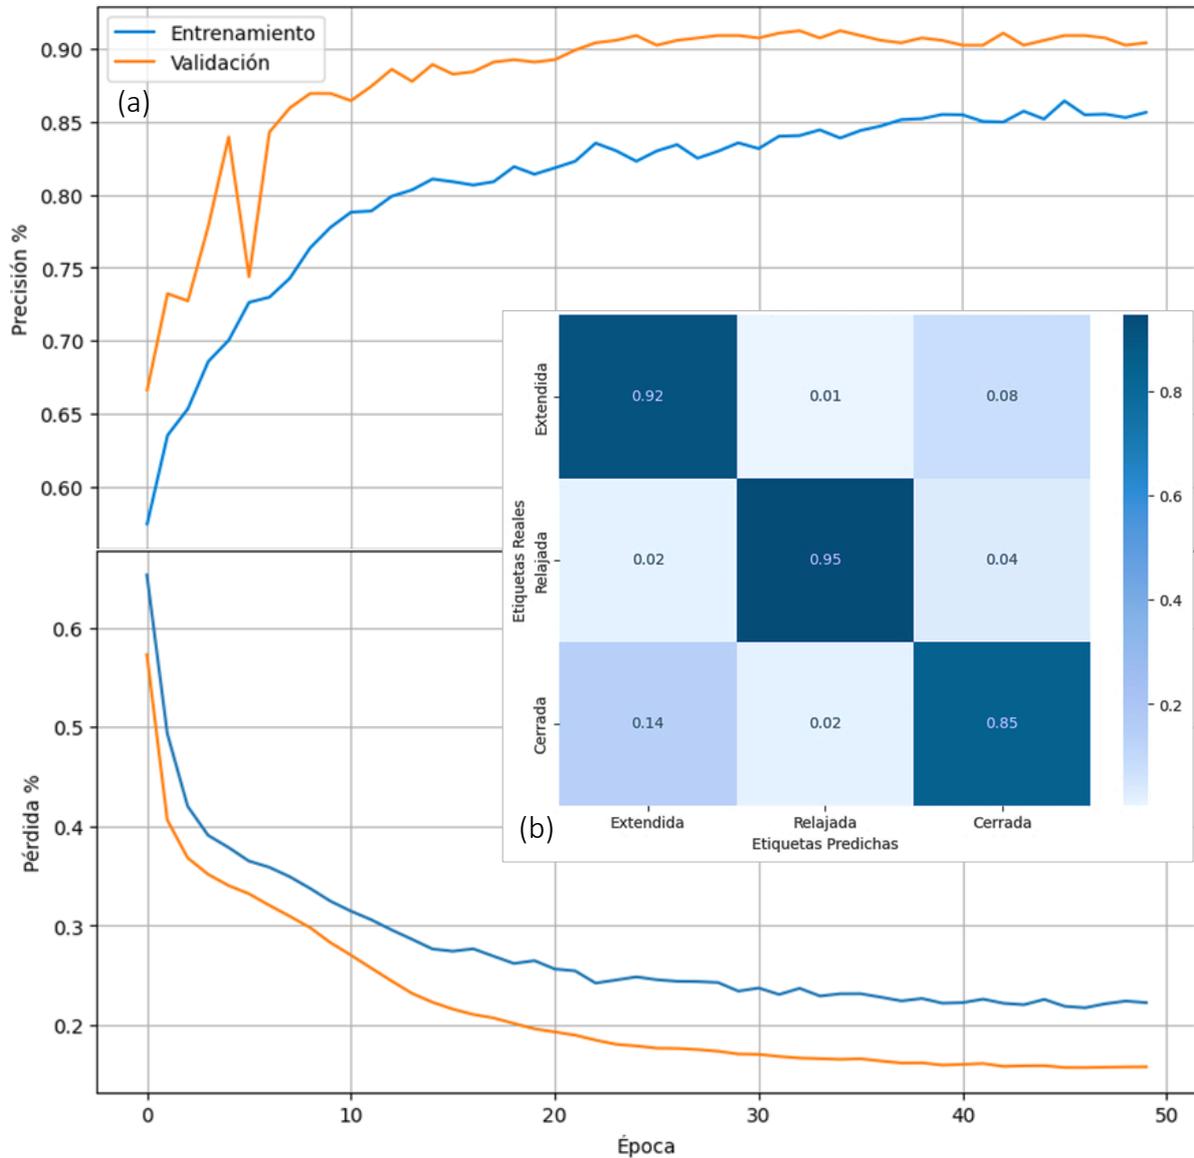


Figura 3

Curva de aprendizaje, pérdidas y matriz de confusión normalizada de RNN



3.3. Red Neuronal Convolutacional (CNN)

El mejor desempeño fue obtenido por la red neuronal convolutacional (CNN), que alcanzó una precisión global del 92,69 % y 7,31 % de pérdidas. Este modelo fue capaz de extraer características espaciales relevantes de las señales EMG, lo que permitió una mejor clasificación de los tres estados de la mano. La CNN mostró un rendimiento superior en comparación con las redes secuenciales y recurrentes, especialmente en la diferenciación de los estados de mano extendida y cerrada.

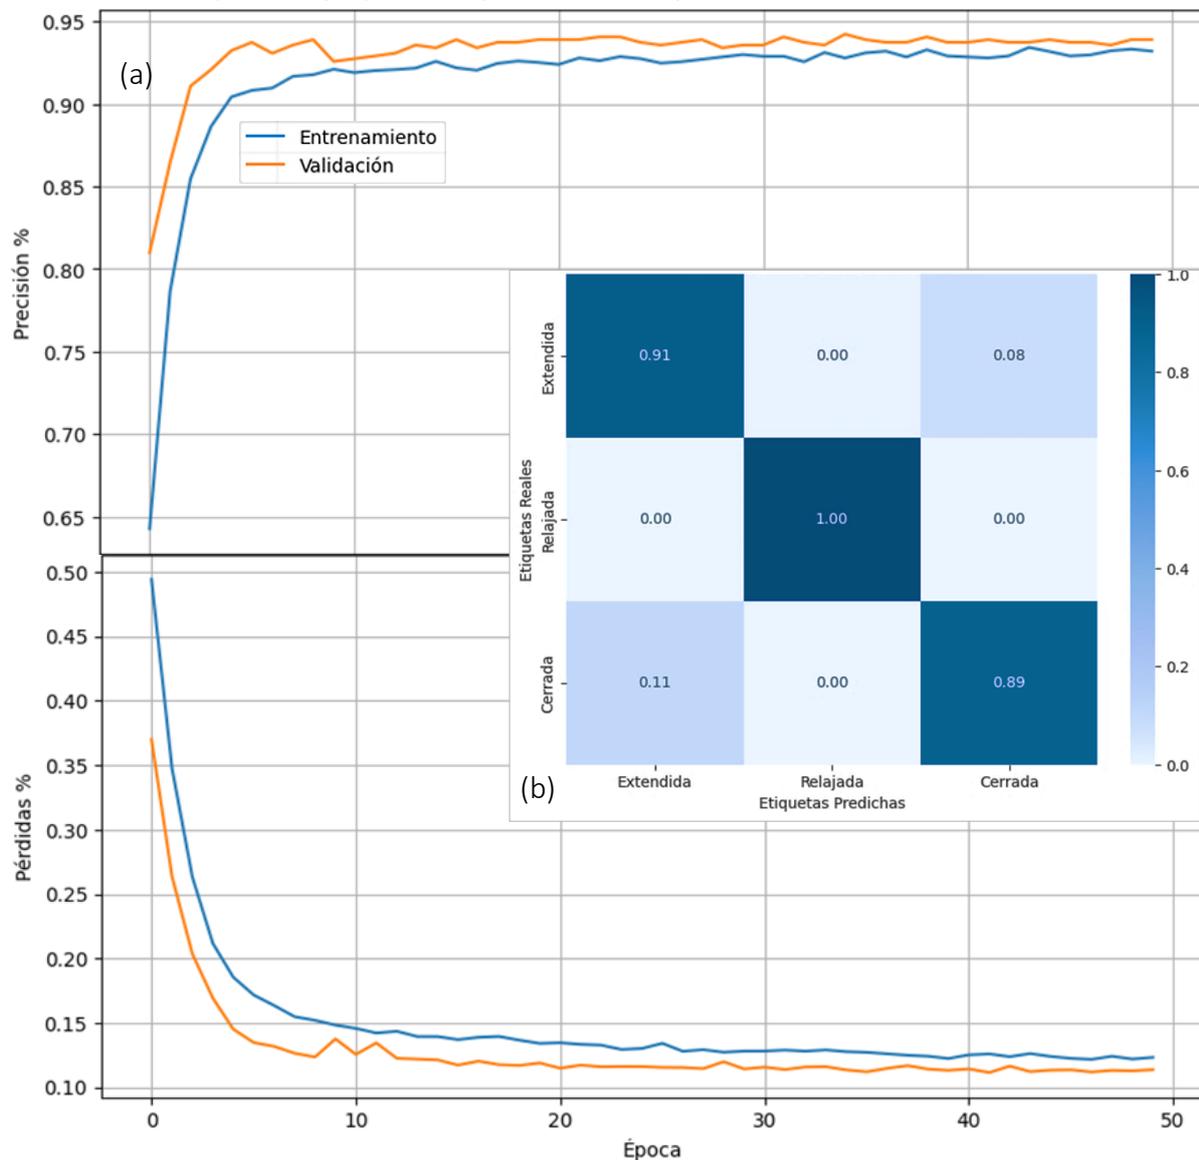
La curva de aprendizaje de la CNN mostró una mejora constante en la precisión durante las primeras 30 épocas, estabilizándose en torno al 92 %. La curva de validación también mostró un buen comportamiento, sin signos de sobreajuste o subajuste, lo que sugiere que el modelo logró una adecuada generalización (Figura 4a). En cuanto a la matriz de confusión normalizada, el modelo clasificó correctamente el 89 % de los casos en los que la mano estaba cerrada, con



un 11 % de estos casos clasificados incorrectamente como mano extendida. En el estado de mano relajada, la precisión fue del 100 %, mientras que, en el estado de mano extendida la precisión fue del 91 %, con algunos casos clasificados erróneamente como mano cerrada (Figura 4b). En el desempeño general, la red convolucional mostró una mejor capacidad para distinguir entre los tres estados de la mano, en particular en la clasificación de las manos cerrada y extendida, que habían presentado problemas en los otros modelos. El uso de capas convolucionales permitió al modelo capturar patrones espaciales más complejos en las señales EMG, lo que resultó en una mejora en la precisión general.

Figura 4

Curva de aprendizaje, pérdidas y matriz de confusión normalizada de CNN



4. Discusión

Al comparar los resultados, se observa que la red convolucional (CNN) fue la más precisa, superando tanto a la red secuencial como a la recurrente. Este mejor desempeño se atribuye a

la capacidad de la CNN para extraer características espaciales esenciales para la diferenciación de los movimientos de la mano. Aunque los otros modelos también lograron buenas precisiones, tuvieron mayores dificultades para clasificar correctamente los movimientos, especialmente en la diferenciación entre los estados de mano extendida y cerrada. Este hallazgo coincide con lo reportado por Gadekallu et al. (2021), quien destacó la capacidad superior de las CNN para captar patrones espaciales complejos en datos biomédicos.

Los resultados también son comparables con los de Sulla (2023), quien empleó sensores Myoware 2.0 y redes neuronales para clasificar movimientos de miembros superiores en 10 participantes, logrando una precisión del 100 % en algunos casos específicos. Aunque la muestra fue más amplia, la precisión obtenida en este estudio sugiere que las CNN pueden generalizar bien a poblaciones mayores. Aun así, un desafío pendiente es la validación del modelo con una muestra más grande. De manera similar, Reátegui (2024) reportó una precisión del 94,80 % en la clasificación de cinco gestos de mano utilizando un algoritmo SVM multiclase, centrado en un sujeto con amputación transradial. Esto abre una oportunidad para expandir la investigación hacia usuarios con discapacidades. En esa línea, Avilés y Gaibor (2021) lograron una precisión del 78,67 % en la clasificación de movimientos de una prótesis robótica controlada por señales EMG. En un contexto diferente, Aayesha et al. (2021) obtuvieron una precisión del 99,1 % en la clasificación de señales EEG para la detección de crisis epilépticas utilizando CNN. Aunque se trate de aplicaciones distintas, estos resultados refuerzan la capacidad de las CNN para mejorar la precisión en el reconocimiento de patrones en señales biomédicas.

Pese al rendimiento del sistema, se identificaron limitaciones, como el uso de un solo sujeto de prueba, lo que podría restringir la generalización de los resultados. En futuros trabajos, sería beneficioso ampliar la muestra y considerar personas con diferentes características físicas y condiciones musculares. Además, el uso de arquitecturas más avanzadas como redes neuronales profundas, redes generativas adversarias (GANs) o modelos híbridos que combinen CNN y LSTM podría permitir una interpretación más precisa de las señales electromiográficas (EMG), mejorando así la clasificación de los movimientos.

5. Conclusiones

La red neuronal convolucional fue el modelo más adecuado para la clasificación de los movimientos de la mano a partir de señales EMG. Con una precisión del 92,69 %, este modelo demostró ser más efectivo en la extracción de patrones relevantes de las señales mioeléctricas, lo que sugiere que es una opción prometedora para su implementación en aplicaciones prácticas, como el control de prótesis mioeléctricas. Las confusiones observadas entre los estados de mano extendida y cerrada, aunque menores, sugieren que futuras mejoras podrían incluir el uso de arquitecturas híbridas o el ajuste fino de los hiperparámetros para optimizar aún más la precisión del sistema.

6. Referencias Bibliográficas

Aayesha, Qureshi, M. B., Afzaal, M., Qureshi, M. S., y Fayaz, M. (2021). Machine learning-based EEG signals classification model for epileptic seizure detection. *Multimedia Tools and Applications*, 80(12), 17849–17877. <https://doi.org/10.1007/s11042-021-10597-6>



- Avilés, K. P. y Gaibor N. G. (2021). *Diseño e implementación de una prótesis robótica con señales EMG usando técnicas de Inteligencia Artificial* [Tesis de pregrado, Escuela Superior Politécnica del Litoral]. <https://www.dspace.espol.edu.ec/handle/123456789/54698>
- Bates, T. J., Ferguson, J. R., y Pierrie, S. N. (2020). Technological advances in prosthesis design and rehabilitation following upper extremity limb loss. *Current Reviews in Musculoskeletal Medicine*, 13(4), 485–493. <https://doi.org/10.1007/s12178-020-09656-6>
- Chadwell, A., Kenney, L., Thies, S., Galpin, A., y Head, J. (2016). The reality of myoelectric prostheses: Understanding what makes these devices difficult for some users to control. *Frontiers in neurorobotics*, 10. <https://doi.org/10.3389/fnbot.2016.00007>
- Chen, Z., Min, H., Wang, D., Xia, Z., Sun, F., y Fang, B. (2023). A review of myoelectric control for prosthetic hand manipulation. *Biomimetics (Basel, Switzerland)*, 8(3), 328. <https://doi.org/10.3390/biomimetics8030328>
- Childress, D.S. (1985). Historical aspects of powered limb prostheses. *Prosthet Orthot.*, 9, 2–13. http://www.oandplibrary.org/cpo/1985_01_002.asp
- Gadekallu, T. R., Alazab, M., Kaluri, R., Maddikunta, P. K. R., Bhattacharya, S., Lakshmana, K., y Parimala. (2021). Hand gesture classification using a novel CNN-crow search algorithm. *Complex & Intelligent Systems*, 7(4), 1855–1868. <https://doi.org/10.1007/s40747-021-00324-x>
- Igual, C., Pardo, L. A., Jr, Hahne, J. M., y Igual, J. (2019). Myoelectric control for upper limb prostheses. *Electronics*, 8(11), 1244. <https://doi.org/10.3390/electronics8111244>
- Jiang, N., Chen, C., He, J., Meng, J., Pan, L., Su, S., y Zhu, X. (2023). Bio-robotics research for non-invasive myoelectric neural interfaces for upper-limb prosthetic control: a 10-year perspective review. *National Science Review*, 10(5). <https://doi.org/10.1093/nsr/nwad048>
- Li, G. (2011). Electromyography pattern-recognition-based control of powered multifunctional upper-limb prostheses. En *Advances in Applied Electromyography*. InTech. <https://doi.org/10.5772/22876>
- Nayak, S., y Kumar Das, R. (2020). Application of Artificial Intelligence (AI) in Prosthetic and Orthotic rehabilitation. En *Service Robotics*. IntechOpen. <https://doi.org/10.5772/intechopen.93903>
- Reategui, J. E. (2024). *Diseño e implementación de un sistema embebido portátil para la adquisición y procesamiento de señales electromiográficas del antebrazo* [Tesis de pregrado, Pontificia Universidad Católica del Perú]. <https://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/27800>
- Roche, A. D., Rehbaum, H., Farina, D., y Aszmann, O. C. (2014). Prosthetic myoelectric control strategies: A clinical perspective. *Current Surgery Reports*, 2(3). <https://doi.org/10.1007/s40137-013-0044-8>
- Sulla, E. (2023). *Prótesis de brazo electromiográfico intuitivo asistido con inteligencia artificial* [Tesis de maestría, Universidad Nacional de San Agustín de Arequipa]. <https://goo.su/Jl7nnwC>

- Trent, L., Intintoli, M., Prigge, P., Bollinger, C., Walters, L. S., Conyers, D., Miguelez, J., y Ryan, T. (2020). A narrative review: current upper limb prosthetic options and design. *Disability and Rehabilitation. Assistive Technology*, 15(6), 604–613. <https://doi.org/10.1080/17483107.2019.1594403>
- Turner, S., Belsi, A., y McGregor, A. H. (2022). Issues faced by people with amputation(s) during lower limb prosthetic rehabilitation: A thematic analysis. *Prosthetics and Orthotics International*, 46(1), 61–67. <https://doi.org/10.1097/pxr.0000000000000070>
- von Kaeppler, E. P., Hetherington, A., Donnelley, C. A., Ali, S. H., Shirley, C., Challa, S. T., Lutyens, E., Haonga, B. T., Morshed, S., Andrysek, J., y Shearer, D. W. (2021). Impact of prostheses on quality of life and functional status of transfemoral amputees in Tanzania. *African Journal of Disability*, 10. <https://doi.org/10.4102/ajod.v10i0.839>