

Tipo de artículo: Artículo original

Modelo computacional para el diagnóstico preliminar de arritmias cardiacas basado en Redes Neuronales Convolucionales

Computational model for the preliminary diagnosis of cardiac arrhythmias based on Convolutional Neural Networks

Alfonso A. Guijarro-Rodríguez ^{1*} , <https://orcid.org/0000-0001-6046-426X>

Jorge A. Medina-Avelino ² , <http://orcid.org/0000-0003-1682-7953>

Erick J. Limón-Mejillones ³ , <https://orcid.org/0000-0002-4691-7979>

Angie A. Salazar-Salazar ⁴ , <https://orcid.org/0000-0002-6517-7187>

¹ Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil. Correo electrónico: alfonso.guijarror@ug.edu.ec

² Facultad de Ciencias Médicas, Universidad de Guayaquil. Correo electrónico: jorge.medinaa@ug.edu.ec

³ Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil. Correo electrónico: erick.limonm@ug.edu.ec

⁴ Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil. Correo electrónico: angie.salazars@ug.edu.ec

* Autor para correspondencia: alfonso.guijarror@ug.edu.ec

Resumen

La detección de enfermedades cardiovasculares es un proceso llevado por los médicos especialistas en cardiología, comúnmente mediante la exploración y análisis de un electrocardiograma (ECG), la presencia o ausencia de enfermedades cardiovasculares (ECV), se realiza mediante la lectura de una prueba simple e indolora que muestra el ritmo cardiaco, para determinar si existe o no un grado de afectación, de acuerdo con los protocolos que presentan las normas internacionales. Trabajos recientes sugieren que el desarrollado de las nuevas tecnologías permite establecer diagnósticos médicos, para la detección temprana de ECV, para así acelerar la aplicación de los tratamientos. Este trabajo presenta como objetivo seleccionar un modelo computacional basado en redes neurales convolucionales (CNN por sus siglas en inglés), para la detección temprana de anomalías cardiacas a partir de las imágenes de un ECG, para esto se utilizó un proceso de clasificación de cuatro fases: análisis de data, entrenamiento, depuración de datos y la evaluación de resultados. Como insumo se consideró un conjunto de imágenes de ECG, obtenidas desde el sitio de Mendeley data, otro corresponde al aporte del Centro Médico OHS y otras fueron generadas mediante el dispositivo KardiaMobile. Para la clasificación se utilizó una CNN de transferencia de aprendizaje, y para la validación se consideraron 230 imágenes, las cuales fueron corroboradas mediante tres modelos pre-entrenados, Inception V3 con 96% de precisión, ResNet 101 con 93% de precisión y MobileNet V2 con 92% de precisión, logrando clasificar tres tipos de arritmias cardiacas, miocardio, ritmo sinusal normal y anormal.

Palabras clave: Algoritmos; Arritmia Cardíaca; Enfermedades Cardiovasculares; Electrocardiograma; Salud.

Abstract

The detection of cardiovascular disease is a process carried out by cardiology specialists, usually by means of the exploration and analysis of an electrocardiogram (ECG). The presence or absence of cardiovascular disease (CVD) is determined by reading a simple and painless test that shows the heart rhythm, to determine whether or not there is a degree of involvement, in



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

accordance with the protocols presented by international standards. Recent work suggests that the development of new technologies allows the establishment of medical diagnostics for the early detection of CVD in order to accelerate the application of treatments. The aim of this work is to select a computational model based on convolutional neural networks (CNN) for the early detection of cardiac abnormalities from ECG images, using a four-phase classification process: data analysis, training, data cleaning and evaluation of results. As input we considered a set of ECG images obtained from the Mendeley data site, another set of images corresponds to the contribution of the OHS Medical Center and others were generated using the KardiaMobile device. A learning transfer CNN was used for classification, and 230 images were considered for validation, which were corroborated by three pre-trained models, Inception V3 with 96% accuracy, ResNet 101 with 93% accuracy and MobileNet V2 with 92% accuracy, managing to classify three types of cardiac arrhythmias, myocardial, normal and abnormal sinus rhythm.

Keywords: Algorithms; Cardiac arrhythmia; Cardiovascular diseases; Electrocardiogram; Health.

Recibido: 30/07/2022

Aceptado: 28/09/2022

En línea: 01/10/2022

Introducción

Las arritmias son alteraciones en la actividad eléctrica del corazón que provocan una pérdida del ritmo normal, según el artículo presentado por (Bermúdez & Rodríguez, 2021) en él menciona que las causas pueden ser variadas, así como su gravedad y consecuencias clínicas, pudiendo llegar a provocar la muerte o en su defecto consecuencias graves. Este estudio corrobora que la arritmia son una enfermedad cardiovascular causada por anomalías en el sistema eléctrico del corazón que provoca cambios en la frecuencia cardíaca, trastorno que puede significar que el corazón de una persona acelere su latido (taquicardia), o que vaya muy lento (bradicardia) o simplemente presente latidos de forma irregular (palpitaciones).

Las enfermedades cardiovasculares (ECV) son un grupo de enfermedades que afectan al corazón debido a varios factores de riesgos (Veloza, Jiménez, Quiñonez, Polanía, & Pachón, 2019), la obstrucción del flujo sanguíneo afecta a más del corazón al cerebro y por ende a otras partes del cuerpo, la acumulación de grasa o colesterol en arterias produce una serie de enfermedades como la hipertensión arterial, cardiopatía coronaria o infarto de miocardio, enfermedad cerebrovascular, enfermedad vascular periférica, entre otras.

Estudios recientes muestran que el 52% de los estudiantes de la facultad de medicina en la universidad de Pamplona en Colombia son propensos a contraer ECV, debido al estilo de vida en donde a diario se impone el sedentarismo y los malos hábitos de alimentación y solo el 35% de estudiantes realiza actividad física frecuentemente (Moreno, 2018). En base a estos resultados podemos determinar que las cifras son realmente preocupantes, debido a que muchos de los estudiantes que se preparan para ser profesionales no tienen conocimiento acerca de lo que puede conllevar el sedentarismo o entrar en un estilo de vida poco saludable.



(Aristega & León, 2022) en su trabajo de investigación titulado Optimización de algoritmos de machine learning aplicados a problemas de arritmias cardíacas realizado en Guayaquil-Ecuador. Presentó un análisis de arritmias cardíacas, a través de la selección de dos algoritmos convolucionales entre ellos está una CNN y otra utilizando ResNet 101 (Szegedy, Ioffe, Vanhoucke, & Alemi, 2017), para la detección de ECV, como resultado de esta investigación se obtuvo una precisión del 98% de exactitud al realizar la predicción de arritmias cardíacas. Aunque el dataset utilizado en esta investigación se basa en imágenes, estas permiten establecer las bases de una CNN convencional para realizar la desestructuración de una imagen.

(Bermúdez & Rodríguez, 2021) realizaron la investigación cuyo título corresponde a Diseño de un sistema de adquisición y procesamiento de señales electrocardiográficas para la ayuda en el diagnóstico de arritmias mediante CNN. A través de este estudio se describe el uso de la base de datos ECG Heartbeat Categorization Dataset, la cual es utilizada para realizar el entrenamiento de la CNN. La metodología de este trabajo se basó en un análisis detallado sobre los datos de ECG, luego el procesamiento de estas y por último comprobar la veracidad de resultados generados por el algoritmo. Los resultados mostraron que en las predicciones se tuvieron una eficacia de un 90.9%, lo cual es un nivel bastante aceptable al detectar alguna anomalía en el ritmo cardíaco. Trabajo que sirvió de base para entender la desestructuración de las ondas acorde a los tipos de ondas tomadas a través de un sensor de electrocardiograma.

Según (Durán & Del Real, 2017) en su estudio sobre CNN en R: Reconocimiento de caracteres escritos a mano, realizado en la Universidad de Sevilla en España. Podemos notar que esta investigación está enfocada en desarrollar un algoritmo en el lenguaje de programación R que, tras ser entrenado con una amplia base de datos capaz de reconocer caracteres escritos a mano, específicamente se usaron números del 0 al 9. La metodología permitió realizar un análisis de los resultados para verificar la eficacia de clasificación de imágenes, además se muestra que la red ha obtenido un 96 % de acierto con un set de entrenamiento de 10,000 imágenes, de las cuales 5,000 de ellas estaban distorsionadas. Los resultados de este estudio demuestran gran versatilidad y rendimiento de las redes convolucionales, ya que son capaces de aprender a resolver problemas en muchos dominios diferentes.

Los médicos que laboran en la Facultad de Ciencias Médicas (FCM) de la Universidad de Guayaquil decidieron contribuir a la sociedad con estudios preliminares de investigaciones que ayuden y detecten problemas cardiovasculares, esto nos permite presentar una propuesta en la que se aplicará aprendizaje automático que permite un diagnóstico inicial de enfermedades del corazón, para esto se usarán imágenes recopiladas de internet ya que al momento no se cuenta con un dataset propio de la FCM, se desarrolló un modelo predictivo, utilizando CNN, que clasifique las imágenes en sujetos sanos, sujetos con enfermedades miocardio y sujetos con latidos anormales. Se



utilizarán algoritmos pre entrenados para poder ampliar los casos de cada clase y ampliar los parámetros de la red hasta obtener el modelo óptimo.

Para describir mejor este trabajo se lo detalla en cuatro partes clásicas, la sección de materiales y métodos presenta los diferentes tipos de algoritmos de transferencia de aprendizaje entre los cuales se encuentra MobilNet V2 (Howard, y otros, 2017), ResNet 101, Inception V3 (Szegedy, Ioffe, Vanhoucke, & Alemi, 2017), para la clasificación de imágenes de electrocardiogramas con el fin de evaluar el porcentaje de precisión de cada algoritmo, la sección de resultados muestra el nivel de exactitud, cantidad de datos y porcentaje de precisión de cada algoritmo entrenado al analizar imágenes de electrocardiogramas y finalmente las conclusiones, contribuciones de los autores y financiamiento derivadas de este trabajo.

Materiales y métodos

Para realizar el entrenamiento y ajuste de los algoritmos convolucionales, se trabajó desde un equipo portable Core i3 de cuarta generación, 4GB de memoria RAM, almacenamiento de 512GB SSD, un adaptador de red de 1Gbps, en cuanto a software la plataforma base sistema operativo Microsoft Windows 10 Home edition y como navegador Google Chrome, además de una conexión a internet de banda ancha estable y para efectos de ejecutar el proyecto se optó por utilizar Google Colaboratory (Colab), debió a los recursos que brinda Google como no requerir una configuración adicional, acceso a una GPU sin un solo costo, aunque posee una versión de paga, los recursos que ofrece por defecto fueron suficientes para esta investigación, siendo obligatorio contar con una cuenta de Gmail, para garantizar los accesos a colab.

La metodología propuesta, considera un banco de imágenes compuesto por 726 electrocardiogramas, obtenidos de la página de Mendeley data que cuenta con el auspicio del Instituto de Cardiología Multan (MIC), adicional a esto un grupo de imágenes corresponden al Centro Médico OHS que nos brindaron apoyo para este trabajo y finalmente otro grupo de imágenes fueron generadas a través del dispositivo KardiaMobile. La figura 1, muestra una de las imágenes extraídas del repositorio de Mendeley data. Estas imágenes, se redimensionaron ocupando solo la parte de la hoja del electrocardiograma, dejando a un lado los datos como el voltaje, tiempo, etc. Para evitar que el algoritmo extraiga características irrelevantes para la detección de las arritmias.






Figura 1. Electrocardiograma proporcionado por el Instituto de Cardiología Multan.
Nota: Foto tomada de (Khan, Haider, Hussain, & Muzammil, 2021).

Por otro lado, se contó con el apoyo del centro médico OHS el cual proporcionó imágenes de electrocardiogramas de ciertos pacientes; estas imágenes están debidamente clasificadas por tipo de arritmia, este diagnóstico fue dado por un médico especialista; por un electrocardiógrafo llamado Mediblu, los diagnósticos vienen en el formato indicado en la figura 2.



Figura 2. Electrocardiograma proporcionado por el Centro Médico OHS.
Nota: Foto tomada del banco de imágenes del Centro Médico OHS.



Es importante mencionar que las imágenes de MIC se utilizarán para entrenamiento y validación del algoritmo; las imágenes del centro médico OHS servirán para verificación y análisis de resultados del modelo convolucional, cabe recalcar que existe cierta variación del formato, de electrocardiogramas, lo que da paso a aumentar el margen de error al realizar las predicciones de las imágenes, vale la aclaración que los exámenes proporcionados por el centro médico OHS son usados con fines netamente académicos o educativos, y las imágenes del dispositivo KardiaMobile completan el entrenamiento.




Figura 3. Electrocardiograma Generado por KardiaMobile.

Nota: Electrocardiograma Generado por KardiaMobile con un diagnóstico Normal.

KardiaMobile, permite tomar el pulso cardiaco para luego generar un diagnóstico junto a una señal de electrocardiograma en formato PDF, como se puede observar en la imagen de la figura 3, solo cuenta con una línea que es continua a lo largo de toda la imagen y complementan el entrenamiento.

Selección del Algoritmo Convolucional

En este trabajo se realizaron pruebas de tres algoritmos convolucionales de transferencia de aprendizaje que son ResNet 101, Inception V3 y MobileNet V2 con el fin de encontrar el algoritmo que más se adecue a nuestro trabajo.

- **MobileNet** (Howard, y otros, 2017), es una arquitectura sencilla y eficiente en el tiempo que se diseñó originalmente, se muestra en la figura 4. Puede disminuir la complejidad del modelo de entrenamiento al reducir la cantidad de parámetros mientras mantiene un rendimiento aceptable. Estas son capas convolucionales de dimensiones 3×3 y 1×1 , respectivamente. MobileNet V2 tiene 53 capas profundas (Attallah, 2022). Al ser



puesto el algoritmo a prueba se pudo corroborar la efectividad de este modelo a un 92% de precisión (Howard, y otros, 2017).




Figura 4. Arquitectura de MobileNet V2.

- **Resnet** (Szegedy, Ioffe, Vanhoucke, & Alemi, 2017), es una de las CNN que ahorran tiempo y ha ganado popularidad debido a su estructura novedosa. ResNet 101 tiene bloques residuales que incorporan intersecciones en capas estándar de CNN, para atravesar múltiples capas convolucionales, lo que hace que el proceso de convergencia de CNN sea más rápido y fácil a pesar de la gran cantidad de capas convolucionales (Attallah, 2022), tal como se muestra en la figura 5

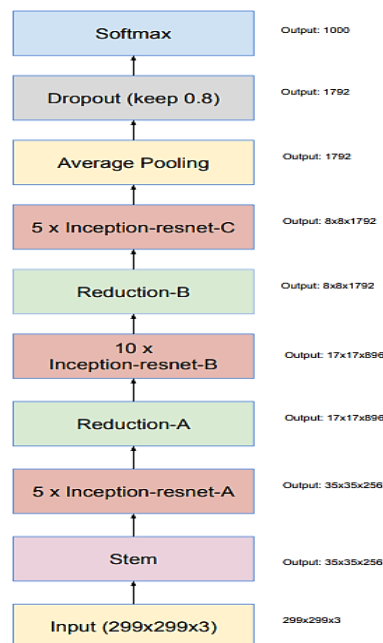


Figura 5. Arquitectura de ResNet 101.



Inception V3 en comparación con arquitecturas más simples y monolíticas, este modelo puede proporcionar redes de visión de alto rendimiento con un costo computacional relativamente bajo (Szegedy, Vanhoucke, Ioffe, Shlens, & Wojna, 2016). Esta arquitectura utiliza menos cantidad de cálculos en comparación con otros modelos de transferencia de aprendizaje, se muestra la arquitectura de Inception V3, en donde para ser utilizado, se debe desactivar la última capa e implementar el dataset clasificado, la arquitectura de Inception V3 se muestra en la figura 6.

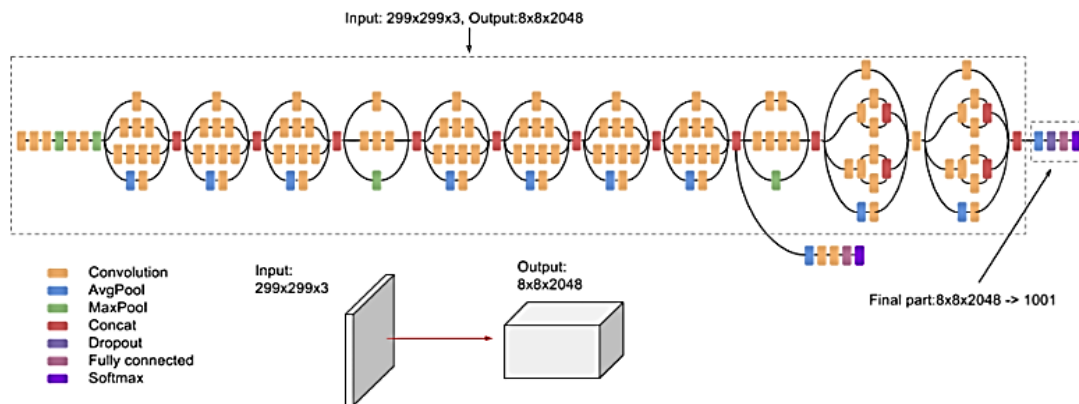


Figura 6. Arquitectura Inception V3.

Análisis de la Data

Existen algunas páginas donde almacenan distintos tipos de datasets de entrenamiento para redes neuronales convolucionales orientadas a la clasificación de ECG, en este trabajo nos centraremos en la página de Mendeley data (<https://data.mendeley.com/>), donde se encontraron imágenes previamente clasificadas por 3 diferentes tipos de electrocardiogramas. Para realizar la selección del dataset, se tuvieron en consideraciones los siguientes aspectos: Los exámenes de ECG que fueran tomados corresponden a los últimos 5 años, los datos proporcionados sean en formato imagen para poder entrenar el modelo, y que exista una clasificación de tipos de arritmias cardiacas para su debido análisis.

Entrenamiento del Modelo

Para realizar el entrenamiento del modelo se realizó mediante los siguientes puntos:

Depuración de datos



Se depuro la data de tal forma que todas tengan la misma señal senoidal, debido a que algunos de los electrocardiogramas consideraban señales de distintas partes del corazón, generando conflictos para las predicciones.

En tabla 1 se puede observar las clasificaciones y cantidad de imágenes de electrocardiogramas depuradas que nos brinda Instituto de Cardiología Multan (MIC), OHS y KardiaMobile.

Tabla 1. Clasificación y Cantidad de los Imágenes para CNN con set de datos de ECV

Datos	MIC	OHS	KardiaMobile
Ritmo Anormal	190	30	30
Ritmo Normal	216	30	30
Miocardio	200	0	0
TOTAL	606	60	60

Entrenamiento

Para realizar el entrenamiento se realizaron pruebas por separado de MobileNet V2, ResNet 101, Inception V3, extrayendo en cada modelo una serie de parámetros, como podemos observar en la tabla 2, se incorporaron imágenes redimensionadas a 224 x 224 que es el tamaño estándar que soporta la red.

Tabla 2. Arquitecturas y características extraídas de Modelos CNN Pre-entrenados

Red Neuronal	Profundidad de Red	Parámetros (Millones)	Tamaño de Imagen	Epochs	Batch Size
MobileNet V2	53	44	224×224	5	132
ResNet 101	101	44	224×224	5	132
Inception V3	48	23	224×224	5	132

Evaluación de Resultados

Para realizar la evaluación de resultados, en cuanto al porcentaje de precisión de los algoritmos, se utiliza la técnica de Validación Cruzada. Luego se evaluó los resultados de predicción con una Matriz de confusión. A continuación, se presentan los detalles de dicha implementación (ver figura 7).



Se utilizó la validación cruzada K-Fol debido a que mejora el modelo mediante la validación de los datos, esta técnica permite que la puntuación del modelo sea independiente de la técnica utilizada para seleccionar el conjunto de datos de prueba y entrenamiento. La validación cruzada K-fold divide el conjunto de datos en un número K de subconjuntos. Por lo tanto, el método de validación cruzada se repite k veces.

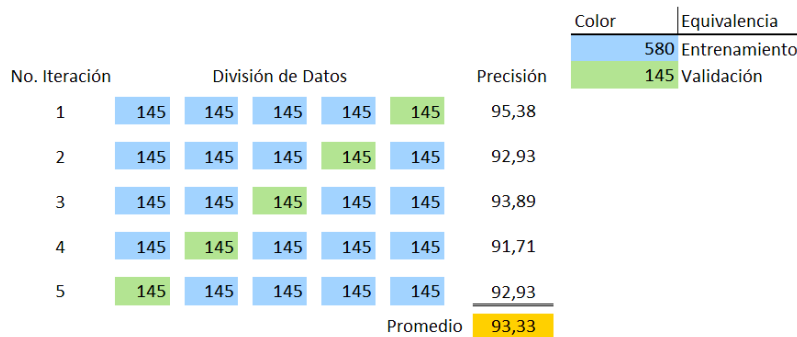


Figura 7. Validación Cruzada.

Validación Cruzada de 5 iteraciones

Como un primer acercamiento del trabajo se consideró cinco iteraciones, se puede observar que en la primera iteración el modelo obtuvo una precisión bastante alta respecto al resto con un 95,38% de exactitud esto significa que los datos de validación que fueron usados son fáciles de predecir, mientras que el más bajo fue la iteración número cuatro con un 91,71% de precisión, esto nos indica que en esta iteración existieron datos un poco difíciles de clasificar a diferencia de la primera. Como promedio de las cinco iteraciones se obtuvo que el algoritmo tiene una precisión de un 93,33% de asertividad.

Matriz de confusión

Existe más de una forma de validar la precisión de predicción del modelo, para esta evaluación de resultados usaremos la matriz de confusión utilizando funciones de sklearn como recall, f1, precisión score, confusión_matrix.

confusion_matrix: En términos de variable **y_real** representa nuestra variable objetivo la realidad, **y_pred** representa nuestra predicción. Estas serán comparadas para verificar verdaderos positivos y falsos positivos.

accuracy_score: calcula la precisión del subconjunto el conjunto de etiquetas previsto para una muestra debe coincidir exactamente con el conjunto de etiquetas correspondiente en **y_true**. La fórmula para calcular es:

$$\text{Accuracy} = ((\text{Predicciones correctas})) / ((\text{Total Predicciones})) \tag{1}$$



precision_score: Se refiere a la dispersión de un conjunto de valores obtenidos a partir de mediciones repetidas de una cantidad. Cuanto menor sea la dispersión, mayor será la precisión. La fórmula es:

$$\text{Precision} = ((\text{Verdaderos Positivos})) / ((\text{Verdaderos Positivos} + \text{Falsos Positivos})) \quad (2)$$

recall_score: es la proporción de ejemplos han sido clasificados como pertenecientes a qué clase de todos los ejemplos pertenecen realmente a esa clase. En otras palabras, es la proporción de ejemplos que han sido bien clasificados. Se calcula con la siguiente formula:

$$\text{Recall} = ((\text{Verdaderos Positivos})) / ((\text{Verdaderos Positivos} + \text{Falsos Negativos})) \quad (3)$$

Realizamos el diseño del gráfico con el comando `sns.heatmap()`, esta función nos permite representar gráficamente los valores del array con diferentes tonos de color para diferentes valores. Se creó los títulos principales de la matriz de confusión con el comando `plt.title()`, `plt.ylabel()` y `plt.xlabel()`.

Matriz de confusión Mobilenet V2: Los datos obtenidos en la diagonal (200, 180, 230) corresponden a las predicciones realizadas de manera correcta por el modelo (Verdaderos Positivos), los datos que se encuentran fuera de esta diagonal corresponden a las clasificaciones realizadas de manera errónea (Falso positivo o Negativo según corresponda). El valor obtenido por el accuracy equivale a una exactitud en predicciones de un 92.05% en estas predicciones fueron acertadas. Mientras que el Precisión nos indica que un 92.05% fueron clasificadas con éxito mientras que el 7.5% de datos fueron predichos de manera errónea. El Recall indica que el modelo pudo predecir del 100% de los datos el 92.05% correctamente.

Matriz de confusión Resnet 101: Para el modelo ResNet 101 con el mismo análisis de la diagonal obtuvo una puntuación de un 93% de asertividad a comparación de MobileNet V2, dando un mejor desempeño al momento de predecir sus datos, pero con un pequeño margen de error, catalogando de manera errónea un total de 41 datos del total.

Matriz de confusión Inception V3: El modelo Inception V3 obtuvo una gran cantidad de asertividad respecto a los modelos mencionados anteriormente con un accuracy de un 96%.

Resultados y discusión

En la tabla 3, se detalla de manera resumida los resultados de las métricas de evaluación que se obtuvieron en los modelos CNN al ser entrenado en forma independiente. Primero usando un dataset de imágenes públicas del instituto de Cardiología Pervaiz Elahi Multan, luego utilizando un dataset de imágenes del centro Médico OHS y por finalmenete las imágenes obtenidas por Kadia.



Tabla 3. Precisión, F1, Recall de Datasets Analizados con Matriz de Confusion

Datos	Épocas	Batch size	Accuracy	Precisión	F1 Score	Recall	Observación
MobileNet V2	5	132	0.92	0.92	0.92	0.92	Ajuste del electrocardiograma: 15.0mm/s, 10mm/mv, 50Hz 0.8Hz
Resnet 101	5	132	0.93	0.93	0.93	0.93	Ajuste del electrocardiograma: 15.0mm/s, 10mm/mv, 0.67-25Hz 0.8Hz
Inception V3	5	132	0.96	0.96	0.96	0.96	Ajuste del electrocardiograma: 15.0mm/s, 10mm/mv, 0.67-25Hz 0.8Hz

Como podemos observar, se muestran en las columnas el tipo de validación y observaciones como la configuración del electrocardiograma, y en las filas, se muestran los modelos de entrenamiento analizados para verificar su efectividad y asertividad acorde a los datos proporcionados. Entre cada modelo se agregaron diferentes tipos de imágenes para analizarlas, estas imágenes son de ICOEM, OHS y KardiaMobile. En lo cual se obtiene las siguientes observaciones:

- Se concretó que el tamaño de 132 lotes para el batch size y 5 épocas, fue la mejor opción debido al porcentaje de asertividad al momento de colocar una cantidad menor a 121 o aumentar o disminuir las épocas, esto debido a que no se contaban con las suficientes imágenes para realizar un entrenamiento más profundo, otros trabajos recomendaban esta configuración para su correcto entrenamiento.
- Las predicciones realizadas por la red Mobilenet V2 con las imágenes que fue entrenado el algoritmo, este realizo una predicción de 92% de manera exitosa, clasificando de manera errónea el 8% de sus datos. Por otro lado, Inception V3 mostró ser más efectivo clasificando con éxito un 96% de sus datos.

Según el objetivo de esta investigación, se busca demostrar que los modelos pre-entrenados de machine Learning MobileNet V2, ResNet 101 e Inception V3, basados en CNN permiten procesar las imágenes de señales de electrocardiogramas para determinar el tipo de arritmias cardiacas. Sin embargo, los resultados mostraron que Inception V3 presento los mejores resultados en comparación con los dos primeros modelos. Sin embargo, al comparar dichos resultados con el trabajo de (Aristega & León, 2022) observamos que difiere en el uso de los algoritmos convolucionales porque ellos operan sobre datos cuantitativos para diagnosticar enfermedades cardiovasculares, es importante mencionar que existe una mejora respecto a la agilidad de programación y ejecución de los datos y la FCM, cuenta con estas dos alternativas para desarrollar su diagnóstico de arritmias cardiacas. Si el objetivo es implementar un sistema que a partir del procesamiento de imágenes realice diagnóstico de las arritmias se



recomienda trabajar con el algoritmo pre-entrenado, Inception V3 desarrollado por GoogleNet en ambiente de Google colab e importando el modelo con librerías de Tensorflow Hub, en donde se encuentran los algoritmos pre-entrenados más populares, para poder tener un ambiente de desarrollo y pruebas ágil y fácil de configurar.

Conclusiones

Se cumplió con el objetivo de realizar el entrenamiento que permite clasificar los tipos de arritmias cardiacas, acorde a las imágenes que se presentaron al modelo, debido a las limitaciones del set de imágenes previamente clasificadas, se realizó el entrenamiento con un dataset un limitado, sin embargo, se logró obtener los datos suficientes para realizar las predicciones con un margen de éxito aceptable.

Las predicciones realizadas por el algoritmo son un diagnóstico preliminar, debido a que los resultados deben validarse por un médico especialista en temas cardiovasculares.

En cuanto a la clasificación se utilizó una CNN de transferencia de aprendizaje y con ella se procedió a la validación con 230 imágenes, las cuales fueron sometidas a los tres modelos pre-entrenados, donde Inception V3 arrojó un 96% de precisión, ResNet 101 93% de precisión y MobileNet V2 un 92% de precisión, logrando clasificar tres tipos de arritmias cardiacas, miocardio, ritmo sinusal normal y anormal.

Se sugiere incrementar los dataset de las señales de ECV etiquetadas para comprobar la efectividad con otros tipos de arritmias.

Agradecimientos

Al decanato de Investigación de la Universidad de Guayaquil, por ser los precursores de la existencias de proyectos multidisciplinarios a través de temas de investigación Aplicada, donde se crean espacios de contribución entre facultades a través de proyectos de fondos competitivos de investigación, dando lugar a la participación de docentes y estudiantes para sacar adelante la producción científica haciendo sinergia entre la Facultad de Ciencias Médicas y la Facultad de Ciencias Matemáticas y Físicas. Además queremos agradecer al centro médico OHS por su aporte con el dataset de imágenes de ECG.

Conflictos de intereses

Los autores no poseen conflictos de intereses.



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

Contribución de los autores

1. Conceptualización: Angie Salazar Salazar.
2. Curación de datos: Erick Limón Mejillones.
3. Análisis formal: Angie Salazar Salazar.
4. Adquisición de fondos: Erick Limón Mejillones.
5. Investigación: Angie Salazar Salazar.
6. Metodología: Angie Salazar Salazar.
7. Administración del proyecto: Alfonso Guijarro Rodríguez.
8. Recursos: Erick Limón Mejillones.
9. Software: Erick Limón Mejillones.
10. Supervisión: Alfonso Guijarro Rodríguez.
11. Validación: Alfonso Guijarro Rodríguez, Jorge Medina Avelino.
12. Visualización: Alfonso Guijarro Rodríguez.
13. Redacción – borrador original: Angie Salazar Salazar.
14. Redacción – revisión y edición: Alfonso Guijarro Rodríguez, Jorge Medina Avelino

Financiamiento

La investigación ha sido financiada mediante fondos institucionales.

Referencias

- Aristega, & León. (2022). Optimización de algoritmos de machine learning aplicados a problemas de arritmias cardíacas. (Trabajo de grado inédito). Universidad de Guayaquil, . Guayaquil, Guayas, Ecuador. Obtenido de <http://repositorio.ug.edu.ec/bitstream/redug/59960/1/B-CISC-PTG%232097-A%c3%b1o%202022%20Aristega%20Pazmi%c3%b1o%20Steven%20Felipe%20-%20Le%c3%b3n%20Mendoza%20Carlos%20Manuel%20.pdf>
- Attallah. (2022). An Intelligent ECG-Based Tool for Diagnosing COVID-19 via Ensemble Deep Learning Techniques. 5(12), 299. doi:<https://doi.org/10.3390/bios1205299>



- Bermúdez, & Rodríguez. (2021). Diseño de un sistema de adquisición y procesamiento de señales electrocardiograficas para la ayuda en el diagnóstico de arritmias mediante redes neuronales convolucionales. *Lexus(4)*, 37. Obtenido de <https://dspace.unitru.edu.pe/bitstream/handle/UNITRU/16524/RodriguezBermudez.pdf?sequence=3&isAllowed=y>
- Durán, & Del Real. (2017). Redes Neuronales Convolucionales en R: Reconocimiento de caracteres escritos a mano. (Trabajo Fin de Grado Inédito). Universidad de Sevilla, Sevilla. 78. Obtenido de https://idus.us.es/bitstream/handle/11441/69564/TFG_Jaime%20Dur%c3%a1n%20Su%c3%a1rez.pdf?sequence=1&isAllowed=y
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., . . . Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. Obtenido de <http://arxiv.org/abs/1704.04861>
- Khan, Haider, Hussain, & Muzammil. (2021). Conjunto de datos de imágenes de ECG de pacientes cardíacos y con COVID-19. *Elsevier*, 34, 1. doi:<https://doi.org/10.1016/j.dib.2021.106762>
- Moreno. (2018). Niveles de sedentarismo en estudiantes universitarios de pregrado en Colombia. 3(44), 553-566.
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. (2017). Inception-v4, inception-ResNet and the impact of residual connections on learning. 4278-4284. doi:<https://doi.org/10.1609/aaai.v31i1.11231>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. 2818-2826. doi:<https://doi.org/10.1109/CVPR.2016.308>
- Veloza, Jiménez, Quiñonez, Polanía, & Pachón. (2019). Variabilidad de la frecuencia cardiaca como factor predictor de las enfermedades cardiovasculares. 206.

