

COMPARATIVA DE DESEMPEÑO DE LOS OPTIMIZADORES ADAM VS SGD EN EL ENTRENAMIENTO DE REDES NEURONALES CONVOLUCIONALES PARA LA CLASIFICACIÓN DE IMÁGENES ECG

*COMPARATIVE PERFORMANCE OF ADAM VS. SGD OPTIMIZERS
IN CONVOLUTIONAL NEURAL NETWORK TRAINING FOR THE
CLASSIFICATION OF ECG IMAGES*

Jaime Jalomo Cuevas

Tecnológico Nacional de México / IT de Cd. Guzmán, México
jaimejc@itcg.edu.mx

Edith Preciado Martínez

Tecnológico Nacional de México / IT de Cd. Guzmán, México
edithm18290012@itcg.edu.mx

José de Jesús García Cortés

Tecnológico Nacional de México / IT de Cd. Guzmán, México
jesusjc@itcg.edu.mx

Sergio Sandoval Pérez

Tecnológico Nacional de México / IT de Cd. Guzmán, México
ssandoval@itcg.edu.mx

José Abel Chocoteco Campos

Tecnológico Nacional de México / IT de Cd. Guzmán, México
jachocoteco@itcg.edu.mx

Recepción: 30/abril/2020

Aceptación: 29/octubre/2020

Resumen

Las Redes Neuronales Convolucionales (RNC) han demostrado ser una herramienta muy potente al momento de analizar imágenes, por lo cual es preciso conocer y experimentar a detalle las bondades que nos ofrece y poder así generar nuevos métodos o aplicaciones con su uso. En el presente se propone una comparativa entre dos clasificaciones de imágenes electrocardiográficas (ECG) en las que se utilizan imágenes sintéticas diseñadas a partir de ecuaciones diferenciales e imágenes reales, además de que al momento de los entrenamientos

se hará uso de dos optimizadores diferentes, el optimizador ADAM y el SGD con el objetivo de dar a conocer las eficiencias de cada uno durante el entrenamiento. Este estudio cuantitativo pretende demostrar la eficiencia de las RNC aplicadas a la clasificación de imágenes de este tipo, la cual resultó ser satisfactoria ya que se puede observar que ambas clasificaciones tuvieron una precisión del 100% al utilizar el optimizador SGD.

Palabras Clave: Red Neuronal Convolutacional, Optimizadores ADAM y SGD, ECG.

Abstract

Convolutional Neural Networks (CNN) have proven to be a very powerful tool when analyzing images, so it is necessary to know and experience a detail of the benefits that it offers us and thus be able to generate new methods or applications with its use. In this paper, we propose a comparison between two classifications of electrocardiographic images (ECG) in which synthetic images designed from differential equations and real images are used, in addition to the fact that at the time of training two different optimizers will be used, the optimizer ADAM and SGD with the aim of making known the efficiencies of each one during training. This quantitative study aims to demonstrate the efficiency of the CNN applied to image classification of this type, which turns out to be satisfactory since it can be seen that both classifications were 100% accurate when using the SGD optimizer.

Keywords: Convolutional Neural Network, ADAM and SGD optimizers, ECG.

1. Introducción

En la actualidad, técnicas como las Redes Neuronales Convolucionales (RNC) han sido de gran utilidad en diversas aplicaciones puesto que estas han demostrado ser más eficientes que otras técnicas en tareas de clasificación de imágenes [Chollet 2018]. Además, se utilizan ampliamente para el reconocimiento de imágenes, detección/localización, e incluso procesamiento de texto [Aggarwal 2018]. Hoy en día un área que se ha visto beneficiada y sigue siendo área de vanguardia para la implementación de este tipo de tecnología es el área médica, desde la aplicación en la detección y clasificación de lesiones en la piel para una posible detección de

cáncer a temprana fase [Pai 2019], hasta la evaluación de la edad ósea [Wang 2018], por mencionar algunas. Por otra parte, el área del aprendizaje profundo (deep Learning) a la cual pertenecen las RNC ha resultado ser favorable en su uso para el análisis de imágenes cardíacas, tal como lo menciona Dorado-Díaz en su trabajo titulado “Applications of artificial intelligence in cardiology. The future is already here” [Dorado-Díaz 2019]. Esto sirve de referencia y da las bases para incursionar en el desarrollo de trabajos donde se apliquen este tipo de redes neuronales, es por eso que en el presente trabajo se propone la clasificación de señales del corazón ECG mediante una red neuronal convolucional implementada en Python mediante la plataforma de aprendizaje profundo TensorFlow [Géron 2017], así como de una comparativa de la aplicación de esta técnica en señales sintéticas generadas mediante el modelo dinámico matemático de la señal ECG propuesto por Patrick E. McSharry [McSharry 2003] y señales reales adquiridas de una persona perteneciente al equipo académico del Instituto Tecnológico de Cd Guzmán, a la par se analizan el uso de los optimizadores “Adam” y “SGD” en estas clasificaciones y la utilización de Google Colaboratory como herramienta de apoyo para el uso de una GPU al momento del entrenamiento de la red.

2. Métodos

Para realizar la comparativa del desempeño de los entrenamientos con imágenes reales e imágenes sintéticas, así como de los optimizadores ADAM y SGD se realizaron 4 entrenamientos con la misma arquitectura para la RNC utilizada, la cual se puede observar en la figura 8. Para la clasificación con imágenes sintéticas las imágenes fueron divididas en 2 conjuntos a clasificar llamados “normal” y “anormal”, por otro lado, para la clasificación con imágenes reales las imágenes fueron divididas en dos conjuntos a clasificar llamados “reposo” y “esfuerzo”. A continuación, se describe el método utilizado para la obtención de las imágenes de señales sintéticas y reales. Las señales sintéticas fueron generadas a partir de las ecuaciones diferenciales 1, 2 y 3 propuestas en el trabajo “*A Dynamical Model for Generating Synthetic Electrocardiogram Signals*” de Patrick E. McSharry.

$$\dot{x} = \alpha x - \omega y \quad (1)$$

$$\dot{y} = \alpha y - \omega x \quad (2)$$

$$\dot{z} = - \sum_{i \in \{P,Q,R,S,T\}} a_i \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - (z - z_0) \quad (3)$$

Este conjunto de tres ecuaciones diferenciales ordinarias representa a las ecuaciones dinámicas de movimiento las cuales definen el modelo dinámico que genera una trayectoria en un espacio tridimensional (3D) [3].

Dichas ecuaciones diferenciales fueron modeladas mediante Simulink y guardadas en un formato de 332x190 pixeles, la figura 1 nos muestra una imagen de una señal sintética del tipo “normal” obtenida mediante la simulación de Simulink, mientras que la figura 2 nos muestra una señal sintética del tipo “anormal”.

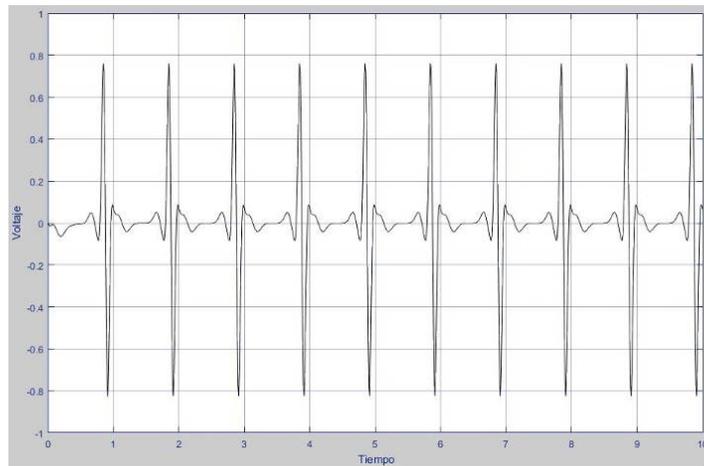


Figura 1 Señal sintetica normal.

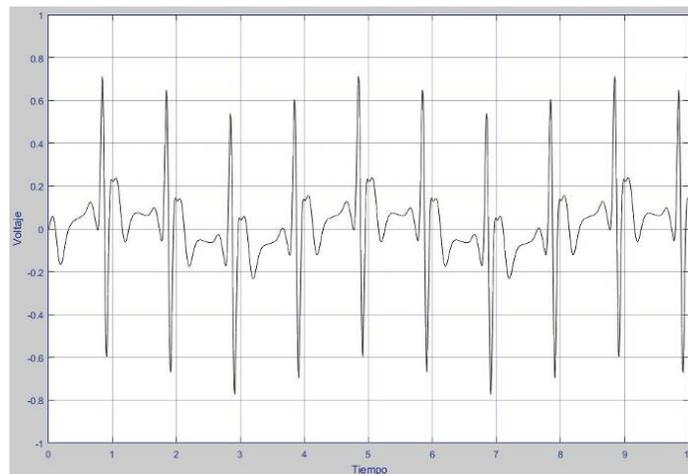


Figura 2 Señal sintetica anormal.

Las señales reales fueron adquiridas en el Instituto Tecnológico de Cd Guzmán, mediante una tarjeta AD 8232 y una tarjeta de adquisición de datos NI DAQ mx 6009. En la figura 3 se observa la tarjeta AD8232, la figura 4 el material total utilizado para la toma de las señales y la figura 5 nos muestra cómo es que se tomaron las muestras.

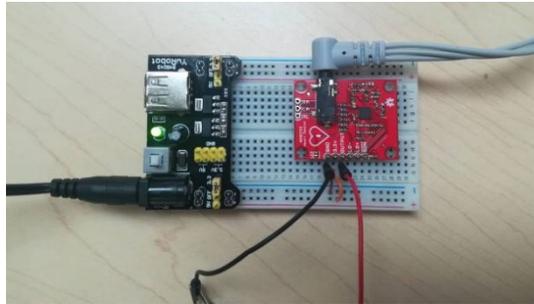


Figura 3 Tarjeta AD 8232.



Figura 4 Elementos utilizados en la toma de señales.



Figura 5 Toma de una señal ECG.

La duración de cada toma fue de 60 segundos y fueron procesadas mediante LabVIEW para generar los datos de ellas, posteriormente las señales fueron particionadas en intervalos de 10 segundos y procesadas nuevamente ahora en Python para filtrar y graficar las señales. La figura 6 nos muestra una señal real del tipo “reposo” y la figura 7 nos muestra una señal real del tipo “esfuerzo”. Las imágenes de estas señales fueron guardadas en un formato de 332x190 pixeles.

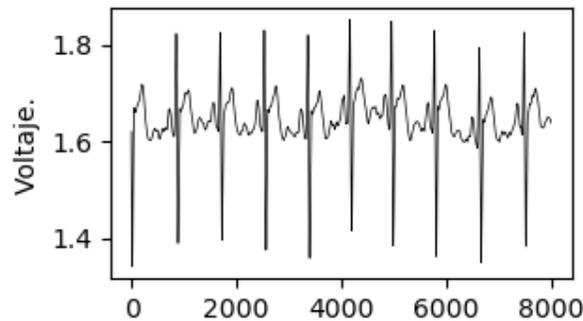


Figura 6 Señal real en reposo.

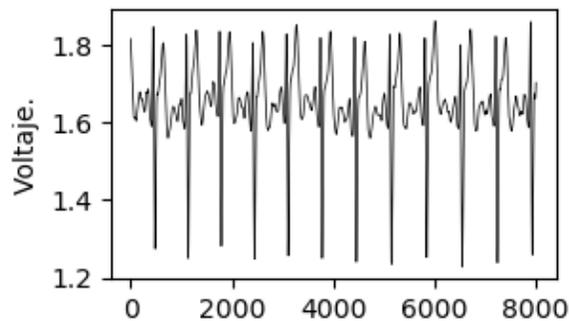


Figura 7 Señal real en esfuerzo.

Red Neuronal Convolutiva (RNC)

La red neuronal convolutiva utilizada (Figura 8) para el entrenamiento consta de 2 bloques con 2 capas convolutivas y 1 capa max pooling, posterior a esto se cuenta con un bloque al cual denominamos Fully-Connected ya que cumple la función de interconectar todas las neuronas de nuestro modelo, cuenta con una capa dense y una capa dropout, así como una última capa dense con una sola neurona del tipo Sigmoid para representar la probabilidad de ser normal o anormal, o en esfuerzo o en reposo para el caso de las señales reales.

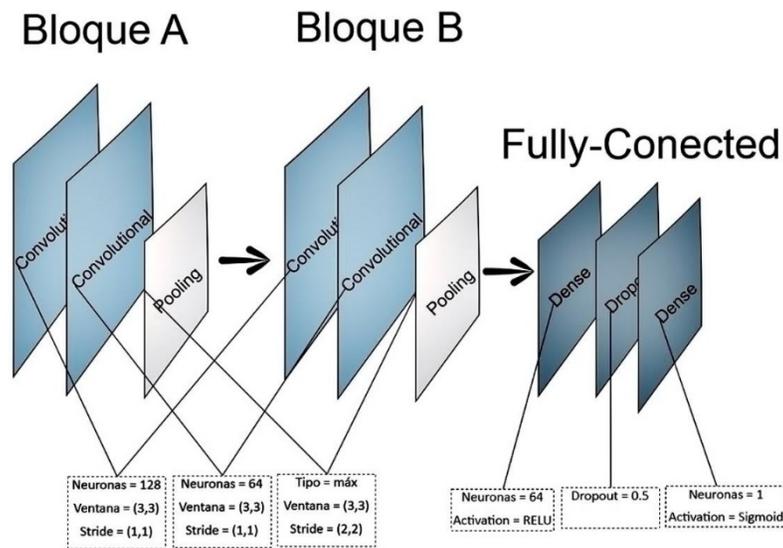


Figura 8 Arquitectura RNC.

Para el entrenamiento las imágenes fueron almacenadas en 2 carpetas diferentes (Entrenamiento y Validación) con subcarpetas para las imágenes de señales normal-anormal en el caso de las sintéticas y reposo-esfuerzo para el caso de las señales reales. El entrenamiento se realizó con 30 épocas con 1000 pasos cada una, fueron necesarios también 100 pasos para los elementos de la carpeta validación.

Google Colaboratory

Haciendo referencia al artículo “Google Colaboratory como alternativa para el procesamiento de una red neuronal convolutiva” [Bodero 2020] los resultados obtenidos en testeo de pérdida y testeo de precisión al entrenar una red neuronal convolutiva en google colaboratory son mejores en comparación de realizar el mismo entrenamiento en un computador personal, motivo por el cual se optó en hacer uso de la herramienta que nos ofrece Google además de poder activar una GPU ya que no se contaba con una.

3. Resultados

A continuación, se presentan los resultados obtenidos para las 4 clasificaciones realizadas, (clasificaciones con señales reales haciendo uso del optimizador ADAM

y del optimizador SGD y clasificaciones con señales sintéticas haciendo uso del optimizador ADAM y del optimizador SGD).

La tabla 1 nos muestra los resultados obtenidos en la época # 30 (es decir al final del entrenamiento) del entrenamiento, conforme el entrenamiento avanzaba los resultados para pérdida y precisión mejoraban, considerando que el valor 1 es el 100 % se buscaba obtener un valor de 1 para la precisión de nuestra red y un valor cercano a 0 para la pérdida lo cual nos asegura que la diferencia entre el valor predicho por el modelo y el valor verdadero es mínima. Como se puede observar, las clasificaciones donde se hizo uso del optimizador SGD tuvieron resultados favorables a diferencia de las clasificaciones realizadas con el optimizador ADAM.

Tabla 1 Comparativa entrenamientos señales Reales y sintéticas época #30.

Señales	Optimizador	Pérdida	Precisión
REALES	Adam	0.6932	0.4788
	SGD	0.0034	0.9993
SINTÉTICAS	Adam	0.6932	0.473
	SGD	1.45E-04	1

La figura 9 y 10 muestran el desempeño del entrenamiento de la red con los diferentes optimizadores, como resultado se puede observar la similitud entre ellos para ambos casos, lo cual nos indica el buen desempeño de nuestra red para diferentes señales.

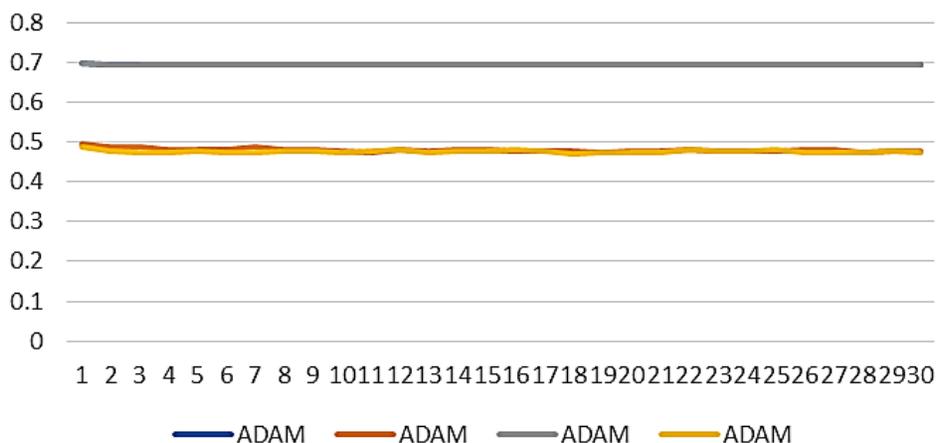


Figura 9 Comparativa de desempeño con Optimizador Adam

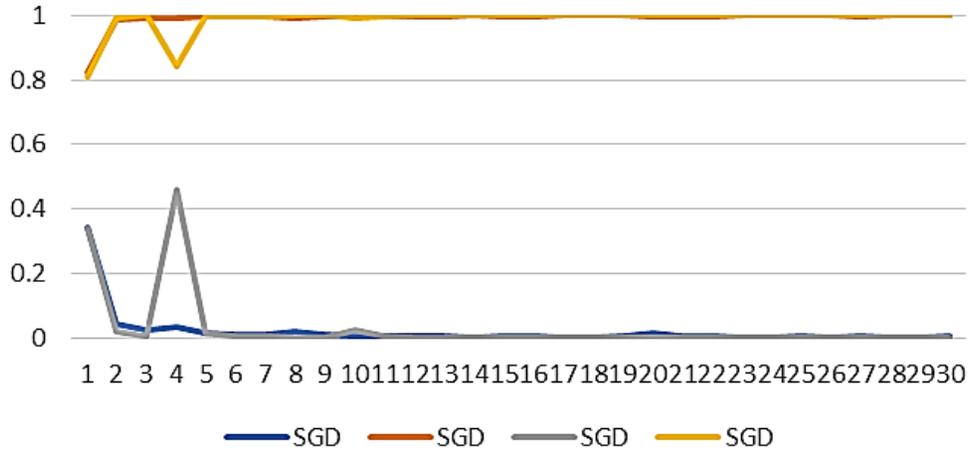


Figura 10 Comparativa de desempeño con Optimizador SGD

Los resultados obtenidos al momento de clasificar imágenes de señales reales con el optimizador ADAM nos muestran como no alcanza la eficiencia suficiente para poder clasificar las señales correctamente, en este caso las señales en reposo las clasificó en el grupo de las señales en esfuerzo “E” (figura 10).

En el caso del entrenamiento con el optimizador SGD todas las imágenes fueron clasificadas correctamente (figura 11).

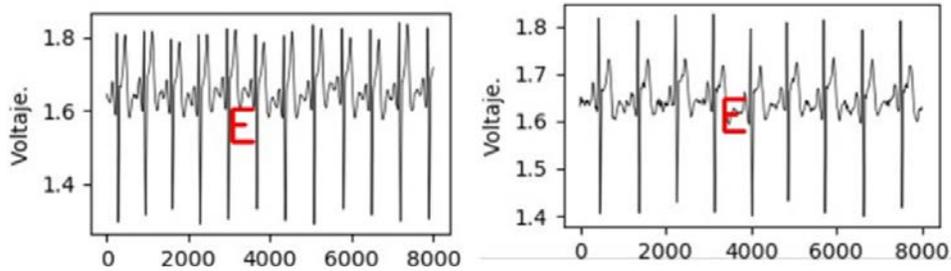


Figura 10 Señales reales clasificadas optimizador Adam.

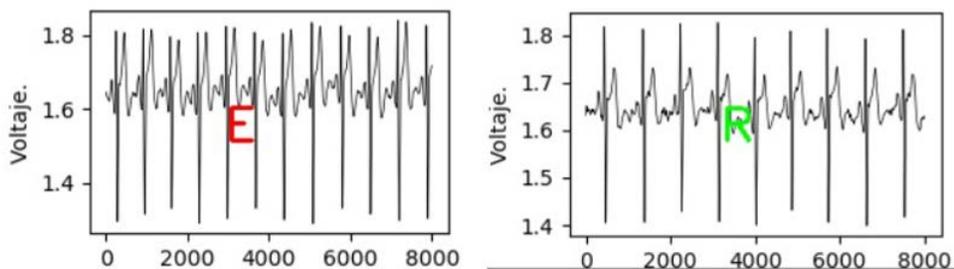


Figura 11 Señales reales clasificadas optimizador SGD.

Para el entrenamiento con las señales sintéticas los resultados fueron igual a los resultados con las señales reales, utilizando los modelos en los que se hizo uso del optimizador ADAM no se logra una buena clasificación (figura 12). Al usar los modelos en el que se utilizo el optimizador SGD todas las imágenes fueron clasificadas correctamente (figura 13).

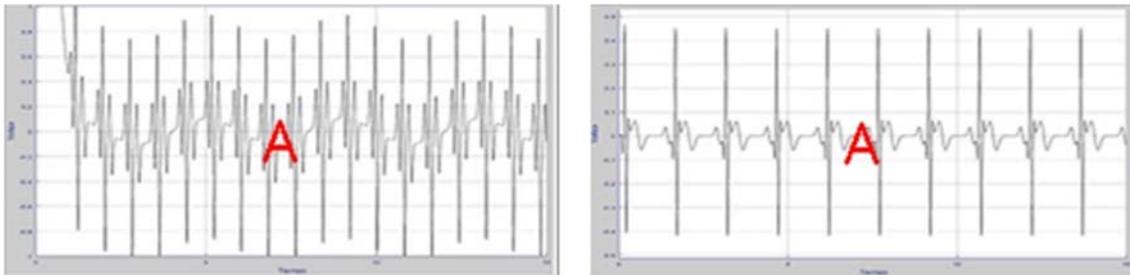


Figura 12 Señales sintéticas clasificadas optimizador ADAM.

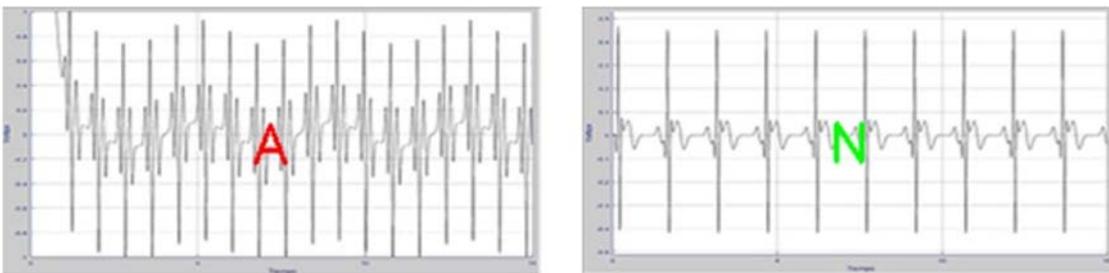


Figura 13 Señales sintéticas clasificadas optimizador SGD.

Nota: Al redimensionar las imágenes para el entrenamiento estas perdieron un poco calidad, esto se puede mejorar haciendo uso de otras herramientas especiales para el tratado de imágenes, para el caso no afecto al funcionamiento de la red ya que las imágenes siguen manteniendo sus formas originales de manera visible.

4. Discusión

Como se puede observar en la tabla 1 “Comparativa entrenamientos señales Reales y Sintéticas época #30” el uso del optimizador SGD resultó ser más eficiente que el del optimizador ADAM, para el caso del optimizador SGD sus parámetros de pérdida y de precisión fueron los ideales acercándose al valor de 0 para la pérdida y de 1 para la precisión, para el caso del optimizador ADAM sus parámetros de

pérdida y de precisión no fueron tan favorables ya que no se acercaron ni en un 50% a lo que se esperaría idealmente para que el entrenamiento pueda considerarse correcto, es por eso que se puede observar en las figuras 10 y 12 como al poner en práctica el entrenamiento obtenido con el optimizador ADAM en las clasificaciones de las señales no supo distinguir entre un tipo de señal y la otra. Sin embargo, con los resultados obtenidos de los entrenamientos realizados con el optimizador SGD se puede corroborar como la arquitectura de esta red resulta eficiente para la clasificación de imágenes de señales ECG, para el entrenamiento de las señales sintéticas la precisión obtenida fue de 1, es decir del 100% (tabla 1), mientras que para el entrenamiento de las señales reales se obtuvo un valor de .9993, es decir 99.93% (tabla 1), esto es de entenderse puesto que las señales sintéticas al ser diseñadas vía simulación pudieron agregárseles características evidentes que diferenciaran una señal de la otra lo cual fue una ventaja para este entrenamiento puesto que la red supo diferenciarlas con mayor facilidad, a diferencia de las señales reales que fueron obtenidas del mismo sujeto de prueba con la diferencia de que unas fueron realizadas en esfuerzo y otras no, de cualquier manera el resultado obtenido para este entrenamiento sigue siendo excelente. Otro dato importante y el cual se pudo corroborar en la realización de este trabajo es la eficiencia de los métodos de optimización no adaptativos al cual pertenece el optimizador SGD a diferencia de los métodos de optimización adaptativos al cual pertenece el optimizador ADAM, como es visto en la mayoría de las aplicaciones y como lo menciona Wilson en su artículo “The Marginal Value of Adaptive Gradient Methods in Machine Learning” [Wilson 2017] el uso de los métodos adaptativos sigue teniendo la delantera sin importar las bondades que ofrecen los métodos no adaptativos, esto puede deberse a la popularidad que fue obteniendo este tipo de método.

5. Conclusiones

“La gente debería dejar de entrenar radiólogos ahora. Es completamente obvio que, dentro de 5 años, el aprendizaje profundo va a hacerlo mejor que los radiólogos porque va a poder tener más experiencia. Pueden ser 10 años” [Pedrosa 2018]. Tal

como lo menciona Pedrosa en su trabajo “Artificial intelligence, ¿big data and beyond. . . are we really being replaced?”, el aprendizaje profundo avanza a pasos agigantados, dejando en duda ciertas tareas a realizar por personas.

Para el caso del presente trabajo el optimizador SGD (Stochastic Gradient Descent) en conjunto con el uso de una GPU resulto ser de utilidad para la clasificación de imágenes ECG optimizando el proceso. Los resultados obtenidos son un buen punto de partida para el diseño de un sistema de reconocimiento y clasificación de señales biomédicas como propuesta de desarrollo tecnológico que beneficie al área médica. En este estudio las imágenes utilizadas en el entrenamiento no contaban con algún tipo de ruido gracias al filtrado y tratado de las mismas con Python, un aspecto a considerar en trabajos futuros es la adquisición de señales reales obtenidas con electrocardiógrafos profesionales ya que son estas las que los médicos analizan en su día a día.

El presente entrenamiento fue suficiente para obtener una buena clasificación de manera binaria “reposo – esfuerzo”, “normal – anormal”, aspectos a considerar a futuro es obtener información de los médicos que nos indique de qué manera realizan ellos la clasificación de sus señales, si para ellos es más que suficiente una clasificación del tipo binario o les sería más útil una con más variables a clasificar, aunque por los resultados ya obtenidos es más que suficiente para tener la certeza que esta misma red neuronal convolucional tendrá el mismo éxito para un caso con más variables.

6. Bibliografía y Referencias

- [1] Chollet, F., DEEPLARNING with Python. MANNING Publications Co, Shelter Island, 2018.
- [2] Aggarwal, Charu C., Neural Networks and Deep Learning. Springer, pág. 40-42, 2018.
- [3] Boderó, E. M., “Google Colaboratory como alternativa para el procesamiento de una red neuronal convolucional”. Revista ESPACIOS. N° 7, 40, 2020.
- [4] McSharry, Patrick.E., A Dynamical Model for Generating Synthetic Electrocardiogram Signals, IEEE Trans.Biomed. N° 3, 50 pág. 289-294, 2003.

- [5] Pai, K., Giridharan, A., Convolutional Neural Networks for classifying skin lesions, IEEE Region 10 Conference, pág. 1794-1796, 2019.
- [6] Wang, S., Zeng, D., Bone Age Assessment Using Convolutional Neural Networks. IEEE International Conference on Artificial Intelligence and Big Data, pág. 175-178, 2018.
- [7] Dorado-Díaz, P., Sampedro, J., Applications of artificial intelligence in cardiology. The future is already here. Elsevier, 2019.
- [8] Géron, A., Hands-On Machine Learning with Scikit-Learn and TensorFlow. O' Reilly, 2017.
- [9] Wilson, A., Roelofs, R., The Marginal Value of Adaptive Gradient Methods in Machine Learning. 31st Conference on Neural Information Processing Systems, 2018.
- [10] Pedrosa, I., Artificial intelligence, big data and beyond. . . are we really being replaced?. Elsevier, N° 5, 60 pág. 359-361, 2018.