

DESARROLLO DE UN SISTEMA PARA CLASIFICACIÓN DE PATOLOGÍAS CARDIOVASCULARES EN SEÑALES ELECTROCARDIOGRÁFICAS (ECG) APLICANDO INTELIGENCIA ARTIFICIAL Y CLOUD COMPUTING

DEVELOPMENT OF A SYSTEM FOR CLASSIFICATION OF CARDIOVASCULAR PATHOLOGIES IN ELECTROCARDIOGRAPHIC SIGNALS (ECG) APPLYING ARTIFICIAL INTELLIGENCE AND CLOUD COMPUTING

Darío Fernando Bravo Tuay¹

Germán Arley Portilla González²

Universidad de Pamplona, Colombia

Resumen

En el presente proyecto se plantea el desarrollo de un sistema para clasificación de patologías cardíacas en señales electrocardiográficas (ECG), mediante la implementación de Inteligencia Artificial (IA), basado en Machine Learning bajo el lenguaje de programación Python sobre Linux. La idea principal de la inteligencia artificial es la de desarrollar métodos y algoritmos que permitan comportarse a las computadoras de modo inteligente. En primer lugar, se adquieren las señales electrocardiográficas de pacientes sanos y pacientes con problemas cardiovasculares por medio de la base de datos denominada "Physiobank" tales como afección valvular, bloqueo de rama, hipertrofia ventricular y disritmia cardíaca, en lo cual se debe aplicar técnicas de tratamiento y procesamiento de señales como lo es Wavelet, FFT, entropía y energía, para la posterior búsqueda de características o patrones que demuestren una diferencia en las señales, por consiguiente, obtener una correcta clasificación mediante la aplicación de técnicas de Machine Learning con respecto a las cardiopatías presentes y dar una mayor facilidad en cuanto al diagnóstico por parte del especialista, con base en lo anterior se selecciona la mejor técnica en cuanto a resultados y optimización. En segundo lugar, una vez finalizada la caracterización y clasificación de las

¹ Estudiante, Universidad de Pamplona, dario.bravo@unipamplona.edu.co

² Docente, Universidad de Pamplona, <https://orcid.org/0000-0002-6292-0270> / german.portilla@unipamplona.edu.co

ondas ECG se procede a aplicar estrategias de Cloud Computing para gestionar los datos, almacenarlos y procesarlos bajo el mismo servidor y entregar resultados en línea.

Las señales ECG se trabajan en formato .mat, estas son preprocesadas y procesadas mediante las técnicas de tratamiento de señales, se implementan técnicas como Support Vector Machine, Naïve Bayes y árboles de decisión, por otro lado, la selección de la técnica a emplearse como clasificación se basa en el mejor porcentaje de clasificación arrojado por el modelo generado por cada una de las técnicas mencionadas anteriormente, una vez se ha seleccionado la mejor técnica se da por finalizado el sistema clasificador de señales y se procede a crear un aplicativo web mediante el uso de un micro-framework denominado Flask el cual se puede implementar en Python, como ventaja se puede ejecutar código bajo dicho lenguaje de programación permitiendo crear su propia página web y poder ser compilada en la nube mediante el servicio Cloud Pythonanywhere.

Palabras clave: lenguaje supervisado; extracción de características; señales electrocardiográficas; Cloud Computing.

Abstract

In this project, the development of a system for the classification of cardiac pathologies in electrocardiographic signals (ECG) is proposed through the implementation of Artificial Intelligence (AI) based on Machine Learning under the Python programming language on Linux. The main idea of artificial intelligence is to develop methods and algorithms that allow computers to behave intelligently. In the first place, the electrocardiographic signals of healthy patients and patients with cardiovascular problems are acquired through the database called "Physiobank" such as valve disease, bundle branch block, ventricular hypertrophy and cardiac dysrhythmia, in which techniques must be applied treatment and processing of signals such as Wavelet, FFT, entropy and energy for the subsequent search for characteristics or patterns that demonstrate a difference in the signals, therefore, obtain a correct classification by applying Machine Learning techniques with respect to the heart diseases present and provide greater ease in terms of diagnosis by the specialist, based on the above, the best technique in terms of results and optimization is selected. Second, once the characterization and classification of the ECG waves is completed, Cloud Computing strategies are applied to manage the data, store and process it under the same server and deliver results online.

The ECG signals are worked in .mat format, these are pre-processed and processed using signal treatment techniques, techniques such as Support Vector Machine, Naïve Bayes and Decision Trees are implemented, on the other hand, the selection of the technique to be used as classification is based on the best classification percentage produced by the model generated by each of the aforementioned techniques, once the best technique has been selected, the signal classifier system is terminated and a web application is created using the Use of a micro-framework called Flask which can be implemented in Python, as an advantage code can be executed under said programming language allowing you to create your own web page and be able to be compiled in the cloud through the Cloud Pythonanywhere service.

Keywords: Supervised language; Feature extraction; Electrocardiographic signals; Cloud Computing.

1. Introducción

En la actualidad hay personas que padecen de graves patologías cardíacas y requieren de atención médica urgente, pero esto no es posible debido a un diagnóstico tardío por parte de la entidad de salud o especialista, a causa de la dificultad tan elevada que presentan las cardiopatías en ser detectadas, esto genera un tiempo excesivo en dar resultados finales, como consecuencia de lo anterior la persona fallece. A partir de las nuevas tecnologías como la adquisición de señales electrocardiográficas (ECG), procesamiento y tratamiento de señales, las herramientas computacionales se deben integrar en la búsqueda de una alternativa para un diagnóstico en menor tiempo posible y así poder otorgar una salud de vida más estable a la persona. Gracias a los nuevos avances científicos y tecnológicos, hoy en día se han desarrollado diversos sistemas para el mejoramiento de la salud de las personas, por tanto, este trabajo presenta una alternativa de diagnóstico rápido y preciso para los pacientes que padecen dichas cardiopatías con la finalidad de mejorar su calidad de salud y vida por medio de la realización correcta de procedimientos asignados por el especialista para la patología presente.

2. Metodología (o desarrollo del tema, según el caso)

En el presente ítem se da a conocer el paso a paso de la metodología implementada para el desarrollo del sistema de clasificación de señales ECG, basándose en conceptos generales con respecto a las temáticas a tratar, la adquisición de señales mediante una base de datos, el

preprocesamiento para el acondicionamiento de las señales y el procesamiento de las mismas para la adquisición de patrones característicos. En la Figura 1 se da a conocer la estructuración metodológica de cada uno de los aspectos más relevantes del trabajo de investigación.

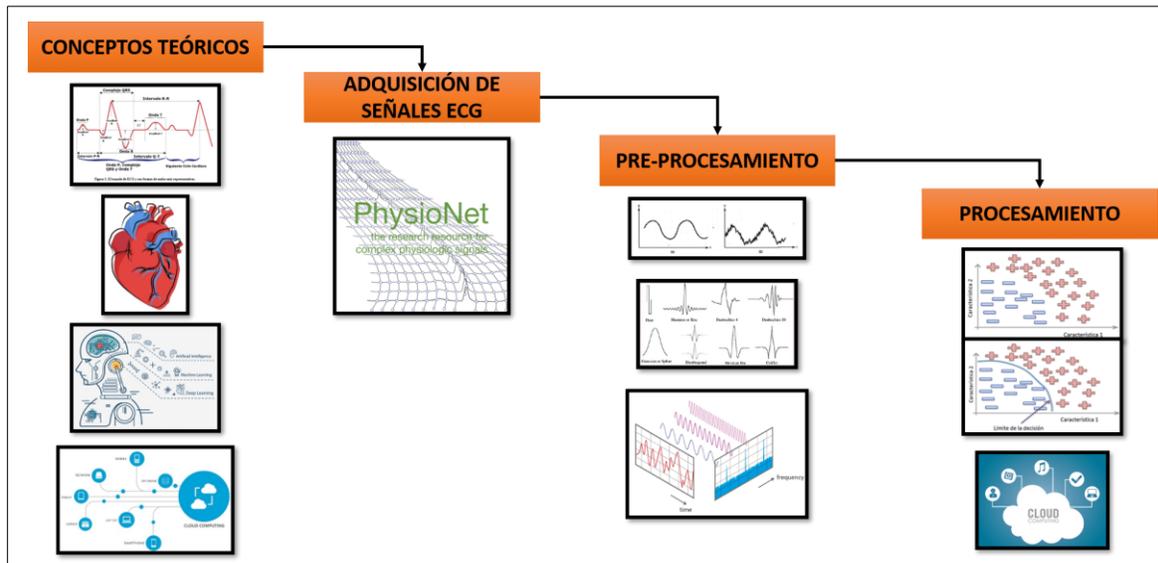


Figura 1. Estructura metodológica.

- **Conceptualización teórica**, es de gran importancia puesto que se obtendrá conocimiento a lo referente, por tanto, se dará una mejor legibilidad al desarrollo del trabajo, algunos de estos conceptos a tener en cuenta son electrocardiograma, errores de obtención de los electrocardiogramas, anatomía del corazón, enfermedades cardiovasculares a tratar en este proyecto (las ya mencionadas en anteriormente), técnicas de procesamiento y extracción de características, inteligencia artificial y Cloud Computing.
- **Adquisición de las señales ECG**, la consolidación de las señales ECG se realiza por medio de la base de datos denominada Physiobank, la cual consta de pequeños números de registros que pueden ser demasiado grandes con un tamaño alrededor del gigabyte. La gran mayoría de las datas se desarrollan en el MIT y el hospital de Beth Israel de Boston las cuales son de acceso gratuito para la comunidad investigadora.
- **Preprocesamiento**, tiene como finalidad el acondicionamiento de las señales que se usarán para las siguientes etapas. Por tanto, para ello se debe realizar un ajuste de amplitud (estandarización de la señal), con respecto a la información que se otorga en el archivo .info, centrar la señal en cero, ajustar la visualización de las señales.

- **Procesamiento**, la etapa de procesamiento consiste en la aplicación de las técnicas para el tratamiento y procesamiento de señales junto con la extracción de características para el reconocimiento y clasificación de las mismas y así otorgar un diagnóstico correcto. En esta etapa se han aplicado diversas técnicas de procesamiento, las cuales se dividen en dos líneas de procesamiento, y estas a su vez se dividen en tres sublíneas cada una.

3. Discusión

El corazón tiene 12 derivaciones, por lo cual, se tienen 12 señales ECG por cada paciente con respecto a cada patología o ya sea un paciente sano. En la Figura 2 a) se aprecia la señal de la derivada *i* del corazón, el procesamiento para cada derivada es el mismo. Todas las señales al cargarse se dejarán con un total de 15.420 muestras, puesto que la mayoría de ella son de 60.000 muestras y otras no, por tanto, dicho valor sería la longitud de la data a trabajar. Una vez que se ha cargado la señal, y se ha desglosado en cada una de sus derivadas y realizado el ajuste de nivel, se procede a aplicar las técnicas de procesamiento de señales. En la Figura 2 b) se aprecia una de las primeras técnicas, la cual es la FFT; se procede a realizar la eliminación de ruido de forma redundante por el hecho de no conocer la frecuencia de corte de la misma, sin afectar la señal puesto que al modificar algún valor o eliminar una frecuencia perteneciente a la data, se podría estar eliminando alguna patología o perturbación en la señal que indica una cardiopatía. En la Figura 2 c) se aprecia la eliminación de ruido mediante la visualización del valor absoluto; finalizado el paso anterior, se procede a aplicar la inversa de FFT para retornar al dominio temporal, y así poder continuar con la aplicación de otras técnicas. La Figura 2 d) muestra dicho paso; se procede a aplicar otra técnica de tratamiento de señales, por ello, la etapa de procesamiento consta de dos líneas de procesado, en primer lugar, se tiene la primera línea con Fourier, a su vez se aplica entropía (por medio de ventanas de 10, 20 y 30 puntos a cada una de las derivadas de la señal) y se normaliza. La Figura 2 e) muestra el resultado de aplicar entropía con una ventana de 10 puntos a la derivada *i*. Finalizada la línea 1 de procesamiento, se procede a aplicar la línea 2, la cual corresponde en aplicar una Wavelet madre db4 (la wavelet madre db4 es la más común y semejante en ser utilizada para la extracción de características en señales ECG), al aplicar Wavelet a cada una de las señales se comprime dicha señal a la mitad de sus muestras, para este caso, se escogió el segundo nivel del coeficiente de aproximación. La Figura 2 f) muestra

dicho proceso. Para finalizar con la línea de procesamiento 2, se aplica energía, consiste en elevar al cuadrado cada uno de los datos del vector de datos que componen la señal ECG, y efectuando sumatorias con una ventana o rango de referencia, para este caso se trabaja con una ventana de 10 puntos y por último se normaliza la señal, en la Figura 2 g) se aprecia dicho proceso.

El preprocesamiento consiste en:

- Estandarización de la señal (ajuste de amplitud) + Centrando señales en cero + Agrupación por datagrama

Las líneas de procesamiento de conforma de la siguiente manera:

- Línea 1: FFT + Entropía (ventana 10 puntos) + Normalización
- Línea 2: Wavelet (db4) + Energía (ventana 10 puntos) + Normalización

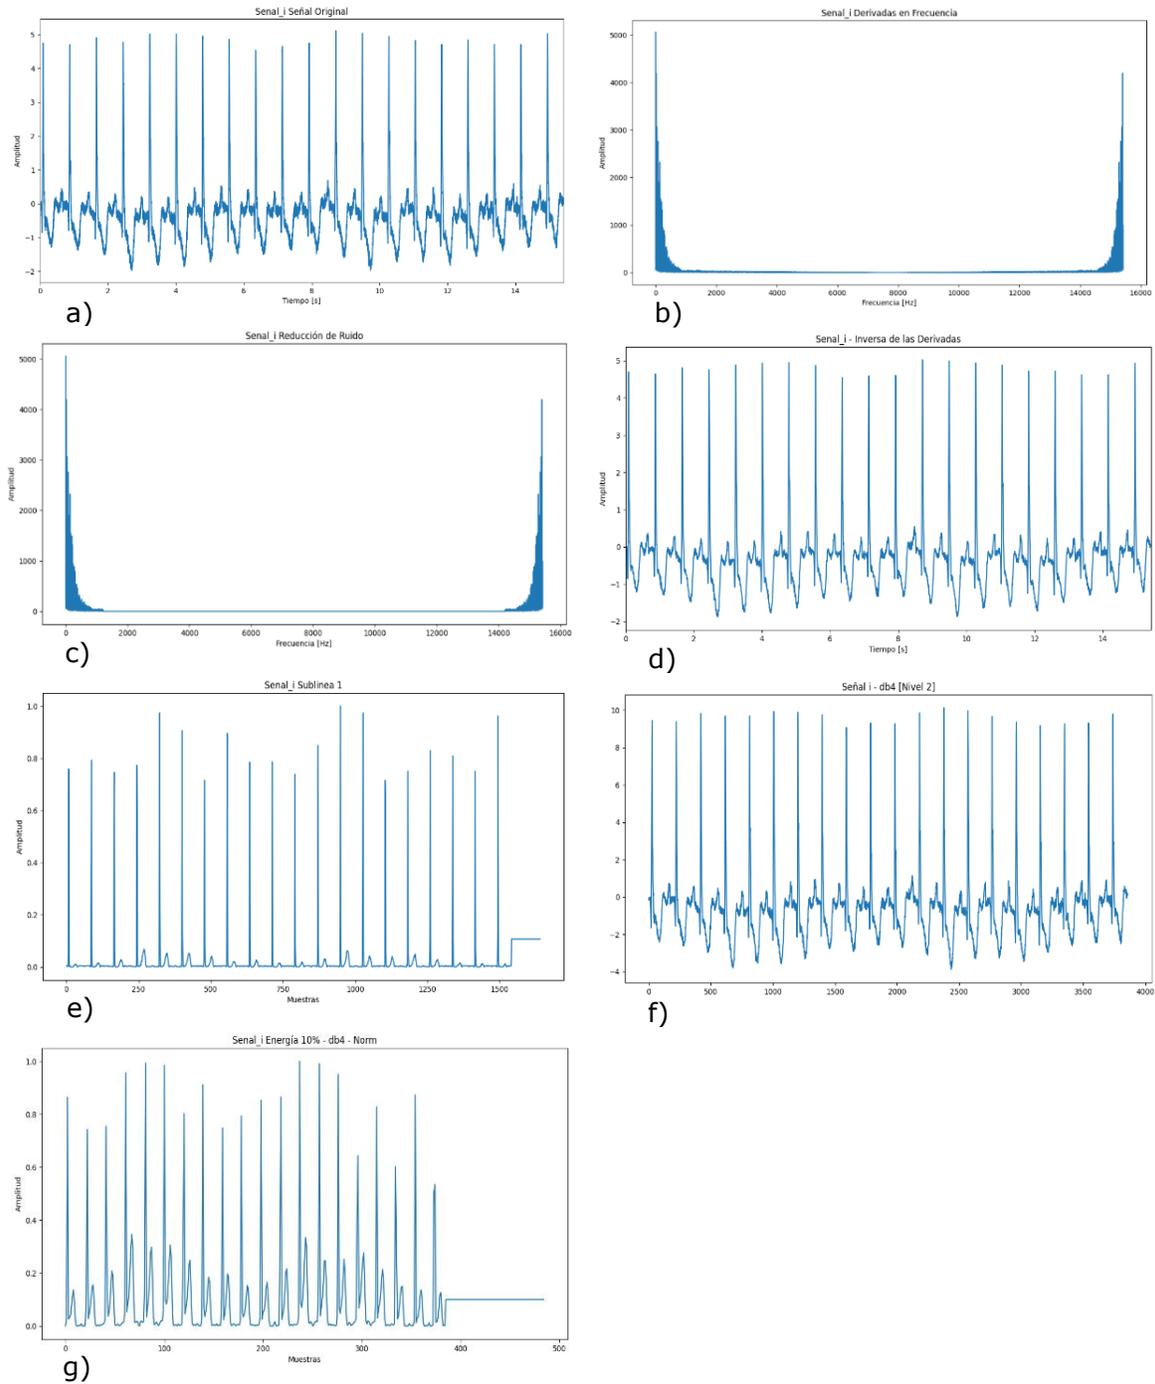


Figura 2. Resultados.

Finalizadas las líneas de procesamiento, se procede a obtener la matriz completa, la cual se usará para crear el modelo con IA y así poder realizar la clasificación. Esta matriz se compone de 375 filas y las columnas dependen de los resultados de las muestras dada por cada línea de procesamiento. Una vez que se ha creado la matriz, el paso a seguir es

crear el modelo mediante las técnicas de inteligencia artificial bajo lenguaje supervisado en Python, para ello, se crean etiquetas para tener como referencia a que clase pertenece cada patología, se aplican técnicas de VSM con kernel lineal, VSM con kernel RBF, Naïve Bayes y árboles de decisión, para estas dos últimas técnicas las etiquetas se aplican de forma binaria, debido a esto se tendrían más modelos en comparación de cada patología con respecto a las señales normales (pacientes sanos).

La creación del modelo implica dividir la matriz completa en una matriz de entrenamiento con la cual se entrena el modelo y una matriz de clasificación para medir la precisión de la predicción resultante por dichas técnicas. Se selecciona el método 80-20; 80% para entrenar el modelo con los datos de la matriz y el 20% restante para testear/clasificar las señales sobrantes y así medir la precisión del mismo.

La selección de la mejor técnica a aplicar en este trabajo se da por el mejor porcentaje de precisión, estos porcentajes se aprecian en la Figura 3.

Técnica IA	Línea 1	Sublínea 1 [%]	Línea 1	Sublínea 2 [%]	Línea 1	Sublínea 3 [%]	Línea 2	Sublínea 1 [%]	Línea 2	Sublínea 2 [%]	Línea 2	Sublínea 3 [%]
VSM (Lineal)		98.67		98.67		98.67		96.0		96.0		93.33
VSM (RBF)		94.67		96.0		96.0		93.33		90.67		90.67
-		-		-		-		-		-		-
Naive Bayes:		-		-		-		-		-		-
Sano_Valvular		96.67		96.67		96.67		93.33		83.33		76.67
Sano_Bloqueo		96.67		100.0		96.67		100.0		93.33		83.33
Sano_Disritmia		100.0		100.0		96.67		100.0		96.67		100.0
Sano_Hipertrofia		93.33		93.33		93.33		83.33		83.33		80.0
-		-		-		-		-		-		-
Arbol Decision:		-		-		-		-		-		-
Sano_Valvular		93.33		96.67		93.33		83.33		96.67		96.67
Sano_Bloqueo		83.33		90.0		93.33		80.0		90.0		90.0
Sano_Disritmia		93.33		96.67		100.0		76.67		93.33		93.33
Sano_Hipertrofia		93.33		100.0		100.0		96.67		100.0		93.33

Figura 3. Porcentajes de clasificación.

La técnica seleccionada es VSM con kernel lineal, por el hecho de crear múltiples clases, ya que uno de los objetivos de este trabajo es seleccionar la mejor técnica de procesamiento, para comparar todas las patologías una vez que se ingrese una señal desconocida al sistema.

El sistema clasificador contará con una interfaz gráfica de usuario para que cargue la señal, se procese y clasifique, esto se observa en la Figura 4. Se tiene la GUI principal, es decir, la ventaja que permite la ejecución de la aplicación completa como tal, la interfaz se implementado como aplicación de escritorio en Ubuntu por medio de un archivo .desktop.

Para ejecutar el software clasificador se debe dar clic en **Comenzar**.



Figura 4 .GUI principal.

En la Figura 5 se tiene la aplicación para clasificar señales, el usuario podrá cargar la señal .dat (una vez que se carga la señal, allí mismo se aplica el preprocesamiento), luego se puede procesar mediante las técnicas de tratamiento y procesamiento de señales, y por último se puede clasificar cada una de las derivadas del corazón por separado para generar un resultado.

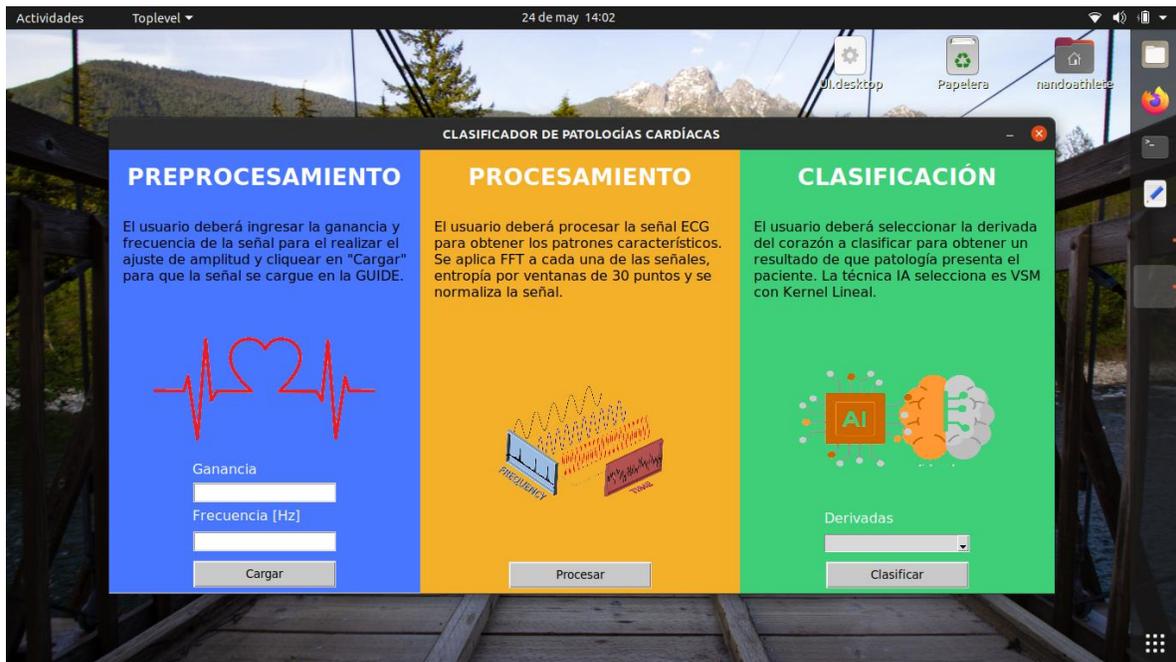


Figura 5. Software clasificador.

Como resultado generado por medio del software, la Figura 6 muestra el resultado obtenido de clasificar una señal ECG.



Figura 6. Resultado clasificación.

A su vez, se anexa un sistema con Cloud Computing para la transmisión de los resultados de señales a clasificar, esto es accesible mediante el enlace: <http://nandoathlete.pythonanywhere.com/>, en la Figura 7 se muestra el aplicativo web desarrollado en Python por medio de Flask.



Figura 7. Aplicativo Web Cloud.

Finalizadas las líneas de procesamiento, se procede a obtener la matriz completa, la cual se usará para crear el modelo con IA y así poder realizar la clasificación. Esta matriz se compone de 375 filas y las columnas dependen de los resultados de las muestras dada por cada línea de procesamiento. Una vez que se ha creado la matriz por cada línea de procesamiento, el paso a seguir es crear el modelo mediante las técnicas de inteligencia artificial bajo lenguaje supervisado en Python, para ello, se crean etiquetas para tener como referencia a que clase pertenece cada patología, se aplican técnicas de VSM con kernel lineal, VSM con kernel RBF, Naïve Bayes y árboles de decisión, para estas dos últimas técnicas las etiquetas se aplican de forma binaria, debido a esto se tendrían más modelos en comparación de cada patología con respecto a las señales normales (pacientes sanos).

La creación del modelo implica dividir la matriz completa en una matriz de entrenamiento con la cual se entrena el modelo y una matriz de clasificación para medir la precisión de la predicción resultante por dichas técnicas. Se selecciona el método 80-20; 80% para entrenar el modelo con los datos de la matriz y el 20% restante para testear/clasificar las señales sobrantes y así medir la precisión del mismo.

La selección de la mejor técnica a aplicar en este trabajo se da por el mejor porcentaje de precisión, estos porcentajes se aprecian en la Figura 8.

Técnica IA	Línea 1	Sublínea 1 (%)	Línea 1	Sublínea 2 (%)	Línea 1	Sublínea 3 (%)	Línea 2	Sublínea 1 (%)	Línea 2	Sublínea 2 (%)	Línea 2	Sublínea 3 (%)
VSM (Lineal)		98.67		98.67		98.67		96.0		96.0		93.33
VSM (RBF)		94.67		96.0		96.0		93.33		90.67		90.67
-		-		-		-		-		-		-
Naive Bayes:		-		-		-		-		-		-
Sano_Valvular		96.67		96.67		96.67		93.33		83.33		76.67
Sano_Bloqueo		96.67		100.0		96.67		100.0		93.33		83.33
Sano_Disritmia		100.0		100.0		96.67		100.0		96.67		100.0
Sano_Hipertrofia		93.33		93.33		93.33		83.33		83.33		80.0
-		-		-		-		-		-		-
Arbol Decision:		-		-		-		-		-		-
Sano_Valvular		93.33		96.67		93.33		83.33		96.67		96.67
Sano_Bloqueo		83.33		90.0		93.33		80.0		90.0		90.0
Sano_Disritmia		93.33		96.67		100.0		76.67		93.33		93.33
Sano_Hipertrofia		93.33		100.0		100.0		96.67		100.0		93.33

Figura 8. Porcentajes de clasificación.

4. Conclusiones

- El hecho de que las señales no sean linealmente separables y a su vez no son estacionarias, implica una mayor complejidad respecto a la extracción de los patrones característicos.
- Las afecciones cardiovasculares se trabajaron de forma global, debido a que la base de datos que proporciona las señales ECG no especifica la clasificación de las afecciones, es decir, para cada una de estas se dispone de más patologías, por tanto, el analizar una

señal con antecedentes de afección valvular no es lo mismo que analizar una señal que presente cardiopatía por hipertrofia, para la primera conlleva más afecciones tales como estenosis cardíaca, estenosis mitral, entre otras. Y para la segunda están las enfermedades por hipertrofia ventricular izquierda y derecha, hipertrofia ventricular izquierda y derecha, entre otros, por tanto, realizar un análisis con mayor profundidad requiere de mucho más tiempo y más conocimiento por parte de la medicina en el área cardiovascular.

- La selección de la primera línea de procesamiento con ventanas de 30 puntos se realiza por elección propia y por el hecho de otorgar un mejor porcentaje de clasificación de tipo multiclase a comparación de las demás técnicas empleadas.
- La implementación de interfaz gráfica de usuario es importante para realizar los pasos de preprocesamiento, procesamiento y obtener como resultado una predicción de forma visual a comparación de ejecutar código por ventana de comandos, lo cual se realiza por medio de tkinter permitiendo diseñar ventanas agradables y de fácil uso para el usuario.
- Se selecciona como servicio Cloud de almacenamiento a Pythonanywhere por la experiencia que se ha obtenido hace unos años realizando pruebas de aplicaciones con API REST mediante la implementación de Flask, lo cual es de gran ayuda por el hecho de permitir ejecutar código Python en aplicativos webs de forma más rápida, fácil y manejable.

Referencias

- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adam, M., Gertych, A. & Tan, R. S. (2017). A Deep Convolutional Neural Network Model to Classify Heartbeats. *Computers in Biology and Medicine* 89:389–396. <https://doi.org/10.1016/j.combiomed.2017.08.022>
- Alonso Guerrero, A. 1983. Anatomía del corazón. *Revista de Enfermería (Barcelona, Spain)* 6(57), 12–15.
- Cardiovasc, Thorac. (2017). Listado de aplicación IA en cardiología. 70, 2016–17.
- García Niebla, J. (s.f.). Errores y artefactos más comunes en la obtención del electrocardiograma. *Siacardio*, 1(8), 1–29. <http://www.siacardio.com/wp-content/uploads/2015/01/ECG->

Capitulo-10-Errores-y-artefactos-comunes-en-ECG.pdf

- Portilla González, G. A. (2017). Desarrollo de un sistema para clasificación de caracteres obtenidos de señales electroencefalográficas (eeg) aplicado en pacientes con afasia motriz. Universidad de Pamplona, Pamplona.
- Jap, D., Stöttinger, M. & Bhasin, S. (2015). "Support Vector Regression: exploiting machine learning techniques for leakage modeling. *ACM*, <https://doi.org/10.1145/2768566.2768568>
- Li, Q., Rajagopalan, C., & Clifford, G. D. (2014). A Machine Learning Approach to Multi-Level ECG Signal Quality Classification. *Computer Methods and Programs in Biomedicine*, 117(3), 435–47. <https://doi.org/10.1016/j.cmpb.2014.09.002>.
- Morales Muñoz, L., Quintana, G. & Niño, L. F. (2015). Modelo computacional para la identificación de endofenotipos y clasificación de pacientes con artritis reumatoide a partir de datos genéticos, serológicos y clínicos, utilizando técnicas de inteligencia computacional. *Revista Colombiana de Reumatología* 22(2), 90–103. <https://doi.org/10.1016/j.rcreu.2015.05.005>
- Oliveira, B. R., Abreu, C.C.E., Duarte, M. A. Q. & Filho, J. V. (2019). Geometrical Features for Premature Ventricular Contraction Recognition with Analytic Hierarchy Process Based Machine Learning Algorithms Selection. *Computer Methods and Programs in Biomedicine* 169, 59–69. <https://doi.org/10.1016/j.cmpb.2018.12.028>
- Palma, J., & Marín, R. (2008). *Inteligencia artificial. Técnicas, métodos y aplicaciones*. Madrid: McGraw-Hill.
- Pozas, G. 2008. El electrocardiograma y su tecnología. *Educación Médica*, 8(24), 27–31.
- Hernández Quintero, N., & Flórez Fuente, A. (2014). Computacion en la nube. *Revista Mundo FESC*, 8, 46–51.
- Valdez Alvarado, A. R. (2020). Machine Learning para todos. *Conferencia. IV Concitek Puno - Perú 2019*. [Ahttps://doi.org/10.13140/RG.2.2.13786.70086](https://doi.org/10.13140/RG.2.2.13786.70086)
- Ruiz Abellón, M. C. (2014). Introducción a los árboles de decisión. https://www.dmae.upct.es/~mcruiz/Telem06/Teoria/arbol_decision.pdf
- Sahoo, S., Mohanty, M., Behera, S. & Sabut, S. K. (2017). ECG Beat Classification Using Empirical Mode Decomposition and Mixture of

Features. *Journal of Medical Engineering and Technology*, 41(8), 652–61. <https://doi.org/10.1080/03091902.2017.1394386>

Sastre, I., Pérez, R.. (2014). *Anatomía y fisiología del corazón*. Universidad Nacional Autónoma de México. <https://www.ruam.unam.mx/portal/recursos/ficha/80561/anatomia-y-fisiologia-del-corazon>

Vidal-Silva, C., & Gatica Rojas, V. (2010). Diseño e implementación de un sistema electrocardiográfico digital. *Revista Facultad de Ingeniería*, 55, 99–107. <https://revistas.udea.edu.co/index.php/ingenieria/article/view/14718>

Sprockel, J. J., Diaztagle, J. Alzate, W. & E González, E. (2014). Redes neuronales en el diagnóstico del infarto agudo de miocardio. *Revista Colombiana de Cardiología*, 21(4), 215-223. <https://www.elsevier.es/es-revista-revista-colombiana-cardiologia-203-articulo-redes-neuronales-el-diagnostico-del-S0120563314000035>

Sprockel Díaz, J. J., , Diaztagle Fernández, J. J., & González Guerrero, E. (2017). Diagnóstico automático del síndrome coronario agudo utilizando un sistema multiagente basado en redes neuronales. *Revista Colombiana de Cardiología*, 24(3), 255-260. <https://doi.org/10.1016/j.rccar.2016.11.010>

López Takeyas, B. (2007). Introducción a la inteligencia artificial. Instituto Tecnológico de Nuevo Laredo, <http://itnuevolaredo.edu.mx/takeyas/Articulos/Inteligencia%20Artificial/ARTICULO%20Introduccion%20a%20la%20Inteligencia%20Artificial.pdf>

Fleifel Tapia, F.. (2008). Inteligencia Artificial. <http://www.cgosorio.es/Docencia/SExInArt/UD1/IntelArtif.pdf>

Yıldırım, Ö., Pławiak, P., Tan, R-S., & Acharya, U. R. (2018). Arrhythmia Detection Using Deep Convolutional Neural Network with Long Duration ECG Signals. *Computers in Biology and Medicine*, 102(1), 411–420. <https://doi.org/10.1016/j.combiomed.2018.09.009>