

## Aproximación de señales ECG y EEG mediante redes neuronales de pulso

Omar Samperio-Vázquez<sup>1</sup>, Juan Carlos González-Islas<sup>1</sup>,  
Luis Enrique Ramos-Velasco<sup>2</sup>, Jesus Patricio Ordaz-Oliver<sup>1</sup>,  
Gildardo Godinez-Garrido<sup>1,3</sup>

Universidad Autónoma del Estado de Hidalgo,  
Hidalgo,  
México

Universidad Metropolitana del Estado de Hidalgo,  
Hidalgo,  
México

Universidad Tecnológica de Tulancingo,  
Hidalgo,  
México

{omarsamvaz, juan\_gonzalez7024, jesus\_ordaz}@uaeh.edu.mx,  
lramos@upmh.edu.mx, gildardo.godinez@utectulancingo.edu.mx

**Resumen.** La aproximación de señales, como el electrocardiograma, el electroencefalograma y el electromiograma (ECG, EEG, por sus siglas en inglés, Electrocardiography, Electroencephalography) mediante modelos matemáticos o computacionales es un área de interés para aplicaciones médicas. En este trabajo de investigación se propone una arquitectura de redes neuronales de pulso para la aproximación de señales fisiológicas electroencefalográficas y electrocardiográficas. En la arquitectura se emplea una señal de persistencia con la finalidad de evitar singularidades del algoritmo de entrenamiento. El esquema propuesto puede ser generalizado y aplicado para aproximar otro tipo de señales tanto fisiológicas como biomecánicas del cuerpo humano con fines de diagnóstico o evaluación de anomalías.

**Palabras clave:** Redes neuronales de pulso, señales fisiológicas, ECG, EEG.

## Approximation of ECG and EEG Signals through Spiking Neural Networks

**Abstract.** The approximation of signals, such as ECG, and EEG (Electrocardiography, Electroencephalography) using mathematical or computational models is an area of interest for medical applications. In this research work, an architecture of pulse neural networks is proposed for the approximation of electroencephalographic and electrocardiographic physiological signals. In the architecture, a persistence signal is used in order to avoid singularities in the training algorithm. The proposed scheme can

be generalized and applied to approximate other types of physiological and biomechanical signals from the human body for the purposes of diagnosis or evaluation of anomalies.

**Keywords:** Spiking neural networks, physiological signals, ECG, EEG.

## 1. Introducción

El modelado matemático y la simulación computacional de señales fisiológicas del cuerpo humano como lo son: el electrocardiograma, el electroencefalograma y el electromiograma (ECG, EEG y EMG, por sus siglas en inglés, Electrocardiography, Electroencephalography, y Electromyography respectivamente), representan un campo de investigación emergente y de sumo interés. Dichas señales fisiológicas son utilizadas por los médicos para diagnosticar el comportamiento normal o irregular de los órganos humanos como el corazón y el cerebro, entre otros [14, 13, 24]. La generación de señales ECG, es ampliamente usado para la prueba, calibración y mantenimiento de equipo de electrocardiografía.

Las señales generadas son mayormente señales ideales y generalmente no se aproximan a las señales reales que contienen ruido [3, 23]. Existen diferentes métodos para generar señales ECG como los basados en: derivadas fraccionarias [6], ecuaciones dinámicas [4], ecuaciones estáticas [15], polinomios de Chebyshev [5, 26]; así como, señales reales almacenadas en bases de datos de ECG [11].

De igual manera, se han reconstruido señales ECG a partir de la adquisición con la plataforma Shimmer y los algoritmos de Emparejamiento orthogonal (OMP por sus siglas en inglés, Orthogonal Matching Pursuit) [12]; o con el uso de un filtro de media móvil y la eliminación de los cruces por cero [25]. En cuanto a las señales de EEG son útiles para monitorear las actividades cerebrales para tareas médicas (detección de convulsiones) y cognitivas (reconocimiento de emociones, interfaz cerebro-computadora). Por lo que el sensado, procesamiento y reconstrucción son de sumo interés para la comunidad científica [20, 22].

Para reconstruir muestras de las señales EEG se han usado redes Neuronales Artificiales de segunda generación (ANN por sus siglas en inglés, Artificial Neural Networks) utilizando subconjuntos de registros de señales pregrabadas [17]. Las redes neuronales de pulso también llamadas redes neuronales de tercera generación (SNN por sus siglas en inglés, Spiking Neural Networks) representan una clase especial de las redes neuronales artificiales, donde los modelos de neuronas se comunican mediante secuencias de pulsos como lo hacen los órganos biológicos [10].

Las redes compuestas de neuronas con pulsos son capaces de procesar una cantidad sustancial de datos utilizando un número relativamente pequeño de pulsos, lo que reduce el tiempo de procesamiento y el consumo de energía [27]. Las SNN resuelven una variedad de problemas específicos en ingeniería aplicada, como el procesamiento rápido de señales, la detección de eventos, la clasificación, el reconocimiento de voz, la navegación espacial o el control de motores. Se ha demostrado que las SNN se puede aplicar no sólo a todos los problemas que pueden resolverse mediante redes neuronales

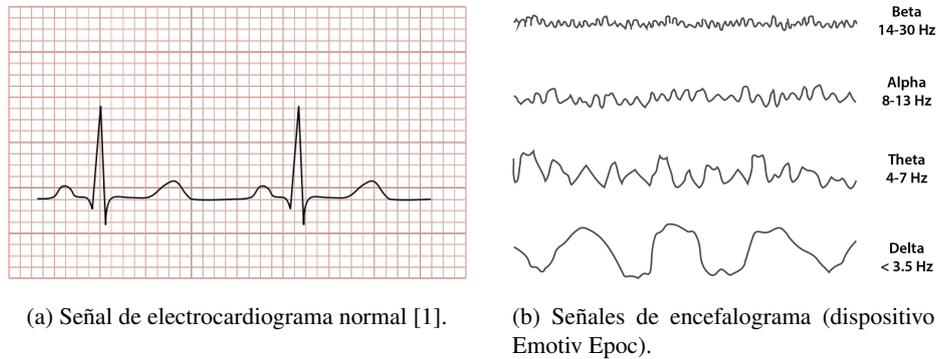


Fig. 1. Señales fisiológicas ECG y EEG.

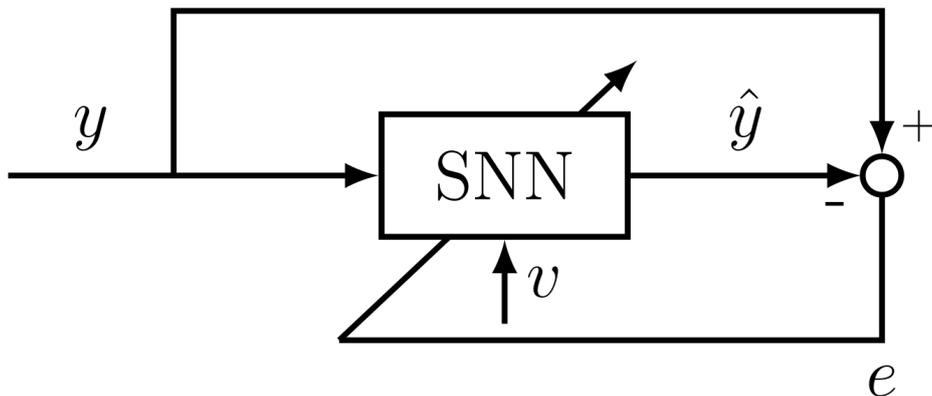


Fig. 2. Esquema propuesto para la aproximación de señales ECG y EEG.

artificiales de segunda generación, sino que los modelos con pulsos son de hecho computacionalmente más poderosos que los perceptrones y las compuertas sigmoidales [19]. Enfoques recientes, han usado SNNs para aproximar de manera eficiente señales electrofisiológicas grabadas, usando una estrategia de cómputo evolutivo y programación de expresión de genes [8, 7]. Los principales desafíos en la generación, síntesis, aproximación o reconstrucción de señales fisiológicas, se centra en tareas de detección, sensado, procesamiento y almacenamiento, con un error mínimo y bajo consumo de energía.

Por tanto, en este trabajo de investigación se propone una arquitectura de redes neuronales de pulso, para la aproximación de señales médicas electroencefalográficas y electrocardiográficas. La organización del resto del artículo está dada de la siguiente manera: en la Sección 2 se presentan el esquema propuesto para la aproximación de las señales biológicas y los diagramas de las SNN, mientras que en la Sección 3 se dan los resultados obtenidos de la aproximación de las señales ECG y EEG, finalmente las conclusiones se enuncian en la Sección 4.

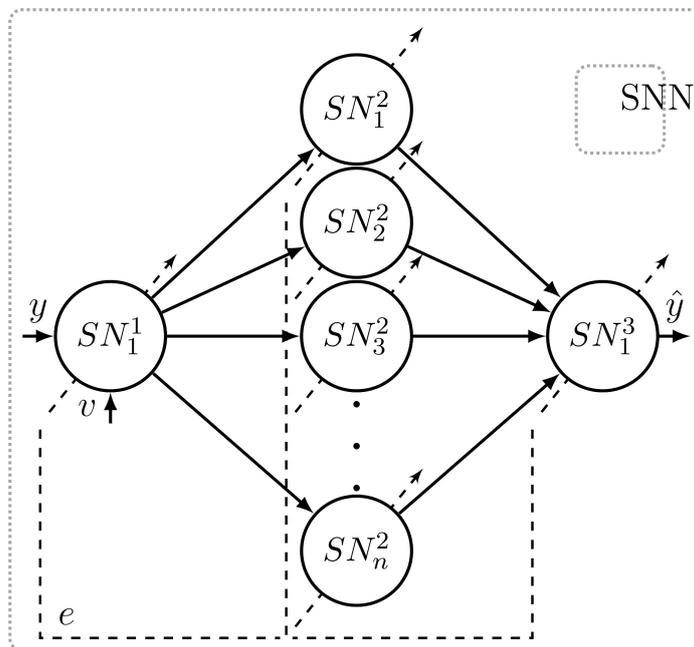


Fig. 3. Diagrama General de una SNN con tres capas.

## 2. Materiales y métodos

El electrocardiograma (Fig. 1a) y el electroencefalograma (Fig. 1b), registran las señales eléctricas del corazón y el cerebro, respectivamente. En el primer caso se colocan electrodos en el pecho para registrar las señales eléctricas que originan los latidos, mientras que para las EEG se miden en el cuero cabelludo mediante electrodos pasivos [14]. En este trabajo para el ECG se utiliza una señal de un adulto con características normales, para el caso del EEG se utiliza la actividad de imaginación de movimiento obteniendo la señal de uno de los ocho electrodos del dispositivo Emotiv EPOC colocados: AF3, AF4, FC5, FC6, P7, P8, O1 y O2, siendo los datos del electrodo AF4.

### 2.1. Esquema propuesto

Existen diversos tipos de modelos matemáticos que representan la dinámica de las neuronas, los cuales son categorizados con base en su nivel de abstracción [9]. En este trabajo se hace uso del modelo matemático de las neuronas con integración y disparo perfecto (PIF por sus siglas en inglés, Perfect integration) [9], con entrenamiento supervisado SpikeProp [2]. En la Fig. 2 se muestra el diagrama a bloques del esquema propuesto. Donde,  $y$  es la señal a ser aproximada mediante la red neuronal tipo pulso y el entrenamiento está supervisado a la señal del error  $e$  que se genera de la diferencia entre la señal a aproximar  $y$  y la señal resultante  $\hat{y}$ . Para el caso de estudio, la entrada  $y$  corresponde a las señales EEG o ECG, respectivamente.

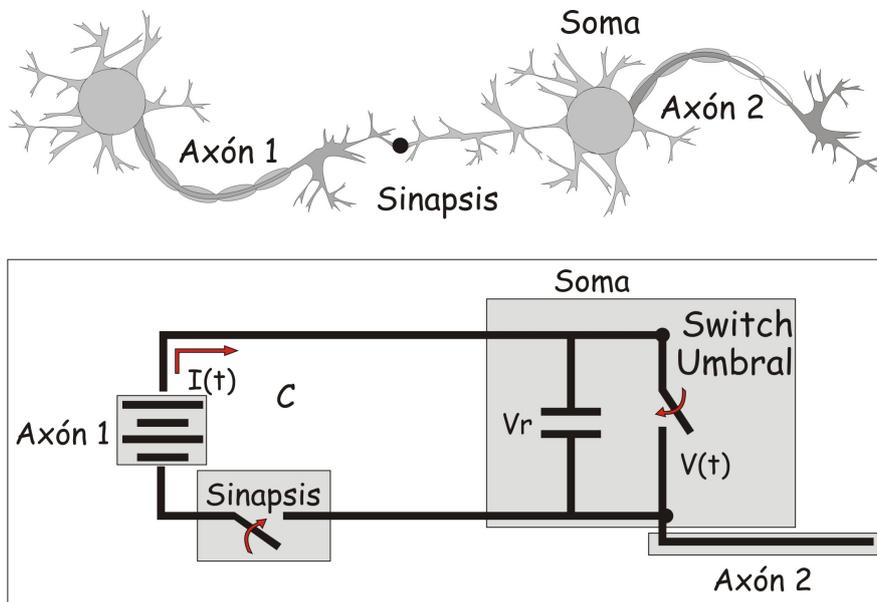


Fig. 4. Representación del modelo integración y disparo perfecto (PIF), de una neurona.

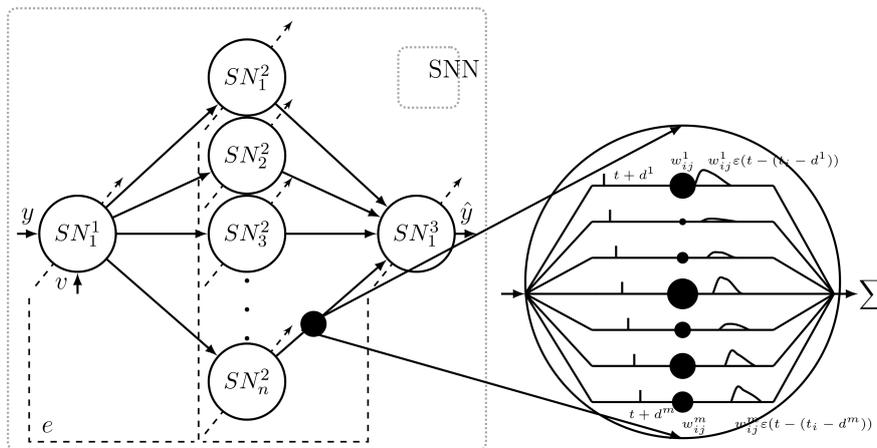
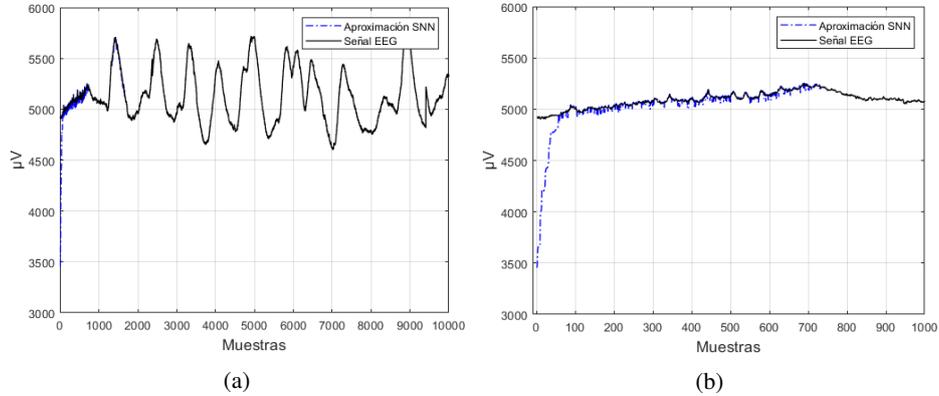
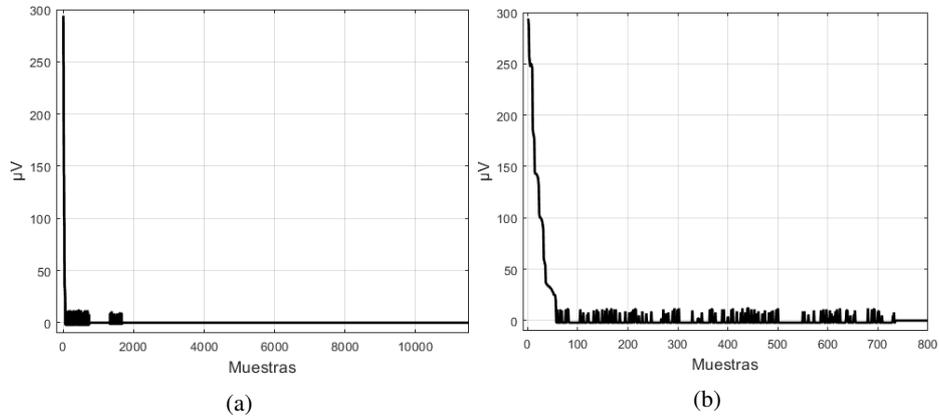


Fig. 5. Representación de los pesos  $w$  en el entrenamiento de una SNN [21].

La salida de la SNN  $\hat{y}$  es la aproximación de la señal deseada,  $v$  es una señal de excitación persistente a la neurona  $SN_1^1$ . Para estos experimentos se considera un pulso equivalente a un disparo neuronal en el instante 200, dentro en la ventana de tiempo de 0 a 1000 muestras, con la finalidad de evitar singularidades del algoritmo. La arquitectura propuesta para este trabajo se muestra en la Fig. 3, dado que se está trabajando con solo una señal de entrada a la vez por tanto se requiere una neurona en la capa de entrada y otra neurona en la capa de salida, es decir, la capa de entrada tiene una neurona  $SN_1^1$ , una capa oculta  $SN_n^2$  con  $n$ -neuronas y una capa de salida  $SN_1^3$  con una neurona.



**Fig. 6.** Aproximación de SNN de la señal EEG, con 5 neuronas en la capa oculta.



**Fig. 7.** Error de aproximación de la señal EEG, con 5 neuronas en la capa oculta.

El número de neuronas  $n$  en la capa oculta depende de la complejidad de la señal de referencia y su selección se hace de manera aleatoria tomando en cuenta la experiencia del usuario experto que programa el algoritmo, por lo que, en este caso, de manera inicial se proponen dos valores  $n = 5$  para la señal EEG y  $n = 10$  para la señal ECG. El valor de  $n$  se modifica hasta encontrar la mejor aproximación dependiendo el error. Cabe hacer mención que también se propusieron valores para  $n$  más grandes como  $n = 20$ ,  $n = 50$ , sin embargo, no se encontraron mejores resultados. Dado, que la red neuronal se entrena con el error, por tanto, para generarlo se requieren la señales  $y$  y  $\hat{y}$  codificada, con esto se obtiene la diferencia entre los tiempos de disparo específicos correspondientes a salidas deseadas y las entradas a la red neuronal. La función de error está dada por:

$$e = y - \hat{y}. \tag{1}$$

## 2.2. La Neurona tipo integración y disparo perfecto

Con la finalidad de comprender el modelo de neurona de integración y disparo perfecto PIF, se emplea un circuito capacitivo como se ilustra en la Fig. 4, donde el

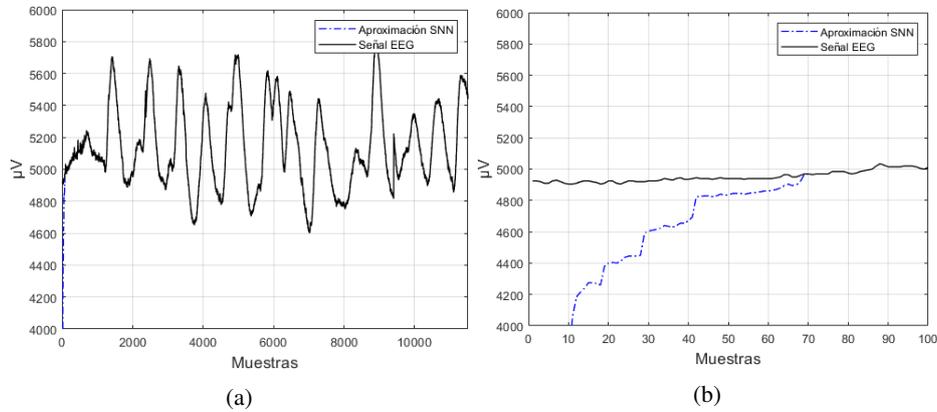


Fig. 8. Aproximación de SNN de la señal EEG, con 10 neuronas en la capa oculta.

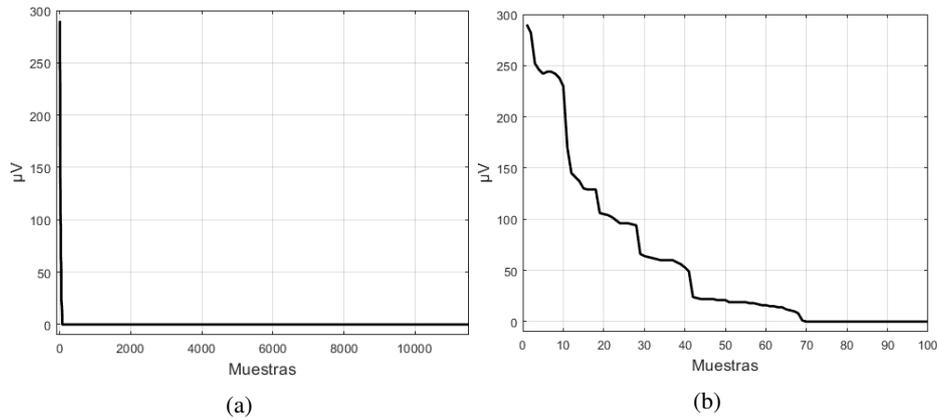


Fig. 9. Error de aproximación de la señal EEG, con 10 neuronas en la capa oculta.

voltaje de entrada se va acumulando en el capacitor y es disparado cuando se cierra el circuito, dicho disparo se presenta en una neurona biológica al momento de hacer la sinapsis. La ecuación diferencial que describe este sistema de neurona está dada por:

$$V(t) = V_r + \frac{1}{C} \int_{t_0}^t I(t) dt, \quad (2)$$

donde  $V(t)$  es el voltaje acumulado en el capacitor,  $V_r$  es el valor del voltaje en reposo del capacitor, o voltaje de relajación de la neurona, propuesto de  $-65$  mV,  $C$  es el valor del capacitor en  $\mu\text{F}$  propuesto de 50, e  $I(t)$  es el valor de la corriente de la fuente o señal de entrada. Para el caso de estudio, se eligió una neurona del tipo integración y disparo perfecto PIF considerándola una de las más sencillas al momento de programarla y que no requiere un costo computacional alto.

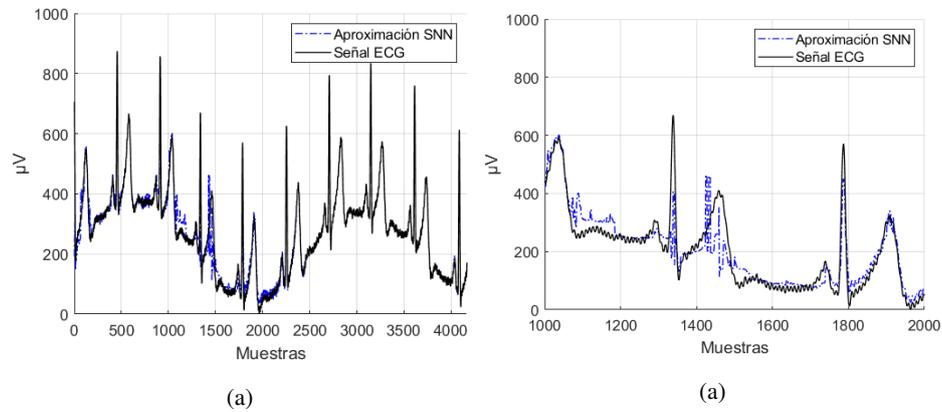


Fig. 10. Aproximación de SNN de la señal ECG, con 5 neuronas en la capa oculta.

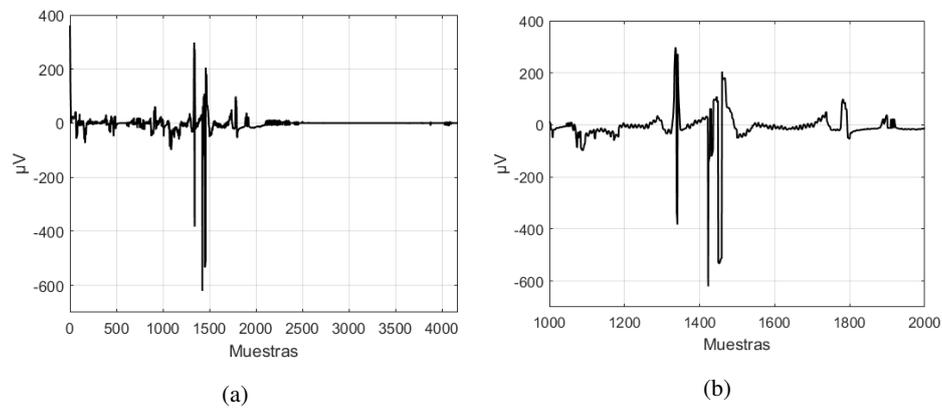


Fig. 11. Error de aproximación de la señal ECG, con 5 neuronas en la capa oculta.

### 2.3. Codificación

El arreglo de neurona en desarrollo requiere un esquema de codificación de velocidad o de tiempo. Generalmente, la primero se hace utilizando la información de la velocidad de disparo (determinado por el número de spikes), mientras que la segunda emplea el disparo como información de tiempo para traducir un patrón de pulso [16]. En este trabajo se usa la codificación temporal, esto es, en la neurona se ajustan los pesos  $w$  de manera que durante la ventana de tiempo de 1000 épocas se obtiene un disparo de la neurona spike.

### 2.4. Método de aprendizaje spikeprop

Bohte et al. [18] propusieron un algoritmo de aprendizaje supervisado basado en el algoritmo BackPropagation de redes neuronales artificiales de segunda generación. Este método se denomina SpikeProp, y fue diseñado para una arquitectura de redes neuronales con múltiples conexiones las cuales tiene múltiples retardos.

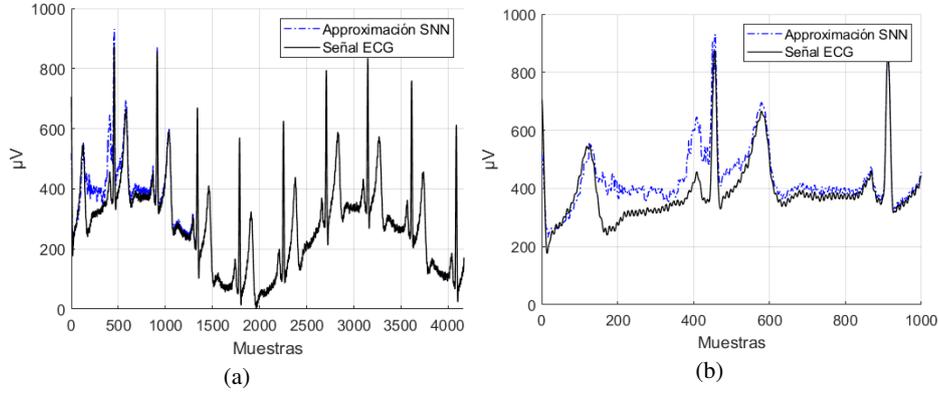


Fig. 12. Aproximación de SNN de la señal ECG, con 10 neuronas en la capa oculta.

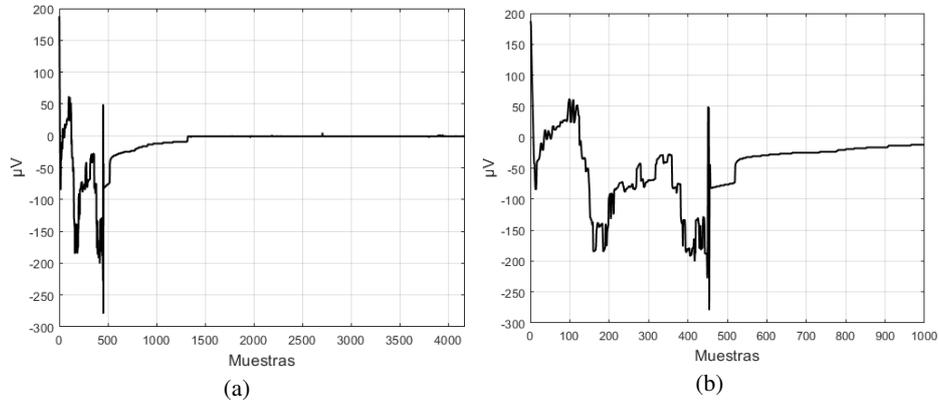


Fig. 13. Error de aproximación de la señal ECG, con 10 neuronas en la capa oculta.

La arquitectura que necesita este entrenamiento es de tipo feedforward, lo que significa que no existe retroalimentación entre ninguna neurona de la red, aunque esto no limita a que la red neuronal tenga una o más capas ocultas. La adaptación de los pesos neuronales relacionados a la neurona de la capa de salida es:

$$\Delta\omega_{ij}^k = -\eta \frac{\partial e}{\partial \omega_{ij}^k}, \quad (3)$$

donde  $e$  es el error y se obtiene mediante (1),  $\omega_{ij}^k$  son los  $k$ -ésimos pesos de la neurona  $i$ -ésima a la neurona  $j$ -ésima, como se muestra en la Fig. 5, y  $\eta$  es la tasa de aprendizaje. Obteniendo la derivada parcial del error con respecto a los pesos se obtiene:

$$\Delta\omega_{ij}^k = -\eta \frac{y_i^k(t_j)e}{\sum_{i,l} \omega_{ij}^l \left( \frac{\partial y_j^l(t_j)}{\partial t_i} \right)}, \quad (4)$$

donde  $\Delta\omega_{ij}^k$  es la modificación que sufren los pesos para llegar a la obtención del peso ideal, tal que la salida  $\hat{y}$  sea la que sea la señal aproximada con el mínimo error.

En (3) se tiene el término llamado tasa de aprendizaje  $\eta$ , que en este trabajo se propuso de 1.5, cabe hacer mención que este parámetro se obtiene de forma empírica proponiendo diferentes valores hasta encontrar el mejor desempeño de la red, para que el tiempo de convergencia sea mínimo.

### 3. Resultados

#### 3.1. Experimento con EEG

En este experimento se toma una señal EEG obtenida con el dispositivo Emotiv EPOC para ser aproximada con una SNN, en este caso se usó la señal de imaginación de movimiento. Empleando dos arquitecturas diferentes con 5 y con 10 neuronas en la capa oculta, respectivamente este número de neuronas se propuso de manera empírica mencionando que se realizaron experimento con menos de 5 neuronas y con más de 10 neuronas, sin embargo, los resultados no son mejores que los mostrados en este trabajo, también se propuso una tasa de aprendizaje  $\eta = 1.5$  en las arquitecturas, observando las diferencias entre ambas.

En la Fig. 6 se observa la aproximación de la señal EEG mediante una SNN, con una arquitectura de 5 neuronas en la capa oculta, así como un acercamiento entre 0 y 1000 muestras para denotar la aproximación antes de la disminución del error. En la Fig. 7, se muestra el error para la aproximación de la señal EEG, con 5 neuronas y un acercamiento igual que en la Fig. 6. Como puede observarse, con 5 neuronas, a partir de la muestra 80 el error se aproxima a 0, sin embargo, hay oscilaciones y es hasta después de la muestra 1500, que el error tiende a 0. Cuando se aumenta el número de neuronas en la capa oculta, se mejora la capacidad de aproximación, aunque existe un compromiso con el costo computacional.

En la Fig. 8 se presentan los resultados de la aproximación y un acercamiento de la señal EEG mediante una SNN, empleando 10 neuronas en la capa oculta. De igual manera que en el caso anterior con una SNN de 5 neuronas, la evaluación de la aproximación se hace mediante el error. En la Fig. 9. Como puede observarse en la Fig. 8 y la Fig. 9 la señal EEG aproximada con una SNN con 10 neuronas en la capa oculta tiene un tiempo de convergencia menor. El error se aproxima a cero en un lapso menor a las 100 muestras (lo que representa un intervalo menor a la frecuencia de muestreo del sensor EPOC Emotiv).

#### 3.2. Experimento con ECG

Para este experimento se utiliza una arquitectura de una neurona en la capa de entrada, 5 y 10 neuronas en la capa oculta y una neurona en la capa de salida, así como una tasa de aprendizaje  $\eta = 1.5$  en ambas arquitecturas. De manera similar al experimento anterior, la Fig. 10 presenta la señal aproximada EEG y un acercamiento mediante una SNN con 5 neuronas en la capa oculta. Por su parte, la Fig. 11 muestra el error de aproximación para este caso. En el experimento con la señal ECG se observa que esta señal es más compleja en su composición, sin embargo, la SNN la aproxima de forma precisa, y con la red de 5 neuronas en la capa oculta, el error lo acerca a cero

a partir de las 2500 muestras. Bajo la misma suposición que en el experimento anterior se mejora la aproximación, en las Figs. 12 y 13, se muestra la señal aproximada ECG y el error de aproximación para una SNN de con 10 neuronas en la capa oculta.

Con la arquitectura de 10 neuronas en la capa oculta el error lo mantiene acotado cerca del cero a partir de las 1500 muestras como se observa en la Fig. 13, mientras que con 5 neuronas el error es más amplio y el tiempo de convergencia es mayor. Una prueba estadística de normalidad del error, que se aplicó a las señales de error de los experimentos es la prueba Kolmogorov-Smirnov, y como resultado muestra que no hay errores sistemáticos, lo que significa que el error tiene una distribución normal estándar (media cero y desviación estándar igual a uno) con un nivel de significación del 5 %.

#### **4. Conclusiones**

De acuerdo a los resultados obtenidos se puede concluir que, las redes neuronales de pulso son útiles para aproximar con precisión y rapidez señales ECG y EEG, ya que requieren un número menor de neuronas. La arquitectura de red propuesta compuesta de tres capas, con una neurona tanto en la capa de entrada como en la capa de salida. Debido que no existe un método para determinar la cantidad de neuronas necesarias en la capa oculta, se determinó heurísticamente empleando 5 y 10 neuronas, respectivamente. Si bien se propusieron valores de  $n$  mayores a 10, los mejores resultados se obtuvieron con la arquitectura de 10 neuronas, tanto para las señales ECG como para las señales EMG. El error converge a cero en menos de 100 muestras de un total de 11,520 para el caso de la EEG. y para el caso de la ECG la convergencia a cero la realiza en las 1000 muestras de un total de 4120. El esquema propuesto se puede ampliar para aproximar otras señales de menor o mayor complejidad, como señales electromiográficas o inherentes a la respiración o el ciclo de marcha humano, con fines de diagnóstico clínico.

#### **Referencias**

1. Azcona, L.: El electrocardiograma. Libro de la salud cardiovascular del Hospital Clínico San Carlos y la fundación BBVA, pp. 49–56 (2009)
2. Bohte, S. M., Kok, J. N., La-Poutré, H.: Error-backpropagation in temporally encoded networks of spiking neurons. *Neurocomputing*, vol. 48, no. 1–4, pp. 17–37 (2002) doi: 10.1016/s0925-2312(01)00658-0
3. Ciucu, R. I., Serîţan, G. C., Dragomir, D. A., Cepișcă, C., Adochiei, F. C.: ECG generation methods for testing and maintenance of cardiac monitors. In: *E-Health and Bioengineering Conference*, pp. 1–4 (2015) doi: 10.1109/EHB.2015.7391513
4. Clifford, G. D., McSharry, P. E.: A realistic coupled nonlinear artificial ECG, BP, and respiratory signal generator for assessing noise performance of biomedical signal processing algorithms. *Fluctuations and Noise in Biological, Biophysical, and Biomedical Systems II*, vol. 5467, pp. 290–301 (2004) doi: 10.1117/12.544525
5. Daoui, A., Yamni, M., Karmouni, H., Sayyouri, M., Qjidaa, H.: Efficient reconstruction and compression of large size ECG signal by Tchebichef moments. In: *International Conference on Intelligent Systems and Computer Vision*, pp. 1–6 (2020) doi: 10.1109/ISCV49265.2020.9204132

6. Das, S., Maharatna, K.: Fractional dynamical model for the generation of ECG like signals from filtered coupled Van-der Pol oscillators. *Computer Methods and Programs in Biomedicine*, vol. 112, no. 3, pp. 490–507 (2013) doi: 10.1016/j.cmpb.2013.08.012
7. Espinosa-Ramos, J. I., Cortés, N. C., Vázquez, R. A.: Spiking neuron model approximation using GEP. In: *IEEE Congress on Evolutionary Computation*, pp. 3260–3267 (2013) doi: 10.1109/CEC.2013.6557969
8. Espinosa-Ramos, J. I., Vazquez, R. A., Cruz-Cortes, N.: Designing spiking neural models of neurophysiological recordings using gene expression programming. *BMC Neuroscience*, vol. 14, no. 1, pp. P74 (2013) doi: 10.1186/1471-2202-14-S1-P74
9. Gerstner, W., Kistler, W. M.: *Spiking neuron models: Single neurons, populations, plasticity*. Cambridge University Press (2002) doi: 10.1017/cbo9780511815706
10. Iannella, N., Back, A. D.: A spiking neural network architecture for nonlinear function approximation. *Neural Networks*, vol. 14, no. 6–7, pp. 933–939 (2001) doi: 10.1016/s0893-6080(01)00080-6
11. Kaur, G.: *Design and development of dual channel ECG simulator and peak detector*. Master's Thesis, Thapar Institute of Engineering and Technology Deemed University (2006)
12. Kerdjij, O., Ghanem, K., Amira, A., Harizi, F., Chouireb, F.: Real ECG signal acquisition with shimmer platform and using of compressed sensing techniques in the offline signal reconstruction. In: *Proceedings of the IEEE International Symposium on Antennas and Propagation*, pp. 1179–1180 (2016) doi: 10.1109/APS.2016.7696297
13. Klabunde, R.: *Cardiovascular physiology concepts*. Lippincott Williams and Wilkins (2011)
14. Klem, G. H., Lüders, H. O., Jasper, H. H., Elger, C.: The ten-twenty electrode system of the international federation. *Recommendations for the Practice of Clinical Neurophysiology: Guidelines of the International Federation of Clinical Physiology EEG Suppl 52*, vol. 52, pp. 3–6 (1999)
15. Kovacs, P.: ECG signal generator based on geometrical features. In: *Annales Universitatis Scientiarum Budapestinensis de Rolando Eotvos Nominatae, Sectio Geologica*, vol. 37, pp. 247–260 (2012)
16. Liu, J., Hu, Y., Li, G., Pei, J., Deng, L.: Spike attention coding for spiking neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, pp. 1–7 (2023) doi: 10.1109/TNNLS.2023.3310263
17. McBride, J., Zhao, X., Munro, N., Jiang, Y., Smith, C., Jicha, G.: Scalp EEG signal reconstruction for detection of mild cognitive impairment and early Alzheimer's disease. In: *Biomedical Sciences and Engineering Conference*, pp. 1–4 (2013) doi: 10.1109/BSEC.2013.6618497
18. McKennoch, S., Liu, D., Bushnell, L. G.: Fast modifications of the spikeprop algorithm. In: *Proceedings of the IEEE International Joint Conference on Neural Network Proceedings*, pp. 3970–3977 (2006) doi: 10.1109/IJCNN.2006.246918
19. Ponulak, F., Kasinski, A.: Introduction to spiking neural networks: Information processing, learning and applications. *Acta neurobiologiae experimentalis*, vol. 71, no. 4, pp. 409–433 (2011) doi: 10.55782/ane-2011-1862
20. Ramakrishnan, A. G., Satyanarayana, J. V.: Reconstruction of EEG from limited channel acquisition using estimated signal correlation. *Biomedical Signal Processing and Control*, vol. 27, pp. 164–173 (2016) doi: 10.1016/j.bspc.2016.02.004
21. Samperio-Vázquez, O.: *Control de un sistema subactuado empleando redes neuronales de pulso*. Master's Thesis, Universidad Autónoma del Estado de Hidalgo (2016)
22. Singh, W., Shukla, A., Deb, S., Majumdar, A.: Energy efficient acquisition and reconstruction of EEG signals. In: *Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1274–1277 (2014) doi: 10.1109/EMBC.2014.6943830

23. Vidhya, V., Unnikrishnan, D.: Synthetic ECG and PPG signal generation using pulse shaping technique. In: Proceedings of the Annual IEEE India Conference, pp. 1–6 (2015) doi: 10.1109/INDICON.2015.7443256
24. Waller, A. D.: A demonstration on man of electromotive changes accompanying the heart's beat. *The Journal of Physiology*, vol. 8, no. 5, pp. 229–234 (1887) doi: 10.1113/jphysiol.1887.sp000257
25. Wu, C. H., Liu, W. X., Lin, M. S., Chen, J. J.: An ECG extraction and reconstruction system with dynamic EMG filtering implemented on an ARM chip. In: IEEE International Conference of Intelligent Applied Systems on Engineering, pp. 62–65 (2019) doi: 10.1109/iciase45644.2019.9074076
26. Yadav, O. P., Ray, S.: Efficient ECG approximation using Chebyshev polynomials. In: Proceedings of the International Conference on Inventive Research in Computing Applications, pp. 1110–1115 (2018) doi: 10.1109/ICIRCA.2018.8597372
27. Yamazaki, K., Vo-Ho, V. K., Bulsara, D., Le, N.: Spiking neural networks and their applications: A review. *Brain Sciences*, vol. 12, no. 7, pp. 863 (2022) doi: 10.3390/brainsci12070863