



CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL
INSTITUTO POLITÉCNICO NACIONAL

UNIDAD MONTERREY

CLASIFICACIÓN DE DATOS ELECTROCARDIOGRÁFICOS USANDO LA VERSIÓN
MULTICANAL DE LA TRASFORMADA DE LONGITUD COMO ESTIMADOR DE
VARIABILIDAD

Tesis que presenta

Jesús Antonio García Arana

Para obtener el grado de

Maestro en Ciencias

En

Ingeniería y Física Biomédica

Director de la Tesis:

Dr. David Gutiérrez Ruiz

Agradecimientos

Este documento es la culminación de una etapa en mi vida académica, el interés por la búsqueda del conocimiento no termina aquí, este es un escalón para mis metas personales.

Agradezco al CINVESTAV, por sus instalaciones y sus profesores los cuales me dieron la oportunidad de realizar este posgrado.

El CONACYT fue un gran apoyo económicamente durante esta etapa y es por esto que le agradezco infinitamente.

De manera especial, agradezco a mi asesora de tesis, la Dra. Dania Gutiérrez, la cual tuvo mucha paciencia conmigo, con los movimientos situados durante la pandemia y el tiempo que pudimos compartir, me llevo muchas enseñanzas de su parte, sin su apoyo no me hubiera sido posible lograr llegar hasta este punto.

Mis profesores durante el programa, los cuales no dudaron en compartir experiencias, conocimientos y enseñanzas a lo largo de estos años, sus felicitaciones y regaños me han llevado a culminar y ser una persona más preparada.

A todos mis amigos, con los que he entablado amistad desde que era un niño, siempre han estado para mí dando palabras de ánimo e inspirándome para cada día ser mejor.

A mi buen amigo Misael que durante el programa nos apoyamos día a día seguir adelante, tanto académicamente como personalmente.

Por último, pero no menos importante a toda mi familia, a mi madre Elvia y mi padre Ismael, los cuales a diario se preocupan por mí, me impulsan a ser un mejor hombre y continuar entregando la mejor versión de mí, sus palabras de ánimo me han llevado hasta el día de hoy.

Resumen

El electrocardiograma (ECG) es un estudio no invasivo, que consta en recolectar la información eléctrica del corazón y graficarla para detectar el estado de este órgano. La digitalización de estas señales permite estudiarlas y analizarlas mediante distintos algoritmos y modelos. Uno de los principales problemas de estudio es la clasificación de cardiopatías.

Anualmente la página PhysioNet propone un reto: en 2021 consistió en clasificar distintas señales de ECG, para lo cual nosotros proponemos utilizar la transformada de longitud para obtener las características principales de las 12 derivaciones del ECG y posteriormente clasificar dichas señales.

La clasificación se llevó a cabo en 6877 señales, las cuales corresponden a ocho cardiopatías y una al ritmo sinusal. Para cada clase se consiguieron sus características principales y se entrenó un modelo de regresión logística.

Los resultados muestran que la transformada de longitud es una buena opción para la clasificación de distintas cardiopatías que afectan principalmente la variabilidad del ritmo cardiaco, teniendo como ventajas una alta sensibilidad.

Abstract

The electrocardiogram (ECG) is a non-invasive study, which consists of collecting the electrical information of the heart and graphing it to detect its state. The digitization of these signals allows them to be studied and analyzed using different algorithms and models. One of the main problems of study is the heart disease classification.

The PhysioNet page annually proposes a challenge. The 2021 challenge is to classify different ECG signals with 2 leads at least, for which we propose to use the length transform to obtain the main characteristics of the 12 leads of each signal and then classify these signals.

The classification was carried out in 6877 signals, which correspond to eight different cardiopathies and the sinus rhythm. For each of these classes their main characteristics were obtained and a logistic regression model fed with these characteristics was trained.

The results show that the length transform is a good option for classifying different heart diseases especially those that affect mainly heart rate variability, with the advantages of high sensitivity.

Índice

1. Introducción.....	1
2. Hipótesis	5
3. Objetivos.....	5
3.1. Objetivo general.....	5
3.2. Objetivos específicos.....	5
4. Metodología.....	6
4.1 Descripción de la base de datos.....	6
4.1.1 Latidos ventriculares ectópicos.....	7
4.1.2 Fibrilación auricular.....	7
4.1.3 Bloqueo de rama izquierda	8
4.1.4 Elevación/depresión del segmento ST.....	9
4.1.5 Bloqueo AV de primer grado	9
4.1.6 Contracción prematura auricular	10
4.1.7 Bloqueo de rama derecha.....	11

4.2	Procesamiento	11
4.2.1	Detección del ritmo cardiaco	12
4.2.2	Transformada de longitud	14
4.2.2	Modelo autorregresivo.....	16
4.2.3	Modelo de regresión logística.....	17
4.2.4	Análisis de datos	20
5.	Resultados	22
6.	Conclusión	27
7.	Referencias	29

Índice de Figuras

Figura 1. A la izquierda colocación de electrodos para derivaciones bipolares y a la derecha colocación de electrodos para derivaciones precordiales. Tomada de [1].	1
Figura 2. ECG normal de dos latidos del corazón. Tomada de [1].	2
Figura 3. Latidos ectópicos acompañados de un bloqueo de rama izquierda. Tomada de [10].	7
Figura 4. Fibrilación auricular. Tomada de [11].	8
Figura 5. Bloqueo de rama izquierda en cada derivación del electrocardiograma. Tomada de [9].	8
Figura 6. A la izquierda isquemia miocárdica con elevación en segmento ST en diferentes derivaciones y a la derecha isquemia miocárdica con supresión en segmento ST en diferentes derivaciones. Tomada de [9].	9
Figura 7. Bloqueo AV de primer grado. Tomada de [12].	10
Figura 8. Contracción prematura auricular, las flechas indican la aparición de estas contracciones prematuras, así como el reinicio del nodo SA y las pausas entre latidos. Tomada de [13].	10
Figura 9. Bloqueo de rama derecha en derivaciones V1 y V6. Tomada de [14].	11
Figura 10. Detección de ritmo cardiaco con método MOBD, periodo refractario = 0.2s y umbral adaptativo = 0.25s.	13
Figura 11. Detección de ritmo cardiaco con método MOBD, periodo refractario = 0.6s y umbral adaptativo = 0.75s.	13
Figura 12. ECG: ritmo sinusal 12 canales.	15
Figura 13. Aplicación de la transformada de longitud a ECG: ritmo sinusal 12 canales.	15
Figura 14. Entrenamiento del modelo de las clases.	19
Figura 15. Clasificación entre clases A y B.	20
Figura 16. Arriba transformada de longitud: ECG: Latidos ventriculares ectópicos y abajo transformada de longitud: bloqueo AV de primer grado.	22
Figura 17. Arriba la transformada de ECG: ritmo sinusal y abajo ECG: fibrilación auricular.	23
Figura 18. Arriba transformada de longitud ECG: bloqueo de rama izquierda y abajo transformada de longitud bloqueo de rama derecha.	24

Figura 19. Arriba transformada de longitud depresión del segmento ST y abajo transformada de longitud elevación del segmento ST. 25

Figura 20. A la izquierda transformada de longitud contracción prematura auricular y la derecha ECG: ritmo sinusal. 26

1. Introducción

Cuando se produce el ciclo cardiaco, la corriente eléctrica se conduce por los tejidos internos y externos, lo cual hace posible colocar electrodos en la piel para lograr registrar los potenciales eléctricos generados. Este registro se conoce como ECG. Un ECG completo consiste en registrar diferentes vistas de los potenciales de acción, estos se denominan derivaciones y se dividen en 3 tipos, estas se detallan a continuación y en la Figura 1:

- Derivaciones bipolares, las cuales registran el potencial de las extremidades del paciente y se denominan bipolares ya que se utilizan dos electrodos que se localizan en lados diferentes del corazón. Se denotan como DI, DII y DIII.
- Derivaciones unipolares ampliadas, las cuales registran dos electrodos en las extremidades al terminal negativo del electrocardiógrafo y un electrodo a la terminal positiva. Se denotan como aVR, aVL y aVF.
- Derivaciones precordiales, cuyo registro se logra colocando un electrodo sobre el tórax del paciente, este electrodo será el terminal positivo mientras que los electrodos que pertenecen al terminal negativo son colocados en las extremidades y unidos. Se denotan como V1, V2, V3, V4, V5 y V6.

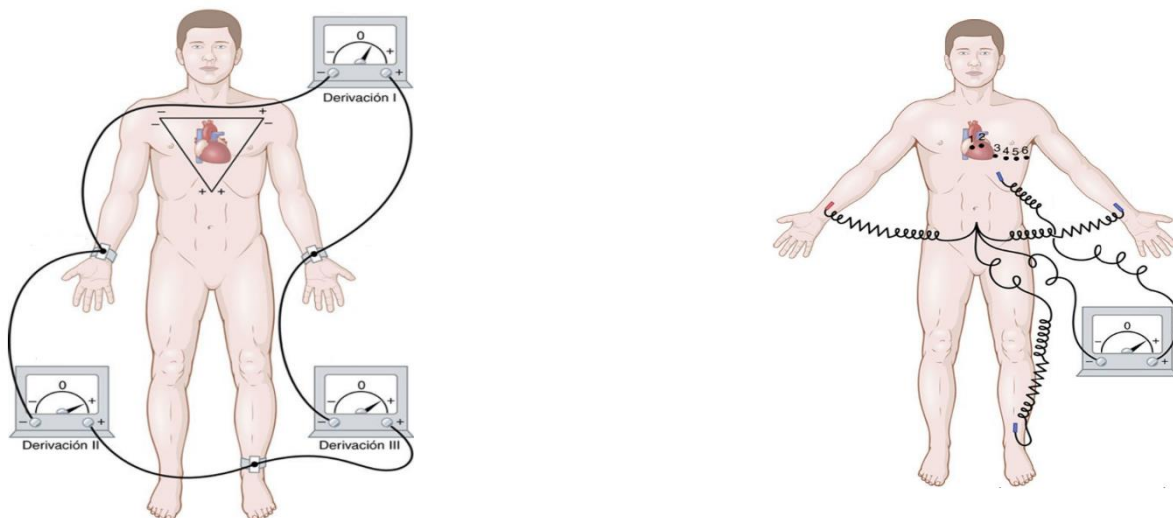


Figura 1. A la izquierda colocación de electrodos para derivaciones bipolares y a la derecha colocación de electrodos para derivaciones precordiales. Tomada de [1].

Un ciclo cardiaco normal típicamente se representa por diferentes ondas e intervalos del ECG los cuales se explican a continuación y en la Figura 2:

- Onda P, que es la producida por los potenciales eléctricos correspondientes a la despolarización de las aurículas antes del comienzo de la contracción auricular. Su duración normalmente es de 0.10s y su voltaje menor a 0.25mV.
- Complejo QRS, que está formado por los potenciales que se generan cuando se despolarizan los ventrículos antes de su contracción. Normalmente tiene una duración menor a 100ms.
- Onda T, el cual se produce por los potenciales que se generan cuando los ventrículos se repolarizan.
- Intervalo P-Q. definido por el tiempo que transcurre entre el comienzo de la onda P y el comienzo del complejo QRS es el intervalo que hay entre el inicio de la excitación eléctrica de las aurículas y el inicio de la excitación de los ventrículos.
- Intervalo Q-T. que corresponde a la contracción del ventrículo dura casi desde el comienzo de la onda Q (onda R si no hay onda Q) hasta el final de la onda T [1].




Figura 2. ECG normal de dos latidos del corazón. Tomada de [1].

Una alteración en esta señal puede ser indicador de una cardiopatología. Observando la señal modificada, un especialista es capaz de determinar mediante su experiencia y conocimiento que tipo de patología es, por qué se origina y qué es lo que está afectando. Por otra parte, la comunidad científica a buscado intensamente emplear distintas técnicas y algoritmos para la extracción de información y diagnóstico [2] con la finalidad de obtener mejores resultados.

El complejo QRS marca el inicio de la contracción ventricular izquierda, lo cual detectar este patrón tiene muchas aplicaciones clínicas sobre todo con el uso de las nuevas tecnologías en medicina y en la detección digital [3]. Se utilizan diferentes métodos y algoritmos con la finalidad de lograr la detección. Por otra parte, es posible detectar las características principales de esta señal al igual que los patrones que alteran la morfología como el caso de distintas cardiopatías.

Conforme ha pasado el tiempo, los equipos médicos han evolucionado en cuanto a su tecnología, costo, tamaño, precisión y exactitud. Específicamente dentro del campo del estudio del miocardio también se ha encontrado un avance exponencial en detección de cardiopatías por medio de lecturas de las señales electrocardiográficas. Es de interés estudiar las enfermedades cardiovasculares porque han sido una de las principales causas de muerte cada año, tanto en hombres como en mujeres, tal es el caso que registra el Instituto Nacional de Estadística y Geografía como la primera causa de muerte en México en el año 2020, con 218, 885 defunciones en total [4].

A la fecha, gran parte del análisis de la actividad cardiaca se hace por expertos médicos que diagnostican los registros del ECG. Sin embargo, existe un alto interés en la comunidad científica en coadyuvar en el diagnóstico mediante herramientas computacionales. Durante las últimas décadas el software de detección del complejo QRS ha mejorado y evolucionado conforme el desarrollo de las tecnologías de computación. Entre los algoritmos con los que se han trabajado están las redes neuronales, algoritmos genéticos, transformadas de wavelet, bancos de filtros, transformadas no lineales, entre otros [5]. Gracias a la detección y caracterización de patrones en el ECG es posible realizar comparaciones para lograr clasificar y diagnosticar una cardiopatía de manera automatizada, mediante el desarrollo de un algoritmo.

Uno de los primeros algoritmos utilizados con el fin de detectar el complejo QRS es el algoritmo Pan-Tompkins el cual se desarrolló en 1985 [6]. Este algoritmo propone una detección en tiempo real basada en el análisis de las pendientes, amplitud y ancho de los complejos QRS. El algoritmo incluye una serie de filtros a la señal original, el primer filtro es un filtro pasa-bajas que utiliza coeficientes enteros para disminuir la complejidad computacional, seguido de un filtro pasa-altas que atenúa el ruido proveniente de la señal. El tercer filtro es un filtro derivativo que acentúa las pendientes de la señal, las cuales corresponden al complejo QRS, así como disminuir las ondas P y T. En seguida se eleva al cuadrado la señal para volverla positiva, acentuar las frecuencias altas y por último suprimir las diferencias pequeñas de las ondas P y T. A continuación, se aplica un filtro de movimiento promedio con la intención de lograr un suavizado en la señal anterior, la cual muestra múltiples picos durante duración del complejo QRS.

Por último, se agrega un umbral adaptativo, este procedimiento en el algoritmo se adapta para cambiar en el ECG computando estimados de la señal y picos de ruido [7].

Otro algoritmo utilizado en la práctica es el método de multiplicación de las diferencias pasadas (MOBD), como su nombre lo indica (multiplication of backward differences) consta de tomar una muestra y restarla con la siguiente muestra en el tiempo y multiplicarlas por el resto de la señal. Este algoritmo ha presentado un buen rendimiento en relación entre precisión y tiempo de respuesta, y es uno de los algoritmos con menor carga computacional a diferencia de otros como el algoritmo Pan-Tompkins. Sin embargo, en pruebas realizadas en 358551 latidos, la tasa de error al detectarlos es de 6.94% para el algoritmo MOBD y 3.85% para Pan-Tompkins [3].

También se han estudiado y aplicado diferentes transformadas como el caso de la transformada de longitud. Esta última transformada ha sido utilizada en la clasificación de señales en interfaces cerebro-computadora, al pedirle a sujetos realizar distintas tareas y monitorear la actividad cerebral es posible clasificar las señales cerebrales medidas a que tarea corresponde [8]. De ahí el interés de verificar la aplicación de la transformada de longitud para la clasificación de señales electrocardiográficas asociadas a las cardiopatías.

Este trabajo está estructurado de la siguiente manera: en los Capítulos 2 y 3 se muestran la hipótesis y objetivos que persigue esta tesis; el Capítulo 4 desarrolla la base de datos así como los métodos que emplearemos, en particular el uso de la transformada de longitud y los modelos matemáticos que permiten extraer las características principales de cada señal; el Capítulo 5 muestra los resultados del proceso de clasificación por pares de las distintas clases; el Capítulo 6 contiene las conclusiones.

2. Hipótesis

La integración multicanal inherente de la transformada de longitud permitirá obtener características para discriminar datos de electrocardiografía correspondientes a distintas patologías.

3. Objetivos

3.1. Objetivo general

Evaluar el desempeño de un clasificador de regresión logística simple al cual se le alimenta la versión multicanal de la transformada de longitud para discriminar datos de electrocardiografía correspondientes a diversas patologías.

3.2. Objetivos específicos

- Implementar códigos de procesamiento de datos electrocardiográficos usando la versión multicanal de la transformada de longitud
- Implementar una clasificación de datos electrocardiográficos basado en la transformada de longitud como vector de características
- Evaluar la efectividad del clasificador en la discriminación de diversas patologías

4. Metodología

4.1 Descripción de la base de datos

La clasificación de datos de ECG propone retos de innovación e investigación constantes y este proyecto toma como inspiración el reto propuesto en PhysioNet en 2021, “¿Will Two Do? Varying Dimensions in Electrocardiography: The PhysioNet/Computing in Cardiology Challenge 2021” el cual consiste en identificar diagnósticos clínicos de cardiopatías utilizando un ECG de doce canales, para su posterior disminución a seis canales, cuatro canales y por último a 2 canales.

Las señales que se utilizaron en dicho reto y en este proyecto fueron obtenidas mediante la base de datos pública del “China Physiological Signal Challenge in 2018” en <https://physionetchallenges.org/2021/> la cual cuenta con 6877 registros muestreados a 500 Hz con un total de muestras entre 5000 y 12500 por señal. La muestra de pacientes se cuenta con un rango de edades entre 14 hasta 82 años.

Esta base de datos cuenta con $k = 1, 2, \dots, 9$ clases diferentes tipos de datos (cardiopatías y ritmo sinusal), los cuales están asociadas con un número de identificación, este número se encuentra en el “Systematized Nomenclature Of Medicine Clinical Terms” (SNOMED CT: <https://bioportal.bioontology.org/ontologies/SNOMEDCT/>) y estas se muestran a continuación:

Clase	No. de identificación	Cardiopatía	Cantidad (N_k)
clase 1	164884008	ECG: Latidos ventriculares ectópicos	700
clase 2	164889003	ECG: Fibrilación auricular	1221
clase 3	164909002	ECG: Bloqueo de rama izquierda	236
clase 4	164931005	Elevación del segmento ST	220
clase 5	270492004	Bloqueo auriculoventricular de primer grado	722
clase 6	284470004	Contracción prematura auricular	616
clase 7	426783006	ECG: Ritmo sinusal	918
clase 8	429622005	Depresión del segmento ST	869
clase 9	59118001	Bloqueo de rama derecha	1857

Tabla 1. Clases de datos con distintas patologías usadas en este proyecto.

Cada cardiopatía presenta una deformación respecto al ciclo cardíaco típico, a continuación, se detallan las clases que se utilizan [9]:

4.1.1 Latidos ventriculares ectópicos

La clase 1 corresponde a latidos ventriculares ectópicos. Estos latidos son prematuros, además de que surgen desde un foco ectópico, en este caso los ventrículos. Se identifican por presentar complejos QRS ensanchado mayor a 120ms con una morfología anormal, esta se describe como un patrón de repolarización anormal, en donde el segmento ST y la onda T son inversas al complejo QRS (Figura 3).




Figura 3. Latidos ectópicos acompañados de un bloqueo de rama izquierda. Tomada de [10].

4.1.2 Fibrilación auricular

La clase 2 corresponde a un tipo de arritmia denominada fibrilación auricular, y es la patología más común. En la unión americana hasta el año 2012 se calcula que 2.2 millones de personas la presentan. Es una despolarización caótica y desordenada de las aurículas, por lo tanto, hay una pérdida de la función mecánica del corazón. Los impulsos llegan al nodo auriculoventricular (AV) y no todos atraviesan por el haz de His. Debido a esta penetración parcial se produce la arritmia.

El patrón que se observa en la Figura 4 corresponde a la fibrilación auricular y sus características principales son la ausencia de onda P, ondas F que son pequeñas ondas auriculares, irregulares en tamaño y morfología, complejos QRS normal e intervalos RR diferentes.



Figura 4. Fibrilación auricular. Tomada de [11].

4.1.3 Bloqueo de rama izquierda

La clase 3 corresponde al bloqueo de rama izquierda, el estímulo eléctrico no se conduce a través de la rama izquierda por lo cual únicamente se despolariza el ventrículo derecho y de este mismo se crean dipolos que alcanzan al ventrículo izquierdo generando un salto de onda. El estímulo no viaja por el sistema de conducción y condiciona una despolarización lenta traduciéndose en el ECG como un ensanchamiento del complejo QRS. Se observa un complejo QRS con duración mayor a 100ms, ondas R anchas y con muescas en las derivaciones V5 y V6, onda S dominante en V1, rotación del vector QRS a la izquierda como se aprecia en la Figura 5.




Figura 5. Bloqueo de rama izquierda en cada derivación del electrocardiograma. Tomada de [9].

4.1.4 Elevación/depresión del segmento ST

La clase 4 y 8 corresponden a elevación y depresión del segmento ST respectivamente, estos patrones pueden tener diferentes causas tales como la isquemia miocárdica y el infarto. Sin embargo, a manera descriptiva, se presenta mediante una elevación respecto a la línea base como se observa a la izquierda en la Figura 5, mientras que la supresión es una bajada respecto a la línea base del ECG, la cual se puede observar a la derecha de la Figura 6.

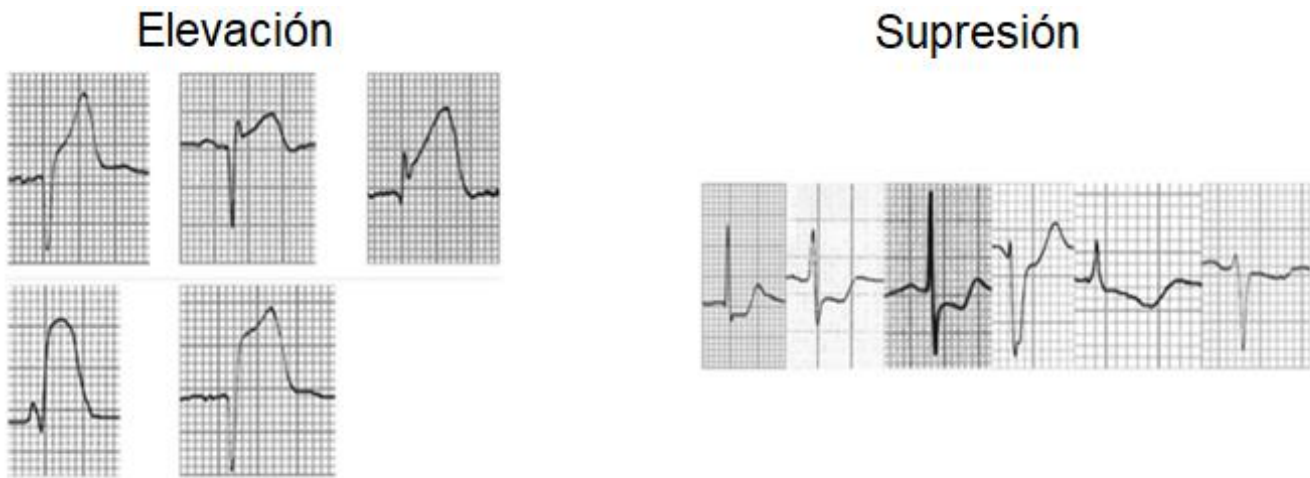


Figura 6. A la izquierda isquemia miocárdica con elevación en segmento ST en diferentes derivaciones y a la derecha isquemia miocárdica con supresión en segmento ST en diferentes derivaciones. Tomada de [9].

4.1.5 Bloqueo AV de primer grado

La clase 5 corresponde al bloque AV de primer grado. Es un retraso de la conducción del impulso proveniente de la aurícula en la unión AV, causado por un periodo refractario en estos tejidos. Esta unión se presenta en el intervalo PR el cual en situaciones normales es de 120ms hasta los 200ms y en caso de presentar este bloqueo AV de primer grado es mayor a 200ms, como se observa en la Figura 6.




Figura 7. Bloqueo AV de primer grado. Tomada de [12].

4.1.6 Contracción prematura auricular

La clase 6 corresponde a contracción prematura auricular, esta cardiopatía es un latido prematuro que se origina en las aurículas. Presenta una onda P anormal, seguida de un complejo QRS normal. Si se produce cerca del nodo AV, entonces aparece una onda P invertida con un intervalo PR corto menor a 120ms. En cambio, si alcanza el nodo sinoauricular (SA), puede despolarizarlo y reiniciar el nodo SA, lo que provoca una pausa antes del siguiente latido. En la figura 8 se observa este fenómeno.



Figura 8. Contracción prematura auricular, las flechas indican la aparición de estas contracciones prematuras, así como el reinicio del nodo SA y las pausas entre latidos. Tomada de [13].

4.1.7 Bloqueo de rama derecha

La clase 9 y última, corresponde al bloque de rama derecha y se caracteriza por presentar un intervalo QRS mayor a 120ms, un patrón RSR en V1 a V3, también denominado complejo QRS en forma de M y onda S ancha y arrastrada con forma de W. En la figura 9 se observa más a detalle.



Figura 9. Bloqueo de rama derecha en derivaciones V1 y V6. Tomada de [14].

4.2 Procesamiento

Las señales se procesaron en diferentes etapas:

- Se utiliza la transformada de longitud con la finalidad de comprimir la información de variabilidad de los 12 canales en una sola señal, la cual facilita su procesamiento.
- Posteriormente se aplica un modelo autorregresivo con lo cual se obtienen las características principales de la señal. Esta información se obtiene en forma de un vector con longitud igual al orden del modelo y se agregan los datos de la edad y el sexo.

- Por último, se utiliza un modelo de regresión logística que permite crear un modelo representativo de la patología contra el que se compararán las señales que se desean clasificar.

En una primera aproximación, en esta tesis se usan los datos de cada patología para crear (*entrenar*) el modelo de regresión logística (RL) y, después, cada uno de esos datos se prueban (*clasifican*) contra los modelos para discriminarlos. A continuación, se detallan cada uno de los componentes de la metodología.

4.2.1 Detección del ritmo cardiaco

En nuestra implementación utilizamos el método MOBD para la estimación del ritmo cardiaco. Si consideramos la señal del ECG como una serie de tiempo, entonces el ritmo cardiaco puede ser calculado a través de las diferencias sucesivas de dicha serie.

Así se define el método MOBD de orden N como:

$$M(n) = \prod_{k=0}^N |x(n - k)|. \quad (1)$$

En nuestra aplicación, el orden escogido es de 4to orden.

Si bien este método es funcional por sí mismo, se consideran algunos parámetros para evitar la detección de falsos positivos. Son dos parámetros principales, el primero es un periodo refractario el cual representa el espacio de tiempo entre un latido y otro, además durante este periodo se ignora cualquier posible detección. De manera estándar se elige 0.2 segundos ya que en un intervalo RR teórico correspondería a una frecuencia cardiaca de 300 latidos por minuto.

Por otra, parte el segundo parámetro que se considera es un umbral adaptativo, el cual disminuye en función de la amplitud del ECG y lo que este por debajo se considera ruido. En las siguientes figuras se observan los efectos de estos parámetros en la detección del pico R.

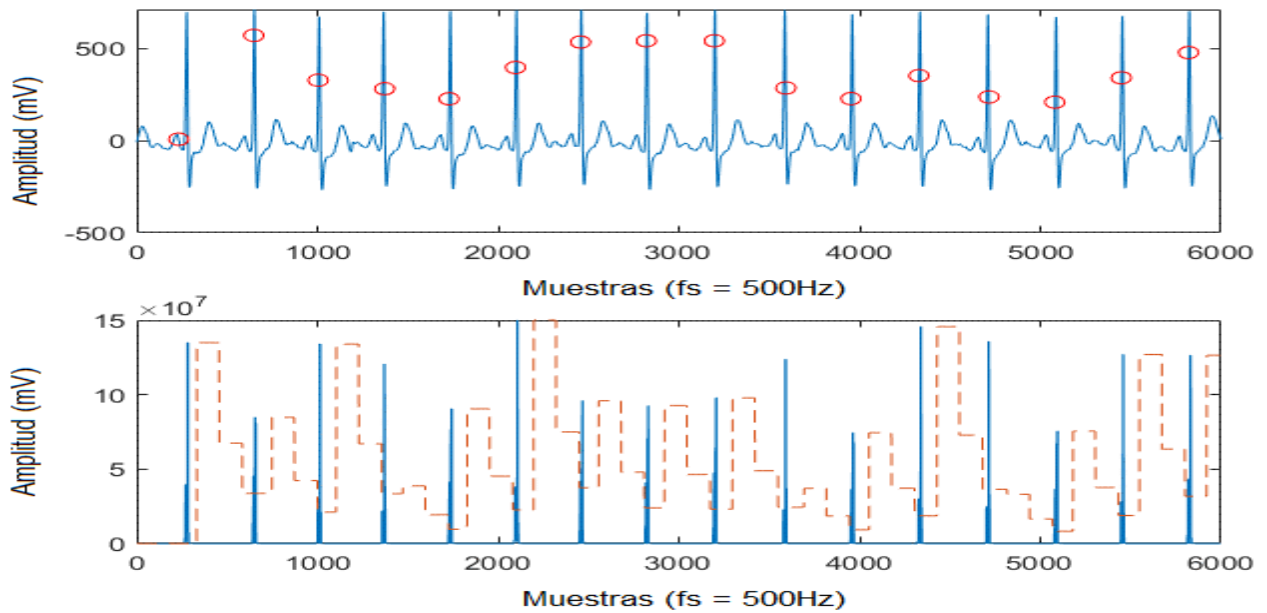


Figura 10. Detección de ritmo cardiaco con método MOBD, periodo refractario = 0.2s y umbral adaptativo = 0.25s.

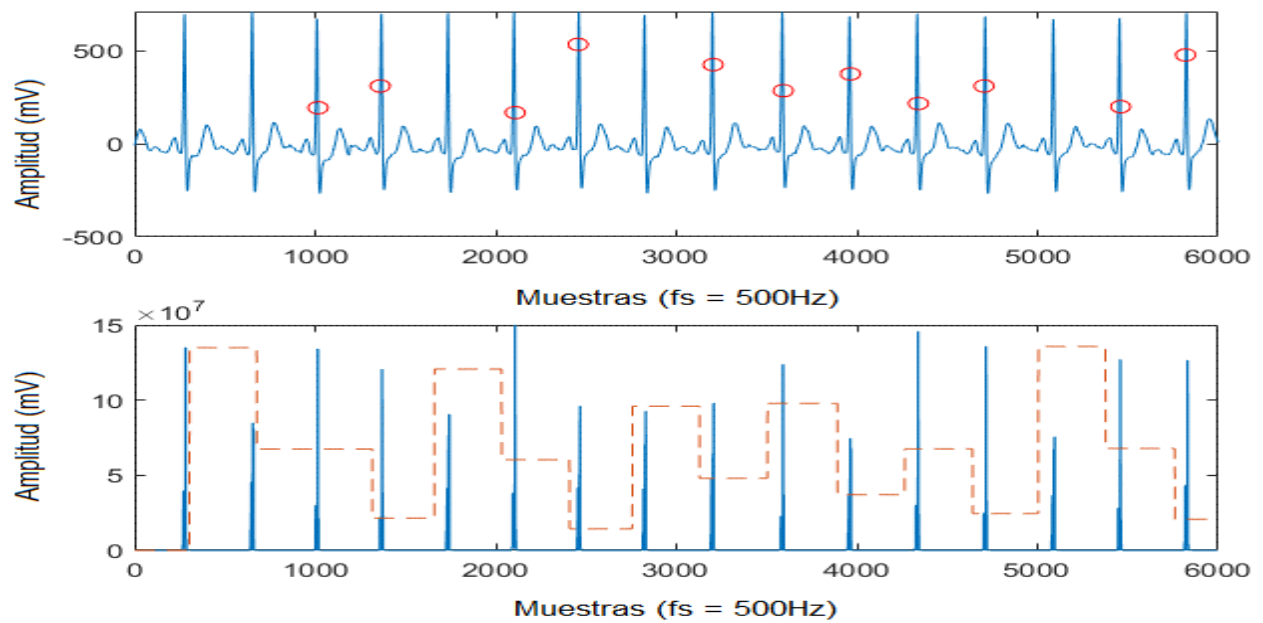


Figura 11. Detección de ritmo cardiaco con método MOBD, periodo refractario = 0.6s y umbral adaptativo = 0.75s.

4.2.2 Transformada de longitud

Esta transformada representa la señal suavizada a través del tiempo. Es usada en problemas de procesamiento de señales en múltiples canales como en el caso de un ECG de 12 canales y la detección del complejo QRS, también se puede utilizar para señales de un solo canal [8].

La transformada de longitud se define como:

$$l_m(n) = \sum_{k=n}^{n+q-1} |x_m(k) - x_m(k-1)|. \quad (2)$$

Donde x_m es la señal a transformar, $n = 1, 2, \dots, N$ muestras en el tiempo, m es el número de canales y q es el número de muestras a procesar en cada instante de tiempo (ventana de procesamiento).

Esta transformada puede ser interpretada como el tiempo que le toma a la señal viajar desde $X_m(1)$ hasta $X_m(N)$ acumulando toda la información de los diferentes canales. A continuación, en la Figura 12 y 13 se muestra un ECG de 12 canales al cual se le aplicó la transformada de longitud con una ventana q igual al 10% del número de instantes de tiempo del ritmo cardiaco estimado del paciente.

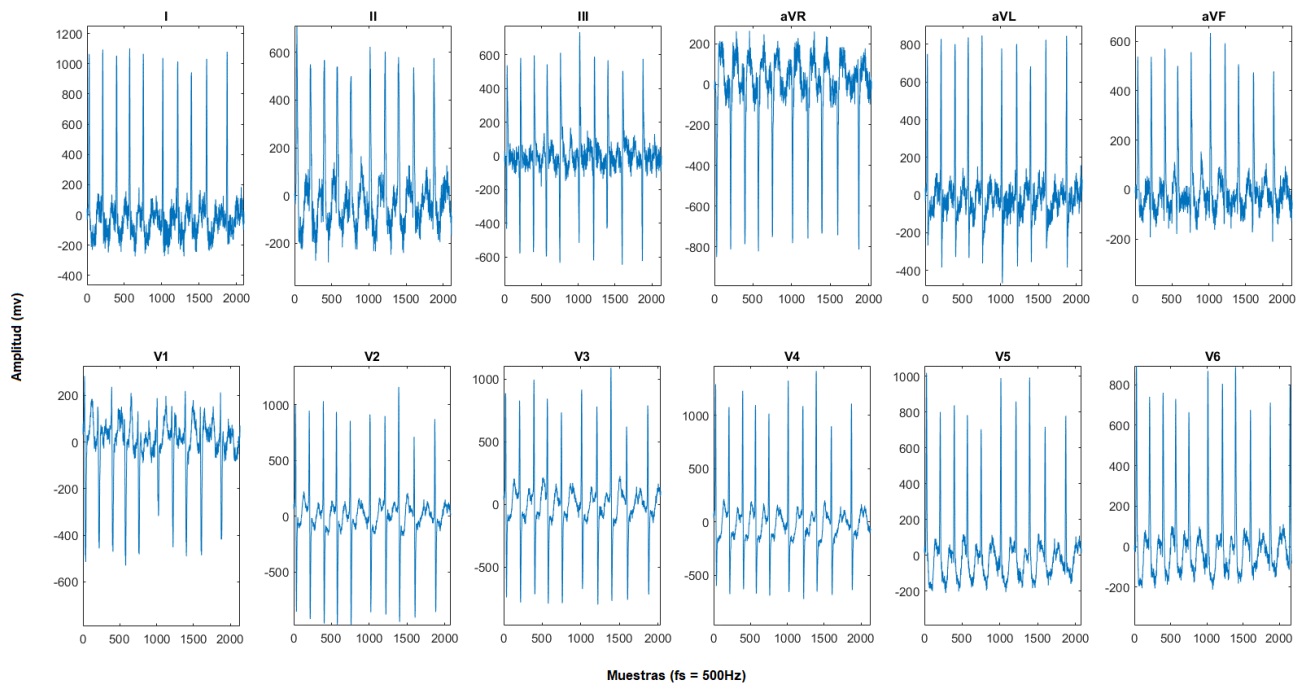


Figura 12. ECG: ritmo sinusal 12 canales.

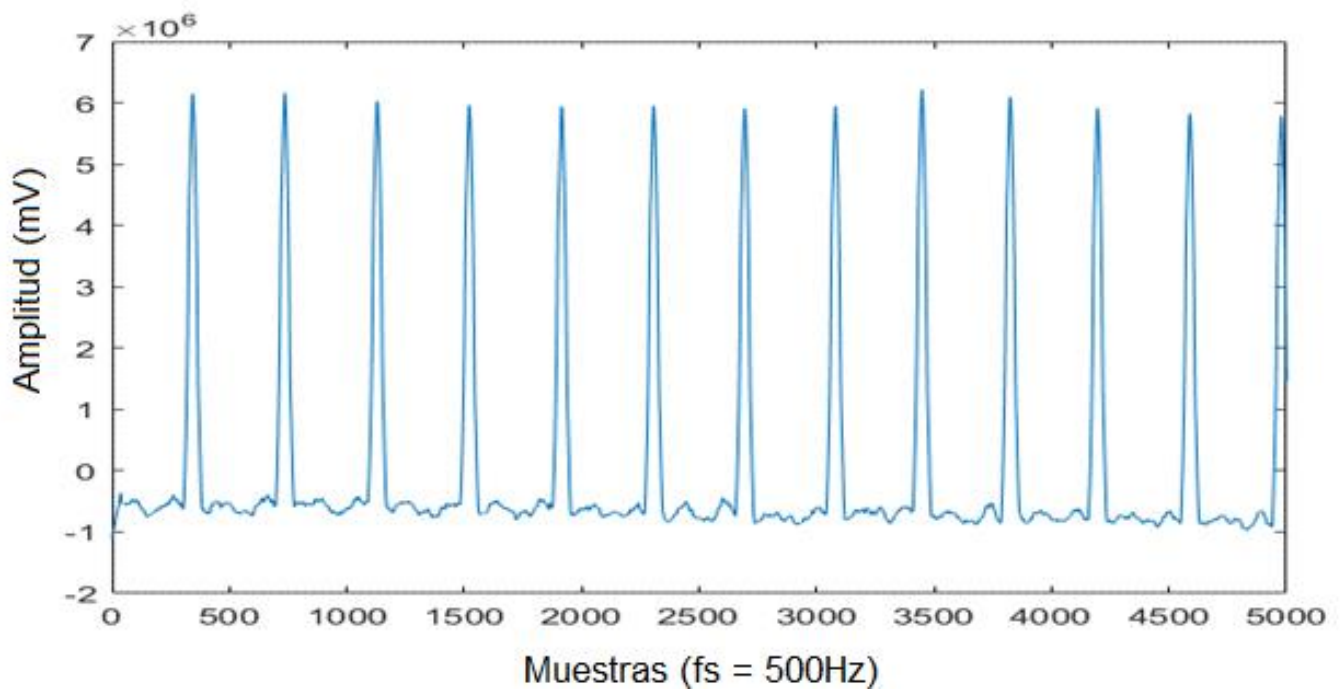


Figura 13. Aplicación de la transformada de longitud a ECG: ritmo sinusal 12 canales.

4.2.2 Modelo autorregresivo

El modelo autorregresivo (AR) se puede definir como una combinación lineal de los P valores pasados de las salidas y las muestras actuales. Sin embargo, en el caso de las señales biomédicas como el ECG la entrada del sistema es completamente desconocida, entonces se puede aproximar la predicción de la muestra actual de la salida usando valores anteriores [7]:

$$\tilde{y}(n) = \sum_{k=1}^P a_k y(n-k). \quad (3)$$

Una vez con la señal $y(n)$ es posible minimizar el error cuadrático total (TSE) del modelo orden P mediante:

$$\epsilon p = \sum_n y^2(n) + \sum_{k=1}^P a_k \sum_n y(n)y(n-k). \quad (4)$$

Por último, podemos expresar el TSE de una manera más simple en términos de la función de autocorrelación $\Phi(i)$ durante un intervalo finito $0 \leq n \leq N-1$ y a su vez asumir que la señal el cualquier punto fuera de este intervalo es 0, entonces se expresa:

$$\Phi(i) = \sum_{n=i}^{N-1-i} y(n)y(n-i), i \geq 0. \quad (5)$$

Y las ecuaciones normales denominadas en (3) $a_k, k = 1, 2, \dots, P$ se pueden escribir en forma de matriz como:

$$\begin{bmatrix} \Phi_y(0) & \Phi_y(0) & \cdots & \Phi_y(P-1) \\ \Phi_y(1) & \Phi_y(1) & \cdots & \Phi_y(P-2) \\ \vdots & \vdots & \ddots & \vdots \\ \Phi_y(P-1) & \Phi_y(P-2) & \cdots & \Phi_y(0) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_P \end{bmatrix} = - \begin{bmatrix} \Phi_y(1) \\ \Phi_y(2) \\ \vdots \\ \Phi_y(P) \end{bmatrix}. \quad (6)$$

4.2.3 Modelo de regresión logística

La regresión logística es un modelo matemático que se puede utilizar para describir las relaciones de múltiples variables X_k a una variable dependiente [15]. Este modelo ayuda a resolver problemas de múltiples variables, por ejemplo, para detectar una enfermedad se toman en cuenta distintos factores, como la disposición genética, enfermedades crónicas, si el paciente es fumador y variables de control como la edad y el sexo. De la misma manera podemos clasificar las características principales de las señales para identificar la cardiopatía correspondiente.

Una vez que se obtienen los vectores de las características principales de las señales, se pueden definir como variables independientes $X_1, X_2 \dots X_l$ donde l es el número de variables independientes, en el caso de este modelo $l = 6$, cuatro correspondientes al modelo AR y dos que corresponden a la edad y sexo.

El modelo de regresión logística, como su nombre lo indica, está basado en la siguiente función logarítmica:

$$f(z) = \frac{1}{1 + e^{-z}} \quad (7)$$

La función $f(z)$ cuando $z = -\infty$ equivale a 0, por otra parte cuando $z = +\infty$, la función es igual a 1, por lo tanto, el rango de $f(z)$ es entre 0 y 1 sin importar el valor de z , esta es la razón principal de la popularidad de este modelo, está diseñado para describir la probabilidad la cual siempre será entre 0 y 1.

Por último, para pasar de la función logística al modelo, se reescribe z como una suma lineal de los coeficientes $\alpha + \beta_k$. Estos coeficientes son los que permiten calcular el modelo, entonces z es un índice que combina todas las X 's quedando como:

$$f(z) = \frac{1}{1 + e^{-(\alpha + \sum \beta_k X_k)}} \quad (8)$$

Para calcular los coeficientes $\alpha \wedge \beta_k$ se utilizan:

$$\beta = \frac{\sum(x_i - \bar{x})(z_i - \bar{z})}{\sum(x_i - \bar{x})^2}. \quad (9)$$

$$\alpha = \bar{z} - \beta(\bar{x}). \quad (10)$$

Donde x_i es el número de dato, \bar{x} es la media de los datos, z_i es el número de dato y \bar{z} es la media, en este caso x corresponde al tiempo y z a la amplitud. Sin embargo, la mayor parte de los lenguajes de programación los calculan sin necesidad de indicarlo.

Gracias a la función sigmoide que se muestra en (7), es sencillo predecir y clasificar en base a la predicción con el modelo establecido, las clases. Estas se toman en pares y se comparan para obtener un porcentaje de clasificación. Si este porcentaje supera el 50% es un indicador de pertenencia, si fuera menor el porcentaje sería un caso del azar o queda fuera de la clasificación de esa clase.

Para nuestra aplicación se utilizó el comando *mrfit* de Matlab la cual entrega la intersección y los coeficientes del modelo del riesgo relativo de pertenecer a la Clase A o a la clase B. En este caso el modelo quedaría definido a continuación:

$$\ln\left(\frac{p_{Clase\ AB} = 0}{p_{Clase\ AB} > 0}\right) = \alpha + \beta_1 X_{AR1} + \beta_2 X_{AR2} + \beta_3 X_{AR3} + \beta_4 X_{AR4} + \beta_5 X_{edad} + \beta_6 X_{sexo}. \quad (11)$$

Donde α corresponde al punto de intersección, β_n son los coeficientes calculados por el modelo, $X_{AR1} \dots X_{AR4}$ son los coeficientes asociados al modelo AR(4), X_{edad}, X_{sexo} son los coeficientes asociados a la edad y sexo, respectivamente. Así, el modelo de regresión logística para cada tipo de datos estará conformado por un juego de coeficientes $\{X_{AR1} \dots X_{AR4}, X_{edad}, X_{sexo}\}$.

Esta clasificación se realiza para cada señal correspondiente a cada par, en la sección de resultados se detallan los pares elegidos. Se toma el modelo correspondiente y se utiliza el comando *mnrval* para obtener una predicción de probabilidad de pertenencia, comparando el modelo con el vector de características de la señal correspondiente, indicando que el mayor corresponde a esa clase. Seguido de esto se compara con la clase ya conocida obteniendo un positivo verdadero o un falso positivo. Por último, todos los positivos verdaderos se promedian y se obtiene un porcentaje total de clasificación para ese par.

Todo el procesamiento y clasificación de las señales se resume en las figuras que se muestran a continuación.

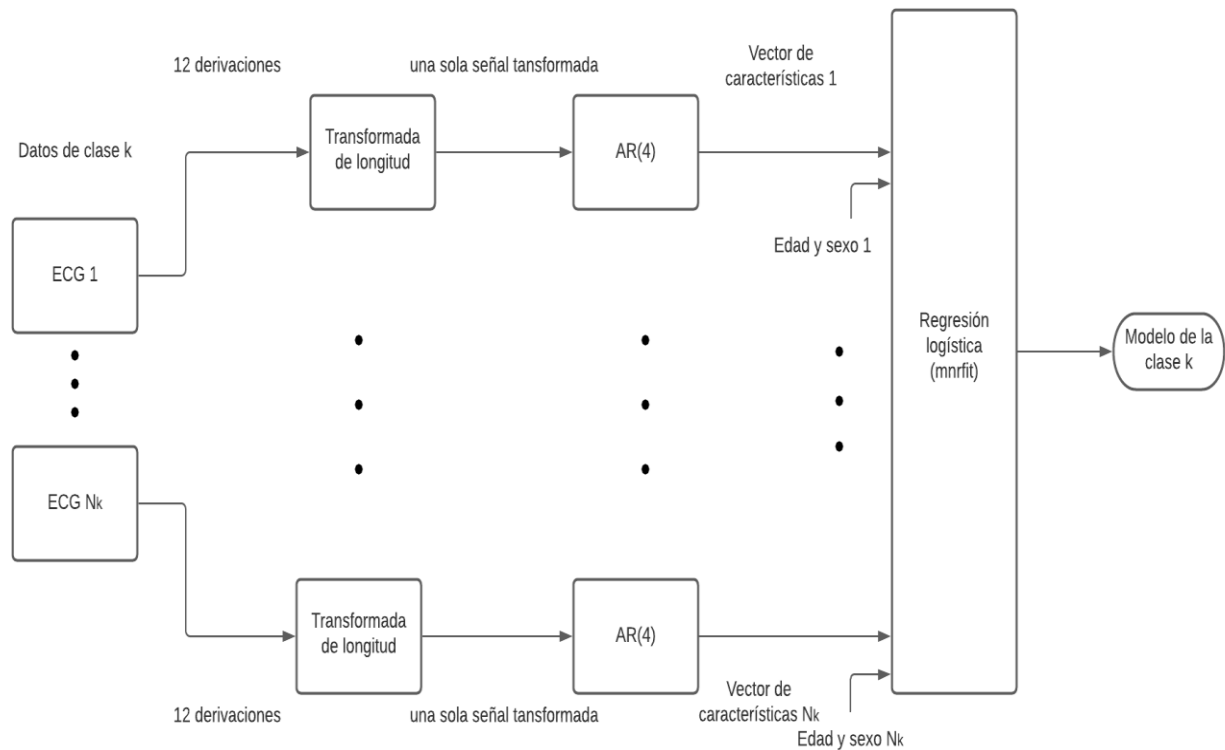


Figura 14. Entrenamiento del modelo de las clases.

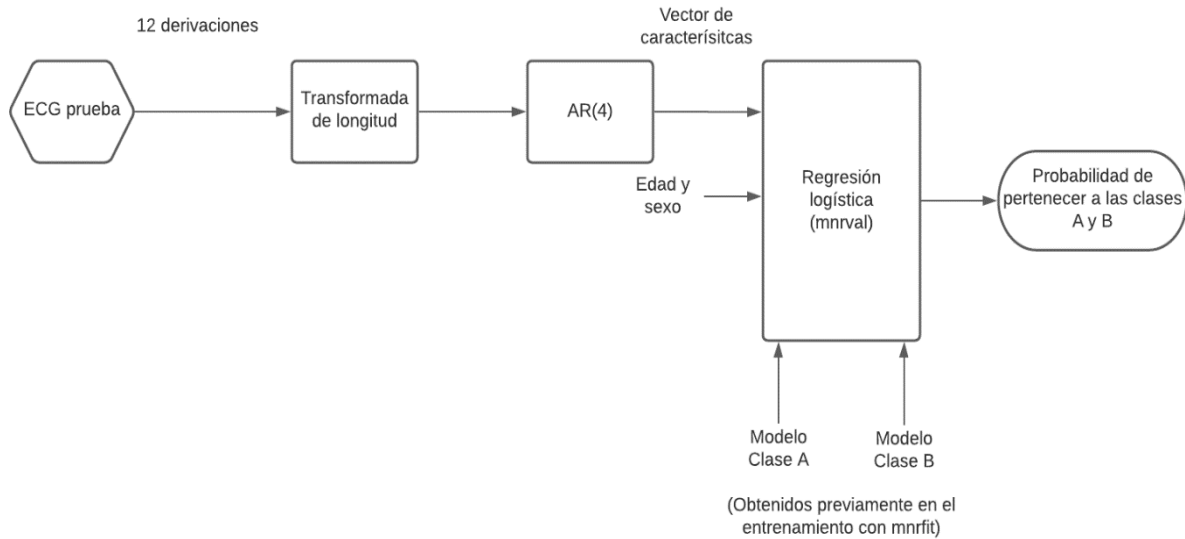


Figura 15. Clasificación entre clases A y B.

4.2.4 Análisis de datos

Se procesaron las señales por pares de clases para obtener los siguientes parámetros:

- Transformada de longitud multicanal
- Características principales del modelo AR
- Predicción de clasificación de las señales

El procedimiento para lograr la clasificación se basa en conseguir las características principales de las señales previamente transformadas mediante la transformada de longitud con un modelo AR de cuarto orden. Este orden fue elegido por un análisis basado en el criterio Bayesiano de Schwarz (BIC), el cual es un criterio para elegir el orden o el modelo en un conjunto de posibles infinitos:

$$BIC = k \cdot \ln(n) - 2 \cdot \ln(L). \quad (12)$$

Donde k es el número de parámetros del modelo y L es la función de verosimilitud para el modelo estadístico; en seguida se aplica el modelo de regresión logística, con el cual es posible comparar las

señales con las que fueron entrenados los modelos, entonces se puede obtener una clasificación de pertenencia a una de las dos cardiopatías que se comparan.

Para obtener los vectores de características, se aplica la transformada de longitud a los 12 canales del ECG para obtener, una nueva señal que corresponde a cada clase, para obtener la ventana q con la cual se aplica esta transformada, se optó por utilizar el correspondiente al 10% del ritmo cardiaco, el cual se estimó mediante el método MOBD.

Una vez obtenida la transformada de longitud de todas las muestras de cada clase, se aplica un modelo AR(4), con lo cual se obtienen los vectores correspondientes a las características de cada clase. De ahí se obtienen cuatro coeficientes, a lo que se agrega la edad y el sexo (1 para mujer y 0 para hombre).

A continuación, se entrena el modelo de regresión logística con los vectores resultantes del modelo AR, estos se usan como datos de entrada, cuando hay un mayor número de datos de entrada, el modelo presentará una clasificación mejor. Una vez que se utilizan todas las muestras de cada clase se obtiene el modelo de regresión logística.

Cuando se termina la fase de entrenamiento comienza la clasificación de las clases, para esto el modelo resultante se compara en pares con cada muestra de las clases correspondientes para obtener un porcentaje de pertenencia a la clase.

5. Resultados

En esta sección se muestran los trazos representativos de las transformadas de longitud de cada clase agrupadas por pares, esto con la finalidad de obtener el porcentaje de clasificación de cada clase en las Figuras 16-20.

El primer par que se comparó fue el de las Clases 1 y 5 donde se obtuvo un 63.02% de clasificación correcta. Aunque la clasificación es mala, está por encima del azar (50%). En este caso se puede observar que los latidos ventriculares ectópicos se presentan de manera no constante, aparecen cada cierto tiempo y lo cual no afecta de manera significativa la variabilidad, mientras que en el bloqueo AV de primer grado hay un aumento en el segmento PR, de la misma manera no afecta en gran medida a la variabilidad, ya que en ambos casos se presentan morfologías y ritmo cardiaco similares, es por esto que hay una dificultad en clasificar estas dos clases.




Figura 16. Arriba transformada de longitud: ECG: Latidos ventriculares ectópicos y abajo transformada de longitud: bloqueo AV de primer grado.

El segundo par que se comparó fue el de las Clases 2 y 7 donde se obtuvo 84.47% de clasificación correcta. Este caso en particular, a simple vista es muy fácil de diferenciar, ya que la fibrilación auricular pierde prácticamente toda la morfología normal, se vuelve una señal muy variable y para nuestro programa es fácil detectar estos cambios.




Figura 17. Arriba la transformada de ECG: ritmo sinusal y abajo ECG: fibrilación auricular.

El tercer par que se comparó fue el de las Clases 3 y 9 donde se obtuvo 90.15% de clasificación correcta. Para este caso se obtuvo el mayor porcentaje de clasificación, esto se debe a que ambas señales presentan variaciones en puntos opuestos, izquierda y derecha, en el ECG también se muestran en lugares contrarios, mientras que en la Clase 3 predomina una onda RSR, en la Clase 9 aparece una onda S mayor, estos cambios de morfología y en la variabilidad general de la señal hacen que sea muy sencillo a nuestro programa clasificar correctamente.




Figura 18. Arriba transformada de longitud ECG: bloqueo de rama izquierda y abajo transformada de longitud bloqueo de rama derecha.

El cuarto par que se comparó fue el de las Clases 4 y 8 donde se obtuvo 84.36% de clasificación correcta. Este par es muy similar al anterior, sin embargo, la diferencia de este par, reside en el segmento ST, mientras uno se eleva, el otro se deprime, y aquí hay un cambio muy evidente para el algoritmo propuesto.




Figura 19. Arriba transformada de longitud depresión del segmento ST y abajo transformada de longitud elevación del segmento ST.

El quinto y último par que se comparó fue el de las Clases 6 y 7 donde se obtuvo 77.77% de clasificación correcta. La Clase 6 presenta un latido fuera de tiempo y una pérdida de la morfología de la onda P, estas características en comparación del ritmo sinusal, son las que permite obtener la clasificación. Sin embargo, como no se presentan de manera continua, muy similar al caso de la Clase 1, puede presentar una complicación para el algoritmo, es por eso que no es una clasificación muy alta pero tampoco baja.

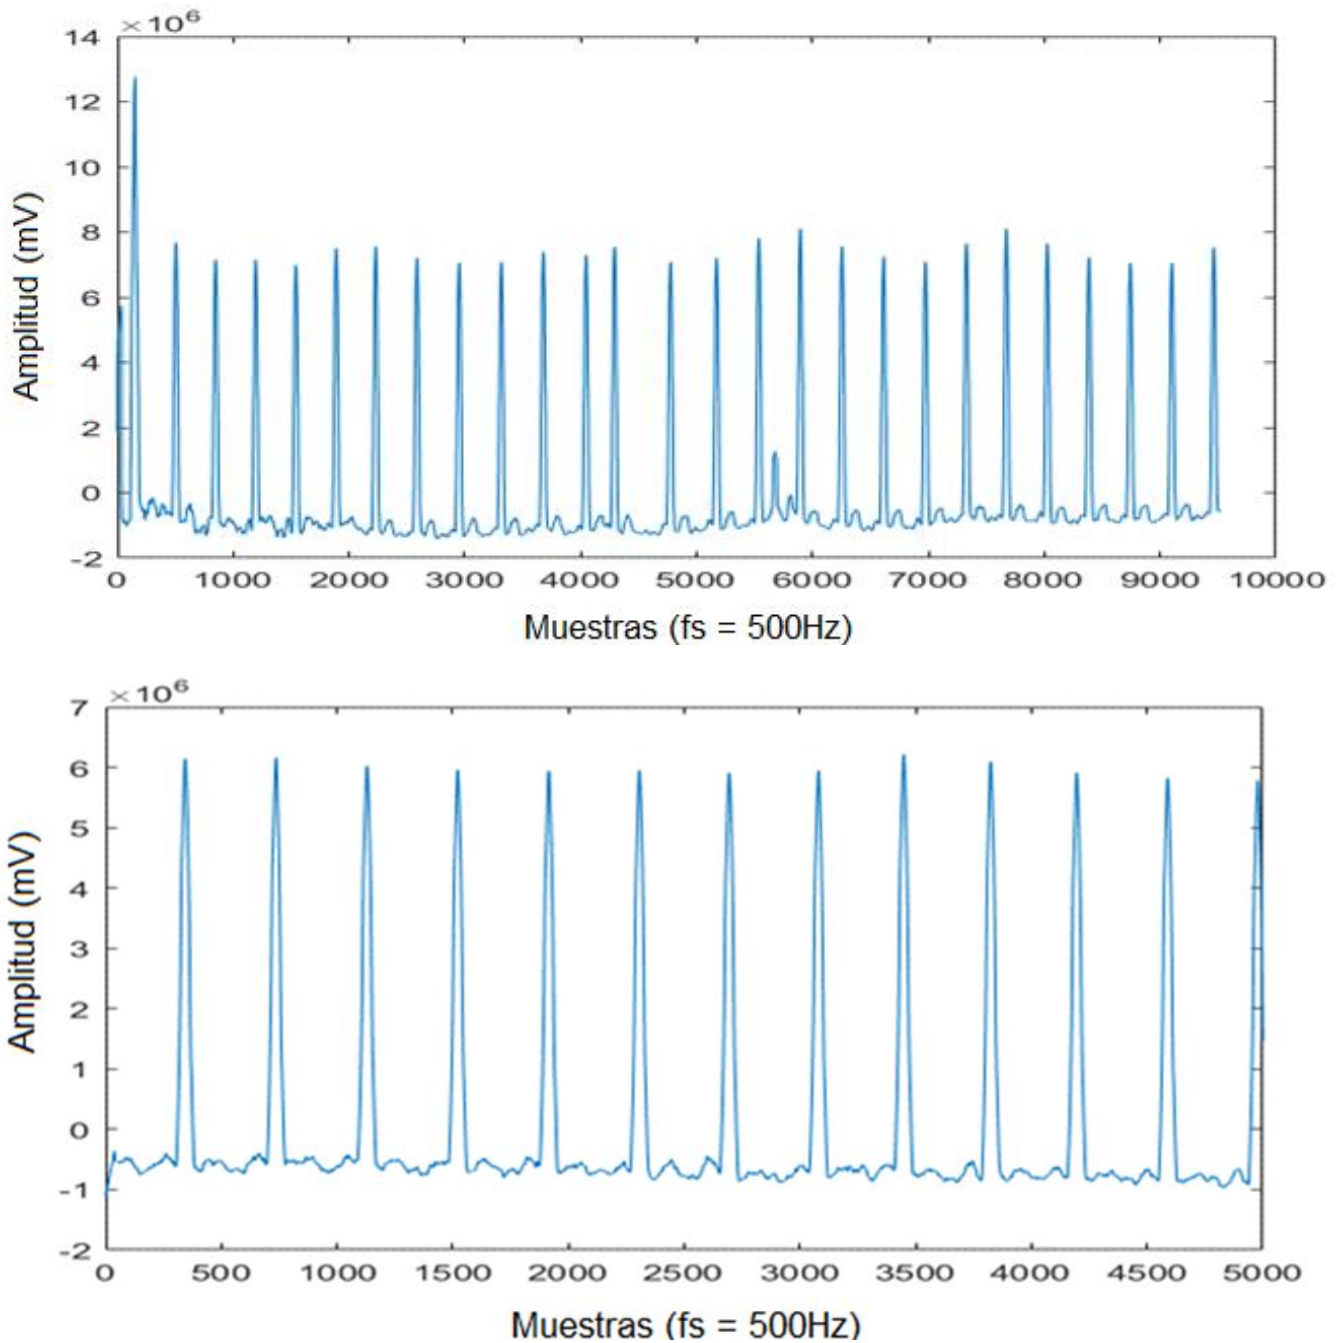


Figura 20. A la izquierda transformada de longitud contracción prematura auricular y la derecha ECG: ritmo sinusal.

6. Conclusión

En esta tesis se utiliza la transformada de longitud para comprimir la información de nueve clases, cada una con 12 derivaciones. El algoritmo propuesto utiliza todas las derivaciones, sin embargo, es posible utilizar menos derivaciones que presenten los cambios entre distintas clases y aun así encontrar porcentajes altos de clasificación correcta.

Este método propuesto, es principalmente sensible a la variabilidad, por lo que presenta debilidades con algunas patologías, principalmente las que se identifican mediante morfología, eventos aleatorios, entre otros, es por esto que el uso de otros métodos como la transformada de wavelet puede ser mejor indicador por ejemplo para potenciales tardíos ventriculares [16].

Se demostró que la transformada de longitud es capaz de comprimir la información correspondiente a múltiples canales de ECG en diferentes cardiopatías, además el algoritmo conformado por la transformada de longitud, el modelo AR y el modelo de regresión logística dieron como resultado la posibilidad de clasificar diferentes patologías.

La clasificación fue posible en las nueve clases de la base de datos “China Physiological Signal Challenge in 2018”, se compararon por pares obteniendo resultados mayores al 50% lo cual indica que la clasificación se realizó de manera correcta. El primer par que se clasificó corresponde a la clase 1 y 5 y se consiguió el porcentaje de clasificación más bajo (63.02%), este bajo porcentaje se debe a que la clase 1 correspondiente a latidos ventriculares ectópicos y estos depende mucho del azar, ya que, en su mayoría, esta cardiopatía se presenta acompañado de bloqueos de rama izquierda y derecha, y en su mayoría son latidos extra que no aparecen de manera constante.

Para los demás casos, al ser señales que presentan variabilidad es sencillo para nuestro modelo detectar y clasificar de manera correcta. Esto se demuestra en el segundo par que se compararon, el bloqueo de rama izquierda y de rama derecha, donde hay un cambio en diferentes puntos del electrocardiograma, en la primera se muestra un aumento en la onda S, mientras que en la segunda patología hay un ensanchamiento en el complejo QRS, este cambio de variabilidad es el que permite un alto porcentaje de éxito. Otro ejemplo es la comparación de la fibrilación auricular y el ritmo sinusal, estas dos señales son dependientes directamente de la variabilidad, en la primera se observa una variabilidad muy alta,

mientras que, en el ritmo sinusal, prácticamente es constante, por ende, nuestro modelo es capaz de clasificar correctamente estas dos clases.

Este trabajo tomó como inspiración el reto de clasificar distintas cardiopatías e ir disminuyendo el número de derivaciones de un ECG para lograrlo, se realizó la primera fase que consta de utilizar las 12 derivaciones utilizando la transformada de longitud, obteniendo resultados satisfactorios.

El siguiente paso para este proyecto es aplicar un método de comparación diferente, enfocado a más clases en lugar de pares. Una manera fácil de implementarlo con lo que aquí se tiene es mediante un proceso de "votación" en donde se realicen todas las clasificaciones posibles a pares de las nueve clases y se vaya registrando el resultado de la clasificación. Al final, la clase que haya recibido más votos, será la ganadora del proceso final.

Otro tema pendiente es el de la disminución del número de derivaciones. Para ello es necesario identificar las cardiopatologías con su número de identificación y con esto seleccionar las derivaciones más importantes para cada señal ya que, en el caso de muchas patologías, se observan cambios en la morfología en algunas derivaciones, como el caso de la Clase 9, donde se observan estos cambios en la derivación V1 y V6.

7. Referencias

- [1] J. Hall y A. Guyton, Tratado de fisiología médica, 13th ed. Spain: Elsevier, 2016.
- [2] J. Rahul , M. Sora y L. D. Sharma, "An Overview on Biomedical Signal Analysis", *International Journal of Recent Technology and Engineering*, vol. 7, no. 5, pp. 206-209, 2019.
- [3] S. Suppappola y Y. Sun, "Nonlinear Transforms of ECG Signals for Digital QRS Detection: A Quantitative Analysis", *IEEE Transactions On Biomedical Engineering*, vol. 41, no. 3, pp. 397-400, 1994.
- [4] INEGI, "Características De Las Defunciones Registradas En México Durante 2020", *Comunicado de prensa*, no. 402/21, p. 4, 2021.
- [5] B.-U. Köhler, C. Henning y R. Orglmeister, "The Principles of Software QRS Detection", *IEEE Engineering In Medicine And Biology*, vol. 21, no. 1, pp. 42-57, 2002.
- [6] J. Pan y W. J. Tompkins, "A Real-time QRS Detection Algorithm", *IEEE Transactions On Biomedical Engineering*, vol. 1 de 2BME-32, no. 3, pp. 230-236, 1985.
- [7] R. M. Rangayyan, Biomedical Signal Analysis a Case-study Approach, New York: Wiley-IEEE Press, 2001.
- [8] D. Gutierrez , F. Garcia-Nocetti y J. Solano-González , "Classification of multichannel EEG data using lenght/energy transform", pp. 221-224.
- [9] J. F. Guadalajara, Cardiología, 7ma ed. México: Mendez Editores, 2012.
- [10] E. Burns y R. Buttner, "Premature Ventricular Complex (PVC)", 2 Jun. 2021. [En línea]. Disponible: <https://litfl.com/premature-ventricular-complex-pvc-ecg-library/>. [Último acceso: 1 Sept. 2021].

- [11] E. Burns y R. Buttner, "Atrial Fibrillation", 6 Jun. 2021. [En línea]. Disponible: <https://litfl.com/atrial-fibrillation-ecg-library/>. [Último acceso: 1 Sept. 2021].
- [12] J. Larkin y R. Buttner, "First Degree Heart Block", 6 Feb. 2021. [En línea]. Disponible: <https://litfl.com/first-degree-heart-block-ecg-library/>. [Último acceso: 1 Sept. 2021].
- [13] E. Burns y R. Buttner, "Premature Atrial Complex (PAC)", 2 Jun. 2021. [En línea]. Disponible: <https://litfl.com/premature-atrial-complex-pac/>. [Último acceso: 1 Sept. 2021].
- [14] E. Burns y R. Buttner, "Right Bundle Branch Block (RBBB)", 5 Mar. 2021. [En línea]. Disponible: <https://litfl.com/right-bundle-branch-block-rbbb-ecg-library/>. [Último acceso: 1 Sept. 2021].
- [15] D. y. K. M. Kleinbaum, Logistic Regression A Self-Learning Text, New York: Springer, 2002.
- [16] M. A. Reyna-Carranza y R. Jané-Campos, "Análisis Multi-Wavelet para la detección de conductividad ventricular anormal en señales ECG de alta resolución", *Revista Biomédica*, vol. 12, no. 2, pp. 98-100, 2001.
- [17] R. M. Rangayyan, Biomedical Signal Analysis A Case-Study Approach, Canada: Jhon wiley & Sons, 2002.