



ESCUELA TÉCNICA SUPERIOR DE INGENIEROS
INDUSTRIALES Y DE TELECOMUNICACIONES

Titulación:

INGENIERÍA BIOMEDICA

Título del proyecto:

ESTUDIO COMPARATIVO DE ALGORITMOS
PARA LA SEGMENTACIÓN DEL
ELECTROCARDIOGRAMA

COMPARATIVE STUDY OF ALGORTIHMS FOR ECG
SEGMENTATION

Idoia Beraza Azurmendi

Armando Malanda

Pamplona, 9 de Abril, 2013

1	INTRODUCCIÓN	4
1.1	OBJETIVO	4
1.2	DESCRIPCIÓN DEL PROBLEMA Y MOTIVACIÓN	4
1.3	SIPNOPSIS.....	4
2	FUNDAMENTOS BÁSICOS	5
2.1	CONCEPTOS BÁSICOS DE ELECTROFISIOLOGÍA CARDIACA	5
2.1.1	EL CORAZÓN	5
2.1.2	SISTEMA DE CONDUCCIÓN ELÉCTRICA DEL CORAZÓN	5
2.1.3	EL ELECTROCARDIOGRAMA (ECG).....	6
2.2	ANÁLISIS MORFOLÓGICO DE LA SEÑAL ECG.....	10
2.3	SEGMENTACIÓN DE LA SEÑAL ECG.....	12
2.4	MÉTODOS PARA LA SEGMENTACIÓN AUTOMÁTICA DE ECG	12
2.4.1	DIFICULTADES DE LA SEGMENTACIÓN AUTOMÁTICA DEL ECG	12
2.4.2	DESCRIPCIÓN DE LOS METODOS	13
3	ALGORITMOS DE SEGMENTACIÓN A EVALUAR	23
3.1	LAGUNA [1].....	23
3.1.1	FASE 1: SEÑAL DIFERENCIADA	23
3.1.2	FASE 2: UMBRALIZACIÓN ADAPTATIVA	23
3.2	MARTÍNEZ [2]	26
3.2.1	FASE 1: TRANSFORMADA WAVELET DISCRETA (DWT).....	26
3.2.2	FASE 2: UMBRALIZACIÓN ADAPTATIVA	31
3.3	SINGH [3]	33
3.3.1	FASE 1: PRIMERA DERIVADA	33
3.3.2	FASE 2: NUEVO ENFOQUE DE LA UMBRALIZACIÓN (cálculo del desplazamiento vertical).....	34
3.4	DI MARCO [4].....	36
3.4.1	FASE 1: TRANSFORMADA WAVELET DISCRTA	36
3.4.2	FASE 2: UMBRALIZACIÓN ADAPTATIVA EN PROCESAMIENTO A TIEMPO REAL	39
3.5	SUN [5].....	41
3.5.1	FASE 1: DERIVADA MORFOLÓGICA MULTIESCALA (MMD)	42
3.5.2	FASE 2: UMBRALIZACIÓN ADAPTATIVA (ajustado mediante el histograma MMD) 44	44
3.6	MARTÍNEZ [6]	45
3.6.1	FASE 1: TRANSFORMADA FASORIAL (PT).....	45
3.6.2	FASE 2: UMBRALIZACIÓN ADAPTATIVA	46
3.7	VÁZQUEZ [7].....	47
3.7.1	FASE 1: PRIMERA DERIVADA	47
3.7.2	FASE 2: AREA DEL TRAPECIO RECTANGULAR.....	48
3.8	VÌTEK [8].....	49
3.8.1	FASE 1: TRANSFORMADA WAVELET CONTINUA (CWT).....	49
3.8.2	FASE 2: UMBRALIZACIÓN ADAPTATIVA	51
3.9	HUGHES [9]	51
3.9.1	FASE 1: TRANSFORMADA WAVELET DISCRETA (DWT).....	51
3.9.2	FASE 2: MODELOS OCULTOS DE MARCOV (HMM)	52
4	MÉTODOS DE EVALUACIÓN	57
4.1	BASE DE DATOS (QTDB)	57
5	RESULTADOS. COMPARACIÓN DE ALGORITMOS	61
5.1	COMPLEJO QRS	61
5.1.1	QRS _{on}	61
5.1.2	QRS _{off}	62
5.2	ONDA P.....	63
5.2.1	P _{peak}	63
5.2.2	P _{on}	64

5.2.3	P_{off}	65
5.3	ONDA T	66
5.3.1	T_{peak}	66
5.3.2	T_{on}	68
5.3.3	T_{off}	69
6	DISCUSIÓN	71
6.1	CONCLUSIONES	71
6.2	LIMITACIONES	72
6.2.1	IMPLEMENTACIÓN DE ALGORITMOS	72
6.2.2	DATOS PARA LA EVALUACIÓN (BASE DE DATOS)	73
6.3	FUTURAS LÍNEAS DE TRABAJO	73
7	BIBLIOGRAFÍA	75

1 INTRODUCCIÓN

Este capítulo describe el objetivo de la presente investigación, así como el problema y la motivación. Un esquema de la estructura de este informe también es incluido.

1.1 OBJETIVO

Evaluar los diferentes métodos de segmentación de las señales de electrocardiograma (ECG) que permitan la detección automática de las diferentes puntos característicos que conforman la señal.

1.2 DESCRIPCIÓN DEL PROBLEMA Y MOTIVACIÓN

Las patologías cardiacas afecta a un elevado porcentaje de la población mundial, siendo causa principal de muerte en países desarrollados [10]. La técnica más común para su diagnóstico y seguimiento se realiza mediante el electrocardiograma (ECG), ya que es un método no invasivo, relativamente económico y seguro. La señal del ECG representa la actividad eléctrica del corazón; cualquier anomalía en el funcionamiento electrofisiológico del corazón se ve a menudo reflejada en dicha señal.

Existe una amplia variabilidad de enfermedades cardiacas. El diagnóstico de algunas se realiza mediante la información de frecuencia y ritmo cardíaco. Sin embargo, el diagnóstico de muchas otras enfermedades requiere información morfológica de la señal de ECG, ya que cada cardiopatía tiene su forma específica de expresarse. Una vez detectadas las diferentes partes de la señal (ondas, intervalos y segmentos) es más fácil sacar las características morfológicas (amplitud, duración y forma) de cada una, permitiendo un diagnóstico avanzado.

En algunos casos, el especialista necesita marcar manualmente cada punto de la señal, con el fin de realizar un diagnóstico preciso. Sin embargo en registros ECG de larga duración (varios días) este trabajo es tedioso y a menudo no práctico. La enorme cantidad de datos a analizar hace necesaria la utilización de métodos de segmentación automática.

En la actualidad se han desarrollado diversos métodos de segmentación automática de la señal de ECG. En este trabajo se pretende estudiar, evaluar y comparar los diferentes métodos de segmentación existentes en la literatura. Esto permitirá la comprensión de los usos y limitaciones de las técnicas existentes. Por otra parte, se podrá abrir paso a futuras aplicaciones que permitan implementar un sistema de diagnóstico automático avanzado, que permita detectar diferentes enfermedades cardíacas.

1.3 SIPNOPSIS

El resto del documento está organizado de la siguiente manera:

- El capítulo 2 describe los conceptos básicos de la electrofisiología cardíaca y las aplicaciones del análisis morfológico de la señal de ECG. Además, se presenta una revisión de los métodos de segmentación automáticos de ECG de la literatura.
- El capítulo 3 describe los diferentes algoritmos de segmentación automática evaluados en este estudio.
- El capítulo 4 explica los métodos de evaluación utilizados para realizar el estudio de los diferentes algoritmos.
- El capítulo 5 presenta los resultados obtenidos. Comparación entre algoritmos.
- El capítulo 6 contiene la discusión de los resultados mediante conclusiones, limitaciones y futuras líneas de trabajo.

2 FUNDAMENTOS BÁSICOS

Éste capítulo contiene los conceptos básicos de la electrofisiología cardíaca, donde se describe la anatomía del corazón, la función y el sistema de conducción eléctrica, y además, una descripción del electrocardiograma con las explicaciones de las ondas características del ECG. Asimismo en este capítulo se ofrece una breve descripción de la información que se obtiene por medio del análisis morfológico de la señal ECG. Asimismo, describe en que consiste la segmentación y se presenta una revisión de los métodos de segmentación automáticos de ECG de la literatura.

2.1 CONCEPTOS BÁSICOS DE ELECTROFISIOLOGÍA CARDIACA

2.1.1 EL CORAZÓN

El corazón es un órgano muscular cuya función es recolectar la sangre no oxigenada del sistema venoso, bombearla a los pulmones para ser oxigenada, recibir dicha sangre oxigenada y bombearla al sistema arterial [11].

Para ello cuenta con dos cavidades superiores (aurícula izquierda y derecha), dos cavidades inferiores (ventrículo izquierdo y derecho) y cuatro válvulas para el control de flujo sanguíneo (Tricúspide, Mitral, Pulmonar y Aórtica), como se muestra en la Figura 2.1.




Figura 2.1: Anatomía del corazón [12]

2.1.2 SISTEMA DE CONDUCCIÓN ELÉCTRICA DEL CORAZÓN

El ciclo cardíaco en un adulto normal dura aproximadamente un segundo. El encargado de originar el primer impulso eléctrico es el nodo Sinusal (SA) o marcapasos del corazón. Una vez se hayan llenado de sangre las aurículas, este impulso eléctrico se extiende por las mismas a través de las vías internodales, produciendo la despolarización auricular y su consecuente contracción. De esta manera la sangre se impulsa hacia los ventrículos a través de las válvulas Tricúspide y Mitral [13].

La señal eléctrica se propaga hasta el nodo auriculoventricular (AV), donde sufre una pausa de 0,1 segundo para que los ventrículos se terminen de llenar. Después de que las válvulas tricúspide y mitral se cierran firmemente, la onda eléctrica pasa al haz de His y se distribuye a

los ventrículos mediante las fibras de Purkinje, ocasionando la despolarización ventricular y su correspondiente contracción, al mismo tiempo que las válvulas pulmonar y aórtica se abren.

Una vez la sangre es distribuida a los pulmones para ser oxigenada y al resto del cuerpo para oxigenar los tejidos corporales, los ventrículos se relajan (repolarización ventricular) y las válvulas pulmonar y aórtica se cierran, dando paso a un nuevo ciclo cardíaco. A continuación, la Figura 2.2 ilustra las diferentes partes del sistema eléctrico del corazón.




Figura 2.2: Sistema eléctrico del corazón [14]

2.1.3 EL ELECTROCARDIOGRAMA (ECG)

2.1.3.1 Definición

Un electrocardiograma (ECG) es la representación gráfica de la actividad eléctrica del corazón [15]. Se obtiene mediante la conexión de varios electrodos a la superficie de la piel del cuerpo. Estos recogen las señales eléctricas del corazón y las transmiten a la máquina ECG. Aquí, las señales eléctricas son convertidas en líneas onduladas, generando la señal de ECG.

2.1.3.2 Derivaciones

La señal ECG representa los cambios que suceden en el potencial de acción durante el ciclo cardíaco. Estos cambios se interpretan mediante una serie de vectores que indican la magnitud y dirección de la despolarización y la repolarización celular desde distintos lugares de referencia.

En el ECG estándar hay doce derivaciones que se obtiene a través de la colocación de 10 electrodos en la piel del paciente, en las posiciones universales descritas en la Tabla 2.1, tal y como se muestra en la figura 2.3 [16].

Nombre del electrodo	Localización del electrodo
RA (R)	Brazo derecho (right arm), evitando prominencias óseas.
LA (L)	Brazo izquierdo (left arm). Mismo sitio en el que se colocó RA.
RL (N)	Pierna derecha (right leg), evitando prominencias óseas.
LL (F)	Pierna Izquierda (left leg). Mismo sitio en el que se colocó RL.
V1	Cuarto espacio intercostal a la derecha del esternón.
V2	Cuarto espacio intercostal a la izquierda del esternón.
V3	Entre los electrodos V2 y V4.

V4	Quinto espacio intercostal en la línea medio-clavicular.
V5	Misma línea horizontal que V4, pero verticalmente en la línea axilar anterior.
V6	Misma línea horizontal que V4 y V5, pero verticalmente en la línea medioaxilar.

Tabla 2.1: Nombre y posicionamiento de los electrodos.




Figura 2.3: Posición de los electrodos[17].

Las 12 derivaciones se dividen en 3 grupos:

1. *Derivaciones de extremidades o bipolares*: Detectan las variaciones eléctrica en dos puntos y calculan su diferencia (ver Figura 2.4).
 - DI: Diferencia entre brazo izquierdo y brazo derecho.
 - DII: Diferencia entre pierna izquierda y brazo derecho.
 - DIII: Diferencia entre pierna izquierda y brazo izquierdo.




Figura 2.4: Derivaciones de extremidades o bipolares [18].

2. *Derivaciones de extremidades aumentadas (Unipolares)*: Registran las variaciones eléctricas de potencial en un punto (brazo derecho, brazo izquierdo o pierna izquierda) respecto a otro punto imaginario. Estas derivaciones se toman a partir de las 3 primeras I, II, III (ver Figura 2.5).

- aVR: Potenciales eléctricos del brazo derecho respecto a un punto nulo, que se hace uniendo los cables del brazo izquierdo y pierna izquierda

$$aVR = -\frac{I + II}{2}$$

- aVL: Potenciales del brazo izquierdo a diferencia del electrodo negativo que es una combinación del electrodo del brazo derecho y pierna izquierda.

$$aVL = I - \frac{II}{2}$$

- aVF: Potenciales de la pierna izquierda respecto a un electrodo negativo que es la combinación del electrodo del brazo derecho y brazo izquierdo.

$$aVF = II - \frac{I}{2}$$

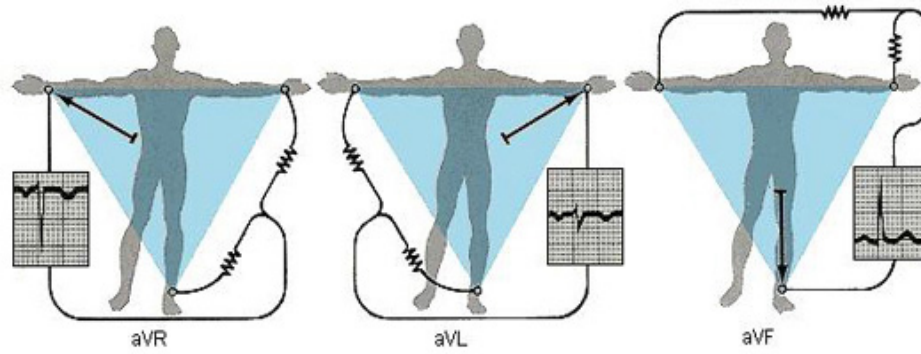


Figura 2.5: Derivaciones de extremidades aumentadas [18].

3. *Derivaciones precordiales (Unipolares):* Se calculan a partir de los 6 electrodos colocados directamente en el pecho (V1,V2,V3,V4,V5,V6). Debido a su proximidad con el corazón no son necesarias aumentarlas. El electrodo negativo en este caso es el Terminal central de Wilson (media de las 3 derivaciones periféricas que se aproxima al potencial promedio de la superficie corporal) y por ello estas derivaciones se consideran unipolares. Estas derivaciones ven la actividad del corazón en el denominado plano horizontal (ver Figura 2.6).

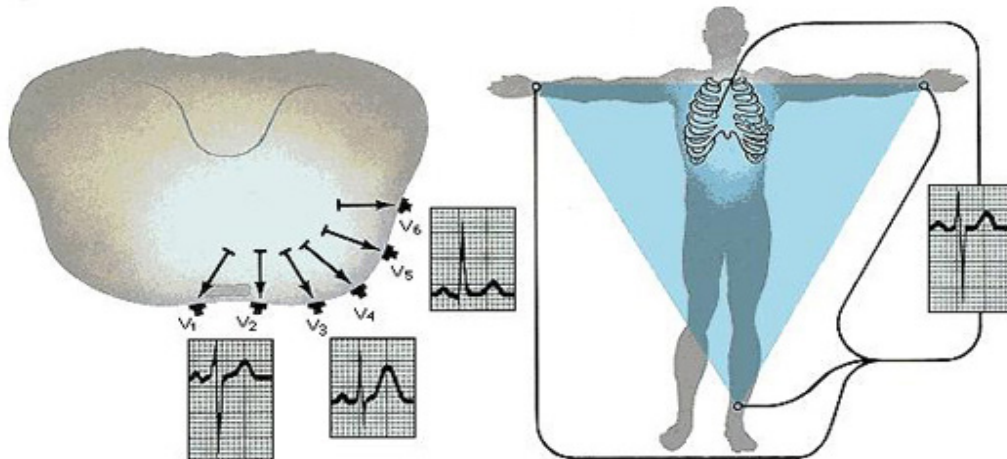


Figura 2.6: Derivaciones precordiales [18].

Mediante este sistema el corazón queda observado por los vectores que se muestran en la siguiente Figura 2.7:




Figura 2.7: Todos los vectores por los que queda observado el corazón.

2.1.3.3 Ondas características de la señal ECG

Un latido de la señal ECG en un adulto sano consiste en una onda P, el complejo QRS, la onda T y la onda U, como se puede apreciar en la Figura 2.8. Entre estas ondas, existen intervalos, segmentos y puntos de referencia de un gran interés diagnóstico. Los más importantes son el intervalo PR, el punto J, el segmento ST, y el intervalo QT [15].

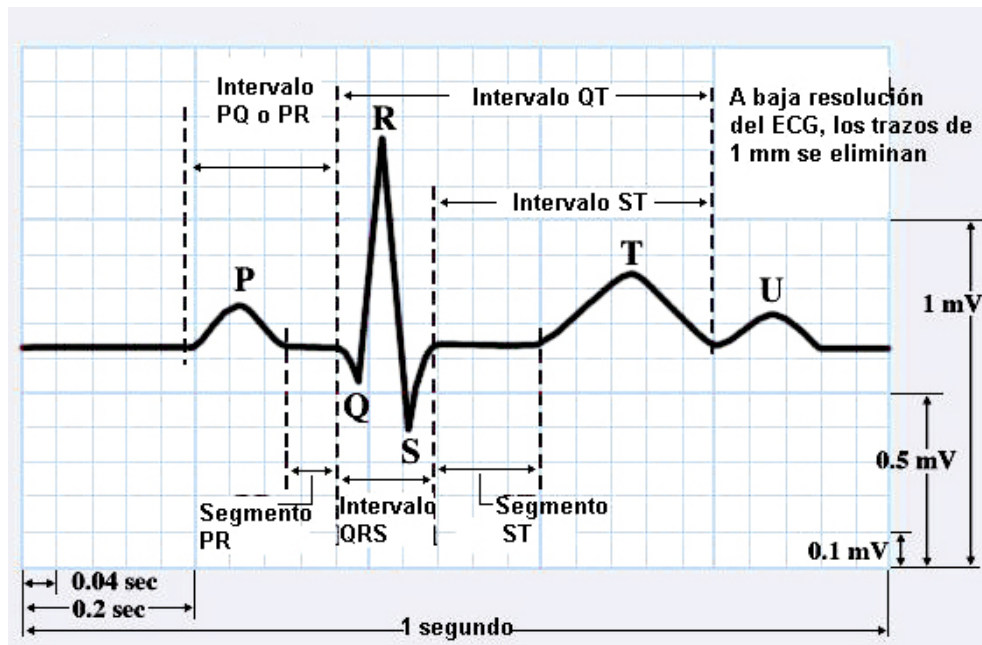


Figura 2.8: Componentes de la señal ECG[19].

Onda P: Representa la despolarización auricular. Es el resultado de la superposición de la despolarización de la aurícula derecha (la parte inicial de la onda) y de la aurícula izquierda (la parte final de la onda).

Complejo QRS: Este complejo corresponde a la despolarización ventricular (derecha e izquierda). Tiene una energía superior que la despolarización eléctrica de las aurículas (onda P), ya que corresponde a la contracción de los ventrículos que tienen una mayor masa muscular y por lo tanto, genera una deflexión con una mayor amplitud. La re-polarización auricular queda eclipsada por el complejo QRS.

-**Onda Q:** Es la primera onda del complejo y presenta valores negativos. Cuando está presente, representa la pequeña corriente horizontal que va de izquierda a derecha a través del septum (pared divisora) interventricular.

-**Onda R:** Es cualquier onda positiva dentro del complejo. Si hay más de una se les nombra de la siguiente manera: R, R', R'', etc. Por lo general, es la onda de mayor amplitud.

-**Onda S:** Es cualquier onda negativa que le sigue a la onda R. Si hay más de una se les nombra de la siguiente forma: S, S', S'', etc.

Onda T: Representa la re-polarización de los ventrículos.

Onda U: No hay mucha claridad de su origen fisiológico. Se cree que es el resultado creado en el músculo ventricular después del potencial de acción.

Intervalo PR o PQ: Representa el tiempo de propagación del estímulo, desde su formación en el nodo SA hasta el comienzo de la activación ventricular. Muestra la despolarización

auricular, así como el periodo de inactividad eléctrica correspondiente al retraso fisiológico que sufre el estímulo en el nodo auriculoventricular (AV). Se mide desde el inicio de la onda P hasta el inicio del complejo QRS.

Intervalo QT: Representa la actividad eléctrica ventricular, es decir, la despolarización y la repolarización ventricular. Se mide desde el principio del complejo QRS hasta el final de la onda T. Su duración varía según la frecuencia cardíaca.

Segmento PR: Es el trazo horizontal isoelectrico que va del final de la despolarización auricular al principio de la despolarización ventricular.

Segmento ST: Es el trazo horizontal isoelectrico que va desde el final de la despolarización ventricular al principio de la re-polarización ventricular.

2.2 ANÁLISIS MORFOLÓGICO DE LA SEÑAL ECG

Existe una amplia variedad de patologías que pueden ser diagnosticadas mediante el análisis de la señal ECG. Muchas de ellas pueden ser diagnosticadas a partir del ritmo cardíaco. Para encontrar el ritmo de la señal, solo es necesario encontrar la onda R. Esta onda es la más fácil de encontrar, ya que posee la mayor amplitud de la señal. Midiendo el intervalo RR, se puede obtener fácilmente la frecuencia del ciclo cardíaco. Pero muchas otras enfermedades necesitan la información morfológica de la señal para ser diagnosticadas. En estos casos, la información amplitud, duración y forma de las diferentes partes de la señal ECG (ondas, intervalos y segmentos) son necesarias.

Para reconocer los puntos más relevantes de la señal de ECG, es necesario conocer que partes de la señal son importantes para el diagnóstico de las diferentes enfermedades.

El estudio de la morfología de la señal de ECG puede ser de utilidad para el diagnóstico de varias patologías tales como:

- Trastornos en la secuencia de activación:
 - Trastornos de la conducción auriculoventricular (bloqueos).
 - Bloqueos de rama.
- Incremento patológico del grosor de la pared o del tamaño de las aurículas y los ventrículos (hipertrofia, miocarditis).
- Isquemia miocárdica e infarto.
- Efectos de los fármacos (digital, quinidina)
- Desequilibrio de electrolitos (potasio y calcio)

Existen numerosos estudios en la literatura sobre los efectos de estas patologías en la señal ECG. Muchas enfermedades no solo afectan a una parte de la señal, sino que podrían estar afectando a varias partes de la misma. Además, puede observarse en más de una derivación. El análisis de cada parte separada dentro del latido de ECG puede dar diferente información [20].

Onda P:

- Aumentos en la amplitud → Hipertrofia auricular derecha.
- Aumentos en la duración → Hipertrofia aurícula izquierda
- Onda invertida → Latido ectópico auricular (no originado en el nodo sinusal).
- Ausencia de la onda → Fibrilación auricular o bloqueo SA (sino-auricular).

Complejo QRS: Las anomalías en el complejo QRS pueden indicar bloqueo de rama, taquicardia de origen ventricular, hipertrofia ventricular u otras irregularidades ventriculares así como alteraciones electrolíticas.

- Incrementos excesivos en la amplitud → Dilatación e hipertrofia de las cavidades ventriculares.
- Decremento de la amplitud → Vejez, enfisema, mixedema, derrame pericárdico o pleural, infarto agudo de miocardio.
- Aumentos en la duración → Trastornos de la conducción intra-ventricular (bloques de rama), hipertrofias ventriculares, alteraciones electrolíticas.

Onda T: La onda T es muy “inestable” y existe una larga lista de posibles causas de los cambios de la onda T. Los cambios en la onda T pueden ser señal de que “algo” no es normal, pero no dice mucho acerca de la gravedad. Las posibles causas de las anomalías de la onda T pueden ser la osquemia e infarto de miocardio, pericarditis, miocarditis, contusión cardíaca, eventos neurológicos agudos, prolapso de la válvula mitral, efecto medicamentos (por ejemplo, digoxina), desequilibrio electrolítico (por ejemplo, hiperpotasemia).

Onda U: Su presencia suele estar vinculada a trastornos de tipo hidroelectrolíticos, acción de determinadas drogas, y raramente a la isquemia.

Intervalo PR ó PQ:

- Alargado → Generalmente corresponde a bloqueo AV de primer grado.
- Acortado → Taquicardias, síndromes de pre-excitación (síndrome de Wolff-Parkinson-White “WPW”) y ritmos nodales o auriculares bajos.

Intervalo QT: Varía en función de la frecuencia cardíaca, la edad, el género, o incluso durante el día en una misma persona (15 a 70 ms). Los cambios patológicos en el intervalo QT pueden ser debido a la diabetes mellitus, hipertensión arterial, tumores o infecciones del sistema nervioso central, enfermedad coronaria, obesidad, alcoholismo, nefropatía, hepatopatía, síndrome del QT congénito, que pueden ser estudiadas a través de este intervalo. Mas específicamente:

- Alargado → Cardiopatía isquemia, miocardiopatías, Hipocalcemia, Mixedema, trastornos electrolíticos, intoxicación por determinadas drogas, síndrome del QT largo(hereditario), síndromes complejos como el de Romano-Ward ó en el de Jerwell y Lange-Nielsen en donde la presencia y severidad de arritmias ventriculares es notable.
- Acortado → Hipercalcemia, hiperpotasemia, re-polarización precoz (atletas), digoxina.

Segmento PR:

- Elevación o depresión del segmento PR → Infarto auricular o pericarditis.

Segmento ST: Básicamente, hay dos anomalías que se detectan en el segmento ST:

- Depresión del segmento ST → Generalmente un síntoma de isquemia cardiaca.
- Elevación del segmento ST → Infarto de miocardio, pericarditis aguda o una miocarditis.

2.3 SEGMENTACIÓN DE LA SEÑAL ECG

La segmentación de la señal ECG es el proceso de dividir la señal en sus partes características principales. El objetivo es simplificar la señal para que sea más fácil de analizar. La segmentación se usa tanto para localizar objetos como para encontrar los límites de estos dentro de una señal. Se considera que mediante la localización de la posición exacta de 8 puntos específicos señalizados en la Figura 2.9, se puede obtener la información morfológica de las ondas principales de la señal ECG.

La mayor parte de la información de utilidad clínica del ECG se encuentra en los intervalos definidos por los estos 8 fiduciales característicos nombrados de izquierda a derecha como: P_{on} (principio de la onda P), P_{peak} (pico de la onda P), P_{off} (final de la onda P), QRS_{on} (principio del complejo QRS), QRS_{off} (final del complejo QRS), T_{on} (principio de la onda T), T_{peak} (pico de la onda T) y T_{off} (final de la onda T).

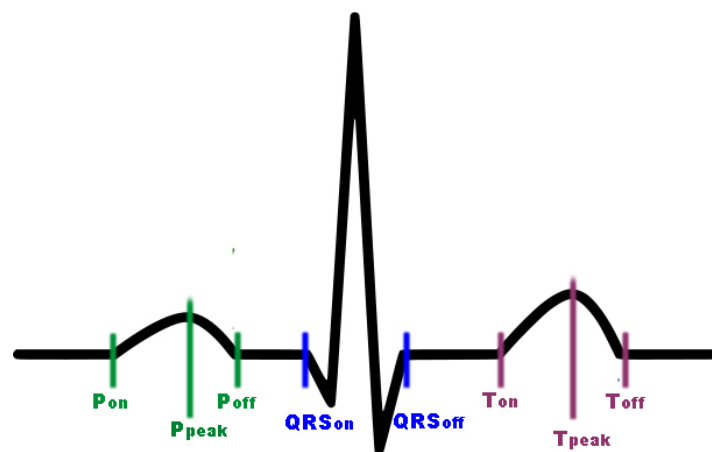


Figura 2.9: Definición de los puntos característicos del ECG para ser segmentado

2.4 MÉTODOS PARA LA SEGMENTACIÓN AUTOMÁTICA DE ECG

Dado que la mayoría de la información de utilidad clínica del electrocardiograma se encuentra dentro de los intervalos de tiempo y amplitudes determinados por los puntos fiduciales, la segmentación automática del ECG ha sido objeto de intensa investigación durante las últimas tres décadas para clínicos e ingenieros biomédicos. Tras una larga búsqueda bibliográfica, más de 50 publicaciones acerca de la segmentación automática de ECG han sido encontradas.

2.4.1 DIFICULTADES DE LA SEGMENTACIÓN AUTOMÁTICA DEL ECG

El desarrollo de un método sólido y preciso para la segmentación automática de ECG sigue siendo un tema de investigación activa, ya que no es una tarea fácil. Además del ruido que suele ir incorporado, la forma de onda del ECG es muy variable entre distintos sujetos, así como en un mismo sujeto. Esta variabilidad intra-sujeto depende de varios factores. El factor que más afecta es la ubicación del electrodo con respecto a las fuentes cardiacas. Otros factores son la posición del cuerpo, el ruido eléctrico, los artefactos musculares y el mal contacto de los electrodos. La variabilidad es considerable incluso en sujetos sanos, pero en la de individuos que sufren de isquemia (insuficiencia en el suministro de oxígeno al tejido

cardíaco) o arritmias (ritmos cardíacos irregulares) es dramática, variando incluso de latido a latido.

Por otra parte, las bandas frecuenciales de las ondas que componen la señal ECG, es decir la onda P, complejo QRS y la onda T, se solapan unos con otros (ver Figura 2.10), no pudiendo ser separados mediante filtros simple.

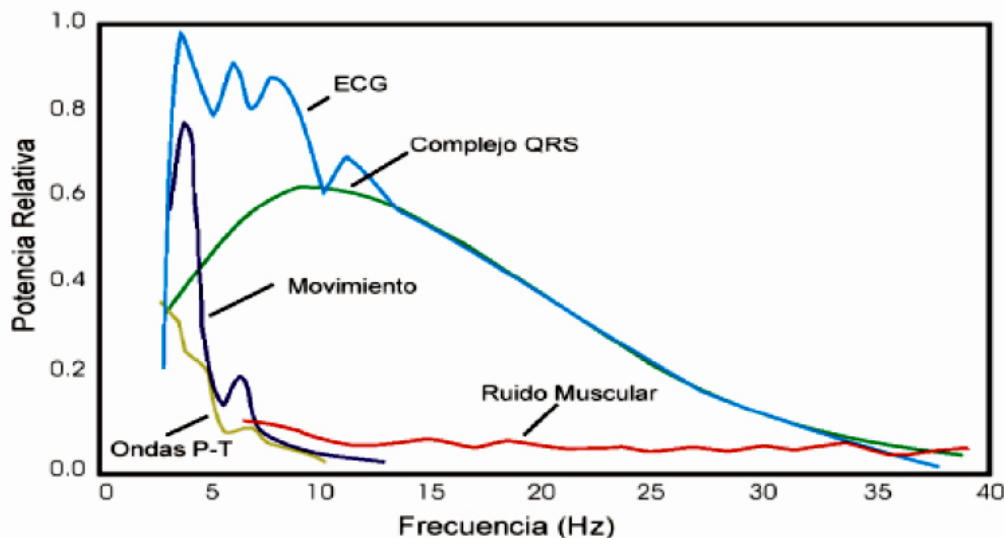


Figura 2.10: Espectro de frecuencias de la señal ECG.

Aunque el complejo QRS sea el más fácil de segmentar, tienen una gran variabilidad morfológica. Las ondas P y T también pueden tomar diferentes formas, pudiendo ser invertidas o bifásicas, lo que aumenta la dificultad de determinar con precisión su aparición o desplazamiento. La onda P se caracteriza por su baja amplitud y puede ser enmascarada por el ruido muscular o por el movimiento del electrodo. Además, esta onda puede estar ausente por alguna patología en las aurículas o aparecer parcialmente superpuesta en patrones de ritmos cardíacos acelerados. La precisión para determinar el final de la onda T tiene muchas dificultades debido a la suave transición de la señal. El hecho de que no hay una norma universal que defina la posición exacta de los diferentes puntos fiduciales, complica aún más la tarea.

2.4.2 DESCRIPCIÓN DE LOS METODOS

Tal y como se ha explicado anteriormente, la señal ECG suele estar representada mediante 12 derivaciones diferentes, que dependen de la posición de los electrodos en la superficie del paciente. Muchas aplicaciones cardíacas no-diagnósticas, no requieren de toda la configuración de las 12 derivaciones ECG, ya que emplean un número limitado de electrodos. En algunos casos, es suficiente con una única derivación, que requiere solo de tres electrodos. Estas aplicaciones se centran en la monitorización ambulatoria del ECG, es decir, en condiciones sin restricciones, en donde los sujetos realizan sus actividades normales en sus vidas cotidianas.

La mayoría de los algoritmos de segmentación de ECG encontrados en la literatura están programados para que respondan de manera efectiva ante cualquiera de las 12 derivaciones, pudiendo así, realizar la segmentación con solo una derivación. Cuando se dispone de varias derivaciones se encuentran los puntos fiduciales por separado en cada derivación de la señal ECG, y después, se determina la posición global específica mediante reglas de selección especial. Este trabajo solo se centra en comparar los algoritmos de segmentación automática de ECG que utilizan una sola derivación, pudiendo ser cualquiera de las 12 ya mencionadas.

Los algoritmos dividen la segmentación automática de ECG en un número de etapas diferentes. Existen dos fases principales que son comunes en la mayoría de algoritmos. La

primera fase, transforma la señal ECG con la finalidad de extraer o resaltar la información que se encuentra en las diferentes ondas de la señal. La segunda fase determina la posición de los diferentes puntos fiduciales de acuerdo a una serie de reglas, que dependen de la manera en la que se ha transformado la señal en la primera fase.

2.4.2.1 Fase 1: Transformación de la señal ECG. Extracción de las características.

Esta primera fase se encarga de transformar la señal ECG con el fin de extraer las características morfológicas pertenecientes a las diferentes ondas. Mediante este procedimiento se pretende retener la información útil, es decir, encontrar una representación efectiva de la señal, tal que sus características temporales y espectrales fundamentales sean capturadas en una forma más compacta e informativa que la señal pura [21].

El preprocesado de la señal se realiza dentro de esta fase, con el fin de eliminar las perturbaciones asociadas a los registros ECG. El presente trabajo no se centra en el estudio de los métodos de eliminación de artefactos y ruido propio de la señal ECG, dado que existe un número extenso de trabajos que hacen frente a este tema.

Diferenciación y derivada

En la literatura se proponen diferentes transformadas para llevar a cabo esta primera fase. Uno de los primeros métodos exitosos de segmentación automática de ECG fue propuesto por Laguna et al [22] en 1990 (y más tarde en 1994 [1]). En él, se transforma la señal ECG mediante una ecuación de diferenciación, después de haber pasado un filtro paso banda de segundo orden. La finalidad de esta transformada, es obtener una definición modificada de la pendiente de la señal ECG, como característica para la detección de las componentes de la señal.

En la literatura varios autores han utilizado este tipo de transformada, así como la primera y la segunda derivada de la señal, que ofrece un resultado similar [23-31]. Mientras la primera derivada informa de si la función crece o decrece y en qué medida lo hace, la segunda derivada permite determinar los intervalos en que la función es cóncava o convexa, así como los puntos de inflexión. Este tipo de transformada proporciona información del tiempo pero no de la frecuencia.

Transformada de Fourier (FT)

La transformada de Fourier también ha sido utilizada para la segmentación de ECG. En 1992 Murthy et al [32] utilizó la transformada discreta de Fourier (DFT). Esta transformada proporciona la información de las frecuencias presentes en la señal, y con ello se puede resaltar su frecuencia fundamental. Este tipo de transformada también sirve para extraer la duración del período, pero no para indicar ni su comienzo ni su final. No proporciona información temporal (esencial en la segmentación), por lo cual no existen muchos algoritmos de segmentación que utilicen la FT.

Transformada wavelet (WT)

La transformada wavelet proporciona una descripción de la señal tanto en el dominio temporal como en el dominio frecuencial. Permite la representación de las características temporales de la señal ECG a diferentes resoluciones (escalas), en función de su contenido frecuencial. De esta manera, el ruido y los artefactos pueden ser evitados, sin necesidad de un previo filtrado, si se tiene en cuenta la diferente contribución del ruido a distintas escalas.

En 1995, Li et al [33] fue el primero que utilizó la transformada wavelet para la segmentación de ECG exitosamente. Desde entonces, un esfuerzo de investigación significativo ha sido dedicado a la explotación de este método prometedor [34-51]. En particular, Li et al [33] utilizó la WT diádica (DWT) que lo calculó con el algoritmo de Mallat [52]. Más tarde en el

2004, Martínez et al [2], cuyos resultados siguen siendo a día de hoy un referente, empleó también la DWT, pero en este caso, calculándolo mediante el algoritmo de *à trous*. Posteriormente, otros autores han utilizado esta técnica (DWT) para realizar la segmentación automática del ECG a tiempo real, como por ejemplo Boichat et al [37], Di Marco et al [4] o Rincón et al [35] entre otros, este último, optimizado y adaptado a una plataforma de sensores portátiles comercial.

La Transformada wavelet continua (CWT) [8, 50] también ha sido propuesta para la segmentación de la señal ECG, pudiendo así utilizar cualquier escala real positiva, mientras que con la DWT solo se limita a las escalas que son potencia de dos.

La forma de la WT y por consiguiente el resultado de la segmentación, está estrechamente unido al tipo de wavelet madre que se utilice, la cual, depende directamente de la aplicación. Existen muchas wavelets madre agrupadas en familias según su utilidad; Ingrid Daubechies quien es el mayor constructor de wavelets ha propuesto tres familias, la Daubechies (conjunto de wavelets ortonormales apropiadas para señales discretas), la Coiflets y la Symmlet que siendo similares a las Daubechies tienden a ser casi simétricas. Las Biortonormales es una familia que presenta la propiedad de fase lineal. Algunas están definidas por una función explícita como wavelet Haar, la Morlet o la wavelet sombrero mexicano que no es más que la segunda derivada de la función gaussiana. Las principales y más conocidas familias de wavelet son la Dubechie, la Coiflet y la Symmlet.

En la literatura se pueden encontrar diferentes Wavelet madre utilizadas para realizar la transformada de la señal ECG. Andreao et al [53] realizó un estudio comparativo entre cinco funciones wavelet continuas, más la combinación de dos de ellas para ver como afectaba a la segmentación de ECG.

Reconocimiento de patrones y función de correlación

Los algoritmos basados en la estimación de la función de correlación han sido utilizados principalmente para la detección de las diferentes ondas de la señal ECG. Esta transformada que se realiza mediante plantillas de diferentes medidas y formas para las diferentes ondas, también ha servido para algoritmos de segmentación tales como Last et al [54] con la correlación cruzada multicomponente, Baas et al [55] y Vila et al [37] para ubicar el final de la onda T, ó Schreier et al [25] que utiliza la CC después de haber realizado la primera derivada, para determinar el principio del complejo QRS y el final de la onda T.

En este tipo de algoritmos de reconocimiento de patrones, la idea básica para la detección de la forma de onda es construir primero una plantilla de la forma de onda de la que se quiere detectar y, a continuación, correlacionar la plantilla con la señal para detectar la correspondiente forma de onda. Estos métodos parecen tener una ventaja si se trabaja con señales contaminadas con ruido. Sin embargo, debido a las grandes variaciones morfológicas en las formas de onda, no parece muy razonable construir una plantilla “universal” para cubrir todas las diferentes situaciones. Y la construcción de un modelo específico para cada caso en particular puede necesitar la intervención de expertos humanos.

Transformada Hilbert (HT)

La transformada de Hilbert ha sido utilizada para la identificación de la onda R, por lo que se emplea en general, en algoritmos que segmentan el complejo. Una función real y su transformada de Hilbert, están relacionadas entre sí de tal manera que juntos crean una denominada señal analítica fuerte. La señal analítica puede ser escrita con una amplitud y una fase en la que la frecuencia instantánea es nada más que la derivada de la fase. La envolvente es definida como el módulo de la señal compleja, formada por la señal filtrada de ECG (la parte real) y la transformada de Hilbert de la señal filtrada (parte imaginaria). Tiene la particularidad de ser una onda cóncava en forma de campana, donde su comienzo y final corresponden al principio y al final del complejo QRS respectivamente. Los algoritmos que

emplean la transformada de Hilbert [30, 34, 45, 56, 57], suelen ir acompañados por otras transformadas como la TW o el filtro derivador.

Aproximaciones lineales a trozos (PLAs: Piecewise linear approximations)

El algoritmo basado en aproximaciones lineales a trozos descrito por Koski et al [58], fue utilizada en 1998 para la segmentación de ECG por Vullings et al [59]. Este enfoque se aplicó para transformar la señal de ECG en una secuencia de líneas rectas (ver Figura 2.11), donde los puntos finales de estas líneas son considerados como un conjunto de posibles puntos fiduciales.




Figura 2.11: Ejemplo de la transformación: la función (en azul) y su aproximación lineal (en rojo)

En el 2006, Zifan et al [60] elaboró un método veloz de segmentación, basándose en Vuilling et al [59]. Utilizó una transformada modificada a la anterior (PLAs) llamada “Aproximación Constante a Trozos Adaptativa” (APCA: Adaptive Piecewise Constant approximation) para representar adaptativamente la señal de ECG. Ésta transformada aproxima cada serie de tiempo a un conjunto de segmentos de valores constantes de diversas longitudes, de tal forma que sus errores de reconstrucción individuales sean mínimos (ver Figura 2.12).




Figura 2.12: Señal original de tiempo denominada C (arriba) y su transformada APCA (abajo).

Multiple higher order moments (MHOM)

Homaeinezhad et al [44] realizó en el año 2009 un algoritmo de segmentación de la señal de ECG Holter, basado en *Multiple higher order moments* y un año más tarde ideó una extensión de este algoritmo, esta vez basándose en *Multiple-order derivative wavelet based measure (MDWM)*[45].

Para efectuar la transformada MHOM, la señal ECG es primero transformada mediante la

DWT y a continuación, una ventana que se desliza muestra a muestra es aplicada para conseguir la denominada señal MHOM. En cada paso que da esta ventana deslizante, primero se calcula el valor medio, la varianza, la asimetría y la curtosis del segmento extraído; para que posteriormente, se superpongan todas estas medidas y se vaya obteniendo la señal MHOM.

En cuanto a la obtención de la señal MDWM, primero se implementa un filtro (FIR) paso banda y se realiza la transformada DWT (á trous), para potenciar los efectos de las ondas de baja potencia tales como la onda P o la onda T. Después, una ventana de longitud uniforme se desliza muestra a muestra, y en cada paso se calculan seis parámetros: la suma de la transformada de Hilbert no lineal amplificada, la suma de la diferenciación de primer orden, la suma de la diferenciación de segundo orden, la longitud de la curva, el área y la varianza del segmento extraído. Se normalizan todos los parámetros y se superponen para producir la señal MDWM.

Ambas señales (tanto la MHOM como la MDWM) reaccionan ante los bordes de la señal en lugares de máxima (mínima) pendiente y en ubicaciones de máxima (mínima) elevación. Por lo tanto, estas señales transformadas permiten detectar los bordes y extremos de la señal extraída en la ventana de análisis. En ellas se ocultan importantes características geométricas tales como el ratio entre el valor máximo y mínimo, el área, el grado de suavidad o impulsividad y el grado de simetría o asimetría

Derivada morfológica multiescala (MMD: multi-scale morphological derivate)

Sun et al [5] (en 2005) aplicaron la MMD, sustituyendo la derivada convencional de la señal por la derivada morfológica. La MMD fue obtenida primero realizando un filtrado morfológico, que reduce el ruido y corrige desviación de la línea base y después, calculando su derivada a una escala determinada, todo ello mediante el uso de las operaciones morfológicas de apertura, cierre, dilatación y erosión.

Mediante esta transformada (MMD), los puntos fiduciales quedan resaltados, ya que son representados mediante máximos y mínimos locales. Se sabe que contra mayor sea la escala, el número de máximos y mínimos es mucho menor que en escalas menores. Además, el ruido de alta frecuencia decae en gran medida en escalas mayores, de modo que menos ruido extremo es encontrado a escalas mayores. Por lo tanto, la señal transformada mediante la derivada morfológica fue utilizada con la mayor escala posible, pero menos que el ancho de la onda característica multiplicado por la frecuencia de muestreo de la señal ECG.

Transformada fasorial (PT: Phasor transform)

Recientemente, Martínez et al [6], ha ideado un algoritmo rápido y fácil de implementar basada en la transformada fasorial. Ésta transformada convierte cada muestra instantánea de la señal ECG en un fasor simple, maximizando las diferentes ondas de la señal. La PT es una herramienta sencilla que puede representar una función sinusoidal en el dominio complejo. El resultado es un número complejo, llamado fasor, que conserva la información de la señal con respecto a los valores de la fase y la media cuadrática.

De esta manera, teniendo en cuenta la variación instantánea de la fase en muestras consecutivas de la transformada fasorial del ECG, las ligeras variaciones provocadas por las ondas P y T en los registros originales se maximizan, independientemente de su baja amplitud. Esto hace que la detección de dichas ondas sea notablemente más fácil.

2.4.2.2 Fase 2: Identificación de los puntos fiduciales

Las técnicas usadas para identificar los puntos fiduciales (P_{on} , P_{peak} , P_{off} , QRS_{on} , QRS_{off} , T_{on} , T_{peak} y T_{off}) tras haber primero transformado la señal ECG, se pueden dividir en dos

grupos principales: las técnicas basadas en reglas heurísticas y las basadas en modelos estocásticos o probabilísticos. La mayoría de algoritmos encontrados en literatura se basan en reglas heurísticas.

Reglas heurísticas

El primer paso que se realiza en los métodos segmentación que utilizan reglas heurísticas, es la detección del pico de la onda R, con el fin de tomar este punto como referencia. Si nos fijamos en las características morfológicas del ciclo cardíaco, en cada latido, la onda R es la onda que presenta mayor energía en la mayoría de las 12 derivaciones estándar, excepto en las primeras derivaciones precordiales (V1 y V2) y en la derivación aumentada aVR, donde el máximo en estos casos se encuentra en la onda Q [21].

Dada ésta característica, la onda R es la más fácil de identificar, pero no por ello la menos importante. La detección de la onda R informa de la posición de los latidos, así como de la longitud y duración de estos. Así, es de esperar que la precisión con la que se realiza la detección de la onda R tiene un impacto significativo en el rendimiento de la segmentación.

Una vez que se ha estimado la posición de R, se procede a establecer ventanas de búsqueda hacia adelante y hacia atrás (a partir de la posición de R) con el fin de localizar los puntos fiduciales. Generalmente, primero se establecen las ventanas de búsqueda para localizar los límites del complejo QRS (QRS_{on} y QRS_{off}), y después, los puntos fiduciales de las ondas P y T (P_{on} , P_{peak} , P_{off} , T_{on} , T_{peak} y T_{off}).

Las medidas de la ventanas también toman un papel importante a la hora de ubicar los puntos fiduciales adecuadamente, ya que es necesario que abarquen correctamente la onda a segmentar. Estas medidas dependen de medidas heurísticas que dependen de la experiencia que tenga el autor del algoritmo. Generalmente, el tamaño de la ventana de búsqueda está en función de la duración del intervalo R-R.

Una vez enventanado el segmento de la señal a estudiar, se buscan las características específicas que representan las diferentes partes de la señal. Finalmente, se determinan las posiciones de los puntos fiduciales a través de umbrales adaptativos u otras reglas heurísticas.

Umbralización adaptativa (regla de decisión)

Dependiendo de la transformación de la señal ECG realizada en la primera fase, la representación de las ondas y sus fiduciales en la señal transformada será de una forma u otra. Por ejemplo, las transformadas más populares que son tanto la transformada wavelet, como la primera derivada o la diferenciación, los picos de las ondas de la señal original, son representados mediante cruces por cero entre un modulo máximo y un modulo mínimo de una amplitud que sobrepase un cierto umbral (ver Figura 2.13)

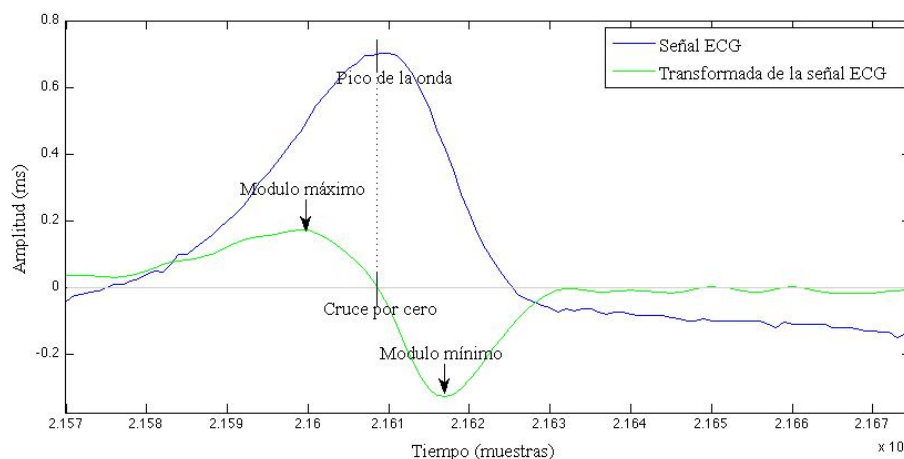


Figura 2.13: Ejemplo de búsqueda del pico de una onda mediante una transformada típica.

Una vez detectada la onda, se busca hacia atrás y hacia adelante los módulos máximos que representen la primera y la última pendiente de la onda. Entonces, los límites se definen como la primera muestra (hacia atrás desde el primer modulo máximo para encontrar el principio de la onda y hacia delante desde el último modulo máximo para encontrar el final de la onda) cuyo valor sea menor que un umbral pre-determinado (ver Figura 2.14).

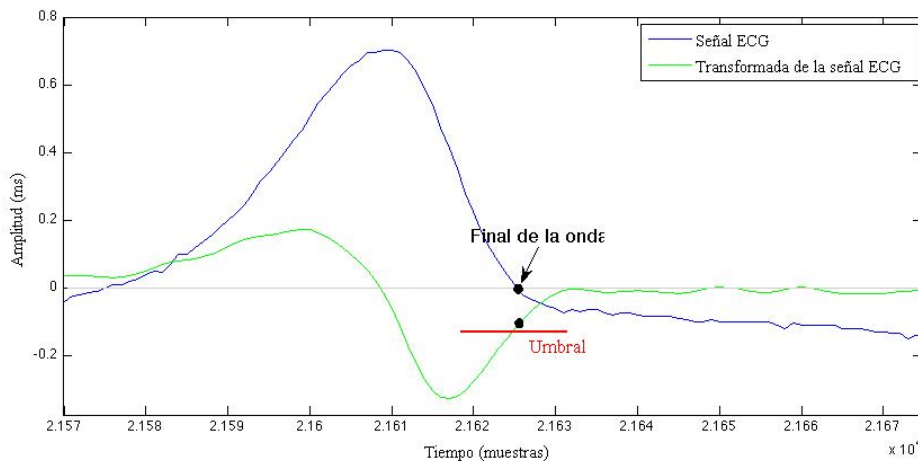


Figura 2.14: Ejemplo de la búsqueda del final de una onda mediante la umbralización adaptativa.

Además los algoritmos basados en reglas heurísticas suelen considerar diferentes morfologías de las ondas e incluyen medidas de protección, basadas en intervalos de tiempo y reglas de signo, para evitar discontinuidades en las ondas y deflexiones anómalas en la señal ECG.

2.4.2.2.1 Modelos estadísticos

Los modelos estadísticos reemplazan las normas heurísticas comúnmente utilizadas en la detección de formas de onda, que generalmente requieren de umbrales. Varios software comerciales han sido desarrollados mediante algoritmos que utilizan reglas heurísticas, con el fin de ayudar a los cardiólogos a segmentar largos registros de ECGs. No obstante, estos software no proporcionan una segmentación precisa (por las dificultades que ello conlleva), ya que necesitan de repetidas correcciones. Los modelos probabilísticos pueden llegar a ser una herramienta de apoyo a la decisión, que no solo imite el comportamiento de un cardiólogo, sino que también pueda adquirir un modo de razonamiento y proporcione su propio análisis del problema.

Modelos ocultos de Markov (HMM: Hidden Markov Model)

Entre los métodos probabilísticos, los modelos ocultos de Markov son los más populares para el tratamiento de señales ECG. Los HMM constituyen una herramienta de modelización altamente flexible, inicialmente utilizada en el campo del reconocimiento automático del habla, que ha encontrado en los últimos años numerosas aplicaciones en áreas científico-técnicas muy diversas.

HMM es un proceso por el cual se observa el comportamiento del sistema de manera indirecta, pues los estados del mismo permanecen ocultos por el observador. Tanto en la detección, como en la segmentación de la señal ECG, la mayoría de la información puede ser obtenida a partir de las propiedades estadísticas de la señal, las cuales varían con el tiempo.

El electrocardiograma, puede ser visto como un sistema que viaja a través de diferentes estados (formas de onda características de la señal: onda P, complejo QRS y onda T). En cada estado las propiedades estadísticas de la señal son diferentes. Los modelos estadístico estándares a menudo no captan estas propiedades, ya que solo modelan las propiedades estadísticas globales de la señal. Uno de los modelos que es capaz de hacer frente a las

señales cuyas propiedades estadísticas varían a través del tiempo, son los modelos ocultos de Markov.

Desde su desarrollo a finales de 1960 y principios de 1970, los modelos ocultos de Markov han demostrado ser un tipo de modelo estadístico poderoso y flexible para describir muchos tipos diferentes de datos secuenciales. El uso de modelos ocultos de Markov para el análisis de señales ECG fue investigado por primera vez en 1990 por Coast et al [61], que utilizó este tipo de modelos, con el fin de analizar las arritmias cardíacas. Siguiendo el trabajo de Coast et al [61], seis años más tarde, Koski et al [62] realizó un modelo oculto de Markov para el modelado de la señal ECG, utilizando el algoritmo Baum-Welch para la búsqueda de los parámetros del modelo. El objetivo de éste trabajo fue examinar la utilidad de los HMMs, ya que proporcionaban descripciones estadísticas útiles de la señal ECG, para la clasificación de los latidos y la compresión de datos.

En 1996, Clavier y Boucher [63], investigaron el uso de modelos de árbol ocultos de Markov para la segmentación ECG. De la misma manera, Crouse et al [64] propuso otro método usando la combinación de WT (como transformada de la primera fase) y HMM. En el 2000 Stamkopoulos et al [65] aplico HMM con densidades de observación auto-regresivos (AR) mediante ajustes de un “filtro Kalman AR”. Los parámetros HMM fueron entrenados de manera no supervisada usando el algoritmo EM (por sus siglas en inglés Expectation-Maximization). Más tarde, Graja y Broucher [66] realizaron un modelo oculto de marcov multiescala con el propósito de segmentar la señal ECG que previamente había sido transformada con la DWT.

Recientemente, una gran cantidad de autores han investigado el uso de HMM, proporcionando resultados fiables para la segmentación de la señal ECG. Entre ellos, en la literatura se han podido encontrar los métodos de Krimi et al [42], Thomas et al [50], Andreao et al [53], Lannoy et al [38], Frenay et al [31] y Shi et al [43].

- HSMM(*Hidden Semi-Marcov Model*)

El problema de los modelos probabilísticas, y en concreto de los HMM, es su dificultad para determinar los valores adecuados de los diferentes parámetros, es decir, las probabilidades de estado inicial, las probabilidades de transición entre estados y las probabilidades de salida. Pero la limitación más importante de los modelos ocultos de Markov estándares, es la manera en que se modela la duración de los estados. Así, para una determinada forma de onda de ECG dada, la decodificación de la secuencia de estado, puede contener muchas más transiciones de estado que las que realmente existen en la presente señal.

Una solución a este problema es post-procesar el estado de secuencias decodificado, usando un filtro de mediana, diseñado para suavizar las secuencias cuya duración se sabe que es fisiológicamente plausible. Sin embargo, un enfoque con más principios y más eficaz, es modelar la densidad de probabilidad de cada duración de cada estado individual explícitamente, usando un hidden semi-Marcov model. Esta perspectiva fue utilizada por Thoraval et al [68] en 1992. Recientemente Hughes et al [9] y Vaessen et al [67] han demostrado la eficacia del método de HSMM para llevar a cabo la segmentación automática de ECG.

Alineamiento temporal dinámico (Dynamic time warping, DTW)

El algoritmo de alineamiento temporal dinámico nos permite medir la similitud entre dos secuencias que pueden variar en el tiempo o en el espacio. Este método tiene en cuenta la variación en la escala del tiempo entre dos latidos a comparar. Por lo tanto, DTW comprime o expande una secuencia (no linealmente en el tiempo) hasta que se proporcione un ajuste “óptimo” entre las dos secuencias. Así, éste método hace frente a la problemática debida a que el ritmo del corazón no siempre es el mismo, lo que produce importantes distorsiones temporales, ya que un latido no siempre se realiza a la misma velocidad.

En esencia, el DTW es un esquema de ajuste de características que mediante la alineación temporal, pretende hacer concordar de forma adecuada las diferentes partes de la señal de ECG a segmentar con la de referencia. Para ello, compara cada latido del corazón con un conjunto de plantillas de las ondas P, QRS y T, y se seleccionan las mejores coincidencias para la detección de los fiduciales.




Figura 2.15: Ejemplo del algoritmo de DTW cuando se comparan dos latidos del corazón completos. La matriz muestra el "camino" donde coinciden partes similares de los dos latidos.

Originalmente, al igual que los modelos ocultos de Markov, el algoritmo DTW se usaba para comparar distintos patrones acústicos en el reconocimiento automático del habla. En 1998 Vulling et al [59] propuso un método de segmentación de ECG utilizando DTW para la segmentación de ECG, inspirado por una popular técnica de reconocimiento del habla [69]. En el 2006, como extensión al trabajo de [59], Zifan et al [60], presentó otro algoritmo de segmentación automática de ECG utilizando DTW.

Red neuronal artificial (ó red neuronal)

Las redes neuronales son ampliamente utilizados en las tareas de procesamiento de señales [70-74]. Una red neuronal artificial, es un modelo matemático inspirado por redes neuronales biológicas que sirven para la estimación de probabilidades. Mediante esta aplicación de algoritmos que imitan los procesos de las neuronas reales, se puede lograr que la red "aprenda" a resolver muchos tipos de problemas. Bystricky et al [75] utiliza las redes neuronales para determinar el final de la onda T y en el método de segmentación de Shi et al [43] una de las aplicaciones de las redes neuronales es la generación de las probabilidades de emisión en la teoría de HMM.

Algoritmo evolutivo (EA)

Un problema recurrente encontrado en muchos algoritmos propuestos para detectar y segmentar ondas ECG es el ajuste de los numerosos parámetros utilizados. Por ejemplo el algoritmo de segmentación de ECG típico basado en TW, requiere más de 15 parámetros

(definición del tamaño de las ventanas, amplitudes de las ondas y pendientes, frecuencia de corte de los filtros, niveles de los umbrales, etcétera). El algoritmo evolutivo, ajusta los parámetros de la etapa de segmentación con el fin de minimizar el error, que mide cuán cerca están los fiduciales detectados por el algoritmo, de los puntos característicos anotadas por un cardiólogo.

Es bien sabido que el ajuste de estos parámetros es una tarea compleja que se suele realizar empíricamente y de forma manual, con la base de la experiencia del diseñador. Para resolver este problema de optimización multiobjetivo, Dumot propone un nuevo algoritmo evolutivo para la segmentación ECG primero en [46], y 3 años más tarde en [47].

Best basis(BB)

El algoritmo de BB implementado para la segmentación de la señal ECG fue implementado por Krim y Brooks [76, 77] fundamentándose en las características intrínsecas de la señal como el suavizado y la curvatura. Es un algoritmo de descomposición óptima, que selecciona la mejor base para segmentar las ondas y complejos relevantes de la señal ECG. Introduce un nuevo criterio de optimalidad que se basa en una combinación lineal de la medida de entropía y una función que mide la uniformidad de la señal. Este método, a pesar de ser determinístico, puede ser observado como un método bayesiano estadístico.

Enfoque bayesiano

El enfoque bayesiano es un método alternativo para el análisis estadístico de datos, que contrasta con los métodos convencionales de inferencia, en parte por hacer un manejo subjetivo, no frecuentista, del concepto de probabilidad. Se denomina método bayesiano por basarse originalmente en el teorema de Bayes, que en esencia nos permite, si conocemos la probabilidad de que ocurra un suceso, modificar su valor cuando se dispone de nueva información.

Varios algoritmos para la segmentación de la señal ECG [75, 78, 79] utilizan técnicas bayesianas en combinación con otros métodos, tanto para entrenar el modelo planteado, como para representar una relación a priori entre los componentes de las ondas de ECG. Estos modelos tienen en cuenta las correspondientes distribuciones previas de los parámetros desconocidos (amplitudes y ubicaciones de las ondas, los coeficientes de forma de onda, etcétera). Las distribuciones previas y la probabilidad de los datos observados son combinados para proporcionar la distribución a posteriori de los parámetros desconocidos. Esta distribución posterior depende de hiperparámetros que se pueden fijar a priori o estimarse a partir de datos observados.

Otros métodos probabilísticas

En la literatura existen más métodos de segmentación de ECG que utilizan algoritmos probabilísticos o estadísticos, como por ejemplo Ilianes-Manriquez en [24] que está basado en una prueba estadística para detectar cambios de la media en una señal auxiliar calculado a partir de varias derivaciones de ECG. En concreto, se basa en el test estadístico CUSUM, ya que es útil para la detección de cambios abruptos en las señales y en los procesos dinámicos. Recientemente, un algoritmo que utiliza la decisión estadística para detectar y segmentar las ondas características del ECG ha sido el de Gaffari et al [44-45].

Además, la segmentación también puede estar basada en el concepto de ajustar un modelo realista de la señal ECG y en la extracción de parámetros del modelo para determinar el principio y el final de las formas de onda. Se ha prestado especial atención a modelos de mezclas Gaussianas, cuyos parámetros pueden ser estimados por gradientes de pendiente [80] o filtros Kalman (KFs)[81-82].

3 ALGORITMOS DE SEGMENTACIÓN A EVALUAR

En este capítulo se describen los 9 algoritmos elegidos para ser implementarlos y evaluarlos mediante el estudio comparativo. Varios algoritmos comparten ciertos métodos, si algún aspecto ha sido profundizado en la descripción de un algoritmo, no se vuelve a explicar.

La detección de la onda R no ha sido considerado en este trabajo, ya que a día de hoy existen numerosos trabajos que abarcan este tema. Los enfoques más importantes propuestos en la literatura para la detección de la onda R se resumen en Köhlet et al [83]. Además, un detector de ritmo cardíaco sólido ha sido ya desarrollado por los autores en previos trabajos [84].

3.1 LAGUNA [1]

El trabajo de Laguna et al [1] es uno de los primeros referentes de la segmentación ECG. Su algoritmo se basa en la señal diferenciada y en la umbralización adaptativa.

3.1.1 FASE 1: SEÑAL DIFERENCIADA

Con el propósito de obtener la información de los cambios de la pendiente de la señal ECG a segmentar, la señal es transformada en esta primera fase mediante un diferenciador paso bajo. Para ello, en el algoritmo propuesto, antes de calcular la señal diferenciada, primero filtra la señal con un filtro Lynn paso banda de (0.8-18HZ, 3dB). Así, se atenúan las variaciones de la línea de base y la contaminación de las altas frecuencias. En el algoritmo realizado en este estudio, este primer preprocesador se hace con un filtro FIR Equiriple paso banda(0.5-18Hz) ya que con la frecuencia de corte de 0.8 Hz se eliminaba parte de la señal necesaria. El resultado de la señal transformada es mostrado en la Figura 3.1.




Figura 3.1: Señal ECG original (en azul) y su transformada, la señal diferenciada (en rojo).

3.1.2 FASE 2: UMBRALIZACIÓN ADAPTATIVA

El primer paso, es detectar el complejo QRS, que por su característica morfológica pertenece a la onda de mayor amplitud del latido. Este punto ya está ubicado de antemano, ya que se puede utilizar cualquier detector del complejo QRS encontrados en la literatura.

Por cada complejo QRS detectado se busca en la en la señal transformada, la onda de mayor amplitud denominada en este caso P_{kn} . Por cada P_{kn} se buscan los picos más cercanos hacia adelante (P_{pos}) y hacia atrás (P_{pre}).

El pico de la onda R (R_P) será (detectado de antemano) será el cruce por cero entre P_{kn} y el P_{pos} ó P_{pre} , dependiendo de el que mayor valor tenga.

El pico de la onda Q (Q_P), en caso de que exista, corresponderá con el cruce por cero anterior a R_P en la señal transformada. Si entre Q_P y R_P hay una distancia de más de $80ms$, el algoritmo considera que no existe tal onda Q. De la misma manera, el pico de la onda S (S_P) se le atribuye al siguiente cruce por cero respectivo a R_P . En caso de que dicho punto se encuentre a una distancia menor que $80ms$ con respecto a R_P .

A partir de dichos puntos se pueden encontrar el principio y el final del complejo QRS, QRS_{on} y QRS_{off} respectivamente. Para determinar el fiducial QRS_{on} se realiza una búsqueda hacia atrás desde la posición Q_P (ó R_P en su defecto) en la señal transformada para encontrar el punto denominado Q_i (ó R_i) que es el mayor modulo máximo anterior a Q_P . Buscando hacia atrás desde este punto (Q_i ó R_i) el fiducial QRS_{on} será la primera muestra que cruce el umbral H_q (o H_r). El calculo del umbral se hace mediante el valor Q_i (ó R_i) dividiéndolo por una constante que toma diferentes valores dependiendo de si la onda Q está presente o no:

- Si la onda Q esta presente: $H_q = \frac{d(Q_i)}{K_q}$ [$K_q = 2$]
- Si la onda Q no esta presente: $H_r = \frac{d(R_i)}{K_r}$ [$K_r = 2$]

El fiducial QRS_{off} se detecta de una manera similar pero buscando hacia adelante en vez de hacia atrás.

Para realizar la segmentación de las ondas P y T, la señal diferenciada se vuelve a filtrar con un filtro paso bajo con frecuencia de corte de $12Hz$, ya que las componentes frecuenciales de dichas ondas son menores que las del complejo QRS.

A continuación se explica la manera de determinar los fiduciales T_{peak} y T_{off} . Para ello, se delimita una ventana de búsqueda a partir de las características de ECG, donde debería de encontrarse la onda T. La ventana se posiciona teniendo como referencia la posición de R, y su ancho variará dependiendo de la medida del actual intervalo R-R promedio. Los limites de la ventana se calculan de la siguiente manera:

- Posición de inicio de la ventana $\begin{cases} 140ms & \text{si } RR_m > 700ms \\ 100ms & \text{si } RR_m < 700ms \end{cases}$
- Posición de final de la ventana $\begin{cases} 500ms & \text{si } RR_m > 700ms \\ 0.7RR_{av}ms & \text{si } RR_m < 700ms \end{cases}$

Una vez enventanada la onda T, se consideran cuatro formas de onda posibles: Normal, invertida, descendente y ascendente (ver Figura 3.2).

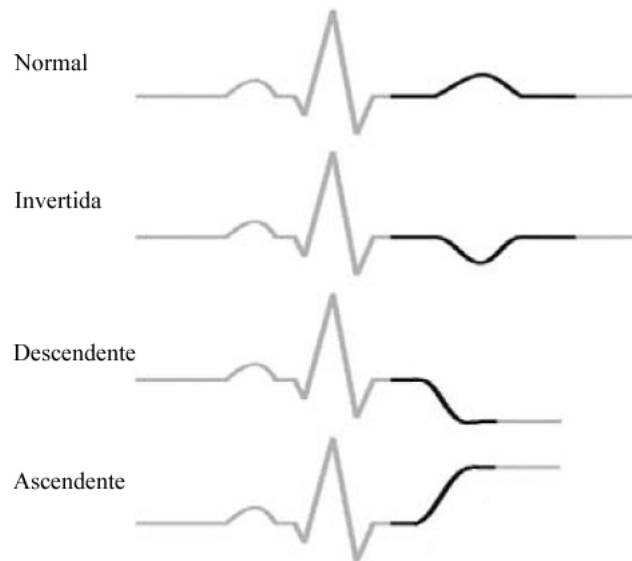


Figura 3.2: Las 4 morfologías posibles de la onda T consideradas por Laguna et al [1].

El objetivo de analizar las diferentes ondas T es encontrar el punto T_i (señalado en la Figura 3.4), que representa la última pendiente de la onda T. En la ventana de búsqueda se buscan dos módulos máximos, uno positivo y otro negativo nombrados como Max y Min respectivamente.

A partir de la posición de T_i se realiza una búsqueda hacia delante para encontrar el final de la onda T (T_{off}) que se le atribuirá a la primera muestra que quede por debajo (ó por encima si la forma de onda es invertida ó ascendente) de un umbral que se calcula de la siguiente manera:

$$T_h = \frac{\text{amplitud}(T_i)}{K^*}$$

*El valor de K se da al final de este apartado

Para localizar el pico de la onda T, se busca hacia atrás desde el punto T_i para encontrar el primer cruce por cero que correspondo a un máximo en la señal original (ver Figura 3.2).

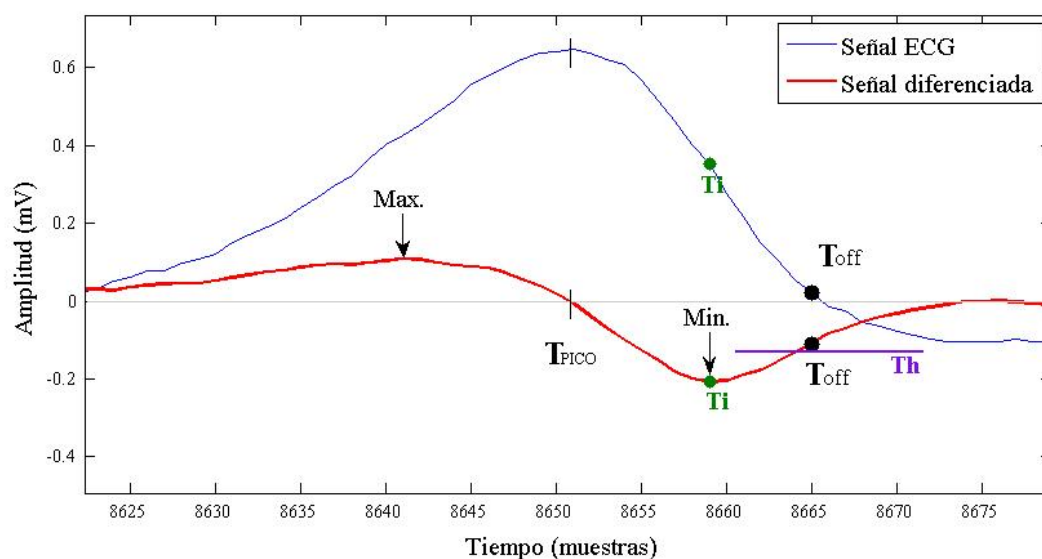


Figura 3.2: Determinación del pico y final de la onda T (T_{peak} y T_{off}) con una morfología "normal" mediante el método de umbralización.

El mismo proceso es implementado para señalar el principio de la onda T (T_{on}), marcando el punto T_i como el primer modulo máximo que representa la primera pendiente de la onda (en caso de que tuviese más de una) y desde ahí buscar hacia atrás el primer punto que sobrepase el umbral definido para dicho punto.

Por último, la segmentación de la onda P, se hace con una ventana de búsqueda donde su final se sitúa 225ms antes de la posición de la onda R, con una anchura de 155ms. Esta ventana se acorta cuando se presenta en ella la onda Q o T. Además, se tiene en cuenta la posible ausencia de la onda P, de tal manera que si los valores absolutos de amplitud dentro de la ventana de búsqueda no son mayores que el 2% del valor absoluto de la onda R del mismo latido, se considera que no existe onda P. Los puntos fiduciales de esta onda se encuentran siguiendo un procedimiento similar al establecido para la onda T.

El valor de K es una constante que fue experimentalmente ajustado. Consigue su mejor resultado de umbralización con los siguientes valores.

- K=2, para el principio de las ondas Q y T; y el final de P.
- K=3, para el final de la onda S y T.
- K=5, para el principio y final de R.

3.2 MARTÍNEZ [2]

En Martínez et al [2] se desarrolló un sistema sólido de segmentación basado en la transformada de wavelets y la umbralización adaptativa. Este sistema fue evaluado en las bases de datos estándares (QT database y CSE database) logrando unos resultados destacados (superando incluso algunos de los resultados de otros algoritmos de prestigio que había hasta entonces). Dichos resultados han sido hasta el día de hoy un referente para evaluar los algoritmos de segmentación.

3.2.1 FASE 1: TRANSFORMADA WAVELET DISCRETA (DWT)

Partiendo del hecho de que las señales de ECG no son estacionarias, en [2] se realiza un análisis no paramétrico para la extracción de información, el cual se lleva a cabo empleando la Transformada Wavelet, que permite la localización conjunta en los dominios de tiempo y frecuencia.

Esta es una herramienta adecuada para analizar la señal de ECG, que se caracteriza por una aparición cíclica de patrones con diferentes contenidos frecuencias (QRS, P y T). Además, el ruido y los artefactos que afectan a la señal de ECG también aparecen en bandas frecuenciales diferentes, contribuyendo así de diferente manera a las diversas escalas. Es por ello, que mediante la selección de las escalas adecuadas se puede evitar el ruido y los artefactos, no teniendo que hacer uso de un preprocesamiento o filtrado previo.

Antes de entrar de explicar la WT específica que se utiliza en el presente algoritmo, a continuación se realiza una introducción de las funciones wavelet y su relación con los bancos de filtros.

3.2.1.1 Introducción a la transformada wavelet (WT)

La transformada wavelet es una herramienta matemática que proporciona la descripción de la señal en términos de tiempo-frecuencia, permitiendo mostrar las características temporales de la señal a diferentes resoluciones en función a su contenido frecuencial. En la Figura 3.3 se puede apreciar un segmento de la señal ECG con sus correspondientes escalas de la transformada wavelet.




Figura 3.3: Las primeras cinco escalas de la TW de ondas simuladas de ECG [2]

Podemos definir la transformada wavelet Continua (CWT) ($W_a X(b)$) de la señal ($X(t)$), como la suma en el tiempo del producto de la señal por la versión escalada a y trasladada b de un prototipo de wavelet original $\Psi(t)$, tal y como se puede observar en la siguiente ecuación:

$$W_a X(b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt, a > 0$$

La función original $\Psi(t)$ sin trasladar ni escalar se la denomina la “wavelet madre” o “wavelet prototipo”. La función wavelet prototipo $\Psi(t)$ es una onda pequeña en el sentido de que tiene una duración limitada. Se describe mediante una función de oscilación que desciende rápidamente a cero, teniendo un valor promedio nulo y energía finita concentrada alrededor de un punto.

Si se desea centrar la función $\Psi(t)$ en un valor distinto a cero, se modifica el parámetro de traslación b al tiempo requerido. Por otra parte, si lo que interesa es ampliar o reducir el intervalo de tiempo en que la función tiene valores no nulos significativos, lo que se modifica es el factor de escala a . Contra mayor es el factor de escala a , más ancha es la función de la wavelet base, y en consecuencia, los coeficientes correspondientes proporcionan la información de los componentes de la señal a más bajas frecuencias, y viceversa. Esto ofrece una descripción en el dominio de tiempo/escala de la señal $X(t)$ con una mayor resolución temporal a altas frecuencias y mayor resolución frecuencial a frecuencias bajas. Para distinguir a la función trasladada y escalada de aquella original, se suele usar la notación $\Psi_{a,b}$ representada en la siguiente ecuación:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), a > 0.$$

A partir de las ideas generales de las funciones wavelet, su definición y el significado de la transformada wavelet continua, en la práctica se han desarrollado varios modelos, generalmente aplicados en su forma discreta. El algoritmo de Martínez et al [2] se lleva a cabo utilizando la Transformada Wavelet Discreta (DWT) con escalado diádico (uno de los modelos más recurrentes en la práctica).

Transformada Wavelet Discreta (DWT)

Para la obtención de la DWT, tanto el factor de escala a como el parámetro de traslación b , pueden ser discretizados. A efectos computacionales, no se realiza el cálculo de los coeficientes a todas las escalas. La manera de discretización común y elegida en éste algoritmo es la escala diádica en el plano tiempo-escala, donde los valores de a y b son: $a=2^k$ y $b=2^k l$ ($k \in \mathbb{N}, l \in \mathbb{Z}$). La transformada es llamada Transformada Wavelet Diádica, la cual posee la propiedad de ser invariante a las traslaciones, de tal manera que un desplazamiento en el tiempo de la función resultará un desplazamiento idéntico en los coeficientes de la wavelet (propiedad recomendada para propósitos de reconocimiento de patrones). La función base de esta manera queda de la siguiente forma:

$$\psi_{k,l}(t) = \frac{1}{\sqrt{2^k}} \psi\left(\frac{t - 2^k l}{2^k}\right); \quad (k,l) \in \mathbb{Z}^2$$

Y la DWT, entonces, se calcula:

$$W_x(s, \tau) = \frac{1}{\sqrt{2^k}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t - 2^k l}{2^k}\right) dt; \quad (k, l) \in \mathbb{Z}^2$$

Donde $W_x(s, \tau)$ son los coeficientes de la DWT en la escala s y en el desplazamiento del tiempo τ .

De acuerdo con el algoritmo de Mallat, para la señal de tiempo discreto, la transformada wavelet discreta diádica (DWT) es equivalente a un banco de filtros de octava, que puede ser implementado como una cascada de celdas idénticas de filtros FIR paso bajo y paso alto, seguido de un submuestreo, tal y como se puede ver representado en la Figura 3.4.

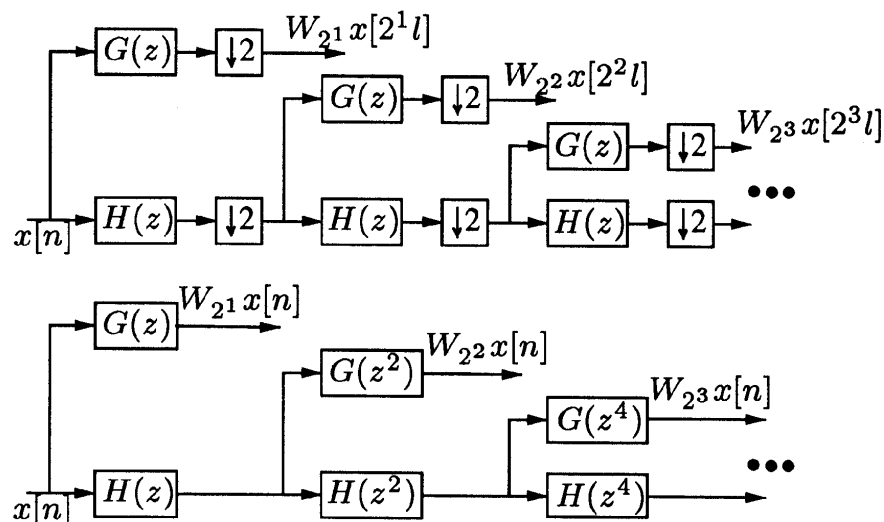


Figura 3.4: Implementación de dos bancos de filtros de la DWT. Algoritmo de Mallat (figura de arriba). Implementación sin decimar, algoritmo de à trous (figura de abajo).

Con ello se obtienen los coeficientes de la transformada $W_{2^k} x[2^k l]$ y los residuales paso bajo a partir de los que se puede reconstruir el banco de filtros. Donde $g(k)$ y $h(k)$ son funciones de respuesta al impulso de los filtros pasabajo y pasaalto asociados respectivamente. El

inconveniente que presenta esta transformada es que es invariante en el tiempo, es decir, la resolución temporal se reduce al incrementar la escala. Este efecto es evitado utilizando el algoritmo *à trous* que no realiza el submuestreo de la señal, ya que tan solo opera sobre ella mediante los correspondientes bancos de filtros, como se puede comprobar en la Figura 3.4. De esta manera se obtiene una representación redundante de la señal, pero la resolución temporal se mantiene igual a diferentes escalas.

Los filtros de esta transformada en niveles sucesivos son formados mediante la inserción de ceros entre los coeficientes originales del filtro. En particular, los filtros en el nivel j -ésimo se producen mediante la inserción de $2^{j-1} - 1$ zeros entre cada uno de los coeficientes. Este procedimiento es conocido comúnmente como el algoritmo *à trous*.

La respuesta en frecuencia de cada una de las escalas viene dada por la función wavelet prototipo utilizada, por lo tanto, es de extrema importancia que su elección atienda al contenido de frecuencias específicas de interés de la señal. Se puede demostrar que tomando como prototipo wavelet $\Psi(t)$ la derivada de la función de suavizado $\theta(t)$, la CWT de la señal $y(t)$ en la escala a es dado por:

$$W_a^y(b) = -a \left(\frac{d}{db} \right) \int_{-\infty}^{+\infty} x(t) \theta_a(t-b) dt,$$

Donde $\theta_a(t) = \frac{1}{\sqrt{a}} \theta\left(\frac{t}{a}\right)$ es la versión escalada de la función de suavizado.

Así, la transformada wavelet en la escala a es proporcional a la derivada de la versión filtrada de la señal con una respuesta al impulso suavizada en la escala a (ver Figura 3.5).




Figura 3.5 : wavelet prototipo $\Psi(t)$ y la función de suavizado $\theta(t)$

Con respecto a la segmentación automática de la señal ECG, esta propiedad es muy conveniente para el propósito de detección de las ondas ECG, que están compuestas de pendientes y máximos (mínimos) locales. Estas propiedades al igual que con la señal diferenciada de Laguna et al [1] son las siguientes:

- Los picos de la señal ECG corresponden al cruce por cero de la WT.
- Los pendientes en la señal ECG corresponden a máximos y mínimos en la WT.

El prototipo wavelet utilizada en este trabajo, que mantiene estas propiedades, es la spline cuadrática, originalmente propuesto en [85], cuya transformada de Fourier viene dado por:

$$\psi(\Omega) = j\Omega \left(\frac{\sin \frac{\Omega}{4}}{\frac{\Omega}{4}} \right)^4$$

Para el prototipo wavelet seleccionado los filtros $H(z)$ y $G(z)$ son de la siguiente forma:

$$H(e^{j\omega}) = e^{j\omega/2} \left(\cos \frac{\omega}{2} \right)^3$$

$$G(e^{j\omega}) = 4je^{j\omega/2} \left(\sin \frac{\omega}{2} \right)$$

Que son filtros FIR con respuesta al impulso:

- Banco de filtros paso bajo:

$$h[n] = \frac{1}{8} * \{\delta[n+2] + 3\delta[n+1] + 3\delta[n] + \delta[n-1]\}$$

$$h: \{h_{2M}, 0 \dots 0, h_M, 0 \dots 0, h_0, 0 \dots 0, h_{-M}\} = \left\{ \frac{1}{8}, 0 \dots 0, \frac{3}{8}, 0 \dots 0, \frac{3}{8}, 0 \dots 0, \frac{1}{8} \right\}$$

- Banco de filtros paso alto:

$$g[n] = 2 * \{\delta[n+1] - \delta[n]\}$$

$$g: \{g_M, 0 \dots 0, g_0\} = \{2, 0 \dots 0, -2\}$$

Dada esta wavelet prototipo, la información a evaluar lo determinan los máximos y mínimos locales y los cruces por cero en diferentes escalas. La detección de cada punto fiducial debe ser realizado en su escala adecuada, atendiendo a los componentes frecuenciales dominantes de cada onda de ECG. Las características de las ondas espectrales se presentan Figura 2.10 del “Capítulo 2” y si se comparan con la respuesta en frecuencia equivalente de varias escalas representadas en la Figura 3.6 se puede ver que:

- La mayor parte de la energía del ECG se encuentra en las escalas 2^1 a 2^5 .
- Para escalas mayores que 2^4 la energía del complejo QRS es muy bajo.
- Las ondas P y T producen componentes importantes en las escalas 2^4 y 2^5 .




Figura 3.6: Respuestas en frecuencia equivalentes a la DWT a las escalas $a = 2^m, m = 1, \dots, 5$ ($F_s = 250\text{Hz}$).

3.2.2 FASE 2: UMBRALIZACIÓN ADAPTATIVA

Para la segmentación del complejo QRS se utilizan principalmente las escalas 2^1 y 2^2 de la transformada wavelet. Primero, se detectan en la escala 2^2 , los dos módulos máximos de distinto signo que rodeen los puntos de referencia Pkn (pico de la onda R). Para que se consideren módulos máximos significativos, tienen que sobrepasar los umbrales: γQRS_{pre} y γQRS_{post} , donde,

$$\gamma QRS_{pre} = 0.06 \max(|W_{2^2}x[n]|) \text{ y}$$

$$\gamma QRS_{post} = 0.09 \max(|W_{2^2}x[n]|) \text{ (} n \in sw_{QRS} \text{)}$$

es decir, el máximo de la señal dentro de la ventana de búsqueda sw . De esta manera, el paso por cero entre estas curvas significativas en la escala 2^1 , son asignados a los picos de las ondas del complejo QRS, que serán etiquetados dependiendo del signo y de la secuencia lógica de los módulos máximos adyacentes. Para ello, se tiene en cuenta las posibles morfologías del complejo QRS, que puede estar compuesto por tres ó menos ondas. En este algoritmo, las morfologías a considerar son las siguientes: QRS, RSR', QR, RS, R y QS (ver Figura 3.7).

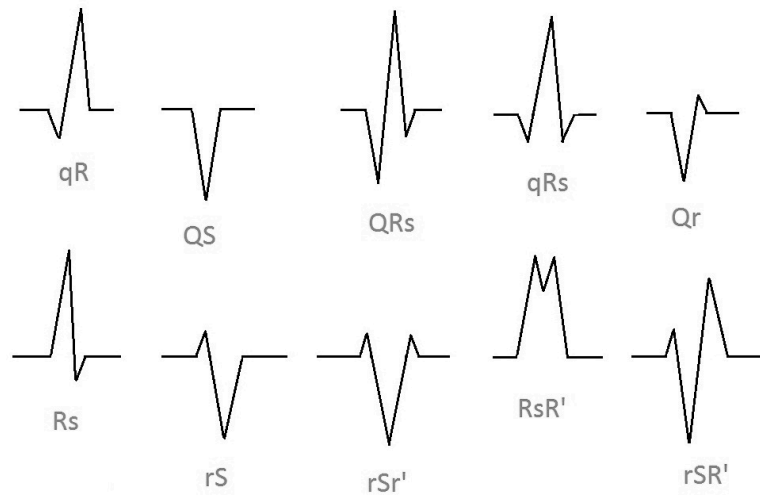


Figura 3.7: Distintas morfologías del complejo QRS

Además, el presente algoritmo incluye medidas de protección basados en reglas de intervalos y signos, para no confundir “notches” o deflexiones anormales con las ondas reales de la señal ECG.

Una vez identificado el primer y último modulo máximo en la escala 2^2 de la transformada wavelet, pertenecientes a la primera (n_{first}) y última (n_{last}) pendiente de la señal original ECG, se busca hacia atrás del primer modulo máximo en busca del fiducial QRson y hacia adelante del último modulo máximo en busca del fiducial QRsoff, siguiendo dos criterios:

1. Se busca la primera muestra que cruce el umbral ξ_{QRson} para el fiducial QRson y ξ_{QRsoff} para el fiducial QRsoff. Los umbrales son calculados tomando en cuenta la amplitud del modulo máximo n_{first} y n_{last} :

$$\xi_{QRson} = \begin{cases} 0.05 W_{2^2}x[n_{first}], & \text{si } W_{2^2}x[n_{first}] > 0 \\ 0.07 W_{2^2}x[n_{first}], & \text{si } W_{2^2}x[n_{first}] < 0 \end{cases}$$

$$\xi_{QRsoff} = \begin{cases} 0.125 W_{2^2}x[n_{last}], & \text{si } W_{2^2}x[n_{last}] > 0 \\ 0.71 W_{2^2}x[n_{last}], & \text{si } W_{2^2}x[n_{last}] < 0 \end{cases}$$

2. Se busca el modulo máximo anterior a n_{first} y posterior a n_{last} .

Finalmente, el fiducial, tanto QRSON como QRSoFF, serán el punto mas cercano al complejo QRS.

La onda T es primero detectada mediante una ventana de búsqueda, que es definida por cada latido en la escala 2^4 . La posición de la ventana deslizante es relativa a la posición del complejo QRS correspondiente y su tamaño depende del intervalo RR que es calculado de forma recursiva. (como no se especifica como se calcula la dicha ventana en este trabajo se ha utilizado la misma que en Laguna et al [1], explicada anteriormente)

Dentro de esta ventana se buscan los máximos locales, y si al menos dos de ellos tienen una amplitud superior al umbral ϵ_T , se considera que la onda T está presente.

$$\epsilon_T = 0.25RMS(W_{2^4}x[n]),$$

donde $RMS(W_{2^4}x[n])$ es calculado en cada intervalo entre dos complejos QRS consecutivos. Si la onda T está presente, los máximos locales de la WT en la escala 2^4 cuya amplitud supere el umbral γ_T , son considerados pendientes significativas de la onda, y el cruce por cero entre ellos como el pico de la onda T.

$$\gamma_T = 0.125max(W_{2^4}x[n]), \text{ (máximo de la señal en la ventana de búsqueda (sw)) } n \in sw_T$$

La onda T puede presentarse con diferentes morfologías. Martinez et al [2] considera las seis posibles formas que son: positiva (+), negativa (-), bifásica (+/-) ó (-/+), solo descendente y solo ascendente (ver Figura 3.8).

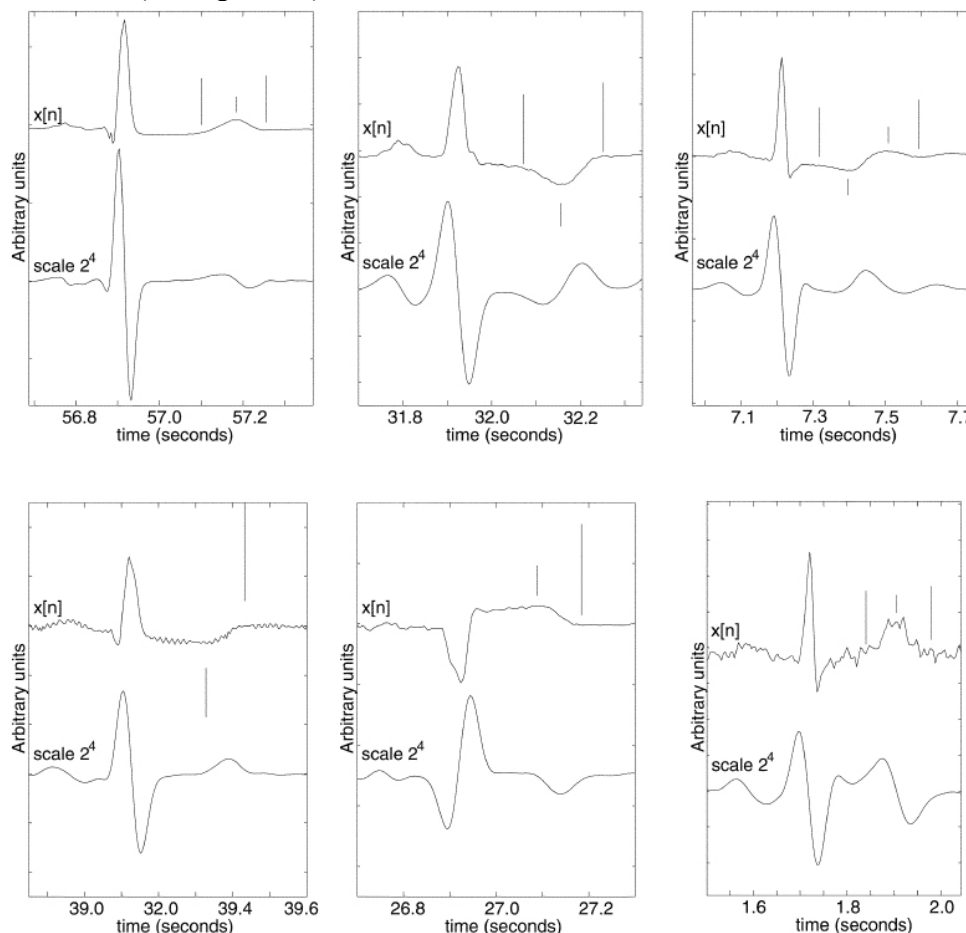


Figura 3.8: Diferentes morfologías de la onda T y su respectiva transformada en la escala 2^4 .

Dependiendo del número de módulos máximos significativos encontrados y sus polaridades, se le asignara una de las 6 morfologías a cada onda T. De ésta manera se identifican el primer y último modulo máximo (n_{first} y n_{last}) correspondientes a la primera y última pendiente de la onda T, para utilizarlos como punto de partida en la búsqueda de los limites de la onda T. Así, los fiduciales T_{on} y T_{off} son identificados aplicando el mismo criterio utilizado para la detección de QR_{on} y QR_{soff} pero con los umbrales ξ_{Ton} y ξ_{Toff} en la escala 2^4 .

$$\begin{aligned}\xi_{Ton} &= 0.25 W_{2^4}x[n_{first}] \\ \xi_{Toff} &= 0.4 W_{2^4}x[n_{last}]\end{aligned}$$

Si la onda T no es encontrada en la escala 2^4 , se repite en mismo proceso pero en una escala mayor 2^5 . Teniendo en cuenta la pérdida de resolución temporal, que es mayor a mayores escalas.

La segmentación de la onda P sigue los mismos pasos que la onda T, pero con distintos parámetros en cuanto a la ventana de búsqueda y los umbrales de decisión, ya que la posición y tamaño de las ondas T y P son distintas. Además, se consideran solo cuatro posibles formas de onda: positiva (+), negativa, y bifásica (+/-) ó (-/+).

En cuanto a la ventana de búsqueda, el algoritmo original utiliza una ventana dependiente de la distancia R-R lo cual es una decisión lógica, pero en su publicación no expone la manera en la que se realiza. En el algoritmo empleado para la evaluación de este trabajo, tras haber mirado el comportamiento de varias ondas P de la base de datos QT (QTDB), no se ha advertido ninguna lógica entre la distancia R-R y la posición o la longitud de la onda P. Por ello se ha optado por utilizar una ventana fija cuyo empuje se posiciona 90 muestras antes de la posición R y termina 25 muestras antes de la onda R, en señales con una frecuencia de muestreo de 250 Hz.

Los umbrales adaptativos necesarios para llevar a cabo la segmentación de la onda P son los siguientes:

$$\begin{aligned}\epsilon_P &= 0.02RMS(W_{2^4}x[n]) \\ \gamma_P &= 0.125max(W_{2^4}x[n]), n \in SW_P \\ \xi_{Pon} &= 0.5 W_{2^4}x[n_{first}] \\ \xi_{Poff} &= 0.9 W_{2^4}x[n_{last}]\end{aligned}$$

3.3 SINGH [3]

Singh et al [3] propone una nueva técnica para la segmentación de las ondas P y T basado en la derivada del tiempo y la umbralización adaptativa, utilizando diferentes técnicas para las distintas ondas (P y T). Para realizar la segmentación mediante esta técnica, es necesario obtener los fiduciales QRS_{on} y QRS_{off} , que pueden ser obtenidos a partir de algún algoritmo con resultados aceptables existentes en la literatura. En este trabajo dichos fiduciales han sido determinados mediante el algoritmo de Martinez et al [2] ya explicado anteriormente.

3.3.1 FASE 1: PRIMERA DERIVADA

Para la segmentación de la onda P se calcula la primera derivada, donde cada muestra de la forma de onda tiene en cuenta el efecto de sus muestras vecinas. El procedimiento del cálculo de la primera derivada es inspirada en Menard et al [86] adaptado más tarde por Friesen et al [232]. Este método no solo considera las estimaciones de la derivada en el tiempo, sino que también tiene en cuenta las estimaciones del ruido de alta frecuencia presente en el latido.

La primera derivada del ECG, $Y_n T$, en el instante de tiempo T , se calcula utilizando la ecuación de diferencia de tiempo mostrada en la siguiente ecuación:

$$Y_n T = -2x_{(n-2)T} - x_{(n-1)T} + x_{(n+1)T} + 2x_{(n+2)T}$$

Donde $X_n T$ representa las muestras de la señal de tamaño n en el instante de tiempo discreto T .

La segmentación de la onda T se realiza empleando el análisis derivativo de la curva. Para ello, se pasa un filtro paso bajo recursivo que corrige los patrones oscilatorios del potencial de referencia descrito en la siguiente ecuación:

$$Y_n T = 2y_{(n-1)T} - y_{(n-2)T} + x_n - 2x_{(n-4)T} + x_{(n-8)T}$$

3.3.2 FASE 2: NUEVO ENFOQUE DE LA UMBRALIZACIÓN (cálculo del desplazamiento vertical)

Con el fin de determinar segmentar la onda P, se ajusta una ventana de tiempo (ver Figura 3.9) antes del fiducial QRS_{on} . La ventana de tiempo es establecida heurísticamente y se extiende desde el principio del latido del corazón hasta el fiducial QRS_{on} . El principio del latido es determinado mediante la búsqueda de la primera muestra isoelectrica antes del inicio de la deflexión atrial.

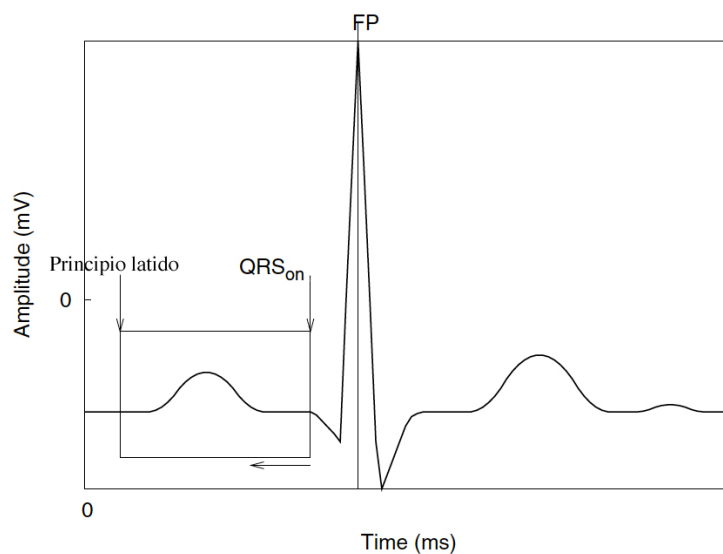


Figura 3.9: Ventana de búsqueda para la segmentación de la onda P

Una vez enventanada la onda P, se calcula el umbral de la pendiente (θ). Este es adaptado y establecido continuamente, mediante la siguiente función:

$$\theta = 0.30(\mu_{MS} - \mu_{HF_{noise}})$$

Donde, μ_{MS} es la media de las pendientes significativas mas recientemente detectadas y $\mu_{HF_{noise}}$ es la media del ruido de alta frecuencia presentes en los latidos detectados.

El nivel de ruido de alta frecuencia presente en cada latido, ha sido estimado mediante un filtro paso alto como el que se muestra a continuación:

$$Y'_{nT} = X_{nT} - 2X_{(n-1)T} + X_{(n-2)T}$$

El final de la onda P (P_{off}) se ubica en la muestra donde la transformada de la pendiente es más negativa. El pico de la onda P (P_{peak}) se identifica en el punto donde se realiza el cruce por cero de la señal de la pendiente (S_q). Este punto necesita un método de ajuste debido a la presencia de ruido de alta frecuencia. Para ello se busca la muestra vecina del cruce por cero que exceda HF_{noise} y es nombrado como S_p . Si la muestra de S_q y S_p es la misma, se considera dicho punto como el fiducial P_{pico} , si no, es considerado el punto P_{pico} como S_q . Una vez ubicado el pico de la onda, se busca hacia atrás (desde P_{peak} hasta el principio de la onda) el punto mínimo de la transformada de la pendiente que será identificado como el fiducial P_{on} . En la Figura 3.10 se muestra un ejemplo de la segmentación de la onda P.

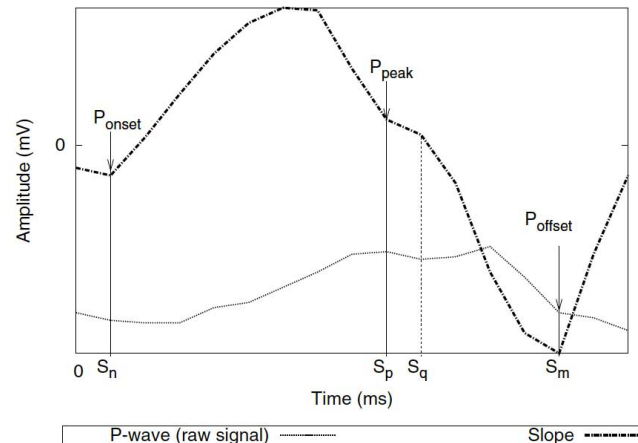


Figura 3.10: Segmentación de la onda P mediante el algoritmo de Singh et al [3]

En el caso de la onda T la ventana de búsqueda se extiende desde $QRS_{off}+80ms$, hasta $QRS_{off}+470ms$ ver Figura 3.11.

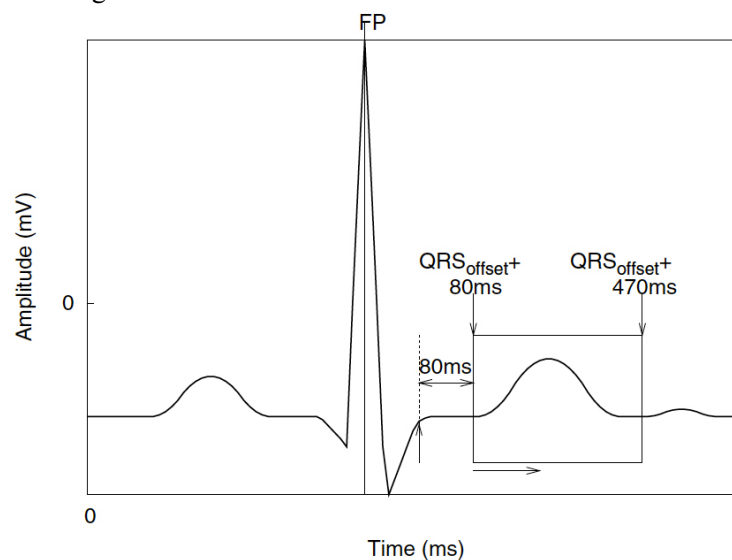


Figura 3.11: Ventana de búsqueda para la segmentación de la onda T [3].

El pico de la onda T (T_{peak}) se determina utilizando la derivada del tiempo y la técnica de la umbralización adaptativa, de forma similar a la determinación del pico de la onda P.

Para la determinación del final de la onda T (T_{off}), primero se busca en la señal derivada el punto de máxima amplitud dentro de la ventana de búsqueda denominado d_{peak} . Este punto representa el mayor cambio en la pendiente de la señal original. Una vez obtenido el punto d_{peak} , se establece el punto d_R al final de la ventana de búsqueda ($QRS_{off}+470ms$). A continuación se dibuja una línea recta (L_R) que va desde el punto d_{peak} hasta d_R asumiendo

que sus coordenadas son (x_{peak}, y_{peak}) y (x_R, y_R) respectivamente. La ecuación para trazar la línea L_R se formula de la siguiente manera:

$$L_R = y - y_{peak} = \Delta * (x - x_{peak})$$

$$\text{donde } \Delta = \frac{y_R - y_{peak}}{x_R - x_{peak}}$$

Por cada muestra del intervalo $[d_{peak}, d_R]$ se calcula la distancia vertical existente entre la amplitud de la señal derivada y la amplitud que tiene la línea L_R en la misma muestra. Digamos que d_i es la posición de alguna muestra en el intervalo $[d_{peak}, d_R]$, cuya coordenada es (x_i, y_i) . Entonces, el desplazamiento vertical, δ_i correspondiente a la muestra d_i , es calculada utilizando la siguiente formula:

$$\delta_i = |y_{peak} + \Delta * (x_i - x_{peak}) - y_i|$$

donde y_i es el desplazamiento vertical de la muestra correspondiente a la posición x_i de la señal derivada.

El objetivo es encontrar la posición en que la desviación vertical es máxima, ya que éste punto corresponde a la posición del fiducial T_{off} . Por lo tanto, se selecciona el máximo de δ_i , de la siguiente manera $\delta_{max}^R = \text{Max}(\delta_i)_{i=d_{peak}}^{i=d_R}$. La posición donde el desplazamiento vertical es máximo se le nombra d_k , y la muestra correspondiente a dicha posición es marcado como T_{off} en la señal original, tal como se muestra en la Figura 3.12. De la misma manera se puede determinar el fiducial T_{on} rastreando la señal hacia atrás desde d_{peak} .




Figura 3.12: Detección del fiducial T_{off} dentro de la ventana de búsqueda [3].

3.4 DI MARCO [4]

Di Marco et al [4] presentan un algoritmo avanzado de segmentación de la señal ECG en tiempo real basado en tan solo dos escalas de la transformada wavelet discreta y la técnica de la umbralización adaptativa.

3.4.1 FASE 1: TRANSFORMADA WAVELET DISCRTA

La teoría general de la transformada wavelet ya ha sido descrito en detalle anteriormente en la descripción de la Fase 1 del algoritmo de Martínez et al [2]. La diferencia aquí, es que Martínez et al [2] utiliza un grado 3 (con $r = 1$) dentro de la familia de funciones de spline, cuyo grado se expresa como $2r + 2$ para la función de suavizado $\theta(t)$, y el presente

algoritmo utiliza un valor de $r = 3$, es decir el 8.º grado. De esta manera, su transformada de Fourier es de la siguiente forma:

$$\Theta(\omega) = \left(\frac{\sin \frac{\omega}{4}}{\frac{\omega}{4}} \right)^8$$

y la transformada de Fourier de la función wavelet se calcula mediante la ecuación que se describe a continuación:

$$\Psi(\omega) = j\omega \left(\frac{\sin \frac{\omega}{4}}{\frac{\omega}{4}} \right)^8$$

A diferencia de la mayoría de los métodos de segmentación que utilizan la transformada DWT, donde para el cálculo de la función de suavizado (spline cuadrática) utilizan $r = 1$, en este método la razón de tomar un valor más alto de r ($r = 3$) es reducir la anchura del filtro paso banda equivalente a escalas mayores que 2^1 , así como la anchura de la función wavelet, para mejorar la separación entre las bandas de frecuencia a través de las escalas. El único inconveniente es que el número de derivaciones del filtro aumenta con r , por lo que se llega a un compromiso entre el esfuerzo computacional y el desempeño de la segmentación.

La Figura 3.13 muestra la función de suavizado $\theta(t)$ y la función wavelet $\psi(t)$ para $r = 1$ y $r = 3$, donde se pueden apreciar sus diferencias. La anchura del soporte de la función de suavizado disminuye a medida que aumenta r .




Figura 3.13: La función de suavizado a la izquierda y la función wavelet a la derecha, para $r = 1$ (línea discontinua) y $r = 3$ (línea sólida).

De esta manera, el filtro paso bajo H y el paso alto G se expresan como:

$$H(e^{j\omega}) = e^{j\frac{\omega}{2}} \left(\cos \frac{\omega}{2} \right)^7$$

$$h(n) = \frac{1}{8}d(n+2) + \frac{3}{8}d(n+1) + \frac{3}{8}d(n) + \frac{1}{8}d(n-1)$$

$$G(e^{j\omega}) = 4e^{j\frac{\omega}{2}} \sin \frac{\omega}{2}$$

$$g(n) = 2d(n+1) - 2d(n)]$$

La respuesta en frecuencia de los filtros equivalentes para las cuatro primeras escalas se muestra en la Figura 3.14, tanto para $r=1$ (función de suavizado spline cuadrático) como para

$r=3$ (octavo grado de la función de suavizado spline). Para cualquier escalada 2^k , el filtro paso banda se estrecha con el aumento de r , mejorando la separación de frecuencia del banco de filtros a través de las escalas.




Figura 3.14: Magnitud de respuesta en frecuencia equivalente del filtro. espectro de las diferentes escalas con los filtros equivalentes a $r=1$ (línea discontinua) y $r=3$ (línea solida). Con la frecuencia de muestreo de 250Hz.

La energía de las ondas principales que componen la señal ECG, es decir, el complejo QRS, ondas P y T, se encuentra dentro de un rango de frecuencias limitado. Como consecuencia, solo se va a necesitar un número limitado de escalas para la segmentación de la señal ECG. En este trabajo solo vamos a utilizar dos escalas 2^2 y 2^3 (ver Figura 3.15).




Figura 3.15: Señales utilizadas en este trabajo: Señal original ECG (en azul) y las dos escalas 2^2 (en verde) y 2^3 (en rojo) de la DWT.

Las propiedades generales de la DWT que ya han sido explicadas anteriormente, van a ser las mismas para este método. Por lo que los cruces por cero de la DWT corresponden a los máximos y mínimos locales de la señal original, y los valores máximos absolutos de la DWT corresponden a la máxima inclinación de la pendiente de la señal ECG.

El algoritmo propuesto en este trabajo está destinado a un procesamiento en tiempo real, por lo que si nos encontramos en cualquier tiempo discreto T_i , se supone que solo tenemos disponibles las muestras ECG anteriores $T_k \leq T_i$.

3.4.2 FASE 2: UMBRALIZACIÓN ADAPTATIVA EN PROCESAMIENTO A TIEMPO REAL

La umbralización adaptativa es similar en todas las aplicaciones. La diferencia en este caso es que se realiza en tiempo real y emplea diferentes umbrales de decisión, así como diferentes ventanas de búsqueda. En este apartado se describe por encima estas diferencias respecto a la umbralización descrita en algoritmos anteriores.

El algoritmo comienza con la detección del complejo QRS como en la mayoría de los métodos de segmentación. A continuación se realiza la búsqueda para el fiducial QRS_{on} , empezando por la posición de n_{pre} , que representa el modulo máximo que precede el cruce por cero de Rp (onda R) en la escala 2^2 (ver Figura 3.16).

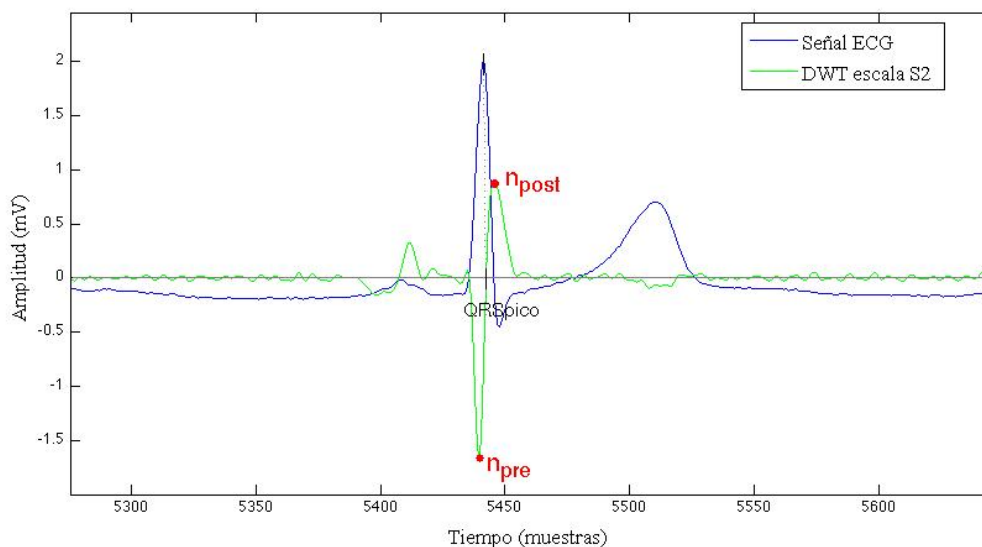


Figura 3.16: Representación de los módulos máximos pertenecientes al complejo QRS (n_{pre} y n_{post}).

Para la identificación de QRS_{on} se busca hacia atrás dentro de una ventana fija de 120 ms que precede a n_{pre} y guardar la primera muestra que cruza el umbral $\mathcal{E}^2 Q_{onI}$.

$$\mathcal{E}^2 Q_{onI} = \frac{S_{n_{pre}}^2 + S_{n_{post}}^2}{32}$$

La búsqueda continua hasta detectar un modulo máximo cuya amplitud es mayor que el umbral $\mathcal{E}^2 Q_{onII}$ o hasta llegar al final de la ventana de búsqueda.

$$\mathcal{E}^2 Q_{onII} = \frac{S_{n_{pre}}^2 + S_{n_{post}}^2}{16}$$

Si se verifica dicha propiedad, el modulo máximo encontrado es nombrado como n_{left} y se define un nuevo umbral, $\mathcal{E}^2 Q_{onIII}$. El algoritmo busca hacia atrás desde n_{left} hasta la primera muestra que cruza el umbral $\mathcal{E}^2 Q_{onIII}$ o llega hasta el final de la ventana de búsqueda.

$$\mathcal{E}^2 Q_{onIII} = \frac{S_{n_{left}}^2}{4}$$

Si existe este último punto, dicha muestra es nombrada como QRS_{on} . Si bien no se encuentra ningún modulo máximo dentro de la ventana de búsqueda mayor que $\mathcal{E}^2 Q_{onII}$ o se ha llegado hasta el final de la ventana sin encontrar el punto que cruza $\mathcal{E}^2 Q_{onIII}$, el fiducial QRS_{on} será asignado a la primera muestra que pasa por $\mathcal{E}^2 Q_{onI}$, guardado anteriormente.

Se adopta un criterio simétrico para la identificación del fiducial QRS_{off} , rastreando hacia delante de la posición n_{post} (ver figura xx(anterior)) o si existe, hacia delante del modulo máximo significativo a la derecha de n_{post} , nombrado como n_{right} . En este caso, los 3 umbrales empleados son los siguientes:

$$\begin{aligned}\mathcal{E}^2 Q_{off} I &= \frac{S_{n_{post}}^2}{4} \\ \mathcal{E}^2 Q_{off} II &= \frac{S_{n_{post}}^2}{8} \\ \mathcal{E}^2 Q_{off} III &= \frac{S_{n_{right}}^2}{4}\end{aligned}$$

La segmentación de las ondas P y T se realiza en la escala 2^3 de la DWT, donde es necesario haber obtenido de antemano los fiduciales QRS_{on} y QRS_{off} como posición de referencia.

En primer lugar se precede a segmentar la onda P para la que son consideradas las posibles morfologías mono- y bifásicas. Se establece una ventana de búsqueda en la escala 2^3 , cuyo final se establece en el fiducial QRS_{on} y el principio es elegido dependiendo de la siguiente condición:

$$\begin{aligned}\text{si } \frac{1}{2} RR < 300ms &\Rightarrow QRS_{on} - \frac{1}{2} RR \text{ (principio de la ventana)} \\ \text{si } \frac{1}{2} RR > 300ms &\Rightarrow QRS_{on} - 300ms \text{ (principio de la ventana)}\end{aligned}$$

Dentro de esta ventana se guardan todos los cruces por cero (n_z). Los cruces por cero se buscan en una subporción de la ventana, donde se excluye los primeros 100ms los cuales son usados solo para la determinación del Pon.

Cada vez que se detecta un cruce por cero, se determinan el par de módulos máximos adyacentes, n_{pre} y n_{post} , y sus amplitudes globales $AMM_{p(n_z)}$ asociadas, definidas como la diferencia entre el máximo positivo y el mínimo negativo. El cruce por cero (n_z) que tenga asociado el valor máximo de amplitud $AMM_{p(n_z)}$ es marcado como el pico dominante de P.

Para determinar si la onda P tiene una morfología bifásica o monofásica, se prueba una condición específica:

$$\frac{1}{2} |S^3_{n_{post}}| \leq |S^3_{n_{pre}}| \leq 2 |S^3_{n_{post}}|$$

Si esta condición se verifica, y el cruce por cero n^L_z precedente a n_z está a una distancia menor que 100ms, la siguiente condición es también comprobada:

$$A_{MMp(n^L_z)} > \frac{3}{4} A_{MMp(n_z)}$$

Si se verifican las dos condiciones, la onda P es considerada bifásica y la referencia n_{pre} es entonces asignada a la muestra correspondiente al modulo máximo más a la izquierda de n^L_z . Si las condiciones anteriores no se verifican la onda P es considerada monofásica y la posición de n_{pre} se deja sin modificar. Este punto de referencia (n_{pre}) es el punto de partida para la búsqueda hacia atrás de P_{on} , que se asigna a la primera muestra que cruce el umbral $\mathcal{E}^3 P_{on}$.

$$\mathcal{E}^3 P_{on} = \frac{S^3_{n_{pre}}}{4}$$

La identificación del fiducial P_{off} sigue el mismo procedimiento que P_{on} buscando hacia

delante desde el punto n_{post} , considerando la posibilidad de encontrar n^R_z (cure por cero siguiente a n_z a una distancia menor que 100ms), y utilizando, en este caso, el umbral $\mathcal{E}^3 P_{off}$.

$$\mathcal{E}^3 P_{off} = \frac{35S_{n_{post}}^3}{64}$$

En cuanto a la segmentación de la onda T, se consideran seis posibles morfologías las mismas que en Martínez et al [32]. Por cada complejo QRS identificado, se segmenta la onda T del latido anterior. Su búsqueda se realiza a lo largo de una ventana fija cuyos límites son los siguientes:

$$W_T = \left\{ n_{QRSoff(i-1)} + 80ms, n_{QRSoff(i-1)} + \frac{19RR}{32} \right\}$$

Primero se busca el pico dominante de la onda T en una subventana:

$$W_{Tp} = \left\{ n_{QRSoff(i-1)} + 80ms, n_{QRSoff(i-1)} + \frac{RR}{2} \right\}$$

Todos los cruces por cero encontrados en dicha ventana son guardados y por cada uno se calcula el valor de $A_{MM}(n_z)$ (valor absoluto de la diferencia entre n_{pre} y n_{post}). Se etiqueta como n_z al cruce por cero que corresponda al mayor valor de $A_{MM}(n_z)$. Si existe un cruce por cero n^L_z a la izquierda de n_z que cumpla la siguiente condición:

$$A_{MM}(n^L_z) > \frac{51}{64} A_{MM}(n_z)$$

Entonces se considera que la onda T es bifásica, cuyo pico dominante es n^L_z . El modulo máximo a la izquierda de n^L_z es nombrado como n_{pre} . Si no existe n^L_z o no es verificado, n_z se mantendrá como P_{pico} y n_{pre} como el modulo máximo anterior a n_z . El fiducial T_{on} es determinado de acuerdo al umbral $\mathcal{E}^3 T_{on}$.

$$\mathcal{E}^3 T_{on} = \frac{S_{n_{pre}}^3}{4}$$

Mirando hacia la derecha de n_z se comprueba si existe un cruce por cero significativo n^R_z que cumpla el siguiente criterio:

$$A_{MM}(n^R_z) \geq \frac{1}{2} A_{MM}(n_z)$$

Si es así, n_{post} será asignado al modulo máximo a la derecha de n^R_z , de lo contrario será el modulo máximo a la derecha de n_z . En ambos casos el final de la onda T (T_{off}) será asignada a la primera muestra que cruce la el umbral $\mathcal{E}^3 T_{off}$.

$$\mathcal{E}^3 T_{off} = \frac{19S_{n_{post}}^3}{64}$$

3.5 SUN [5]

Sun et al [5] desarrollaron una nueva técnica basada en la transformada de la derivada morfológica multiescala (MMD, por las siglas en Inglés Multi-scale Morphological Derivate) para la detección de los puntos fiduciales de las ondas características de ECG. En la primera fase del algoritmo, sustituye la derivada convencional de la señal por la derivada morfológica multiescalada. En la segunda fase, se establecen ventanas de búsqueda en la señal transformada (MMD) y se calcula en ellas el histograma para obtener los valores de los

umbrales decisivos. Es por ello, que este método ofrece un proceso menos heurístico que la que ofrece la umbralización adaptativa común.

3.5.1 FASE 1: DERIVADA MORFOLÓGICA MULTIESCALA (MMD)

En esta primera fase, a la señal ECG original de entrada se le aplican tres funciones morfológicas. La primera para corregir la línea base, la segunda para reducir el ruido de la señal, y por último, con el resultado obtenido, se calcula la derivada morfológica multiescala.

Todo éste proceso es realizado mediante el uso de las operaciones fundamentales morfológicas de dilatación \oplus , erosión \ominus , apertura \circ y cierre \bullet , donde estas dos últimas operaciones morfológicas (apertura y cierre), no son más que una combinación de las dos primeras (dilatación y erosión).

Concretamente, la dilatación es una operación de expansión mientras que la erosión es una operación de estrechamiento. La apertura se realiza mediante la erosión de una función f por un elemento estructurante B seguida de la dilatación del resultado por el mismo elemento estructurante B . Ésta operación es usada para suprimir los picos de la señal. Por el contrario, el cierre, se calcula mediante la dilatación de una función f por un elemento estructurante B seguida de la erosión del resultado, y es usado para suprimir los valles de la señal. Las ecuaciones de la apertura y cierre de una función f por un elemento estructurante B , se expresan mediante las siguientes:

$$\begin{aligned} f \circ B &= (f \ominus B) \oplus B && \text{(apertura)} \\ f \bullet B &= (f \oplus B) \ominus B && \text{(cierre)} \end{aligned}$$

Un procedimiento más detallado para la obtención de la transformada MMD, es descrita a continuación.

Primero se realiza la corrección de la deriva de la línea base. Para ello, se estima la deriva de la línea de base f_b , que tiene la señal de entrada f_o mediante la ecuación:

$$f_b = f_o \circ B_o \bullet B_c = (((f_o \ominus B_o) \oplus B_o) \oplus B_c) \ominus B_c$$

En toda operación morfológica, es necesaria la definición previa del tamaño y forma del conjunto llamado elemento estructurante. En este caso se utilizan los elementos estructurantes B_o y B_c , que son definidos como dos segmentos de línea horizontal de amplitud zero de distintas longitudes. La longitud de B_c , debe de ser mayor que B_o y este último mas largo que $T_W F_S$, donde T_W es la anchura de la onda característica. Concretamente, en este trabajo, B_o es un vector de ceros de longitud 50 y B_c de longitud 75.

Como se puede observar en la ecuación anterior, la primera operación es la erosión $f_o \ominus B_o$. Gracias a que el elemento estructurante B_o es un segmento horizontal compuesto por ceros, la erosión puede ser implementada como una simple búsqueda del mínimo valor dentro de la ventana definida por el elemento estructurante (ventana de 50 muestras) que irá avanzando muestra por muestra. La función resultante será una señal donde se han guardado todos los mínimos de cada substracción de 50 muestras de la señal f_o .

Si al resultado obtenido mediante la primera operación de erosión es nombrado f_1 , la segunda operación es una dilatación cuya operación es $f_1 \oplus B_o$. Esta operación utiliza el mismo elemento estructurante B_o , que al ser una línea horizontal de ceros, puede ser implementado como una búsqueda del máximo valor de f_1 dentro de la ventana de

longitud 50. El resultado en este punto será el resultado de la operación de la apertura $f_o \circ B_o$.

La siguiente operación es un cierre compuesto de una dilatación seguido de una erosión, que usa como señal de entrada el resultado previo de la apertura y utiliza un elemento estructural B_c (vector horizontal de 75 ceros). Después de este cierre obtenemos la derivación de la línea base f_b para ser sustraído de la señal original de ECG nombrada como f_o y obtener la señal con la corrección de la línea de base f_{bc} .

$$f_{bc} = f_o - f_b$$

A continuación, se procede a eliminar el ruido de la señal, que parte del resultado f_{bc} y se realiza la siguiente operación:

$$f = \frac{1}{2} (f_{bc} \oplus B \ominus B + f_{bc} \ominus B \oplus B)$$

En este caso el elemento estructurante B es un vector horizontal de cinco ceros. La señal filtrada final puede apreciarse en la Figura 3.17, donde f es la señal tras el preprocesado.




Figura 3.17: Ejemplo filtrado morfológico, señal ECG con la deriva de la línea de base corregida (verde), señal preprocesada (rojo).

Por último, se realiza la transformada morfológica multiescala M_f , sobre la señal de entrada f corregida. Para ello se calcula su derivada morfológica en la escala S_m .

$$M_f^{ds}(x) = \frac{\max\{f(t)\}_{t \in [x-s, x+s]} + \min\{f(t)\}_{t \in [x-s, x+s]} - 2f(x)}{s}$$

Con el fin de no aplanar las características de las ondas del ECG, S_m debe de ser lo mas alto posible, pero menor que $W_w \cdot f_s$, donde W_w representa la anchura de la onda característica y f_s la frecuencia de muestreo.

La señal transformada finalmente es de la forma que se muestra en la Figura 3.18.




Figura 3.18: Ejemplo de la transformada de la derivada morfológica multiescala (MMD)

Mediante esta transformada (MMD), los puntos fiduciales quedan resaltados, ya que son representados mediante máximos y mínimos locales. Se sabe que contra mayor sea la escala, el número de máximos y mínimos es mucho menor que en escalas menores. Además, el ruido de alta frecuencia decae en gran medida a escalas mayores, de modo que la señal presenta menos ruido extremo. Para este trabajo, la señal transformada mediante la derivada morfológica fue utilizada con la mayor escala posible, pero menor que $W_w \cdot f_s$.

3.5.2 FASE 2: UMBRALIZACIÓN ADAPTATIVA (ajustado mediante el histograma MMD)

La segmentación se realiza mediante la detección de máximos y mínimos locales significativos de la transformada MMD. Una pendiente positiva en la señal ECG, es representada en la transformada MMD como una onda positiva a su izquierda y una negativa a su derecha. Por ello los picos positivos en la señal ECG corresponden a mínimos locales en la M_f^{ds} . En el principio o final de una onda en la señal ECG, provoca un aumento brusco en el valor de la transformada. Por lo tanto, los inicios y los finales de las ondas corresponden a los máximos o mínimos locales en la señal M_f^{ds} , dependiendo de la polaridad de la onda.

Los máximos y mínimos locales significativos son aquellos que tengan una amplitud absoluta mayor que el umbral Thf , en la escala seleccionada. El umbral adaptativo Thf es calculado mediante el histograma de la transformada MMD en la ventana de búsqueda. El valle de entre dos picos consecutivos del histograma da lugar al valor del umbral.

Por cada pico R detectado, el primer máximo local a la izquierda es considerado como el comienzo de la onda R y el máximo local a la derecha como el final. El primer mínimo local a la izquierda de la onda R positiva es detectado como la onda Q. Si este mínimo local no es detectado en los primeros 120ms a la izquierda de R, se considera que no existe dicha onda. El mismo principio se aplica para la onda S, que es asociada al primer mínimo local a la derecha de la onda R positiva.

Los siguientes dos máximos locales consecutivos a la izquierda de la onda Q, son asociados al final y al principio de la onda P. De la misma manera, el primer y segundo máximo local a la derecha de la onda Q, son determinados como el principio y el final de la onda T, respectivamente.

Sun et al [5] no menciona el uso de ventanas de búsqueda para las ondas P y T. En este trabajo al realizar este algoritmo se ha optado utilizar una ventana de búsqueda basada en del algoritmo que Di Marco et al (4) explicada en el anterior apartado, tanto para la onda T como para la onda P.

3.6 MARTÍNEZ [6]

Este algoritmo presenta un nuevo método de segmentación ECG basada en la transformación fasorial (PT, phasor transform). El método es caracterizado por su bajo coste computacional y simplicidad matemática, además de su robustez.

3.6.1 FASE 1: TRANSFORMADA FASORIAL (PT)

La transformada fasorial de la señal ECG se obtiene convirtiendo cada muestra instantánea de la señal, en un fasor simple, que maximiza las diferentes ondas de la señal. La PT es una herramienta sencilla que puede representar una función sinusoidal en el dominio complejo. El resultado es un número complejo, llamado fasor, que conserva la información de la señal con respecto a los valores de la fase y la media cuadrática.

Una señal sinusoidal genérica discreta puede representarse como:

$$x[n] = A \cos(\omega n + \varphi) = \Re\{Ae^{j(\omega n + \varphi)}\}$$

donde A es la amplitud y φ la fase de la sinusoidal. Su PT proporcionaría un fasor de rotación en el plano complejo con una magnitud A , velocidad de rotación ω y una fase inicial φ , es decir, la PT de la señal sinusoidal discreta se representaría mediante la ecuación:

$$PT\{x[n]\} = Ae^{j\varphi} = A \cos(\varphi) + jA \sin(\varphi)$$

En este trabajo, se considera al valor constante R_v como parte real y a la señal original de ECG, representada mediante $x[n]$, como parte imaginaria del componente fasorial. De este modo el fasorial $y[n]$ puede ser definido para cada muestra discreta como:

$$y[n] = R_v + j x[n]$$

La magnitud $M[n]$ y la fase $\varphi[n]$ del fasorial es calculado mediante las ecuaciones siguientes:

$$M[n] = \sqrt{R_v^2 + x[n]^2}$$

$$\varphi[n] = \tan^{-1} \left(\frac{x[n]}{R_v} \right)$$

El valor de R_v determina el grado de aumento de las ondas de ECG en la señal fasorial, de manera que, a menor R_v , mayor es la diferencia entre las variaciones de la fase. Las ondas características del ECG se detectan mediante la aplicación directa de la PT, con un valor de $R_v = 0.001$, al valor absoluto del ECG original $|x[n]|$, al que se le ha eliminado previamente la deriva de la línea de base, mediante un filtro paso alto con una frecuencia de corte de 0.5 Hz.

En la Figura 3.19, se muestra un ejemplo de un latido de la señal ECG ($x[n]$), donde se puede observar la notable baja amplitud de las ondas P y T, junto con su

transformada fasorial $\varphi[n]$ correspondiente, en la cual las ondas P y T están considerablemente amplificadas.




Figura 3.19: Señal ECG de entrada, en la figura de arriba, $x[n]$ y su correspondiente transformada fasorial $\varphi[n]$, debajo[6].

3.6.2 FASE 2: UMBRALIZACIÓN ADAPTATIVA

Una vez que la onda R es detectada, se establecen los umbrales γ_{QRS_-} y γ_{QRS_+} a su alrededor. Estos umbrales son definidos como los puntos más cercanos a la onda R, en el que $\varphi[n]$ es menor que el 25% de su máxima variación de fase ($\pi/2$). Se establece una ventana de 35ms anterior al umbral γ_{QRS_-} para buscar la onda Q y otra posterior a γ_{QRS_+} en busca de la onda S. Si en dichas ventanas no se encuentran las ondas Q y/o S, los umbrales γ_{QRS_-} y γ_{QRS_+} representarán los fiduciales QRS_{on} y QRS_{off} . Si de lo contrario las ondas Q y/o S son detectadas, un nuevo umbral adaptativo en función a la amplitud de la onda es establecido y se busca la primera muestra por debajo de dicho umbral para etiquetarlo como QRS_{on} y QRS_{off} .

Con el fin de detectar y segmentar la onda P se establece una ventana de búsqueda con respecto a la posición de QRS_{on} detectado anteriormente. Su anchura se adapta en cada latido, siendo la cuarta parte de la distancia entre el pico del actual pico de R y el anterior. (En este trabajo en vez de utilizar la cuarta parte los resultados mejoraban utilizando la tercera parte).

Dentro de esta ventana, se elimina la media del segmento ECG y se aplica la PT con la constante $R_v = 0.003$. Se ubica el máximo local de $\varphi[n]$ y se corrobora su coherencia con el pico de la onda. Para este propósito, se comprueba que las muestras anteriores y siguientes presentan una magnitud $M[n]$ menor que la muestra seleccionada. En el caso afirmativo, la muestra es anotada como el valor máximo de la onda P (P_{peak}). De lo contrario, se reduce el ancho de la onda, ya que es posible que la ventana abarque parte de la onda T del latido anterior. Este proceso es repetido interactivamente, hasta detectar el pico de la onda P. Finalmente, si la amplitud de la onda detectada es menor que el 5% de la amplitud de la onda R, se considera que la onda P está ausente.

El pico de la onda P sirve de referencia para determinar el principio y el final de dicha onda. Para ello, se establece una ventana de 15ms relativa P_{peak} antes y después de este punto. Se elimina la media al segmento ECG dentro de estas ventanas y se calcula su PT con un valor de $R_v = 0.005$. Después se calcula la primera derivada de $\varphi[n]$ con el fin de localizar la transición de la fase desde su mínimo a su máximo (ver Figura 3.20). Para identificar P_{on} y P_{off} se busca el cruce por cero representativo en la señal derivada $\varphi'[n]$. Si estos puntos no son detectados se repite el mismo proceso con un valor de R_v menor hasta encontrar ambos límites.




Figura 3.20: Representación de la señal fasorial, $\varphi[n]$, y su correspondiente derivada $\varphi'[n]$, usada para determinar el principio y el final de las ondas P y T [6].

La detección y segmentación de la onda T se lleva a cabo con un proceso similar a la descrita para la onda P. En este caso establece una ventana de búsqueda de mayor longitud, 25ms. Además, dado que la onda T por lo general presenta una amplitud mayor que la onda P, se requiere una amplificación menor, por lo que se utiliza un valor de $R_v = 0.1$.

3.7 VÁZQUEZ [7]

Aquí se propone un nuevo enfoque para la localización del final de la onda T, como alternativa a las umbralizaciones adaptativas populares. Este nuevo método está basado en el cálculo sucesivo del área del trapecio rectangular formado a partir de las muestras de la señal ECG al final de la onda T, concretamente a partir del punto T_{peak} . Para la búsqueda del fiducial T_{off} , Vázquez et al [7] recomiendan aplicar la primera derivada, después de haber filtrado la señal ECG original mediante un filtro paso banda. En éste trabajo se ha aplicado este nuevo enfoque para determinar además, el principio de la onda T y los límites de la onda P.

Es conveniente aclarar que Vázquez et al [7], solo tienen en cuenta la detección del fiducial T_{off} , partiendo de que ya se tiene detectado el pico de la onda T. Los autores de éste método, proponen utilizar cualquier algoritmo de la literatura que proporcione unos resultados aceptables. Para la realización de este trabajo, se ha utilizado el método de la umbralización adaptativa propuesto por Martínez et al [2], pero aplicando a la primera derivada en vez de las diferentes escalas de la DWT, con el fin de obtener los fiduciales QRS_{on} , QRS_{off} , P_{peak} y T_{peak} . De esta manera, se puede comparar la DWT frente a la señal derivada, en la identificación de dichos fiduciales.

Finalmente, se aplica el método propuesto por Vázquez et al [7] para determinar el final de la onda T, así como el principio de la misma y los límites de la onda P.

3.7.1 FASE 1: PRIMERA DERIVADA

La señal ECG es primero filtrada mediante dos filtros Butterworth de 4.º orden. Éstos son un filtro paso alto con una frecuencia de corte de 0.5 Hz, utilizado para corregir la línea base y

un filtro paso bajo con una frecuencia de corte de 30 Hz, para reducir el ruido de la señal. Una vez filtrada la señal ECG, se calcula la primera derivada de esta señal. En la Figura 3.21 se puede observar la señal ECG original y el resultado correspondiente de la transformada realizada en esta primera fase, para su posterior segmentación.




Figura 3.21: Señal ECG de entrada (en azul) y la primera derivada de la misma (en verde).

3.7.2 FASE 2: AREA DEL TRAPEZIO RECTANGULAR

Tal y como se ha mencionado anteriormente, los fiduciales QRS_{on} , QRS_{off} , P_{peak} y T_{peak} son determinados mediante la umbralización adaptativa propuesta por Martínez et al [2], pero en la señal descrita en esta Fase 1 en vez de en las distintas escalas de la DWT.

Los fiduciales restantes son establecidos mediante el método propuesto por Vázquez et al [7]. Éste método está basado en el cálculo sucesivo de las áreas de un trapecio rectangular, formado por tres vértices fijos y uno móvil (x_i, y_i), que se desplaza a través de la señal, desde (x_m, y_m) hasta (x_r, y_r) , mientras se calcula el área total en cada desplazamiento. Finalmente, el límite de la onda es designado a la muestra donde el área (A) del trapecio es máxima (ver Figura 3.22).

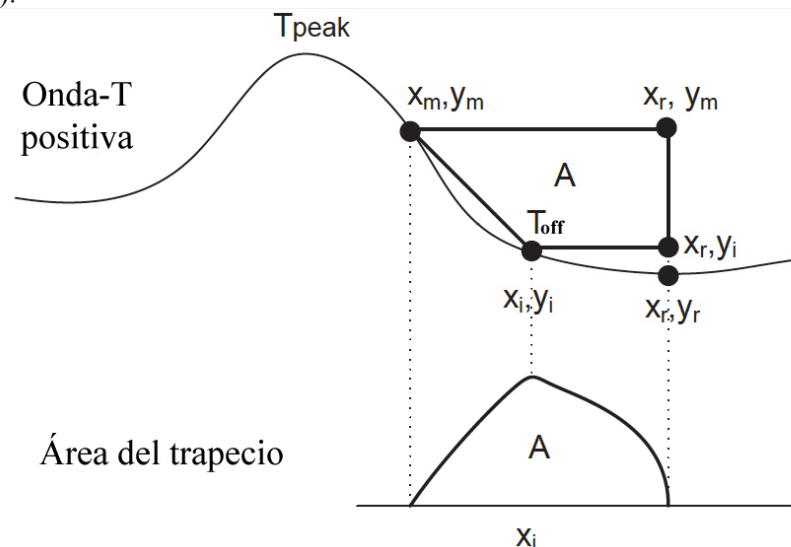


Figura 3.22: Determinación del final la onda T, mediante el cálculo del área de varios trapecios rectangulares formados por tres puntos fijos y uno móvil (x_i, y_i).

La fórmula para el cálculo del área de dicho trapecio es:

$$A = 0.5(y_m - y_i)(2x_r - x_i - x_m)$$

Los vértices que componen el trapecio utilizados por ejemplo para el cálculo del final de la onda T son:

- (x_m, y_m) : Es el máximo local en la señal derivada a la derecha del fiducial T_{peak} que representa la última pendiente de la señal ECG original. El valor de la derivada en este punto es un mínimo negativo para las ondas T positiva y un máximo positivo para las ondas T negativas.
- (x_r, y_r) : Es el punto de referencia situado en el segmento isoelectrico T-P. Su localización exacta no es de gran importancia, siempre y cuando se ubique más lejos que el final de la onda T y su valor sea cercano a cero.
- (x_i, y_i) : Es el punto móvil que se desplaza muestra a muestra entre los dos puntos descritos anteriormente.

Además del fiducial T_{off} , propuesto por Vázquez et al [7], éste principio es utilizado para determinar los fiduciales T_{on} , P_{on} y P_{off} .

3.8 VÍTEK [8]

El algoritmo de Vitek [8] es un método rápido y sencillo de segmentación ECG basado en la transformada wavelet continua (CWT). Para su mayor eficacia, este algoritmo primero calcula la CWT para la segmentación del complejo QRS en la escala acorde a la frecuencia fundamental del complejo. Los fiduciales de las ondas características del ECG son determinados aplicando la umbralización adaptativa en la escala CWT correspondiente.

3.8.1 FASE 1: TRANSFORMADA WAVELET CONTINUA (CWT)

La señal de ECG es transformada mediante la transformada wavelet continua. Como ya se ha explicado antes, las diferentes escalas de la transformada wavelet, describen las características del tiempo de una señal a diferentes bandas de frecuencia. Mientras que la transformada wavelet diádica (DWT) utilizada hasta ahora, se limita a las escalas que son potencia de dos, la CWT puede ser evaluada en cualquier escala real positiva. Mediante la selección de la escala óptima, la influencia de los ruidos, los artefactos y la deriva de la línea base puede ser minimizada.

La CWT es una señal de tiempo continuo $x(t)$ definida mediante la integral:

$$CWT(b, a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt,$$

donde $\psi(t)$ es la función wavelet (wavelet madre), a es el parámetro de escala y b el parámetro de traslación.

La wavelet madre utilizada para la realización de esta algoritmo es la wavelet biortogonal bior1.5. Debido a que las diferentes ondas características de la señal ECG contienen diferentes bandas frecuenciales, se emplean dos escalas diferentes, una para el complejo QRS y otra para las ondas P y T. Concretamente, para una señal con una frecuencia de muestreo de 500Hz, la escala 15 es usada para el complejo QRS y la 41 para las ondas P y T (ver Figura 3.23).

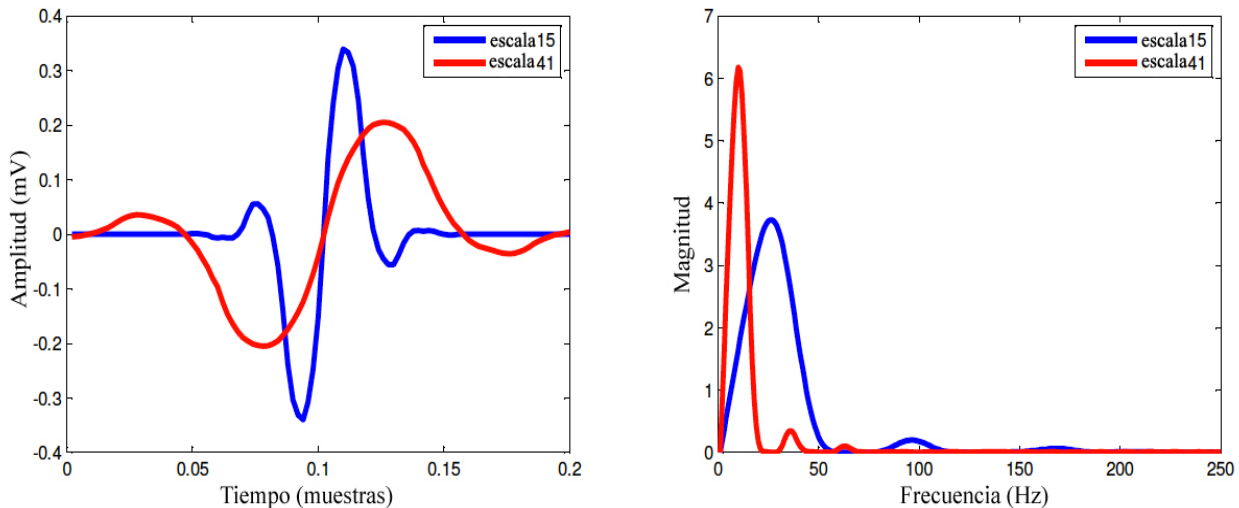


Figura 2.3: Wavelet bior1.5 a la izquierda y su espectro a la derecha en las escalas 15 y 41.

La señal resultante tras calcular la CWT en la escala 15 para la segmentación del complejo QRS se muestra en la Figura 3.24.




Figura 3.24: Muestra la señal ECG (azul) junto a su respectiva CWT (azul) en la escala 15(500Hz).

Tras el cálculo de los fiduciales QRS_{on} y QRS_{off} se procede transformar la señal para la segmentación de las ondas P y T. Para ello se elimina el complejo QRS de la señal ECG original, mediante la interpolación entre los puntos QRS_{on} y QRS_{off} , y se calcula la CWT de la señal resultante en la escala 41 (ver Figura 3.25). De esta forma se evita la influencia del complejo QRS en ondas adyacentes.




Figura 3.25: Muestra la señal ECG (azul) junto con la señal interpolada (fuxia) y su respectiva CWT (azul) en la escala 41 (500Hz).

3.8.2 FASE 2: UMBRALIZACIÓN ADAPTATIVA

Una vez más, la información necesaria para la segmentación son los cruces por cero y los módulos máximos y mínimos locales significativos, cuya posición se encuentre dentro de las distintas ventanas de búsqueda. Tras determinar la posición y la forma de las ondas, se identificarán los fiduciales a través de umbrales definidos de acuerdo a las distintas amplitudes de la señal.

3.9 HUGHES [9]

Con el fin de evaluar un método estadístico como alternativa a las normas heurísticas comúnmente utilizadas para la segmentación de ECG, se ha optado por hacer uso de los modelos ocultos de Markov o HMM (por sus siglas en inglés, *Hidden Markov Model*). Entre los métodos probabilísticos, éstos son los más populares en el tratamiento de señales ECG.

El modelo oculto de Markov generado en este trabajo para evaluar la capacidad de segmentación de ECG, está basado en el algoritmo de Hughes et al [9]. El modelado se realiza a partir de la transformada wavelet de la señal ECG original de entrada, con el objetivo de obtener más información sobre las ondas de la señal. Este tipo de algoritmo, además, no requiere de la detección previa del complejo QRS (ó onda R) como punto de referencia para la segmentación de ECG. Los fiduciales a determinar mediante este método van a ser solo cinco, concretamente, P_{on} , P_{off} , QRS_{on} , QRS_{off} y T_{off} . Esto es debido a los estados y la arquitectura de HMM planteada, que podría ser modificada para obtener todos los fiduciales deseados.

3.9.1 FASE 1: TRANSFORMADA WAVELET DISCRETA (DWT)

Se ha demostrado que el rendimiento de HMM para la segmentación de ECG puede ser mejorado si en la primera fase se utiliza la derivación o la transformada wavelet de la señal ECG. Por ello, con la intención de obtener el mejor resultado, se ha optado por utilizar la DWT. En particular, la DWT se ha realizado de la misma manera que en el algoritmo Martínez et al [2], ya explicada anteriormente.

En concreto, la DWT es realizada de la misma manera que en Martínez et [2], ya explicada anteriormente, de la cual se utilizan las escalas 2^2 , 2^3 y 2^4 . En dichas escalas de la DWT, se encuentra el mayor contenido de la señal ECG.

Pero si además de estas 3 escalas, se utiliza la señal ECG original filtrada, se ha comprobado en este trabajo, que el algoritmo proporciona mejores resultados. De esta manera se van a utilizar 4 señales en el modelo oculto de Marcov (señal ECG + 3 escalas de la DWT). Éstos se corresponden con las salidas físicas del sistema a modelar.

3.9.2 FASE 2: MODELOS OCULTOS DE MARCOV (HMM)

Los Modelos ocultos de Marcov (HMM) son métodos probabilísticas que capturan el ciclo natural de los componentes de ECG (es decir, ondas P, QRS y T). Son capaz de modelar las propiedades estadísticas de la señal ECG, y las decisiones se derivan de su máxima probabilidad. De esta manera, la ondas no son caracterizadas mediante umbrales. En vez de utilizar reglas heurísticas, se utilizan reglas de probabilidades.

A continuación, se introducirán los conceptos básicos de los modelos ocultos de Marcov, para poder comprender el método utilizado.

Introducción a los Modelos Ocultos de Marcov (HMM)

Los modelos ocultos de Marcov asumen que el sistema estudiado sigue un proceso de Markov con parámetros ocultos. Donde la propiedad de Markov, consiste en que el estado del sistema en un tiempo particular t , solo depende del estado del sistema en el tiempo o muestra inmediatamente anterior ($t - 1$). En otras palabras, si se conoce la historia del sistema hasta su instante actual, su estado presente resume toda la información relevante para describir en probabilidad si estado futuro:

$$P(S_{t+1}|S_t, S_{t-1}, S_{t-2}, \dots) = P(S_{t+1}|S_t)$$

La tarea fundamental consiste en determinar los parámetros ocultos a partir de los parámetros observados. La diferencia fundamental respecto a un modelo de Marcov habitual consiste en que los estados no son directamente visibles para el observador, pero sí lo son las variables influenciadas por el estado. Cada estado tiene una distribución de probabilidad asociada sobre el conjunto de posibles valores de salida. La secuencia de valores de salida generados a partir de un HMM nos dará cierta información sobre la secuencia de estados.

Los HMM pueden ser muy variado, en función de cómo se diseñe. Su arquitectura se da de acuerdo al número de estados que lo componen y las transiciones permitidas entre dichos estados. Un ejemplo gráfico se muestra en la Figura 3.26.




Figura 3.26: Ejemplo de la topología de un HMM

El diagrama muestra la arquitectura general de un HMM. Cada círculo representa una variable aleatoria que puede tomar determinados valores. Los círculos rojos representan los estados. La variable aleatoria X es el valor de la variable oculta en el instante de tiempo t . La variable aleatoria Y es el valor de la variable observada en el mismo instante de tiempo t . Las flechas verticales indican las dependencias condicionales y las horizontales las posibles transiciones entre estados.

En concreto, un HMM es caracterizado por los siguientes parámetros:

- N determina el número de estados del modelo. El conjunto de todos los estados posibles se denotan como $S = \{S_1, S_2, \dots, S_N\}$, donde el estado particular en el tiempo t se denota como q_t . Estos estados están ocultos y son predecidos a partir de los datos observables, que determinarán cual de los N estados pertenece a cada muestra de tiempo t .
- M es el número de los distintos símbolos de observación por estado o el número de mezclas gaussianas de la función de densidad de probabilidad, dependiendo de si las observaciones son discretas o continuas respectivamente. Estos se corresponden con las salidas físicas del sistema a modelar, y en caso de que sean discretas se denotan como: $V = \{V_1, V_2, \dots, V_M\}$ en discretas y $O = \{O_1, O_2, \dots, O_T\}$ en continuas .
- La distribución de probabilidades de transición de estado, definida por la matriz $A = \{a_{ij}\}$, del tamaño de $N \times N$. Esta distribución indica la probabilidad de transición del estado i en el tiempo particular t , al estado j , en el tiempo subsiguiente $t + 1$.

$$a_{ij} = P(q_{t+1} = S_j | q_t = S_i), \quad 1 \leq i, j \leq N.$$
- La distribución inicial de estado $\pi = \{\pi_i\}$, que define la probabilidad de cualquier estado de ser el estado inicial de las secuencias dadas, donde,

$$\pi_i = P(q_1 = S_i), \quad 1 \leq i \leq N.$$
- La distribución de probabilidades de las observaciones para cada estado del sistema. Como ya se ha mencionado antes, las observaciones pueden ser discretas o continuas, por lo que el cálculo de esta distribución es diferente para cada caso.

- Si las observaciones son discretas, es decir, pertenecen a un vector de símbolos finitos (de tamaño M), la probabilidad de observar un símbolo v_k habiendo un estado j , se define como,

$$b_j(k) = P(v_k \text{ en } t | q_t = S_j) \quad 1 \leq j \leq N, 1 \leq k \leq M$$

siendo la emisión de probabilidad discreta de la forma de $B = \{b_j(k)\}$.

- Si por el contrario las observaciones son continuas, como es el caso de la señal ECG o sus transformadas, se asume que las distribuciones de probabilidad de los símbolos observables $B = \{b_j(O_t)\}$, son densidades de probabilidad definidas sobre espacios de observación continuos. Para este caso la forma más extendida de distribución es la de una mezcla de funciones de densidad de tipo gaussiano.

$$b_j(O_t) = \sum_{m=1}^M d_{jm} \mathcal{N}(O_t, \mu_{jm}, C_{jm}), \quad 1 \leq j \leq N$$

Donde O_t es el vector característico de la secuencia que está siendo modelada, d_{jm} es el coeficiente m-ésimo de la mezcla en el estado j y \mathcal{N} es la probabilidad gaussiana con un vector medio μ_{jm} y una matriz de covarianza de C_{jm} para la m-ésima componente de la mezcla en el estado j .

Resumiendo, una especificación completa de un HMM requiere de la determinación de dos parámetros del modelo (N y M), y la definición de las probabilidades de tres medidas A , B y π . Así, la manera compacta de representar un HMM, se da por el conjunto de estos tres últimos parámetros, como:

$$\lambda = (A, B, \pi)$$

Un aspecto importante de las descripciones de probabilidades, es que las restricciones estocásticas de los parámetros HMM deben satisfacer las siguientes condiciones:

$$\begin{aligned} \sum_{i=1}^N \pi_i &= 1 \\ \sum_{j=1}^N a_{ij} &= 1 & 1 \leq i \leq N \\ \sum_{k=1}^M b_j(k) &= 1 & 1 \leq i \leq M \end{aligned}$$

Debido a la forma de la HMM, existen tres problemas básicos que deben ser resueltos:

1. Dada la secuencia de observación $\mathbf{O} = O_1, O_2, \dots, O_T$ y el modelo λ , como calcular $P(\mathbf{O}|\lambda)$, la probabilidad de obtener dicha secuencia de observaciones. Para solucionar este problema se puede utilizar el Algoritmo forward y backward (Rabiner [87]).
2. Dada la secuencia de observación $\mathbf{O} = O_1, O_2, \dots, O_T$ y el modelo λ , como escoger la secuencia de estados $Q = q_1, q_2, \dots, q_t$ que mejor explique las observaciones. Este problema es resuelto mediante el algoritmo Viterbi. La terminología de este problema es denominado comúnmente *Inferencia*.
3. Como ajustar los parámetros del modelo $\lambda = (A, B, \pi)$ para maximizar $P(\mathbf{O}|\lambda)$. Esto también puede llamarse *proceso de aprendizaje o entrenamiento*, usado para obtener de manera óptima los parámetros del modelo. Se actualiza los valores de los parámetros mediante diferentes algoritmos y con ello se consigue modelos más ajustados a la realidad.

En realidad, el aprendizaje se hace de distinta manera dependiendo de si el conjunto de datos está etiquetado (o “anotado”), es decir, que consta tanto de las secuencias de observación como de las correspondientes secuencias de los estados ocultos, entonces el problema de estimación de los parámetros de HMM puede ser visto como un problema de aprendizaje supervisado. Al contrario, si el conjunto de datos consta de sólo las secuencias de observación, entonces es visto como un problema de aprendizaje no supervisado.

En el modelo supervisado se pueden sacar las probabilidades de manera relativamente sencilla mientras que en el no supervisado necesita un proceso más complicado. Un método general para el aprendizaje no supervisado es el de Expectation-Maximization (EM).

HMM aplicado al método de segmentación ECG

Desde la perspectiva de modelado de la señal ECG, la hipótesis de un estado de Markov se puede justificar desde una secuencia típica de estados ECG (es decir, las formas de onda características) que obedecerán la propiedad de Markov. En particular, se han considerado 5 estados, estos son, la onda P, Iso1 (segmento P-R), complejo QRS, intervalo S-T, Iso 2 (segmento T-P) (ver Figura 3.27). Así, para los tipos de señales de ECG considerados aquí, la secuencia de estados ECG normalmente toman la siguiente forma:

Onda P \rightarrow Iso 1 \rightarrow Complejo QRS \rightarrow intervalo S-T \rightarrow Iso 2 \rightarrow Onda P \rightarrow ...

Por lo tanto, en cualquier punto de la secuencia de estado ECG, el siguiente estado únicamente depende del estado actual. Además, existe un orden simple de izquierda a derecha, en la secuencia de estado de ECG, que pueden ser incorporados en la arquitectura de estados de HMM (mostrada en la Figura 3.27). Por lo tanto, la hipótesis de estado de Markov implícita en HMMs está justificada en el contexto capaz de modelar la señal de ECG.

La arquitectura HMM básica de cinco estados con dos estados referentes a la línea base, no tiene en cuenta la posible aparición de la onda U o la posible desaparición de la onda P. Como se puede observar tampoco se tiene en cuenta el segmento S-T, por lo que no se puede obtener el fiducial T_{on} . Concretamente los fiduciales que se van a obtener mediante este método son: P_{on} , P_{off} , QRS_{on} , QRS_{off} y T_{off} .

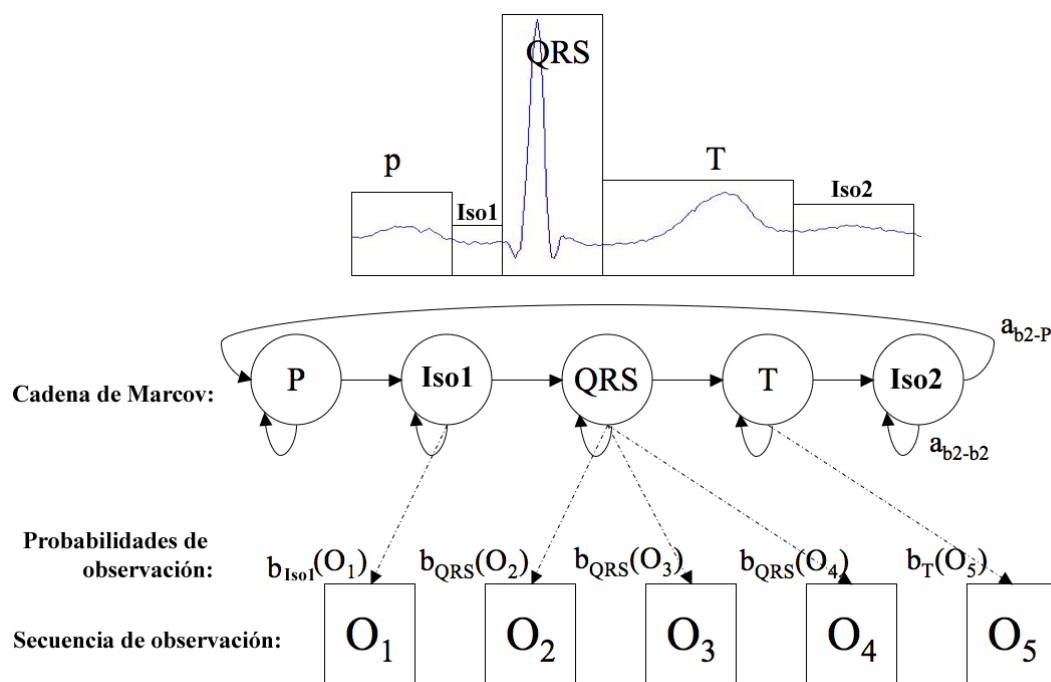


Figura 3.27: Topología de HMM utilizado en éste trabajo para la segmentación ECG.

El HMM requiere de una etapa de extracción de características, para construir la secuencia de observación O . En este punto, se implementa la transformada Wavelet, en la que se utilizan las tres escalas mencionadas anteriormente (2^2 , 2^3 y 2^4).

Como resultado, la secuencia de observaciones generada después de la extracción de parámetros es de la forma de $O = (O_1, O_2, \dots, O_T)$, donde T es la longitud de la señal en número de muestras y cada observación O_t es un vector de tamaño 4, compuesta por el valor de la amplitud de las 3 escalas de la DWT y de la señal ECG filtrada (las 4 señales tienen la misma resolución temporal).

Las distribuciones de probabilidad de los símbolos observables $B = \{b_j(O_t)\}$, se modelan mediante la función de densidad de probabilidad de mezcla gaussiana.

El HMM debe ser previamente entrenado, esto requiere estimar los parámetros del modelo con el objetivo de que conozca o aprenda las morfologías de las ondas ECG. En este trabajo, el aprendizaje del modelo se ha realizada de manera supervisada, donde las probabilidades se derivan directamente de la señal ECG anotada. Para el entrenamiento se realiza en los 5 primeros latidos de todas las ondas de la base de datos QT (QTDB).

Una vez que se tiene los tres parámetros de que describen el HMM, es decir, la probabilidad de la distribución inicial, la probabilidad de transición y la probabilidad de emisión (ó distribución de probabilidad de observación), se realiza la segmentación de la señal ECG mediante el algoritmo Viterbi, que relaciona cada observación O_t a un estado de HMM, siguiendo el criterio de máxima probabilidad con respecto a la estructura del modelado del latido. Así, por cada señal de entrada tendremos una señal que nos dirá a que estado pertenece cada muestra.

Los fiduciales se determinan en los puntos donde exista un cambio de estado en la señal de salida del algoritmo Viterbi. Se sabrá a que fiducial pertenece con exactitud dicho cambio, mirando de qué estado a qué estado se produce la transición. Como ejemplo, si la transición se realiza del estado 1 al estado 2, el fiducial será nombrado como P_{off} .

Una limitación importante del modelo oculto de Markov estándar, es la manera en que se modela la duración de los estados. Así, para una determinada forma de onda de ECG dada, la decodificación de la secuencia de estado, puede contener muchas más transiciones de estado que las que realmente existen en realidad en la presente señal ECG. La segmentación HMM resultante puede ser pobre y las resultantes medidas a partir de los puntos segmentados no fiables.

Hughes et al [9] ha investigado el uso de HSMM (Hidden semi-Markov model) para mejorar el modelado de la duración de estado. El HSMM se diferencia del HMM estándar en que los coeficientes de cada transición a un mismo estado (a_{ii}) se establecen a cero, y una densidad de probabilidad explícita es especificada para la duración de cada estado. De esta manera, las densidades de duración de estado individuales gobiernan la cantidad de tiempo que el modelo pasa en un estado determinado, y la matriz de transición gobierna la probabilidad del siguiente estado, una vez haya transcurrido este tiempo.

El mayor inconveniente es que la decodificación Viterbi para el HSMM es que es muy lento, ya que pierde la propiedad de Markov de HMM de primer orden y hay que probar de forma explícita cada duración de estado posible en cada momento.

En este trabajo se ha utilizado una manera mas sencilla para hacer frente ha este problema, sin hacer uso de HSMM. En este caso, se obliga a que cada estado tenga una duración mínima explícita, incorporando dicha restricción de duración en al algoritmo Viterbi. Se incluye una nueva variable en la estructura del modelo. Éste es un vector de $1 \times N$ ($N=n^\circ$ de estados, en este caso 5) donde contiene la duración mínima para cada uno de los estados del modelo.

4 MÉTODOS DE EVALUACIÓN

Éste capítulo describe el método utilizado para la evaluación de los algoritmos de segmentación de ECG. Describe la base de datos empleada y las diferentes pruebas realizadas a los algoritmos seleccionados en éste estudio.

4.1 BASE DE DATOS (QTDB)

En este trabajo, se evalúa la precisión de cada algoritmo para anotar automáticamente los 8 puntos fiduciales de la señal ECG (mostrados en la Figura 2.9 del capítulo 2). Al no existir una definición universal que dicte el principio y el final de cada onda de la señal ECG, se utilizan señales ECG con anotaciones manuales realizadas por cardiólogos como referencia. Concretamente en este trabajo se utiliza la base de datos QT PhysioNet (QTDB).

La base de datos QTDB contiene una recopilación de 105 registros seleccionados principalmente de otras bases de datos de ECG ya existentes, como la base de datos MIT-BIH de arritmias o la base de datos de la Sociedad Europea de Cardiología ST-T, entre otros. Las señales fueron elegidas para representar una amplia variedad de morfologías ECG, incluyendo un número significativo de registros de pacientes. El origen de las señales y su distribución se muestra en la Tabla 4.1.

MIT-BIH Arrhyth.	MIT-BIH ST DB	MIT-BIH Sup. Vent.	MIT-BIH Long Term	ESC STT	MIT-BIH NSR DB	Sudden Death
15	6	13	4	33	10	24

Tabla 4.1: Distribución de los 105 registros de acuerdo a su base de datos original: (MIT-BIH Arrhythmia; European ST-T; MIT-BIH Supraventricular Arrhythmia; MIT-BIH Long Term ECG; MIT-BIH ST Change; BIH Hospital Normal Subjects; BIH Hospital Sudden Death Patients)

Cada registro de ECG, contiene dos de las doce derivaciones con una longitud de 15 minutos y una frecuencia de muestreo de 250 Hz. En cada registros, entre 30 y 100 latidos representativos están anotados manualmente por un cardiólogo. Las anotaciones están realizadas a partir del minuto 10 del inicio de la grabación, donde 30 de ellos están anotados consecutivamente, a fin de permitir el estudio de las variaciones morfológicas latido a latido. Además, 11 de los registros están anotados por un segundo experto, que permite determinar la variabilidad entre observadores

Las anotaciones disponibles en esta base de datos son el pico, comienzo y final del complejo QRS (QRS_{on} , QRS_{peak} , QRS_{off}) y de la onda P (P_{on} , P_{peak} , P_{off}); y el pico y final de la onda T (T_{peak} , T_{off}). Las anotaciones del inicio de la onda T (T_{on}) están presentes en menos latidos, en concreto T_{on} fue anotado en 1345 latidos, a diferencia de los mas de 3600 latidos que están anotados. Además, si en los latidos anotados existe la presencia de la onda U, el pico y el final del mismo también están anotados, aunque no se tomen en cuenta en la evaluación de los algoritmos seleccionados.

En la realización del presente trabajo, se consideran 100 registros de los 105 que componen la QTDB. Los registros sel35, sel50, sel37, sel44 y sel232 fueron descartados, por no incluir las anotaciones del fiducial QRS_{peak} usado como referencia.

4.2.2 Criterio de evaluación

La media μ y la desviación estándar σ de la diferencia entre la referencia (anotaciones manuales realizadas por un experto) y el punto detectado por el algoritmo, son los parámetros utilizados para medir el error. Además, algunos métodos incluyen los parámetros de SE y P^+ para evaluar sus algoritmos. La gran mayoría de los métodos de segmentación, parten de una primera detección de la onda R, por ello, los parámetros de SE y P^+ de cada fiducial,

dependerán de la calidad del algoritmo escogido para la detención de la onda R. Esto es debido a que se supone que existe un fiducial P_{on} , P_{peak} , P_{off} , QRS_{on} , QRS_{off} , T_{on} , T_{peak} y T_{off} por cada onda R detectada.

El primer parámetro a evaluar es la sensibilidad (Se), que calcula el porcentaje de puntos que son capaces de determinar adecuadamente los diferentes algoritmos. Se obtiene un valor de (Se) específico para cada punto fiducial, calculado mediante la ecuación que sigue. Como es de esperar, éste parámetro van a depender básicamente del algoritmo elegido para la detección de la onda R, ya que por lo general, por cada onda R detectada se anotan los 8 puntos fiduciales. Pero pueden existir otras variables que alteren este factor, como por ejemplo, una detección de un punto a una distancia suficientemente grande respecto a al punto de referencia.

- **Sensibilidad (Se)**

$$Se = \frac{VP}{VP + FN} [\%]$$

VP (verdaderos positivos) = (las ondas que están presentes y son anotadas) Es el número total de puntos anotados correctamente, es decir, cuando la diferencia entre el punto anotado por el especialista y el detectado por el algoritmo no es mayor que 150ms.

FN (falsos negativos) = (ondas que están presentes pero no son anotadas) Numero total de fiduciales no anotados, es decir, cuando el proceso de segmentación falla en la determinación de un fiducial con una distancia mayor que 150ms respecto al de su referencia.

La Especificidad ($TP/(TP + FP)$) no va a ser calculado en este trabajo. La razón de ello es que un punto detectado por el algoritmo que no haya sido anotado por el cardiólogo no se puede saber si es erróneo o no; es decir, no se puede saber si el cardiólogo no ha anotado dicho punto, porque ha considerado que no existe, o porque no podía saber con seguridad la posición exacta, ya sea por la presencia de ruido o por otro argumento diferente.

Para evaluar los algoritmos se calcula el error. Este error se obtiene midiendo la diferencia entre los puntos marcados manualmente por el especialista y los puntos detectados automáticamente por el algoritmo. El error entonces, expresado en milisegundos, se calcula como se muestra en la ecuación siguiente, donde X hace referencia a los difenetes fiduciales ($Ponset$, $Poffset$, $Ppeak$, $QRSonset$, $QRSoffset$, $Tonset$, $Tpeak$ and $Toffset$), n es el numero de latido al que pertenece dicho fiducial y m el número del registro.

$$\begin{aligned} Xd(n, m) &= \text{fiducial detectado por el algoritmo} \\ Xr(n, m) &= \text{fiducial de referencia} \\ Diff(n, m) &= (Xd(n, m)) - (Xr(n, m)) \text{ (ms)} \end{aligned}$$

La base de datos QT, tal y como se ha explicado antes, tiene dos derivaciones. Los algoritmos a evaluar utilizan solo una derivación para realizar la segmentación. Primero anotan todos los puntos en las dos derivaciones por separado, y luego por cada punto detectado, se selecciona para su evaluación, el resultado de la derivación que menor error produzca respecto al de la referencia. Esta decisión, se justifica, debió a que el cardiólogo realiza las anotaciones observando las dos derivaciones y anota cada fiducial a partir de la derivación que mejor lo represente.

Los diferentes 8 puntos fiduciales se evalúan por separado. Así, por cada fiducial X , se obtiene la media μ y la desviación estándar σ meidnate las siguientes ecuaciones.

- **Media (μ)**

-Media del error en cada registro:

$$\mu_{x(m)} = \frac{1}{N} \sum_{n=1}^N Diff(n) \text{ (ms)} = \frac{1}{N} \sum_{n=1}^N \sqrt{(Xd(n) - Xr(n))^2}$$

-Media del error global del algoritmo:

$$\mu_x = \frac{1}{M} \sum_{m=1}^M \mu_{x(m)} \text{ (ms)}$$

Este valor por si solo puede ser poco representativo de la precisión del algoritmo, ya que es muy sensible a valores extremos. Por ello, se acompaña de la desviación estándar (σ), que muestra la medida de centralización o dispersión de los errores cometidos por el algoritmo a evaluar respecto al error medio. Concretamente, este parámetro nos indica la estabilidad del algoritmo en cuanto a su precisión a la hora de segmentar la señal.

Primero se calcula la desviación estándar del error de cada punto fiducial en cada registro, tal y como se muestra en la siguiente ecuación, y después, se calcula la media de las desviaciones estándar a través de los registros, obteniendo la desviación estándar global (σ), expresada en milisegundos.

- **Desviación estándar (σ)**

- Desviación estándar de cada registro

$$\sigma_{x(m)} = \sqrt{\frac{1}{N-1} \sum_{n=1}^N [Diff(n, m) - \mu(m)]^2} \text{ (ms)}$$

- Desviación estándar global

$$\sigma_x = \frac{1}{M} \sum_{m=1}^M \sigma_{x(m)} \text{ (ms)}$$

“Common Standards in Electrocardiography (CSE) working party” recomendó varias indicaciones para la evaluación de los algoritmos de segmentación de señales ECG utilizando la CSE data base, [88]. La primera indicación propuesta para que un algoritmo de segmentación automática se considere aceptable, es que sus mediciones se tienen que aproximar lo máximo posible al de las de la referencia. La segunda indicación y la más importante, es que la desviación estándar no supere los límites mostrados en la Tabla 4.2.

	P_{onset}	P_{offset}	QRS_{onset}	QRS_{offset}	T_{offset}
$\sigma_{accepted}$	10.2	12.7	6.5	11.6	30.5

Tabla 4.2: Desviación estándar recomendado por la CSE working party[88].

Según la CSE working party, todo algoritmo de segmentación automática evaluada en su base de datos, debería de cumplir los límites indicados para ser considerado un algoritmo fiable. Los valores de los límites se decidieron de manera empírica, suponiendo que iban a ser utilizados solo en la CSE data base. De todos modos, varios autores han utilizado estos

valores como referencia para considerar su algoritmo aceptable, aunque hayan sido evaluados mediante otras bases de datos como la base de datos QT. Adquirir dichos límites con la base de datos QT es más complicado, ya que contiene un mayor número de señales, con menos resolución, frecuencia de muestreo y calidad, y con más ritmos y cambios morfológicos.

- **Clasificación en grupos:**

Los registros se clasifican en 4 grupos dependiendo de la media μ y la desviación estándar σ obtenida para cada fiducial. Este tipo de clasificación, fue propuesto por Jane et al [23] y más tarde por [27] y Martínez et al [2] para identificar la fuente del error a la hora de segmentar los límites de la onda T cuando los resultados tenían poca validación. De esta manera, se puede observar los diferentes errores obtenidos por el algoritmo en los diferentes registros.

Para dicha clasificación, se necesita un límite aceptable para la media y otro para la desviación estándar. La definición de los límites está basada en decisiones empíricas. Jane et al [23] consideró como límites, 40 ms para la media y 50 ms para la desviación estándar, en la clasificación de los algoritmos a la hora de determinar el fiducial T_{off} . Más adelante Vila et al [27] y Martínez et al [2] ajustaron esos límites. En cuanto a la media, Laguna et al [1] comprobó que no era posible lograr una segmentación cuyo error medio estuviera por debajo de 10 ms para cualquier fiducial, ni siquiera entre anotaciones manuales realizadas por cardiólogos, por lo que se Vila et al [27] considero como límite para considerar un algoritmo apto, un error medio de 15 ms. En cuanto a la desviación estándar para la segmentación del punto T_{off} , se considero un límite de 30.6 ms, de acuerdo a las recomendaciones de la CSE working party [88].

De acuerdo a estas consideraciones, en la evaluación de este trabajo, un error medio μ aceptable es considerado hasta 15ms y el error de σ aceptable es considerado de acuerdo al criterio de la CSE mostrada en la Tabla 4.3.

Los cuatro grupos se definen de la siguiente manera: grupo 1 μ y σ aceptables, grupo 2 σ aceptable pero no la μ , grupo 3 μ aceptable pero no la σ , grupo 4 μ y σ no aceptables.

Grupo 1	$\mu < 15(\text{ms})$	$\sigma < \sigma_{\text{aceptable}}(\text{ms})$	Registros bien segmentados, con una μ y σ razonable.
Grupo 2	$\mu > 15(\text{ms})$	$\sigma < \sigma_{\text{aceptable}}(\text{ms})$	Registros segmentados con errores de identificación morfológica.
Grupo 3	$\mu < 15(\text{ms})$	$\sigma > \sigma_{\text{aceptable}}(\text{ms})$	Generalmente registros con pobre SRN debido al ruido o ondas de pequeña amplitud.
Grupo 4	$\mu > 15(\text{ms})$	$\sigma > \sigma_{\text{aceptable}}(\text{ms})$	Registros cuyas características son una combinación de los del grupo 2 y 3. Por lo general, error de identificación morfológica junto con pobre SNR.

Tabla 4.3. Clasificación de los grupos con sus características correspondientes.

Una vez obtenida la agrupación se puede observar la media, la desviación estándar y el porcentaje de registros al que pertenece cada grupo y así, poder identificar en qué tipo de señales falla el algoritmo a evaluar.

5 RESULTADOS. COMPARACIÓN DE ALGORITMOS

La evaluación de los nueve algoritmos es realizada de forma comparativa en este capítulo. Para ello, se presentan conjuntamente los resultados de todos los algoritmos para cada uno de los ocho fiduciales. Los fiduciales están agrupados en las 3 ondas características de la señal ECG: complejo QRS (QRS_{on} , QRS_{off}), onda P (P_{peak} , P_{on} , P_{off}) y onda T (T_{peak} , T_{on} , T_{off}).

Concretamente, por cada punto fiducial los resultados son representados mediante tres gráficas. La primera gráfica muestra los valores de sensibilidad (Se [%]) pertenecientes a cada algoritmo para el fiducial a evaluar. La segunda gráfica muestra el rango de error en milisegundos de cada algoritmo calculado a partir del error medio μ y la desviación estándar σ , en la que se puede apreciar claramente la dispersión del error. Por último, para una evaluación más detallada, la tercera gráfica presenta la clasificación en grupos de los registros segmentados. Cada barra de la gráfica muestra mediante diferentes colores, el porcentaje de registros pertenecientes a los diferentes grupos. Por ejemplo, el porcentaje del grupo 1 (G1), es el porcentaje de registros donde el fiducial a evaluar ha sido anotado correctamente por el algoritmo.

5.1 COMPLEJO QRS

El complejo QRS alberga la onda más prominente de la señal ECG y por lo tanto, al ser la onda más fácil de detectar, los fiduciales pertenecientes a este complejo presentan los mejores resultados. Los algoritmos de segmentación evaluados en el presente trabajo, ofrecen altos valores de Sensibilidad (Se). Todos ellos obtienen el 100% tanto para el fiducial QRS_{on} como para el QRS_{off} , excepto el algoritmo de Laguna et al [1] que presenta un resultado levemente menor, con un valor de $Se=99,94\%$ para el fiducial QRS_{on} y $99,71\%$ para el fiducial QRS_{off} .

A continuación, se presentan los resultados obtenidos para los fiduciales QRS_{on} y QRS_{off} . Dado que el algoritmo propuesto por Singh et al [3] no realiza la segmentación del complejo QRS, no se muestran resultados de dicho algoritmo para ninguno de los dos fiduciales.

5.1.1 QRS_{on}

Los resultados obtenidos para el fiducial QRS_{on} por cada algoritmo se muestran en las siguientes gráficas de comparación:




Figura 5.1: Resultados obtenidos por cada algoritmo para el fiducial QRS_{on} . (a) Gráfica comparativa de la Sensibilidad. (b) Gráfica comparativa del error (diferencia entre las anotaciones manuales y las anotaciones automáticas del algoritmo) representadas de acuerdo a su media y desviación estándar.




Figura 5.2: Estudio comparativo de la clasificación en grupos de cada algoritmo para el fiducial QRS_{on} . Los valores decisivos para agrupar los registros en cuanto al fiducial QRS_{on} son $\mu_{acceptable} = 15 \text{ ms}$ y $\sigma_{acceptable} = 3,75 \text{ ms}$.

Comentar que el hecho de que el grupo 1 no tenga un porcentaje elevado, no quiere decir que el algoritmo no determine este fiducial correctamente del todo, si se tiene en cuenta que para pertenecer al grupo 1, el resultado tiene que tener una media menor que 15 ms y una desviación estándar menor 3,75 ms. Este último valor es muy exigente, ya que requiere tener una desviación estándar menor a 1 muestra (4 ms). Es por ello que existen muchos registros clasificados en el grupo 3 ($\mu < 15 \text{ ms}$, $\sigma > 3,75$).

Los mejores resultados en cuanto al fiducial QRS_{on} , han sido obtenidos mediante los algoritmos de Martínez et al [2] y Hughes et al [9]. El algoritmo basado en Martínez et al [2] logra el menor error promedio con sólo -1,4 ms y el basado en Hughes et al [9] logra la menor desviación estándar con solo 6,6 ms (menos que 2 muestras de desviación). Además, en la clasificación de grupos, más del 50% de los registros segmentados pertenecen al grupo 1 en ambos casos. Sin embargo, el algoritmo de Hughes et al [9] obtuvo el mayor porcentaje de registros segmentados correctamente con un 60 %.

Asimismo, los algoritmos basados en Vázquez et al [7] y Vitek et al [8] obtienen unos resultados considerablemente buenos, con un error medio de tan solo 3,1 ms y 2,2 ms (menores que 1 muestra), una desviación estándar de 7,1 ms y 7,5 ms (menores que 2 muestras) y 47% y 48 % de registros segmentados pertenecientes al grupo 1 respectivamente.

5.1.2 QRS_{off}

Los resultados obtenidos para el fiducial QRS_{off} por cada algoritmo son mostrados en las siguientes gráficas:

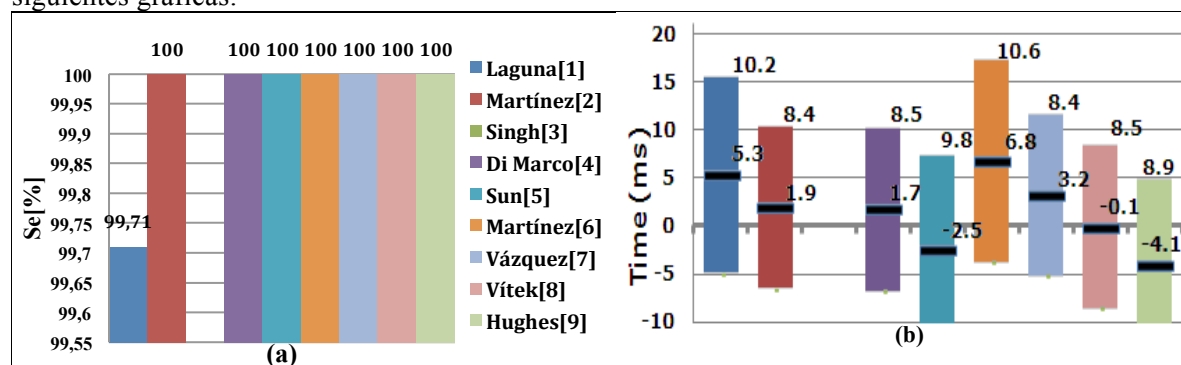


Figure 5.3: Resultados obtenidos por cada algoritmo para el fiducial QRS_{off} . (a) Gráfica comparativa de la Sensibilidad. (b) Gráfica comparativa del error (diferencia entre las anotaciones manuales y las anotaciones automáticas del algoritmo) representadas de acuerdo a su media y desviación estándar.




Figura 5.4: Estudio comparativo de la clasificación en grupos de cada algoritmo para el fiducial QRS_{off} . Los valores decisivos para agrupar los registros en cuanto al fiducial QRS_{off} son $\mu_{acceptable} = 15 \text{ ms}$ y $\sigma_{acceptable} = 11,6 \text{ ms}$

En general, los resultados han sido muy positivos para la segmentación del complejo QRS. Viték et al [9], Martínez et al [2] y Di Marco et al [4], quienes utilizaron la Transformada Wavelet, obtuvieron los mejores resultados para el fiducial QRS_{off} . Todos ellos obtuvieron una media de error de menos de 2 ms, junto con una desviación estándar de aproximadamente 2 muestras (8 ms). Si nos fijamos en el resultado del error medio, destaca el algoritmo de Viték et al [8], ya que obtiene un error medio de solo $-0,1 \text{ ms}$. En cuanto a la clasificación en grupos, los tres algoritmos mencionados logran obtener más de un 80% de los registros segmentados en el grupo 1.

5.2 ONDA P

Dentro de un latido de ECG de una señal normal, la onda P tiene la amplitud más baja, siendo muchas veces menor que la amplitud del ruido. Entre otros aspectos, esta propiedad hace que dicha onda sea más difícil de segmentar y es por ello que presenta peores resultados de segmentación que la obtenida para el complejo QRS.

5.2.1 P_{peak}

Las tres gráficas que representan los resultados del fiducial P_{peak} por cada algoritmo se muestran a continuación. El algoritmo basado en Hughes et al [9] no determina ningún pico de la señal ECG, es por ello que no se muestran sus resultados para este fiducial.




Figura 5.5: Resultados obtenidos por cada algoritmo para el fiducial P_{peak} . (a) Gráfica comparativa de la Sensibilidad. (b) Gráfica comparativa del error (diferencia entre las anotaciones manuales y las anotaciones automáticas del algoritmo) representadas de acuerdo a su media y desviación estándar.




Figura 5.6: Estudio comparativo de la clasificación en grupos de cada algoritmo para el fiducial P_{peak} . Los valores decisivos para agrupar los registros en cuanto al fiducial P_{peak} son $\mu_{acceptable} = 15 \text{ ms}$ y $\sigma_{acceptable} = 8 \text{ ms}$.

El método que destaca claramente frente a los otros métodos en la determinación de la posición del pico de la onda P, es el de Sun et al [5]. Presenta la Se más alta con un 99,81% y el menor error, con una media de $-0,6 \text{ ms}$ y una desviación estándar de $9,0 \text{ ms}$. Además, obtiene el porcentaje más alto de registros clasificados en el grupo 1, con un 65,6%.

El algoritmo de Martínez et al [2] obtiene los segundos mejores resultados con una sensibilidad de 99,49%, un error de $-3,7 \pm 11,5 \text{ ms}$ y con un 60,41% de los registros segmentados clasificados en el grupo 1.

5.2.2 P_{on}

Las tres gráficas representantes de los resultados del fiducial P_{on} por cada algoritmo son las siguientes:

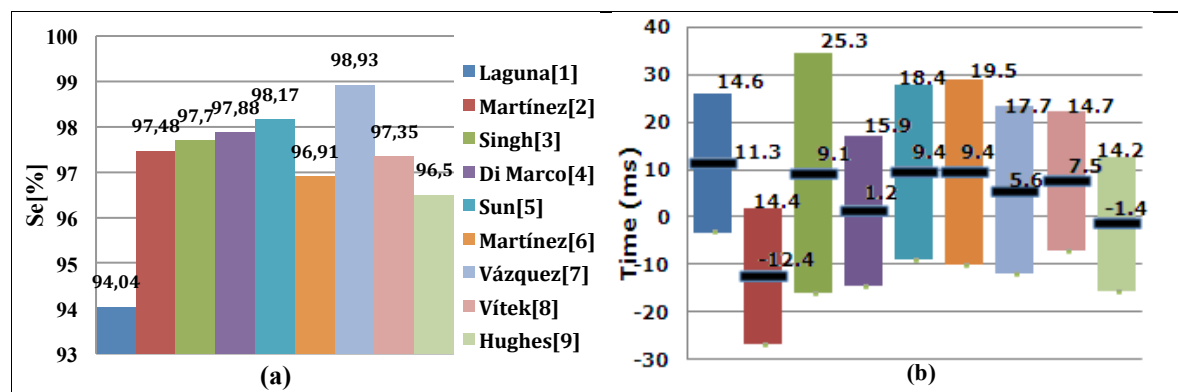


Figure 5.7: Resultados obtenidos por cada algoritmo para el fiducial P_{on} . (a) Gráfica comparativa de la Sensibilidad. (b) Gráfica comparativa del error (diferencia entre las anotaciones manuales y las anotaciones automáticas del algoritmo) representadas de acuerdo a su media y desviación estándar.




Figura 5.8: Estudio comparativo de la clasificación en grupos de cada algoritmo para el fiducial P_{on} . Los valores decisivos para agrupar los registros en cuanto al fiducial P_{on} son $\mu_{acceptable} = 15$ ms y $\sigma_{acceptable} = 12$ ms.

En lo que respecta a los resultados obtenidos para el fiducial P_{on} , el método de segmentación utilizado por Di Marco et al [4] obtiene uno de los mejores resultados con un error promedio de tan solo 1,2 ms y una desviación estándar de 15,9 ms. Asimismo, este algoritmo obtiene una sensibilidad bastante alta con un 97,88%. El porcentaje de los registros, que por su correcto resultado para la segmentación del fiducial P_{on} han sido clasificados en el grupo 1 es de un 56,25%.

Con el algoritmo de HMM basado en el de Hughes et al [9], se logra un resultado similar respecto al error medio ($\mu = -1,4$ ms), obteniendo además la menor desviación estándar ($\sigma = 14,2$ ms). Aunque la sensibilidad haya sido algo menor (96,50%), el porcentaje de registros pertenecientes al grupo 1 es algo mayor (57,89%). En cuanto a la sensibilidad, Vazquez et al [7] ha sido el que mayor resultado a obtenido con un valor de 98,93%, pero a costa de presentar un mayor error con una media de 5,6 ms y desviación estándar de 17,7 ms.

5.2.3 P_{off}

Los resultados obtenidos para el fiducial P_{off} por cada algoritmo se muestran en las siguientes gráficas de comparación.




Figura 5.9: Resultados obtenidos por cada algoritmo para el fiducial P_{off} . (a) Gráfica comparativa de la Sensibilidad. (b) Gráfica comparativa del error (diferencia entre las anotaciones manuales y las anotaciones automáticas del algoritmo) representadas de acuerdo a su media y desviación estándar.




Figura 5.10: Estudio comparativo de la clasificación en grupos de cada algoritmo para el fiducial P_{off} . Los valores decisivos para agrupar los registros en cuanto al fiducial P_{off} son $\mu_{acceptable} = 15$ ms y $\sigma_{acceptable} = 12,7$ ms.

Todos los algoritmos presentan una sensibilidad elevada, todos ellos mayores que 98%, aunque Vázquez et al [7] proporcione la sensibilidad más alta para el fiducial P_{off} ($Se=99,72\%$), los mejores resultados han sido obtenidos mediante Hughes et al [9]. Este método de HMM [9] logra un error promedio de 1,1 ms y una desviación estándar de 11,6 ms (una desviación menor que la establecida por la CSE working party [88]). El porcentaje de registros segmentados clasificados en el grupo 1 es considerablemente mayor con respecto a los obtenidos mediante los otros algoritmos con un 72,91%.

Aunque los resultados de los algoritmos basados en Di Marco et al [4] y Laguna et al [1] nos hayan obtenido de las mejores Se , ambos han logrado clasificar un 61,46% en el grupo de los registros segmentados correctamente. Di Marco et al [4] con un error de $2,9 \pm 15,3$ ms y Laguna et al [1] con un error de $5,4 \pm 13,7$ ms.

5.3 ONDA T

Aunque la amplitud de la onda T sea significativamente mayor en comparación con la de la onda P, la segmentación de ésta onda no ha dado lugar a mejores resultados. Entre otros aspectos, la dificultad para segmentar la onda T reside en la suave transición de la amplitud de la señal al principio y al final de la onda, además de la variabilidad morfológica en la que puede mostrarse dicha onda. En este estudio los peores resultados de segmentación han sido obtenidos a la hora de segmentar la onda T.

5.3.1 T_{peak}

A continuación se presentan los tres gráficos pertenecientes a los resultados de la onda T_{peak} . Como ya se ha comentado con anterioridad no se han segmentado los picos de las ondas de la señal ECG mediante el método de HMM. El método de Hughes [9] no ha sido evaluado para este fiducial por lo que no se muestran sus resultados.




Figura 5.11: Resultados obtenidos por cada algoritmo para el fiducial T_{peak} . (a) Gráfica comparativa de la Sensibilidad. (b) Gráfica comparativa del error (diferencia entre las anotaciones manuales y las anotaciones automáticas del algoritmo) representadas de acuerdo a su media y desviación estándar.




Figura 5.12: Estudio comparativo de la clasificación en grupos de cada algoritmo para el fiducial T_{peak} . Los valores decisivos para agrupar los registros en cuanto al fiducial T_{peak} son $\mu_{acceptable} = 15 \text{ ms}$ y $\sigma_{acceptable} = 8 \text{ ms}$.

El método que ofrece el mejor desempeño a la hora de determinar la posición del pico de la onda T, ha sido el método de Martínez et al [2], cuyo resultado ha sido $Se=97,48\%$, $\mu=0.7 \text{ ms}$ y $\sigma=12,1 \text{ ms}$. Mediante el método de Di Marco et al [4] se han obtenido unos resultados similares, estos son $Se=97,31\%$, $\mu=1,9 \text{ ms}$ y $\sigma=12,8 \text{ ms}$. Aunque el algoritmo basado en Laguna et al [1] haya obtenido una menor Se (95,61%), ha tenido el mayor porcentaje de registros segmentados en el grupo 1 (61,9%).

Como dato curioso, aunque en general el algoritmo basado en Singh et al [3] haya obtenido los peores resultados en este estudio, en el caso de este fiducial ha logrado la menor desviación estándar con un valor de 6,8 ms, siendo el único que ha respetado la norma de la CSE working party [88]. Claro que no consigue una segmentación correcta ya que tiene un error medio de 14,4 ms, bastante alto en comparación con el resto de los algoritmos, probablemente por un error de identificación morfológico, que puede ser corregido simplemente atrasando 3 muestras, ya que por lo general detecta el pico de la onda T más adelante que la referencia.

5.3.2 T_{on}

El fiducial T_{on} no ha sido considerado en la segmentación de la señal ECG en la mayoría de los algoritmos de la literatura. Para el presente estudio éste fiducial ha sido considerado en la medida de lo posible, muchas veces, adecuando la misma metodología adoptada para los otros fiduciales. Además, las anotaciones manuales del fiducial T_{on} , solo existen en una tercera parte de los latidos anotados de la base de datos QT (QTDB). Es por ello que los resultados obtenidos pueden no ser muy representantes. Los gráficos pertenecientes a los resultados se muestran a continuación. El algoritmo de HMM basado en Hughes et al [9] no presenta resultados para el principio de la onda T.




Figura 5.13: Resultados obtenidos por cada algoritmo para el fiducial T_{on} . (a) Gráfica comparativa de la Sensibilidad. (b) Gráfica comparativa del error (diferencia entre las anotaciones manuales y las anotaciones automáticas del algoritmo) representadas de acuerdo a su media y desviación estándar.




Figura 5.14: Estudio comparativo de la clasificación en grupos de cada algoritmo para el fiducial T_{on} . Los valores decisivos para agrupar los registros en cuanto al fiducial T_{on} son $\mu_{acceptable} = 15 \text{ ms}$ y $\sigma_{acceptable} = 30,6 \text{ ms}$.

Los resultados en general para el fiducial T_{on} presentan un aumento del error medio así como de la desviación estándar que varía entre 23 y 30 ms (5-7 muestras) respecto a los otros fiduciales.

La mayor Sensibilidad los han obtenido los métodos de Martínez et al [6] y Sun et al [5] con un 97,81% y un 97,73% respectivamente. Sin embargo, la desviación estándar más baja la obtiene Martínez et al [2], con un error de $14,4 \pm 21,3 \text{ ms}$. El método basado en Di Marco et al [4] presenta el mayor porcentaje de registros clasificados en el grupo 1 (58,14%), además de conseguir el error medio más bajo 5,8 ms, con una desviación estándar de 23,2 ms.

5.3.3 T_{off}

Por último, el fiducial T_{off} es el fiducial que más atención se le ha prestado a lo largo de la literatura por la necesidad de calcular el intervalo QT automáticamente. El final de la onda T, es a menudo el fiducial más difícil de identificar incluso visualmente, por su suave transición. Es por ello, que obtiene los menores valores de sensibilidad en comparación con otros puntos fiduciales.

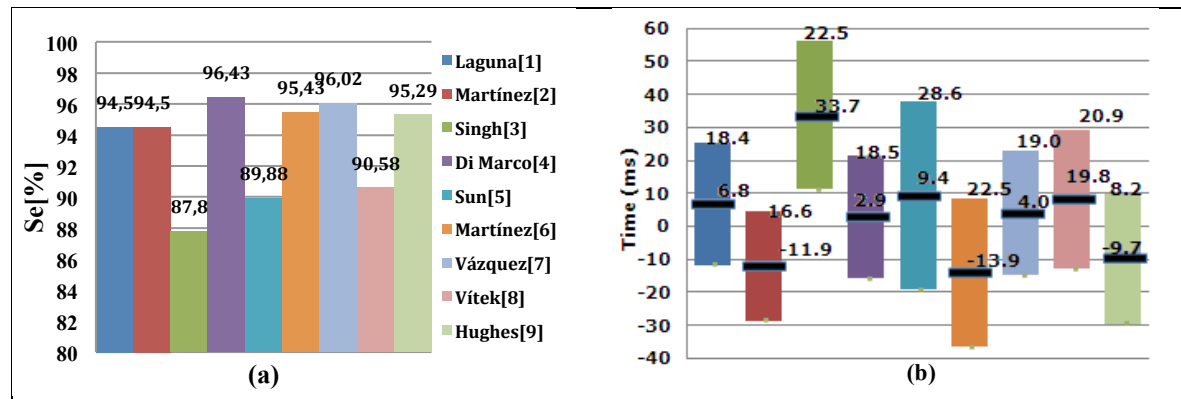


Figura 5.15: Resultados obtenidos por cada algoritmo para el fiducial T_{off} . (a) Gráfica comparativa de la Sensibilidad. (b) Gráfica comparativa del error (diferencia entre las anotaciones manuales y las anotaciones automáticas del algoritmo) representadas de acuerdo a su media y desviación estándar.




Figura 5.16: Estudio comparativo de la clasificación en grupos de cada algoritmo para el fiducial T_{off} . Los valores decisivos para agrupar los registros en cuanto al fiducial T_{off} son $\mu_{acceptable} = 15$ ms y $\sigma_{acceptable} = 30,6$ ms.

Atendiendo a los resultados, los algoritmos que destacan a la hora de determinar el fiducial T_{off} han sido tanto el algoritmo basado en Di Marco et al [4] como el basado en Vázquez et al [7]. Con el método de Di Marco et al [4] los resultados obtenidos han sido: $Se=96,43\%$, $\mu=2,9$ ms y $\sigma=18,5$ ms; y con el método de Vázquez et al [7]: $Se=96,02\%$, $\mu=3,9$ ms y $\sigma=18,9$ ms. Además, los dos métodos han tenido el mayor porcentaje de registros clasificados en el grupo 1, ambos con un 77,78%.

Sin embargo, los resultados para el fiducial T_{off} de los dos métodos referentes, como son el método de Laguna et al [1] (considerando que es el algoritmo más antiguo) y el de Martínez et al [2], no se pueden desestimar. Aunque la sensibilidad obtenida mediante el método de Laguna et al [1] no sea muy alta (94.5%), el error obtenido no es muy grande ($6,8 \pm 18,4$ ms), logrando además, casi un 70% de los registros segmentados correctamente. Por otro lado, el

método de Martínez et al [2] consigue una de las desviaciones estándares más bajas con tan solo 16,6 ms.

No obstante, una vez mas, Hughes et al [9] obtiene la menor desviación estándar con solo 8,2 ms (algo más de 2 muestras), teniendo una sensibilidad de 95,29% y casi un 60% de los registros clasificados en el grupo 1.

6 DISCUSIÓN

El objetivo principal de este trabajo es analizar nueve algoritmos de segmentación de la señal ECG con una base de datos y un método común de evaluación. Cada algoritmo se evalúa y se compara, basándose en los resultados obtenidos sobre las pruebas realizadas. Una conclusión sobre el rendimiento de los algoritmos, sus limitaciones y futuras líneas de trabajo se incluyen en éste capítulo.

6.1 CONCLUSIONES

Los métodos basados en la transformada wavelet han mostrado tener buen rendimiento a la hora de segmentar la señal ECG, ya que son los que mejor caracterizan a las diferentes ondas características de la señal ECG. Los algoritmos que utilizan la transformada wavelet han obtenido los mejores resultados sobre todo a la hora de segmentar el complejo QRS, por lo que se deduce que la WT es muy adecuada para representar especialmente dicho complejo.

En concreto, la transformada wavelet presenta dos propiedades a considerar; en primer lugar, la señal original puede ser descrita en diferentes en diferentes escalas de tiempo, mostrando las características temporales de la señal a diferentes resoluciones frecuenciales. Por ejemplo, en la escala 2^2 pueden distinguirse fácilmente las ondas de alta energía (como es el caso del complejo QRS), sin embargo en las escalas como la 2^4 ó la 2^5 , se presentan las ondas débiles o muy débiles de menor contenido frecuencia (como la onda T o la P). Así, con la TW ha sido posible detectar diferentes ondas con diferentes componentes frecuenciales. En segundo lugar, los factores como el ruido, artefactos y la deriva de la línea de base pueden ser separados en gran parte, de la actividad eléctrica del corazón en base a sus contenidos frecuenciales. Por lo que no requiere de filtrado previo.

Sin embargo, estas transformadas son complejas computacionalmente en comparación con las técnicas estándares basadas en filtrados y/o derivadas, dificultando además la segunda fase del algoritmo, al tener que realizar una búsqueda a través de diferentes escalas para encontrar la que mejor represente la onda a segmentar. De hecho, la segmentación del complejo QRS (los fiduciales QRS_{on} y QRS_{off}), realizada mediante el algoritmo basado en la derivada filtrada seguido por la umbralización adaptativa propuesta por Martínez et al [2], (el algoritmo bajo el nombre de Vázquez et al [7] realizado en este estudio), los resultados obtenidos han sido peores que utilizando la WT pero no por mucha diferencia. Demostrando así, que con menos complejidad se pueden obtener unos resultados similares.

Mediante el uso de solo dos escalas de la transformada wavelet y utilizando la umbralización adaptativa calculada a través de algunos coeficientes locales, el algoritmo de Di Marco et al [4] exhibe una precisa segmentación de la señal ECG en general. Su precisión está cerca de los valores más altos de entre los obtenidos por medio de los otros algoritmos, a pesar de tener una estructura simplificada basada en álgebra lineal. Esto hace que el algoritmo de Di Marco et al [4] sea un candidato adecuado para la segmentación de ECG bajo las estrictas restricciones de potencia y los limitados recursos computacionales de los dispositivos portátiles de diagnóstico de larga duración, como son los de monitorización ambulatoria.

Sin embargo, para una segmentación de la señal ECG en tiempo real, el algoritmo de menor complejidad computacional y mayor rapidez de ejecución es el de Martínez et al [6]. Éste algoritmo basado en la transformada fasorial se caracteriza por su robustez y simplicidad matemática.

El método desarrollado por Sun et al [5] destaca a la hora de determinar los picos las ondas P y T. Ésta cualidad se debe a la propiedad que tiene la MMD de resaltar las ondas de la señal ECG. Además, el filtro morfológico utilizado en este algoritmo es un filtro excelente contra el

ruido de la línea base. Con el presente método, se puede evitar el problema de la desviación de la posición existente a altas escalas de la WT, así como la búsqueda a través de las distintas escalas para localizar las ondas características. Sin embargo, este método tiene un coste computacional mayor en comparación con el resto de los filtros o transformadas utilizadas en este estudio.

Atendiendo a los resultados, el algoritmo basado en el cálculo del área del trapecio rectangular propuesto por Vázquez et al [7] a resultado ser una buena técnica para determinar tanto el principio de la onda P como el final de la onda T. Este método ha sido utilizado para definir 4 puntos fiduciales (P_{on} , P_{off} , T_{on} y T_{off}) mostrando ser una buena alternativa a la umbralización adaptativa, ya que reduce significativamente las reglas heurísticas. La clave reside en determinar adecuadamente los tres vértices fijos que componen el trapecio. El hecho de que los resultados de los fiduciales P_{off} y T_{on} no hayan sido tan buenos, se debe probablemente a la mayor dificultad para determinar correctamente el vértice (x_r, y_r) , perteneciente al segmento isoelectrico, ya que no existe tanto espacio entre los puntos fiduciales P_{off} - QRS_{on} y QRS_{off} - T_{on} . Añadiendo alguna modificación o regla que corrija este inconveniente, sería muy posible obtener una mejora en los resultados de dichos fiduciales, ya que éste método presenta bajo costo computacional, simplicidad matemática y robustez ante el ruido.

Los métodos probabilísticos tales como los HMM ofrecen mejoras significativas en comparación con los métodos heurísticos, ya que pueden a partir de señales reales, adaptarse a condiciones específicas. Los métodos heurísticos se basan en reglas específicas y restrictivas. Además, necesitan determinar una cantidad considerable de parámetros, tales como, tamaño y posición de las ventanas de búsqueda, umbrales de amplitud para determinar si una onda es significativa o saber que máximos y mínimos locales pertenecen a ella, umbrales decisivos de los puntos fiduciales, rangos de frecuencias, parámetros decisivos de la morfología de la onda, etc. Si se utilizan pocos parámetros o reglas heurísticas simples, existe una información inherente de la señal en sí misma, la cual no esté siendo utilizada eficazmente. Los HMM permiten caracterizar las ocurrencias de patrones de ECG (P, QRS y T) con una función de densidad de probabilidad, y todavía conservar las propiedades estructurales cíclicas de ECG mediante su cadena de Markov subyacente. En general, éste método tiene un enfoque más intuitivo de la segmentación del ECG que son fácilmente distinguibles, en vez de operar muestras individuales de la señal.

El algoritmo de HMM realizado en éste estudio basado en el método propuesto por Hughes et al [9], no obtiene un buen rendimiento en términos de Sensibilidad si se compara con el resto de los algoritmos. Sin embargo, se llevó de los mayores porcentaje de registros clasificados en el grupo1. También se obtuvieron valores de error pequeños, generalmente logrando la menor desviación estándar en comparación con los otros algoritmos, lo que refleja una alta precisión en la detección de los puntos fiduciales.

Sin embargo, los métodos probabilísticos son computacionalmente más complejos y requieren de un correcto entrenamiento previo. Uno de los mayores problemas de los modelos probabilísticos, es la dificultad con los HMM de determinar los valores adecuados para los diferentes parámetros, tales como las probabilidades de estado inicial, las probabilidades de transición entre estados, la manera de modelar las duraciones de cada estado y las probabilidades de salida de amplitud y pendiente.

6.2 LIMITACIONES

6.2.1 IMPLEMENTACIÓN DE ALGORITMOS

La mayor limitación a la hora de realizar este estudio comparativo ha sido desarrollar los 9 algoritmos seleccionados, ya que el código implementado por los autores no estaba disponible. Por lo tanto, los algoritmos se implementaron siguiendo las instrucciones

indicadas en las publicaciones de los respectivos autores. Aunque se haya intentado conseguir la reproducción más exacta de cada algoritmo, existen diferencias de código debido a la falta de información.

Además, la mayoría de los algoritmos no consideran todos los fiduciales a evaluar en este estudio. Es por ello, que si no se puede aplicar el método explicado para los otros fiduciales al fiducial no considerado, no ha sido implementado dicho fiducial y por lo tanto, no se muestran sus resultados.

En cuanto al a fase de aprendizaje del algoritmo probabilístico HMM, hubiese sido preferible tener una base de datos adicional para poder entrenar el algoritmo con una amplia gama de señales ECG adecuadamente segmentados, y comprobar después los resultados en otras señales de ECG diferentes.

6.2.2 DATOS PARA LA EVALUACIÓN (BASE DE DATOS)

No existen muchas bases de datos con las anotaciones de la segmentación de la señal ECG. A día de hoy, hasta donde mi conocimiento llega, solo existen 3 bases de datos con anotaciones manuales, estas son, QTDB (QT Database), CSEDB (Common Standards in Quantitative Electrocardiography Multilead database) y CCDD (Chinese Caediovascular Disease Database), donde la única que es de libre acceso y que además tiene mayor número de latidos anotados es la QTDB. Sin embargo, la base de datos QT (QTDB) contiene un número limitado de anotaciones, realizadas además, teniendo a la vista dos derivaciones de la señal ECG. Los algoritmos de segmentación de ECG se basan en la información de una sola derivación, por lo que sería recomendable utilizar una base de datos que tenga las anotaciones realizadas teniendo en cuenta solamente una derivación.

El hecho de que no haya una norma universal que defina la posición de cada fiducial, introduce un considerable subjetividad a las anotaciones manuales de referencia. Sería recomendable evaluar los algoritmos con diferentes bases de datos anotados por diferentes expertos. Todo ello hace que la validación de un algoritmo de segmentador de ECG automático no sea completamente fiable si es únicamente evaluada en la base de datos QT.

Las anotaciones para el inicio de la onda T no están disponibles en muchos de los registros de la base de datos. En concreto, éste fiducial esta anotado en 1345 de los 3600 latidos que están anotados. Esto podría afectar a la fiabilidad de los resultados del fiducia de T_{on} .

6.3 FUTURAS LÍNEAS DE TRABAJO

Existe espacio para la mejora de los métodos probabilísticos HMM, ya que en este trabajo se ha realizado de la manera más simple para poder comprender y evaluar el funcionamiento de este tipo de métodos. Así, una topología de HMM más amplia añadiendo más estados para poder detectar todos los fiduciales requeridos y que también incluya a los estados para diferentes morfologías, podría mejorar considerablemente el rendimiento de segmentación. Además se puede introducir el factor tiempo para el cálculo de las probabilidades o probar el HSMM propuesto por Hughes et al [9], cuyos resultados eran mejores que los de el HMM estándar.

Por otra parte, una vez estudiado las propiedades de los distintos métodos, sería interesante combinar los métodos descritos utilizando las virtudes de cada uno para obtener un mayor rendimiento de segmentación. Por ejemplo, se podría utilizar la WT para segmentar el complejo QRS, utilizar la derivada morfológica multiescala (MMD) para la detección de los picos de las ondas P y T, y establecer los límites de estas dos ondas mediante el cálculo sucesivo de las áreas del trapecio rectangular propuesto por Vázquez et al [7].

Por último, sería recomendable estudiar el efecto de diferentes niveles de ruido en la señal ECG a segmentar, para evaluar la eficacia de los algoritmos en ambientes ruidosos.

7 BIBLIOGRAFÍA

- [1] Laguna P, Jané R, Caminal P. Automatic detection of wave boundaries in multilead ECG signals: Validation with the CSE database. *Comput. Biomed*, 1994; 27(1):45–60.
- [2] Martínez J, Almeida R, Olmos S, Rocha A, Laguna P. A wavelet-based ECG delineator: evaluation on standard databases. *IEEE Trans Biomed Eng*, 2004; 51:570-581.
- [3] Singh YN, Gupta P. ECG to Individual Identification. *IEEE second international conference on biometrics: Theory, Applications and Systems*, 2008; 72-80.
- [4] Di Marco LY, Chiari L. A wavelet-based ECG delineation algorithm for 32-bit integer online processing. *Biomed Eng Online*, 2011; 3:10-23.
- [5] Sun Y, Chan KL, Krishnan SM. Characteristic Wave Detection in ECG Signal using Morphological Transform. *BMC Cardiovascular Disorders*, 2005; 28:1417-2261.
- [6] Martínez A, Alcaraz R, Rieta JJ. Application of the phasor transform for automatic delineation of single-lead ECG fiducial points. *Physiol. Meas*, 2010; 31:1467-1485.
- [7] Vázquez CR, Evangelista J, Marañón EJ, Klautau A, Oliveira RL. New approach for T-wave end detection on electrocardiogram: Performance in noisy conditions. *Biomed Eng Online*, 2011; 10-77.
- [9] Vitek M, Hubres J, Kozumplík J. A wavelet-based ECG delineation with improved P wave offset detection accuracy. *Analysis of Biomedical Signals and Images*, 2010; 20:160-165.
- [9] Hughes NP, Tarassenko L, Roberts SJ. Markov models for automated ECG interval analysis. *Advances in Neural Information Processing Systems*, Cambridge, 2004; 16.
- [10] Sörnmo L, Laguna P. Bioelectrical Signal Processing in Cardiac and Neurological Applications. New York: Elsevier/Academic, 2005.
- [11] Marriott HJL. Practical Electrocardiography. *Baltimore Williams & Wilkins*, 1988; 8: 513–515.
- [12] http://www.texasheartinstitute.org/HIC/anatomy_Esp/anato_sp.cfm
- [13] Klabunde RE. Electrical activity of the heart. *Cardiovascular physiology concepts*. *Lippincott Williams & Wilkins*, 2005. ISBN 0-7817-5030-X
- [14] <http://www.healthwise.org/> <http://www.webmd.com/heart/conduction-system-of-the-heart>
- [15] Dale D. Quick and accurate 12-lead ECG interpretation. *Lippincott Williams & Wilkins, Inc. Usa*, 2007; 4^a edition.
- [16] http://www.welchallyn.com/documents/Cardiopulmonary/Electrocardiographs/PCBased%20Exercise%20Stress%20ECG/poster_110807_pcexerecg.pdf
- [17] <http://www.biolog3000.com/electrode.htm>
- [18] <http://www.electrocardiografia.es/derivaciones.html>

- [19] <http://elmercaderdelasalud.blogspot.com.es/2012/02/el-corazon-ix.html>
- [20] Malmivuo J, Plonsey R. Principles and Applications of Bioelectric and Biomagnetic Fields. *New Yorck, Oxford University Press*, 1995.
- [21] Rodríguez JL. Estudio comparativo de técnicas para extracción de parámetros en señales de electrocardiografía. *Universidad Nacional de Colombia, Ingeniería y Arquitectura*, 2004
- [22] Laguna P, Thakor NV, Caminal P, Jané R, Yoon HR. New algorithm for QT interval analysis in 24-hour Holter ECG: performance and applications. *Med. & Biol. Eng & Comput.*, 1990; 28, 67–73.
- [23] Jané R, Blasi A, García J, Laguna P. Evaluation of an automatic threshold based detector of waveform limit in Holter ECG with the QT database. *Computers in Cardiology*, 1997; 24.
- [24] Illanes-Manriquez A. An automatic multi-lead electrocardiogram segmentation algorithm based on abrupt change detection. *IEEE Eng Med Biol Soc.*, 2010; 2334-7.
- [25] Schreier G, Hayn D, Lobodzinski S. Development of a new QT algorithm with heterogeneous ECG databases. *J Electrocardiol.* 2003; 36:145-50.
- [26] Altuve M, Casanova O, Wong S, Passariello G, Hernandez A, Carrault G. Evaluación de dos Métodos para la Segmentación del Ancho de la Onda T en el ECG. *IFMBE Proceedings*, 2007; 18: 1254–1258.
- [27] Vila JA, Gang Y, Presedo, JMR, Fernandez M, Barro S, Malik M. A new approach for TU complex characterization. *Biomedical Engineering, IEEE Transactions*, 2000; 47: 764-772.
- [28] Chazal P, Celler BG. Automatic measurement of the QRS onset and offset in individual ECG leads. *Biomedical System Laboratory, Engineering in Medicine and Biology Society, Proceeding of the 18th Annual International Conference on the IEEE*, 1996; 4: 1399-1400.
- [29] Gupta R, Mitra M, Mondal K, Bhowmick S. A derivative-based approach for QT-segment feature extraction in digitized ECG record. *Emerging Applications of Information Technology*, 2011; 63-66.
- [30] Mitra M, Mitra S. Time plane ECG feature extraction using Hilbert transform, variable threshold and slope reversal approach. *Communication and Industrial Application*, 2011; 1-4.
- [31] Frénay B, Lannoy G, Verleysen M. Emission Modelling for Supervised ECG Segmentation using Finite Differences. *ECIFMBE, IFMBE Proceedings*, 2008; 1212-1216.
- [32] Murthy ISN, Niranjan UC. Component wave delineation of ECG by filtering in the Fourier domain. *Med & Biol. Eng & Comput.*, 1992; 30: 169-176.
- [33] Li C, Zheng C, Changfeng T. Detection of ECG characteristic points using wavelet transforms. *IEEE Transactions of Biomedical Engineering*, 1995; 42: 21-28.

- [34] Madeiro JP, Cortez PC, Marques JA, Seisdedos CR, Sobrinho CR. An innovative approach of QRS segmentation based on first-derivative, Hilbert and Wavelet Transforms. *Med Eng Phys*, 2012; 34(9):1236-46.
- [35] Rincón F, Recas J, Khaled N, Atienza D. Development and evaluation of multilead wavelet-based ECG delineation algorithms for embedded wireless sensor nodes. *IEEE Trans Inf Technol Biomed*, 2011;15(6):854-63.
- [36] Almeida R, Martínez JP, Rocha AP, Laguna P. Multilead ECG delineation using spatially projected leads from wavelet transform loops. *IEEE Trans Biomed Eng.*, 2009; 56(8):1996-2005.
- [37] Rincón F, Recas J, Khaled N, Atienza D. Development and evaluation of multilead wavelet-based ECG delineation algorithms for embedded wireless sensor nodes *IEEE Trans Inf Technol Biomed*, 2011;15(6):854-63.
- [38] Lannoy G, Frenay B, Verleysen M, Delbeke J. Supervised ECG delineation using the Wavelet Transform and Hidden Markov Models. *ECIFMBE, IFMBE Proceedings*, 2008; 22: 22–25.
- [39] Andreão RV, Dorizzi B, Boudy J. ECG Signal Analysis Through Hidden Markov Models. *IEEE Transactions on Biomedical Engineering*, 2006; 53(8) 1541- 1549.
- [40] Thomas J, Rose C, Charpillet F. A support system for ECG segmentation based on Hidden Markov Models. *Conf Proc IEEE Eng Med Biol Soc.*, 2007; 3228-31.
- [41] Madeiro JP, Cortez PC, Oliveira FI, Siqueira RS. A new approach to QRS segmentation based on wavelet bases and adaptive threshold technique. *Med Eng Phys.*, 2007;29(1):26-37.
- [42] Krimi S, Ouni K, Ellouze N. An Approach Combining Wavelet Transform and Hidden Markov Models for ECG Segmentation. *Information and Communication Technologies: From Theory to Applications, 3rd International Conference*, 2008: 1-4.
- [43] Shi W, Kheidorov I .Hybrid hidden Markov models for ECG segmentation. *Natural Computation (ICNC)*, 2010; 3323-3328.
- [44] Ghaffari A, Homaeinezhad MR, Khazraee M, Daevaeiha MM. Segmentation of holter ECG waves via analysis of a discrete wavelet-derived multiple skewness-kurtosis based metric. *Ann Biomed Eng.*, 2010;38(4):1497-510.
- [45] Homaeinezhad MR, Ghaffari A, Najjaran Toosi H, Tahmasebi M, Daevaeiha MM. A Unified Framework for Delineation of Ambulatory Holter ECG Events via Analysis of a Multiple-Order Derivative Wavelet-Based Measure. *Iranian Journal of Electrical & Electronic Engineering*, 2011; 7(1).
- [46] Dumont Ast J, Hernández AI, Carrault G. Parameter Optimization of a Wavelet-Based Electrocardiogram Delineator with an Evolutionary Algorithm. *Computers in Cardiology* 2005;32:707–710.
- [47] Dumont Ast J, Hernández AI, Carrault G. Improving ECG beats delineation with an evolutionary optimization process. *IEEE Trans Biomed Eng.*, 2010; 57(3):607-15.
- [48] Martínez JP, Olmos S, Laguna. Evaluation of a wavelet-based ECG waveform detector on the QT database. *Computers in Cardiology*, 2000; 27: 81-84.

- [49] Sahambi JS, Tandonz SN, Bhatt RKP. Using wavelet transforms for ECG characterization an on-line digital processing system. *IEEE Engineering in Medicine and Biology*, 1997; 77-83.
- [50] Thomas J, Rose C, Charpillat F. A multi-HMM approach to ECG segmentation. *Conference on Tools with Artificial Intelligence, Proceedings of the 18th IEEE International*, 2006; 609 – 616.
- [51] Almeida R, Martínez JP, Rocha AP, Laguna P. Multilead ECG delineation using spatially projected leads from wavelet transform loops. *IEEE Trans Biomed Eng.*, 2009; 56(8):1996-2005.
- [52] Mallat S. Zero-crossings of a wavelet transform. *IEEE Trans. Inform. Theory*, 1991; 37:1019-1033.
- [53] Andraeo, RV, Boudy J. Combining wavelet transform and hidden Markov models for ECG segmentation. *Hindawi Publishing Corporation, EURASIP Journal on Advances in Signal Processing*, 2007.
- [54] Last T, Nugent CD, Owens FJ. Multi-component based cross correlation beat detection in electrocardiogram analysis. *Biomed Eng Online*, 2004;3(1):26.
- [55] Baas T, Gravenhorst F, Medhat H, Dössel O. Detecting end of T-wave in ECG using a correlation based method. *Proceedings of Biosignal*, 2010.
- [56] Illanes-Manriquez A, Zhang Q. An Algorithm for robust detection of QRS onset and offset in ECG signals. *Computers in cardiology*, 2008;35:857-860.
- [57] Illanes-Manriquez A, Zhang Q. An algorithm for QRS onset and offset detection in single lead electrocardiogram records. *Conf Proc IEEE Eng Med Biol Soc.*, 2007; 541-4.
- [58] Koski A. Segmentation of digital signals based on estimated compression ratio. *IEEE trans. on Biomedical Eng.*, 1996;43(9):928-938.
- [59] Automated ECG segmentation with Dynamic Time Warping. *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 1998; 20(1):163-166.
- [60] Zifan A, Saberi S, Moradi MH, Towhidkhah F. Automated ECG Segmentation Using Piecewise Derivative Dynamic Time Warping. *World Academy of Science, Engineering and Technology*, 2006;20.
- [61] Coast DA, Stern RM, Cano GG, Briller SA. An approach to cardiac arrhythmia analysis using hidden Markov models. *IEEE Transactions on Biomedical Engineering*, 1990; 37(9):826-835.
- [62] Koski A. Modelling ECG signals with hidden Markov models. *Artificial Intelligence in Medicine*, 1996;8:453-471.
- [63] Clavier L, Boucher JM. Segmentation of electrocardiograms using a Hidden Markov Model. Bridging Disciplines for Biomedicine. *IEEE Eng. in Med. and Biol.*, 1996; 45-60.
- [64] Crouse S, Nowak RD, Baraniuk RG. Wavelet based statistical signal processing using hidden markov models. *IEEE Trans.on Biomedical engineering*, 1990; 37:826-836.

- [65] Stamkopoulos T, Maglaveras N, Bamidis PD, Pappas C. Wave segmentation using nonstationary properties of ECG. *In Computers in Cardiology*, 2000; 529-532.
- [66] Graja S, Boucher JM. Multiscale hidden Markov model applied to ECG segmentation. *WISP IEEE International Symposium on Intelligent Signal Processing*, 2003; 105–109.
- [67] Vaeseen MJ, Westra RL, Jong I, Karel JMH. An Approach to ECG Delineation using Wavelet Analysis and Hidden Markov Models. *Universiteit Maastricht, Department of Mathematics*, 2006.
- [68] Thoraval L, Carrault G, Mora F. Continuously variable duration HMMs for ECG segmentation. *In Proceedings IEEE-EMBS*, 1992;529-530.
- [69] Sankoff D, Kruskal JB. Time warps, string edits, and macromolecules: the theory and practice of sequence comparison. *Chapter 1 & 4. Addison-Wesley*, 1983.
- [70] Silipo R, Marchesi C. Artificial neural networks for automatic ECG analysis. *IEEE Transactions on Signal Processing*, 1998; 46(5):1417–1425.
- [71] Orr G, Schaudolph N, Cummins F. CS-449: Neural Networks. *Willamette University*, 1999.
- [72] Andreao RV, Dorizzi B, Cortez PC, Mota JCM. Efficient ECG multilevel wavelet classification through neural network dimensionality reduction. *IEEE Workshop on Neural Network for Signal Processing*, 2002; 395–404
- [73] Bortolan G, Degani R, Willems JL. Neural networks for ECG classification. *Computers in Cardiology*, 1990:269–72.
- [74] Hu YH, Palreddy S, Tompkins WJ. A patient-adaptable ECG beat classifier using a mixture of experts. *Approach IEEE Trans. Biomed. Eng.*, 1997;44:891–900.
- [75] Bystricky W, Safer A. Modelling T-end in Holter ECG's by 2-layer perceptrons. *Computers in Cardiology. Los Alamitos, CA: IEEE Computer Society Press*, 2002;29:105-108.
- [76] Krim H, Brooks DH. Feature-based segmentation of ECG signal. *IEEE-SP International Symposium*, 1996;97-100.
- [77] Krim H, Brooks DH, Pesquet JC, MacLeod RS. Best basis segmentation of ECG signal using novel optimality criteria. *Conference Proceeding*, 1996;5:2750-2753.
- [78] Sayadi O, Shamsollahi MB. A model-based Bayesian framework for ECG beat segmentation. *Physiol Meas.* 2009;30(3):335-52.
- [79] Lin C, Mailhes C, Tourneret JY. P- and T-wave delineation in ECG signals using a Bayesian approach and a partially collapsed Gibbs sampler. *IEEE Trans Biomed Eng.* 2010; 57(12).
- [80] Clifford GD, Villarroel M. Model-based determination of QT intervals. *Comput. Cardiol.*, Valencia, Spain, Sep. 2006; 33: 357–360.
- [81] Sayadi O, Shamsollahi MB. Model-based ECG fiducial points extraction using a modified extended Kalman filter structure. *Int. Symp. Appl. Sci. Biomed. Commun. Tech.* 2008; 1–5.

- [82] Sayadi O, Shamsollahi MB. A model-based Bayesian framework for ECG beat segmentation. *J. Physiol. Meas.*, 2009; 30: 335–352.
- [83] Kohler BU, Hennig C, Orglmeister R. The principles of software QRS detection. *Engineering in Medicine and Biology Magazine, IEEE*, 2002; 21(1):42–57.
- [84] Romero I, Addison PS, Reed MJ, Grubb N, Clegg GR, Robertson CE, Watson JN. Continuous wavelet modulus maxima analysis of the electrocardiogram: Beat characterisation and beat-to-beat measurement. *Int J Wavelets, Multiresolution Inf Process*, 2005; 3(1): 19-42.
- [85] Mallat S, Zhong S. Characterization of signals from multiscale edge. *IEEE Trans. Pattern Anal. Machine Intell.*, 1992; (14):710–732.
- [86] Menard A. Dual Microprocessor System for Cardiovascular Data Acquisition. *Processing and Recordings, In Proc.*, 1981; *IEEE Int Conf. Industrial Elect. Contr. Instrument*, 1981; 64-69.
- [87] Rabiner R. A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 1989; 77.
- [88] Recommendations for measurement standards in quantitative electrocardiography. *European Heart Journal*, 1985;6:815-825.

A. ANEXO 1

I. RESULTADOS DE CADA ALGORITMO

i. RESULTADOS BÁSICOS

Se muestran los resultados obtenidos por cada algoritmo en cuanto a sensibilidad [%], error medio μ y desviación estándar σ probado en la QTDB. Además, si existen, se dan los resultados obtenidos y publicados mediante los algoritmos originales.

LAGUNA[1]

Algoritmo	Parámetros	Pon	Ppeak	Poff	QRSon	QRSoff	Ton	Tpeak	Toff
Laguna [1]	Se [%]	94.04	97.26	98.04	99.94	99.71	95.09	95.61	94.50
	$\mu \pm \sigma$ (ms)	11.27 ± 14.61	11.09 ± 11.61	5.44 ± 13.67	12.12 ± 8.41	5.34 ± 10.22	14.13 ± 25.82	2.10 ± 12.93	6.77 ± 18.39
Laguna original [1]	Se [%]	97.70	97.70	97.70	99.92	99.92		99.00	99.00
	$\mu \pm \sigma$ (ms)	14.0 ± 13.3	4.8 ± 10.6	-0.1 ± 12.3	-3.6 ± 8.6	-1.1 ± 8.3		-7.2 ± 14.3	13.5 ± 27.0
Tolerance 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

MARTÍNEZ [2]

Algoritmo	Parámetros	Pon	Ppeak	Poff	QRSon	QRSoff	Ton	Tpeak	Toff
Martínez [2]	Se [%]	97.48	99.49	99.46	100	100	95.32	97.48	94.50
	$\mu \pm \sigma$ (ms)	-12.40 ± 14.36	-3.68 ± 11.54	-8.44 ± 13.32	-1.36 ± 7.62	1.93 ± 8.45	14.40 ± 21.31	0.75 ± 12.12	-11.91 ± 16.57
Martínez original [2]	Se [%]	98.87	98.87	98.75	99.97	99.97		99.77	99.77
	$\mu \pm \sigma$ (ms)	2.0 ± 14.8	3.6 ± 13.2	1.9 ± 12.8	4.6 ± 7.7	0.8 ± 8.7		0.2 ± 13.9	-1.6 ± 18.10
Tolerancia 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

SINGH [3]

Algoritmo	Parámetros	Ponset	Ppeak	Poffset	QRSonset	QRSoffset	Tonset	Tpeak	Toffset
Singh [3]	Se [%]	97.70	95.99	99.05	100	99.91	79.98	91.02	87.80
	$\mu \pm \sigma$ (ms)	9.15 ± 25.28	13.13 ± 14.97	-7.41 ± 17.17	-3.69 ± 8.97	-2.25 ± 9.47	34.37 ± 27.81	14.42 ± 16.77	33.66 ± 22.49
Tolerancia 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

DI MARCO [4]

Algoritmo	Parámetros	Pon	Ppeak	Poff	QRSon	QRSoff	Ton	Tpeak	Toff
Di Marco [4]	Se [%]	97.88	97.98	98.45	100	100	93.43	97.31	96.43
	$\mu \pm \sigma$ (ms)	1.20 ± 15.96	7.09 ± 12.96	2.88 ± 15.33	6.56 ± 9.52	1.72 ± 8.55	5.81 ± 23.23	1.90 ± 12.79	2.89 ± 18.47
Di Marco original [4]	Se [%]	98.15	98.15	98.15	100	100		99.72	99.77
	$\mu \pm \sigma$ (ms)	-4.5 ± 13.4	-4.7 ± 9.7	-2.5 ± 13.0	-5.1 ± 7.2	0.9 ± 8.7		-0.3 ± 12.8	1.3 ± 18.6
Tolerancia 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

SUN [5]

Algoritmo	Parámetros	Pon	Ppeak	Poff	QRson	QRsoff	Ton	Tpeak	Toff
Sun [5]	Se [%]	98.17	99.81	99.56	100	100	97.73	96.75	89.88
	$\mu \pm \sigma$ (ms)	9.45± 18.42	-0.62± 9.02	3.66± 18.76	7.56± 11.83	-2.54± 9.80	11.53± 23.96	-0.72± 12.61	9.39± 28.65
Sun original [5]	Se [%]	97.2		94.8	100	100	99.8		99.6
	$\mu \pm \sigma$ (ms)	9.0± 9.4		12.8± 13.2	3.5± 6.1	2.4± 10.3	7.9± 15.8		8.3± 12.4
Tolerancia 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

MARTÍNEZ [6]

Algoritmo	Parámetros	Pon	Ppeak	Poff	QRson	QRsoff	Ton	Tpeak	Toff
Martínez [6]	Se [%]	96.91	97.82	98.26	100	100	97.81	97.78	95.43
	$\mu \pm \sigma$ (ms)	9.44± 19.55	4.51± 10.95	-3.87± 15.08	2.87± 11.04	6.77± 10.57	8.35± 30.42	0.85± 14.06	-13.98± 22.49
Martínez original [6]	Se [%]	98.65	98.65	98.65	99.85	99.85	99.20	99.20	99.20
	$\mu \pm \sigma$ (ms)	2.6± 14.5	32± 25.7	0.7± 14.7	-0.2± 7.2	2.5± 8.9		5.3± 12.9	5.8± 22.7
Tolerancia 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

VÁZQUEZ [7]

Algoritmo	Parámetros	Pon	Ppeak	Poff	QRson	QRsoff	Ton	Tpeak	Toff
Vázquez [7]	Se [%]	98.93	99.78	99.72	100	100	93.28	96.81	96.02
	$\mu \pm \sigma$ (ms)	5.57± 17.67	3.17± 15.18	-6.73± 15.23	3.12± 7.10	3.22± 8.36	14.66± 24.27	7.43± 13.81	3.9± 18.9
Tolerancia 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

VÍTEK [8]

Algoritmo	Parámetros	Ponset	Ppeak	Poffset	QRsonset	QRsoffset	Tonset	Tpeak	Toffset
Vitek [8]	Se [%]	97.35	99.34	99.68	100	100	93.50	92.13	90.58
	$\mu \pm \sigma$ (ms)	7.5±14.7	5.0±12. 3	13.1±14.7	2.2±7.5	-0.1± 8.5	1.3±29. 8	5.2±17. 4	8.2±20. 9
Tolerancia 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

HUGHES [9]

Algoritmo	Parámetros	Ponset	Ppeak	Poffset	QRsonset	QRsoffset	Tonset	Tpeak	Toffset
Hughes [9]	Se [%]	96.50		98.45	100	99.48			95.29
	$\mu \pm \sigma$ (ms)	-1.4±14.2		1.1±11.6	2.4±6.5	-4.1±8.9			- 9.7±19. 8
Tolerancia 2s CSE (σ)		10.2		12.7	6.5	11.6			30.6

ii. RESULTADOS: CLASIFICACIÓN EN GRUPOS

LAGUNA[1]

• ONDA P

GRUPOS	Pon			Ppeak			Poff		
	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	45,83	5,08	8,42	54,17	4,47	5,68	61,46	4,11	8,65
G2	3,13	8,20	6,83	3,13	60,10	4,65	3,13	20,67	7,37
G3	25,00	6,96	19,15	28,13	6,91	14,52	21,88	3,42	18,28
G4	26,04	26,67	22,08	14,58	33,26	29,56	13,54	11,28	30,46

• COMPLEJO QRS

GRUPOS	QRSon			QRSoff		
	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	40,00	5,17	5,30	49,00	5,82	7,22
G2	9,00	32,56	5,28	20,00	13,25	6,78
G3	35,00	4,67	9,72	24,00	1,82	16,78
G4	16,00	34,29	15,10	7,00	-8,57	18,58

• ONDA T

GRUPOS	Ton			Tpeak			Toff		
	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	44,19	2,69	19,88	61,86	2,91	5,72	69,47	5,49	13,14
G2	23,26	37,41	18,84	1,03	-100,53	5,12	14,74	6,71	16,87
G3	6,98	-2,66	34,39	26,80	2,93	16,95	5,26	-0,88	38,41
G4	25,58	17,29	40,09	10,31	5,37	46,47	10,53	19,14	45,15

MARTÍNEZ [2]

• ONDA P

GRUPOS	Pon			Ppeak			Poff		
	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	29,47	-9,49	10,00	60,42	-3,63	5,29	47,92	-5,09	8,61
G2	23,16	-18,63	9,55	0,00	NaN	NaN	19,79	-20,63	7,86
G3	22,11	-7,63	16,28	28,13	-4,16	14,59	17,71	-5,38	17,65
G4	25,26	-14,25	22,19	11,46	-2,75	36,98	14,58	-6,64	31,00

• COMPLEJO QRS

GRUPOS	QRSon			QRSoff		
	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	51	-0,44	5,13	82	3,57	7,08
G2	1	-16,27	6,12	2	-4,73	7,05
G3	47	-1,48	9,81	13	0,11	14,99
G4	1	-28,00	33,84	3	-30,40	18,71

- ONDA T

GRUPOS	Toff			Tpeak			Toff		
	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	40,48	3,51	11,95	56,12	3,30	5,59	65,63	-8,08	12,91
G2	38,10	34,62	19,31	1,02	-66,93	5,14	23,96	-21,87	14,38
G3	9,52	-1,57	38,29	30,61	1,78	13,15	5,21	0,88	40,66
G4	11,90	-0,47	45,96	12,24	-7,88	40,06	5,21	-27,23	48,61

SINGH [3]

- ONDA P

GRUPOS	Pon			Ppeak			Poff		
	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	5,21	-4,37	9,27	40,63	4,58	5,20	39,58	-7,18	9,15
G2	5,21	68,43	11,02	3,13	62,53	2,02	8,33	-25,52	8,77
G3	41,67	-3,60	25,23	34,38	4,22	15,71	29,17	-4,47	22,45
G4	47,92	15,35	24,86	21,88	42,92	33,11	22,92	18,99	27,32

- COMPLEJO QRS

GRUPOS	QRSon			QRSoff		
	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	51,00	-0,44	5,13	82,00	3,57	7,08
G2	1,00	-16,27	6,12	2,00	-4,73	7,05
G3	47,00	-1,48	9,81	13,00	0,11	14,99
G4	1,00	-28,00	33,84	3,00	-30,40	18,71

- ONDA T

GRUPOS	Ton			%	Tpeak		Toff		
	%	μ (ms)	σ (ms)		μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	9,76	7,69	21,91	1,06	-1,41	7,93	7,45	5,21	17,51
G2	53,66	50,98	19,30	19,15	25,22	5,80	73,40	43,90	17,14
G3	4,88	1,48	50,19	31,91	2,47	19,46	3,19	7,35	57,59
G4	31,71	39,64	41,73	47,87	20,17	19,65	15,96	10,65	42,91

DI MARCO [4]

- ONDA P

GRUPOS	%	Pon		%	Ppeak		%	Poff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	56,25	1,55	8,19	55,21	7,64	5,83	61,46	6,90	8,88

G2	0,00	0,00	0,00	1,04	15,07	6,19	2,08	-8,60	7,90
G3	31,25	1,33	21,60	32,29	4,41	15,87	23,96	1,73	21,93
G4	12,50	-0,71	36,83	11,46	11,38	39,74	12,50	-12,72	35,62

- **COMPLEJO QRS**

		QRSon			QRSoff	
GRUPOS	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	41	6,53	5,20	81	2,86	6,87
G2	3	18,49	5,47	1	-38,80	4,60
G3	41	6,70	9,62	14	-0,97	15,95
G4	15	3,89	21,84	4	-1,63	17,64

- **ONDA T**

		Ton			Tpeak			Toff	
GRUPOS	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	58,14	1,41	15,52	53,54	5,09	5,53	77,78	2,23	13,32
G2	18,60	31,77	19,23	0,00	0,00	0,00	8,08	-3,06	21,40
G3	11,63	-1,29	49,32	35,35	3,27	14,40	5,05	-1,52	45,99
G4	11,63	-6,57	42,11	11,11	-17,84	42,66	9,09	16,30	44,68

SUN [5]

- **ONDA P**

		Pon			Ppeak			Poff	
GRUPOS	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	32,29	7,04	9,14	65,63	-1,17	5,50	29,17	5,20	10,08
G2	1,04	93,47	9,94	0,00	0,00	0,00	1,04	-47,87	12,58
G3	44,79	5,50	20,52	30,21	0,07	15,28	57,29	2,03	20,85
G4	21,88	17,10	28,25	4,17	3,07	19,20	12,50	11,89	29,92

- **COMPLEJO QRS**

		QRSon			QRSoff	
GRUPOS	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	15	6,97	5,50	68	0,18	7,00
G2	7	22,36	5,48	4	-10,03	8,05
G3	49	6,13	6,13	21	-3,63	-3,63
G4	29	6,73	15,09	7	-21,45	19,47

- **ONDA T**

		Ton			Tpeak			Toff	
GRUPOS	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	34,88	2,05	17,54	58,16	-0,31	5,89	40,40	-2,31	17,18
G2	44,19	27,85	19,93	1,02	-16,00	0,00	23,23	26,79	21,76
G3	4,65	-2,99	42,98	36,73	-0,24	16,96	12,12	-1,79	42,03
G4	16,28	-8,32	43,25	4,08	-7,22	72,41	24,24	17,82	47,67

MARTÍNEZ [6]

• ONDA P

GRUPOS	%	Pon		%	Ppeak		%	Poff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	31,25	7,48	9,34	50,00	3,79	5,67	55,21	-1,70	9,55
G2	1,04	16,65	11,69	0,00	NaN	NaN	4,17	-21,85	10,67
G3	43,75	6,72	23,43	43,75	3,83	14,50	30,21	-3,32	20,05
G4	23,96	16,68	26,13	6,25	15,00	28,31	10,42	-9,72	31,72

• COMPLEJO QRS

GRUPOS	%	QRSon		%	QRSoff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	5,00	5,20	6,08	64,00	5,24	7,91
G2	1,00	25,20	4,72	10,00	19,42	8,57
G3	91,00	1,99	1,99	22,00	2,22	2,22
G4	3,00	18,49	10,72	4,00	24,83	24,63

• ONDA T

GRUPOS	%	Ton		%	Tpeak		%	Toff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	23,26	3,56	16,61	46,46	5,06	6,22	45,45	-6,06	13,18
G2	37,21	28,37	21,13	0,00	0,00	0,00	28,28	-24,39	17,58
G3	23,26	-1,23	50,77	45,45	3,28	17,00	10,10	-0,54	49,92
G4	16,28	-16,99	42,30	8,08	-37,02	42,61	16,16	-26,48	40,13

VÁZQUEZ [7]

• ONDA P

GRUPOS	%	Pon		%	Ppeak		%	Poff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	41,67	5,36	9,12	32,29	5,04	5,53	59,38	-2,30	8,66
G2	0,00	0,00	0,00	0,00	0,00	0,00	3,13	-21,16	9,17
G3	45,83	2,78	19,37	50,00	2,12	15,48	18,75	-2,68	22,76
G4	12,50	3,42	27,66	17,71	-1,10	27,41	18,75	-28,07	24,69

• COMPLEJO QRS

GRUPOS	%	QRSon		%	QRSoff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	47,00	0,64	5,13	86,00	4,59	7,07
G2	2,00	26,67	5,96	2,00	-5,17	10,11

G3	48,00	2,76	8,57	9,00	-3,67	17,70
G4	3,00	32,18	14,98	3,00	-9,51	16,14

- ONDA T

GRUPOS	%	Ton		%	Tpeak		%	Toff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	32,56	4,22	19,76	50,51	6,45	6,04	74,75	-0,02	14,46
G2	46,51	36,47	20,42	0,00	0,00	0,00	10,10	-14,83	20,21
G3	4,65	-3,55	58,82	37,37	5,64	16,83	8,08	-2,66	50,67
G4	16,28	36,06	52,18	12,12	14,35	35,65	7,07	16,71	42,39

VÌTEK [8]

- ONDA P

GRUPOS	%	Pon		%	Ppeak		%	Poff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	42,71	7,74	8,75	51,04	5,63	5,70	23,96	8,43	9,18
G2	12,50	-14,89	8,30	0,00	0,00	0,00	30,21	19,03	8,96
G3	23,96	5,85	20,65	35,42	3,44	15,57	23,96	5,91	20,69
G4	20,83	22,34	24,02	13,54	7,04	28,62	21,88	17,86	21,97

- COMPLEJO QRS

GRUPOS	%	QRSon		%	QRSoff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	48	1,74	5,05	82	0,43	6,57
G2	1	15,33	4,71	1	-19,20	11,09
G3	49	3,11	3,11	12	-3,18	-3,18
G4	2	-15,64	24,34	5	3,26	19,57

- ONDA T

GRUPOS	%	Ton		%	Tpeak		%	Toff	
		μ (ms)	σ (ms)		μ (ms)	σ (ms)		μ (ms)	σ (ms)
G1	42,86	-0,60	19,55	48,45	6,13	5,81	55,67	6,15	12,44
G2	21,43	22,96	19,34	1,03	110,00	2,83	21,65	28,79	14,35
G3	14,29	-0,32	50,61	29,90	1,10	21,71	9,28	-4,57	43,53
G4	21,43	-15,62	46,81	20,62	3,81	39,28	13,40	-7,72	50,68

HUGHES [9]• **ONDA P**

		Pon			Poff	
GRUPOS	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	57,89	-0,26	8,74	72,92	-0,44	7,69
G2	4,21	-29,38	10,21	4,17	14,54	9,75
G3	26,32	-0,83	23,98	16,67	-1,28	18,20
G4	11,58	1,31	29,20	6,25	15,72	41,24

• **COMPLEJO QRS**

		QRSon			QRSoff	
GRUPOS	%	μ (ms)	σ (ms)	%	μ (ms)	σ (ms)
G1	60,00	1,62	5,07	76,00	-0,21	6,58
G2	1,00	16,40	5,97	6,00	-22,67	7,31
G3	37,00	1,55	1,55	10,00	1,01	1,01
G4	2,00	33,47	10,89	8,00	-33,38	25,33

• **ONDA T**

		Toff	
GRUPOS	%	μ (ms)	σ (ms)
G1	59,60	-2,99	13,19
G2	22,22	-23,95	19,88
G3	6,06	2,13	38,23
G4	12,12	-22,98	43,12

B. ANEXO 2

I. RESULTADOS PUBLICADOS

i. ALGORITMOS DE LA LITERATURA

Varios documentos de la literatura se han considerado para estudiar diferentes métodos de detección de la segmentación automática de ECG. Algunos de ellos publicaron sus resultados, la base de datos utilizada y algunas otras características que se resumen en la siguientes tablas. Las tablas están separadas en las tres ondas principales, según la función del algoritmo.

• COMPLEJO QRS

Author/ Year	Methods	Results							
		QTDB				CSEDB			
		QRS _{on}		QRS _{off}		QRS _{on}		QRS _{off}	
		$\mu \pm \sigma$ (ms)	Se (%)	$\mu \pm \sigma$ (ms)	Se (%)	$\mu \pm \sigma$ (ms)	Se (%)	$\mu \pm \sigma$ (ms)	Se (%)
Laguna/1990	-First derivate								
Murthy/1992	-Discrete Fourier transform (DFT)								
Laguna/1994	Multilead ECG signals -Second order band-pass filter -low-pass differentiation - Adaptive Threshold	-4.1 ± 9.0				-2.1 ± 7.4		-0.2 ± 7.9	
Clavier/1996	-HMM								
Brooks/1996	-Best-basis algorithm								
Krim/1996	-Best local trigonometric basis								
Chazal/1996	Multilead ECG signals -First derivate and thresholding					0.1 ± 6.4 (2 σ (ms))		0.0 ± 9.8 (2 σ (ms))	
Sahambi/ 1997	-Dyadic wavelet transform (DTW)					± 2.0		± 4.0	
Jane/1997	-Low pass differentiation (LPD) -Automatic Threshold Bases Detector	-7.8 ± 10.9	99.88	-3.6 ± 10.7	99.88				
Vullings/1998	-Dynamic time warping (DTW) -Piecewise linear approximations (PLA)	-0.83± 10.58		-2.34± 13.90					
Stamkopoulos/ 2000	-Autoregressive filter -HMM (Viterbi algorithm)	-Results are not seriously affected by low signal to noise ratio -Is independent of signal changes in time because of its adaptively							
Martinez/2000	-Dyadic discrete WT (quadratic spline)	4.6 ± 7.8	97.8	0.8 ± 9.0	99.2				
Kunzmann/ 2002	-MOBD (Multiplication of Backward Difference)	-20 ± 10??	99.01	26 ± 11??	99.18				
Schreier/ 2003	-Short time windowing -Modified threshold method: Amplitude calculation.	2.0 ± 11.9	99.83			-0.6 ± 6.4	100		
Hughes/ 2003	-Undecimated WT -HSMM								
Martinez JP/ 2004	-Discrete Wavelet transform (DWT) -Searching window, specific threshold .	4.6 ± 7.7	99.97	0.8 ± 8.7	99.97	1.3 ± 6.3		5.8 ± 10.9	
Last /2004	-Multi-component based Cross Correlation algorithm	±6.6		± 6.9					
Krimi / 2004	-WT -HMM (viterbi algorithm)	-5.8 ± 31.1	95.34						
Vitek/ 2004	- Continuous wavelet transform (CWT)					0.4 ± 4.0		-0.3 ± 5.0	
Madeiro/ 2005	-Wavelet transform (WT) (derivative of Mexican Hat) -Adaptive threshold	-3.4 ± 11.6		-6.5 ± 12.3					
Dumot/ 2005	-Evolutionary Algorithm (EA) -Wavelet Transform (DWT) (based on Martinez et al (32))	0.3 ± 6.6	100	-1.9 ± 8.3	100				
Sun/2005	-Multiscale morphological derivative (MMD) (erosion and dilation)	3.5 ± 6.1	100	2.4 ± 10.3	100				
Thomas/2005	-Continuous HMM (Bayesian algorithm) - WT (Haar wavelet) -One particular HMM for each lead and find	The "cluster" approach gives significantly better results than the "generic" method but presents the drawback of having a higher computation cost.							

	the mean										
Thomas/2006	-CWT (Haar wavelet) -Bayesian HMM										
Hughes/ 2006	-Undecimated wavelet transform -Hidden Markov model (HMM) (Viterbi algorithm) -Use of minimum state duration constraint.										
Vaessen/2006	- Multi-resolution WT - HSMM - WTSign method	HSMM Single Set	9.9 ± 7.2	99.95							
		HSMM Concatenated Set	12.9 ± 13.7	99.94							
		WTSign	-5.8 ± 31.1	95.34							
Zifan /2006	-Adaptive piecewise constant approximation (APCA) -Piecewise derivative dynamic time warping (PDDTW)		-5.2 ± 3.6							-2.1 ± 11.2	
Andreao/2006	-Dyadic WT -HMM	DOC	13.3 ± 7.7							1.6 ± 8.9	
		MHat	3.7 ± 7.5							-9.0 ± 9.0	
		Quadratic b-spline	12.6 ± 7.8								-6.2 ± 8.9
		Morlet	1.8 ± 7.8								-15.1 ± 8.8
		Paul real	8.8 ± 7.9								-15.3 ± 8.8
		Paul magnitude	15.2 ± 7.5								0.4 ± 9.1
		DOG+MHat	14.8 ± 7.4								-5.9 ± 8.7
Andreao/2006	-Hidden Markov Model (HMM) (on-line adaptation) -WT(Mexican hat)	Generic HMM training	11.7 ± 8.4							2.9 ± 10.5	
		Individual's HMM training	4.7 ± 7.8							-4.2 ± 8.9	
		Generic HMM adapted to each individual	9.1 ± 7.6								2.6 ± 10.2
Andrade/2006	-Discrete wavelet transform (DWT) (Daubechies 4) -Inverse discrete wavelet transform (IDWT) -Windowing and thresholding										
Hayn/ 2006	- Amplitude differences range curve -wings function	7.5 ± 12.6	95	5.7 ± 15.1	95	-2.3 ± 6.8	95		-5.6 ± 4.7	95	
Christov/2006	-Find isoelectric line -Minimum value of the angle between two segments	0.46 ± 4.84 PTB ECGDB									
Illanes/ 2007	- Auxiliary signal (Envelope of the ECG) -Windowing -Hypothesis testing (detect mean changes)	0.6 ± 7.2								-0.9 ± 8.2	
Illanes/ 2008	-Envelope QRS complex: Hilbert transform -windowing -Computation of the area indicator	-2.6 ± 7.1								0.7 ± 8.0	
Lannoy/ 2008	-WT (a stepwise forward selection procedure to automatically select the optimal WT) -HMM										
Frenay/ 2008	-ECG signal and its derivative -Hidden Markov models -Emission modeling - Finite differences	Reduce # of parameters (processing time)									
Chouhan/2008	-Modified definition of slope of the ECG signal -Adaptive quantized threshold							-7.5 ± 6.6		0.9 ± 9.2	
Dumont/2008	-Evolutionary algorithm (EA) -Dyadic WT (inspires in Martinez (32))(quadratic spline)									For the standard deviation, the median is lower for Pon, Peak, Poff, QRson and Tpeak.	
Sayadi/2009	-Combination of five Gaussian kernel to represent a single ECG cycle -Model-based Bayesian framework -Modified extended Kalman filter (EKF)										
Ghaffari/2009	- Multiple Higher Order Moments (MHOM) method -Hilbert transform - α -level Neyman-Pearson classifier -Discrete Wavelet-derived multiple skewness-kurtosis based metric	-0.6 ± 3.3	99.97	-0.1 ± 5.4	99.97						
Vitek/2009	-CWT -Global multilead positions were determined from singlelead positions by using special selection rule.							1.5 ± 4.4		2.5 ± 9.7	

Boichat/2009	-Wavelet Transform -Wearable embedded sensor platform		3.9 ± 6.9	100	3.5 ± 8.3	100				
Almeida/2009	-Multilead strategy using spatially projected leads		7.5 ± 11.2	97	6.1 ± 12.3	99	→Best marks			
	-Wavelet transform loops		6 ± 8.2	100	2.8 ± 8.7	100				
Mukhopadhyay /2009	-First derivative -Hilbert Transform -Slope reversal -Adaptative Threshold		Real time ECG signal processing							
Vitek/ 2010	-Continuous wavelet transform (CWT) (bior1.5/scale15) -Singlescale approach(one optimal scale for each waveform)						0.3±4.0	99.19	0.8±4.7	99.19
Martinez A. /2010	-Phasor Transform (PT)	PT on re-annotated QTDB	-1.6 ± 3.3	99.91	-2.8 ± 4.0	99.91				
		PT on originally QTDB	-0.2 ± 7.2	99.85	2.5 ± 8.9	99.85				
Illanes-Manriquez/ 2010	-Abrupt (mean)change detection -Statistical hypothesis (CUSUM) -First and second derivative(in 2 auxiliary signals) -Multi-lead ECG processing									
Shi/2010	-Hidden Markov Model -Neural Network -Wavelet transform									
Gupta/ 2011	-Derivative-based approach -Magnitude and slope threshold based method									
Di Marco/ 2011	-Linear algebra advanced approach -WT (on-line ECG delineation)		-5.1 ± 7.2	100	0.9 ± 8.7	100				
Rincon/ 2011	-Multilead digital WT - Root-mean squared (RMS) -based multilead algorithm (real-time multilead ECG delineation)		3.4 ± 7.0	99.97	3.5 ± 8.3	99.97				
Madeiro/ 2011	-First-derivative -Hilbert Transform -Wavelet Transforms (Mexican hat wavelet) -Adaptive threshold -Surface indicator techniques		2.85 ± 9.90		2.83 ± 12.26					

• ONDA P

Author/ Year	Methods	Results									
		QTDB						CSEDB			
		P _{on}		P _{off}		P _{peak}		P _{on}		P _{off}	
		μ ± σ (ms)	Se (%)	μ ± σ (ms)	Se (%)	μ ± σ (ms)	Se (%)	μ ± σ (ms)	Se (%)	μ ± σ (ms)	Se (%)
Laguna/1994	Multilead ECG signals -Second order band-pass filter -low-pass differentiation - Adaptative Threshold							1.0±7.9		-1.0±5.1	
Sahambi/1997	-Dyadic wavelet transform -1 st derivative of a Gaussian fun. and search window							±4.0		±6.0	
Jane/1997	-Automatic Threshold Bases Detector -Low pass differentiation (LPD)	10.3± 14.8	96.18	-5.73± 13.6	97.01	-0.48± 10.96	97.01				
Vullings/1998	-Dynamic time warping (DTW) -Piecewise linear approximations (PLA)	8.17± 19.16		5.44± 13.64		5.73± 15.87					
Soria/1998	-Adaptive filtering -Least-mean-square algorithm -First derivative										
Ronan/1999	-Wavelet Transform (WT) (Haar wavelet) -Hidden Markov Model (HMM)										
Martinez/2000	-Dyadic discrete WT (quadratic spline in first 4 scales) -Apatative thresholding										
Kunzmann/ 2002	-MOBD (Multiplication of Backward Difference) -HighThres and LowThres	3±68 ??	69.33	-19±35 ??	77.58	-12±40 ??	73.81				
Almeida/2003	-Dyadic discrete WT multiscale methodology (quadratic spline wavelet) -Apatative thresholding	2.0±14.8	98.87	1.9±12.8	98.75	3.6±13.2	98.87				
Martinez/2004	-Discrete Wavelet transform (DWT)	2.0±14.8	98.87	1.9±12.8	98.75	3.6±13.2	98.87	-4.9±5.4		-1.0±6.4	

	-Searching window, specific threshold											
Last/2004	-Multi-component based Cross Correlation algorithm		±11.9		±11.6		±7.8					
Dumot/ 2005	-Evolutionary Algorithm (EA) -Wavelet Transform (DWT) (based on Martinez (32)) - Method for correct definition of thresholds for each wave and definition of temporal search window		1.9±11.8	98.79	3.1±10.2	98.58	1.4±9	98.39				
Sun/ 2005	-Multiscale morphological derivative (MMD) (erosion and dilation) -Adaptative thresholding		9.0±9.4	97.2	12.8±13.2	94.8						
Singh />2005	-Time derivative (derivative curve analysis) -Adaptive thresholding -Position where vertical offset in maximum		5.18±8.1		4.4±6.29							
Zifan/ 2006	-Adaptive piecewise constant approximation (APCA) -Piecewise derivative dynamic time warping (PDDTW)		10.3± 14.1		- 5.7±13.6		3.21± 13.5					
Andreao/ 2006	-Dyadic WT -HMM	DOC	13.4± 16.3		2.2±11.0							
		MHat	15.7± 13.6		-							
		Quadratic b-spline	13.8± 15.1		2.0±11.0							
		Morlet	30.9± 13.6		4.6±10.7							
		Paul real	21.6± 17.4		4.1±10.5							
		Paul magnitude	21.6±17.4		-							
		DOG+MHat	17.5± 15.0		0.7±10.4							
Andreao/2006	-Hidden Markov Model (HMM) -WT(Mexican hat)	Generic HMM training	16.0±18.2		-2.3±-15.2							
		Individual's HMM training	1.2 ±14.4		-							
		Generic HMM adapted to each individual	12.5±13.8		5.4±11.0							
Andrade/ 2006	-Discrete wavelet transform (DWT) (Symlet 7) -Inverse discrete wavelet transform (IDWT) -Delete QRS complex and T wave - Windowing and thresholding											
Hayn/ 2006	- Amplitude differences range curve -Wings function		1.4±28.3		10.0± 25.2				-20.2 ±21.6	8.7±16.0		
Chouhan/2008	-Modified definition of slope of the ECG signal -Adaptive quantized threshold		3.2±9.2		9.4±27.6							
Ghaffari/ 2009	- Multiple Higher Order Moments (MHOM) method -Hilbert transform - α-level Neyman-Pearson classifier -Discrete Wavelet-derived multiple skewness-kurtosis based metric		-1.1±3.4	99.69	-0.1 ±3.1	99.69	3.4±6.3	99.69				
Vitek/ 2009	-CWT - Multilead segmentation								1.1±5.9	2.0±13.5		
Boichat/2009	-WT -Wearable embedded sensor platform		8.1 ±11.1	99.94	1.6 ±10.2	99.94	10.4±9.0	99.91				
Vitek/2010	-Continuous wavelet transform (CWT) (bior1.5/scale41) -Singlescale approach (one optimal scale for each waveform)								1.4±6.1	98.17	1.2±6.1	98.17
Martinez/2010	-Phasor Transform (PT)	PT on re-annotated QTDB	-3.2±7.7	99.27	-0.2±3.5	99.27	1.1±2.0	99.27				
		PT on originally QTDB	2.6±14.5	98.65	0.7±14.7	98.65	32±25.7	98.65				
Lin/2010	-Bayesian algorithm -Markov chain Monte Carlo method (Partially collapsed Gibbs sampler)		3.7±17.3	98.93	-	98.93	4.1±8.6	98.93				
Di Marco/2011	-Linear algebra advanced approach -WT (on-line ECG delineation)		-4.5±13.4	98.15	- 2.5±13.0	98.15	-4.7±9.7	98.15				
Almeida/2010	-Spatially Projected Leads -Wavelet Transform Loops -Multilead methodology (ML)		5.5±23.6	2812/ 2983 94	3.7±16.9	2983/ 2801 94			2.2 ±5.6	22/26 85	1.8±6.7	24/27 89
Lin/ 2011	-Bayesian detection-estimation algorithm -Block Gibbs Sampler		1.7±10.8	99.60	2.5±11.2	99.60	2.7±8.1	99.60				
Rincon/2011	-Multilead digital WT -Root-mean squared (RMS)-based multilead algorithm (real-time multilead ECG delineation)		8.6 ± 11.2	99.87	0.9±10.1	99.91	10.1±8.9	99.87				

• ONDA T

Author/ Year	Methods	Results							
		QTDB						CSEDB	
		T _{on}		T _{off}		T _{peak}		T _{off}	
		$\mu \pm \sigma$ (ms)	Se (%)	$\mu \pm \sigma$ (ms)	Se (%)	$\mu \pm \sigma$ (ms)	Se (%)	$\mu \pm \sigma$ (ms)	Se (%)
Laguna/1994	Multilead ECG signals -Second order band-pass filter -low-pass differentiation -Adaptative Threshold			11.6 ±28.2				1.8 ±10.5	
Sahambi/1997	-Dyadic wavelet transform -1 st derivative of a Gaussian fun. and search window							±20.0	
Jane/1997	-Low pass differentiation (LPD) -Adaptative Threshold	16.0 ±29.8	98.00	18.7 ±29.8	98.92	23.3 ±28.3	98.80		
Vullings/1998	-Dynamic time warping (DTW) -Piecewise linear approximations (PLA)	-14.03 ±31.26		9.39 ±48.98		-7.78 ±35.3			
Soria/1998	-Adaptive filtering (beginning of P and the end of T)								
Daskalov/ 1999	-Angle between adjacent slopes -Wings function (<i>T Offset</i>)			13.5± 14.8	?DB?				
Vila/ 2000	-1 st derivative and 2 st derivative	20.9 ±29.6	99.2	0.8 ±30.3	92.6	-12 ±23.4	92.6		
Martinez/2000	-Dyadic discrete WT (quadratic spline)			-0.6 ±22.6	97.0	-7.4 ±13.8	98.1		
Bystricky/2002	-Neural networks			12±15					
Kunzmann/ 2002	-MOBD (Multiplication of Backward Difference)			-68±46	77.77	-40 ±35	86.48		
Strumillo/2002	-Nonlinear signal decomposition method based on nested median filters							±14.2	
Almeida/2003	-Dyadic discrete WT multiscale methodology (quadratic spline wavelet) -Windowing and thresholding			-1.6± 18.1	99.77	0.2± 13.9	99.77		
Schreier/2003	-Short time windowing -Modified threshold method: Amplitude calculation)			2.98± 35.3	98.31			-2.0± 10.6	100
Martinez JP /2004	-Discrete Wavelet transform (DWT) -Searching window, specific threshold (wide variety of waves)			0.2± 13.9	99.77			1.3± 21.8	
Last/ 2004	-Multi-component based Cross Correlation algorithm			±14.6		±8.2			
Krimi />2004	-Wavelet Transform -HMM (viterbi algorithm)			45± 77.3	86.16				
Vitek/>2004	- Continuous wavelet transform (CWT) (scale 41) -Multilead segmentation							2.0 ±12.4	
Krimi/ 2005	-Adaptation tresholding of MOBD								
Dumot/ 2005	-Evolutionary Algorithm (EA) -Wavelet Transform (DWT) (based on Martinez (32)) - Method for correct definition of thresholds for each wave and definition of temporal search window			3.5± 24	97.09	0± 14.3	98.77		
Sun/ 2005	-Multiscale morphological derivative (MMD) (erosion and dilation) -Moving window-thresholding	7.9± 15.8	99.8	8.3± 12.4	99.6				
Singh/>2005	-Time derivative (derivative curve analysis) -Adaptive thresholding -Position where vertical offset in maximum	1.1± 9.4		6.1± 11.2					
Zhang/2006	-The computation of an indicator related to the area covered by the T-wave curve (the max=T _{off})			0.34± 17.43					
Chen/2006	-Wavelet Transform -Multiscale Differential Operator (MOD)	-7.9± 11.3		-1.8± 16.1		-0.9± 13.1			
Vaessen/ 2006	- Multi-resolution WT - HSMM - WTSign method	HSMM Single Set		0.8± 22.7	95.68				
		HSMM Concatenated Set		9.9± 47	84.05				
		WTSign		45±77.3	86.16				
Zifan/2006	-Adaptive piecewise constant approximation (APCA) -Piecewise derivative dynamic time warping (PDDTW)	-11.6± 28.6		6.7± 33.5		-4.8± 29.9			
Andreao/2006	-Dyadic WT -HMM	DOC		-18.4± 10.1		-17.1± 23.6			
		MHat		-18.9± 7.9		-5.1± 20.7			
		Quadratic b-spline		-20.3± 9.0		-6.9± 23.4			
		Morlet		-35.9± 7.3		-28.0± 38.8			

		Paul real	-30.1± 7.5		-26.8± 21.1				
		Paul magnitude	-19.1± 10.5		-18.6± 22.6				
		DOG+MHat	-9.9± 8.7		1.5± 19.0				
Andreao/2006	- HMM (on-line adaptation) - WT(Mexican hat)	Generic HMM training	-15.1± 24.0		3.1± 29.9				
Individual's HMM training		-13.9± 18.0		14.9± 24.0					
Generic HMM adapted to each individual		-9.8± 9.3		12.1± 21.5					
Andrade/2006	-Discrete wavelet transform (DWT) (Symlet 7) -Inverse discrete wavelet transform (IDWT) -Delete QRS complex - Adaptive thresholding								
Hayn/2006	- Amplitude differences range curve - Wings function		-1.4± 45.8		2.8± 34.9				-3.8± 11.8
Christov/2006	-Find isoelectric line -Minimum value of the angle between two segments				1.28± 16.75	PTB ECGD B			
LLamedo/2006	-Multilead algorithm						0.1±10.2		
Chouhan/2008	-Modified definition of slope of the ECG signal -Adaptive quantized threshold								-18.5± 14.4
Vitek/2009	-CWT -Global multilead positions were determined from singlelead positions by using special selection rule								0.5± 12.2
Almeida/2009	-Multilead strategy using spatially projected leads -Wavelet transform loops		18.7± 27.6	84	7.9±21.7	97			
			11.7± 26.8	100	0±18.8	100	Best marks		
Boichat/2009	-Wavelet Transform -Wearable embedded sensor platform				-0.5 ±16.2	99.97	4.1±12.5	99.97	
Ghaffari/2009	- Multiple Higher Order Moments (MHOM) method -Hilbert transform - α -level Neyman-Pearson classifier -Discrete Wavelet-derived multiple skewness-kurtosis based metric		-1.0 ±3.7	99.93	-0.1 ±5.2	99.93	-0.2 ±2.6	99.93	
Vitek/2010	-Continuous wavelet transform (CWT) (bior1.5/scale41) -Singlescale approach (one optimal scale for each waveform)								-2.2 ±12.2 98.38
Martinez A/ 2010	-Phasor Transform (PT)	PT on re-annotated QTDB			-2.5± 6.2	99.77	-2.5± 2.8	99.77	
		PT on originally QTDB			5.8± 22.7	99.20	5.8± 12.9	99.20	
Lin/2010	-Bayesian algorithm -Markov chain Monte Carlo method (Partially collapsed Gibbs sampler)		7.1± 18.5	99.01	4.3± 20.8	99.81	1.3± 10.5	99.81	
Di Marco/2011	-Linear algebra advanced approach -WT (on-line ECG delineation)				1.3± 18.6	99.77	-0.3± 12.8	99.72	
Guilak/2011	-Spline interpolation -Error metric -Knot location optimization								
Vazquez/ 2011	-Computation of Trapezium's areas	Best beat per record			-2.3±7.1				
		Best lead per record			-2.±16.5				
Lin/2011	-Bayesian detection-estimation algorithm -Block Gibbs Sampler		5.7± 16.5	100	2.7± 13.5	100	0.7± 9.6	100	
Rincon/2011	-Multilead digital WT -Root-mean squared (RMS)-based multilead algorithm (real-time multilead ECG delineation)				-2.4± 16.9	99.97	3.7± 13.0	99.97	