



**I
N
A
O
E**

Sistema biométrico basado en ECG e implementación en un sistema embebido con VHDL

por

Ing. Juan Carlos Bernal Romero

Tesis sometida como requerimiento parcial para obtener el grado
de:

Maestría en Ciencias en la especialidad de Electrónica

En el:

Instituto Nacional de Astrofísica, Óptica y Electrónica
Noviembre, 2020
Tonantzintla, Puebla

Asesor:

Dr. Juan Manuel Ramírez Cortés

©INAOE 2020

Todos los derechos reservados

El autor(a) otorga al INAOE permiso para la reproducción y
distribución del presente documento



Este trabajo está dedicado a mis seres queridos y a la vida, por cada enseñanza, oportunidad, reto y circunstancia que hacen de mi, la persona que soy y que quiero ser.

“... la única forma de hacer un gran trabajo es amando lo que hacen. Si todavía no lo han encontrado, sigan buscando. No se detengan, al igual que con los asuntos del corazón, sabrán cuando lo encuentren. Y al igual que cualquier relación importante, mejora con el paso de los años...” - Steve Jobs.

Agradecimientos

A mi familia, en especial a mi señora madre, por su apoyo incondicional y su dedicación. Cada logro alcanzado se debe también a sus sacrificios y a sus palabras de aliento.

Al doctor Juan Manuel, por su tiempo, su orientación, su motivación, su amistad, su disposición y sobre todo, por brindarme la confianza de desarrollar esta investigación.

A mis compañeros de camino por cada momento vivido, por su amistad y el apoyo mutuo.

Al INAOE y al CONACYT por incentivar las áreas de investigación y desarrollo profesional, que dan oportunidad a realizar esta maestría.

A los demás doctores con los que tuve la oportunidad de tomar clase, gracias por cada enseñanza y al personal administrativo, gracias por la ayuda brindada en todos los procesos realizados.

Índice general

Resumen	xv
1. Planteamiento Metodológico	1
1.1. Introducción	1
1.2. Planteamiento del Problema	3
1.3. Enfoque del problema	4
1.4. Estado del Arte	4
1.5. Justificación	9
1.6. Objetivos	10
1.6.1. General	10
1.6.2. Específicos	10
1.7. Estructura del documento	10
2. Sistema biométrico basado en ECG	13
2.1. Sistema biométrico	13
2.1.1. Propiedades de los rasgos biométricos	14
2.1.2. Estructura de un sistema biométrico	14
2.1.3. Modo de reconocimiento o funcionalidad biométrica	16
2.1.4. Aplicaciones de los sistemas de biometría	16
2.2. Electrocardiograma (ECG)	17
2.2.1. Anatomía y Fisiología del ECG	17
2.2.2. Morfología ECG y ritmo cardíaco	19
2.2.3. Sistemas de adquisición	20
2.2.4. Fuentes de variabilidad de la señal ECG	21
2.3. Pre-procesamiento	21
2.3.1. Filtrado	22
2.3.2. Normalización de amplitud	23
2.3.3. Detección del pico R	24
2.4. Técnicas de extracción de características	25
2.4.1. Serie temporal y señal aleatoria	27
2.4.2. Momentos estadísticos	28
2.4.3. Parámetros Hjorth	29

2.4.4.	Proceso aleatorio estacionario	30
2.4.5.	Autocorrelación	30
2.4.6.	Estimación espectral paramétrica	32
2.5.	Técnicas de toma de decisión y evaluación	35
2.5.1.	Matriz de confusión	36
2.5.2.	Medidas de asociación: distancia y similitud	38
2.5.3.	Métricas de rendimiento para procesos de Autenticación	40
2.5.4.	Métricas de rendimiento para procesos de Identificación	40
2.5.5.	Técnicas de clasificación	41
2.6.	Bases de datos ECG de dominio público	42
3.	Desarrollo experimental en Software	45
3.1.	Construcción de la base datos para el proceso de biometría ECG	45
3.1.1.	Selección de bases de datos ECG	45
3.1.2.	Consolidación de la base de datos ECG	47
3.2.	Implementación en software de la etapa de pre-procesamiento	48
3.2.1.	Desarrollo de la fase de filtrado y normalización de amplitud	48
3.2.2.	Desarrollo de la detección del pico R	48
3.2.3.	Detección fiducial del complejo PQRST promedio	50
3.3.	Planteamiento de validación cruzada mediante combinaciones	51
3.3.1.	Combinaciones posibles de la base de datos	51
3.4.	Desarrollo del sistema de Autenticación	53
3.4.1.	Métricas de asociación	53
3.4.2.	Parámetros de forma	53
3.4.3.	Proceso AC/AR	55
3.4.4.	Comparación de técnicas de extracción de características y métricas	58
3.4.5.	Sistema biométrico de autenticación propuesto	59
3.5.	Desarrollo del sistema de identificación	62
3.5.1.	Identificación con LDA	62
3.5.2.	Identificación con una red neuronal	63
3.5.3.	Identificación con k NN	64
3.5.4.	Sistema biométrico de identificación propuesto	66
4.	Implementación en Hardware	69
4.1.	Sistemas digitales	69
4.2.	Lógica programable	70
4.2.1.	Arreglos de compuertas programables en campos (FPGA)	71
4.3.	Lenguajes de descripción de hardware (HDL)	72
4.4.	Sistema embebido con FPGA	72
4.5.	Desarrollo en hardware	73
4.5.1.	Adquisición - Comunicación UART	74
4.5.2.	Filtrado de fase cero y normalización de amplitud	74
4.5.3.	Detección y alineamiento de los complejos PQRST	74
4.5.4.	Extracción de características	75
4.5.5.	Distancia Mahalanobis	75
4.5.6.	Toma de decisión	77

4.6. Tiempos de ejecución	77
4.7. Recursos utilizados	78
5. Conclusiones y trabajo futuro	81

Índice de tablas

1.1. Estado de arte de investigaciones de biometría basada en ECG.	7
2.1. Resumen de las características de las bases de datos con señales cardíacas más relevantes disponibles públicamente.	43
3.1. Información de las bases de datos seleccionadas para la consolidación.	46
3.2. Base de datos consolidada para biometría ECG.	47
3.3. Longitudes de tiempo de la señal ECG para el reconocimiento biométrico.	47
3.4. Coeficientes del filtro IIR pasa-banda de 1 a 30 Hz.	48
3.5. Coeficientes del filtro IIR pasa altas a 10 Hz.	49
3.6. Resultados del estudio de la variación de la señal a estimar y el número de coeficientes del proceso AR, implementando los métodos de Yule-Walker y Burg para la estimación, en observaciones con duración de 3 s de adquisición para 140 personas.	55
3.7. Resultados del estudio de comparación de técnicas de extracción de características y métricas de asociación para el proceso de autenticación de la base de datos de 140 personas.	59
3.8. Resultados del proceso de autenticación propuesto para 140 personas con una extracción de características de 10 coeficientes y la distancia de Mahalanobis como métrica de asociación.	61
3.9. Resultados del proceso de autenticación para diferentes longitudes de población de la base de datos en los tres tiempo de adquisición, con una extracción de características de 10 coeficientes y la distancia de Mahalanobis como métrica de asociación.	61
3.10. Resultados del proceso de identificación con LDA para 140 personas, con la extracción de características propuesta de 10 coeficientes.	63
3.11. Resultados del proceso de identificación con la red neuronal para 140 personas, con la extracción de características propuesta de 10 coeficientes.	63
3.12. Resultados del proceso de identificación con k NN para 140 personas, con la extracción de características propuesta de 10 coeficientes y la distancia de Mahalanobis como métrica de asociación.	64

3.13. Resultados del proceso de identificación con k NN para diferentes longitudes de población de la base de datos en los tres tiempo de adquisición, con una extracción de características de 10 coeficientes y la distancia de Mahalanobis como métrica de asociación.	66
4.1. Tiempos de ejecución en ciclos de reloj para la implementación en la lógica programable del pre-procesamiento, extracción de características y cálculo de la distancia Mahalanobis.	77
4.2. Recursos utilizados para la implementación en la lógica programable del pre-procesamiento, extracción de características y cálculo de la distancia Mahalanobis.	78

Índice de figuras

1.1.	Número de investigaciones respecto al tiempo de registro ECG adquirido para la detección del complejo cardíaco y extracción de características en el estado del arte de sistemas biométricos con 50 o más personas a reconocer.	9
2.1.	Estructura común de un sistema biométrico basado en [1–3].	15
2.2.	Aspectos importantes en la anatomía y fisiología del ECG. (a) División anatómica del corazón, en azul la mitad derecha y en rojo la mitad izquierda y (b) división del sistema nervioso.	18
2.3.	Ciclo o complejo cardíaco (PQRST) visto con la derivación I. (a) Complejo cardíaco en función del tiempo y (b) representación espectral de las tres ondas que conforman el complejo cardíaco.	19
2.4.	Filtro pasa-banda de 1 a 30 Hz para una señal ECG de longitud finita de tiempo de adquisición. (a) Señal ECG sin filtrado, (b) filtrado con fase lineal de un filtro FIR, (c) filtrado con fase no lineal de un filtro IIR y (d) Filtrado con fase nula o fase cero mediante el algoritmo de filtrado hacia adelante y hacia atrás de un filtro IIR.	22
2.5.	Resumen de técnicas de extracción de características y decisión.	26
2.6.	Aplicación de la estadística descriptiva al complejo cardíaco. (a) Serie temporal del complejo PQRST y (b) función de densidad de probabilidad de la distribución de amplitudes del complejo PQRST en rangos de 0.5 mV.	28
2.7.	Representación de un sistema LTI.	32
2.8.	Matriz de confusión para verificación e identificación.	36
3.1.	Obtención de \mathbf{x}_{QRS} y \mathbf{x}_{dQRS}	49
3.2.	Obtención de \mathbf{x}_{TNL} , \mathbf{x}_{DM} y τ_{umbral}	49
3.3.	Obtención de $\mathbf{x}_{digital}$ y el tren de impulsos \mathbf{x}_R	50
3.4.	Detección de complejos PQRST de una observación cardíaca de 10s para un sujeto seleccionado de forma aleatoria. (a) Alineamiento de 11 complejos PQRST detectados y (b) complejo PQRST promedio.	51
3.5.	Detección de complejos PQRST promedio para las 10 observaciones de 4 personas de la base de datos consolidada, tomando registros de 5s de duración.	52

3.6. Gráficas de dispersión de las combinaciones posibles en dos dimensiones de los 5 parámetros de forma para las 1400 observaciones con duración de 10s cada una.	54
3.7. Gráficas de los resultados del estudio para procesos AR indicados en la tabla 3.6.	56
3.8. Gráficas de dispersión de las combinaciones posibles en dos dimensiones de los 5 coeficientes del proceso AC/AR para las 1400 observaciones con duración de 10s cada una.	57
3.9. Gráficas de los resultados del sistema de autenticación para su fase de entrenamiento con adquisición de señales de 3, 5 y 10s.	60
3.10. Resultados del proceso de autenticación para diferentes longitudes de población de la base de datos en los tres tiempo de adquisición indicados en la tabla 3.9. .	62
3.11. Matrices de confusión normalizadas de la evaluación en la fase de prueba del proceso de identificación con k NN para 140 personas, resultados finales indicados en la tabla 3.12.	65
3.12. Resultados del proceso de identificación con k NN para diferentes longitudes de población de la base de datos en los tres tiempo de adquisición indicados en la tabla 3.13.	67
4.1. Diagrama de bloques del sistema biométrico implementado en un sistema embebido con FPGA.	73
4.2. Esquemático del análisis RTL de la implementación del módulo de filtrado de fase cero y normalización de amplitud.	74
4.3. Esquemático del análisis RTL de la implementación del módulo de detección y alineamiento de los complejos PQRST.	75
4.4. Esquemáticos del análisis RTL de la implementación de la extracción de características.	76
4.5. Esquemático del análisis RTL de la implementación del cálculo de la distancia Mahalanobis.	76

Resumen

El aumento en el diseño y la difusión de dispositivos portátiles de bajo costo para la adquisición y análisis de señales cardíaca, a aumentado los posibles escenarios de aplicación de los sistemas biométricos basados en electrocardiograma (ECG), generando actualmente la investigación sobre el rendimiento del sistema de autenticación e identificación ante fuentes de variabilidad cardíaca, diferentes longitudes de adquisición de la señal y diferentes longitudes de la base de datos, en sistemas con técnicas de extracción de características y toma de decisión que no utilicen muchos recursos para implementar en hardware.

Para la investigación desarrollada se consolidó una base de datos de 1400 registros ECG de 10 s cada uno para 140 personas sanas ante escenarios de variabilidad cardíaca, con la que se estudia un sistema biométrico de mundo cerrado y reconocimiento positivo. El sistema biométrico propuesto consiste en una extracción híbrida de 10 características conformadas por 5 parámetros de forma (asimetría, curtosis, actividad, movilidad y complejidad) y 5 coeficientes de un proceso AC/AR solucionado con el método de Yule-Walker, realizando una comparación del rendimiento del sistema ante técnicas de extracción de características como FFT y AC/DCT, donde la técnica propuesta obtiene el mejor resultado. Además se realiza el estudio del rendimiento del sistema ante diferentes métricas de asociación como es el caso de la distancia de correlación, dtw, euclidiana, Mahalanobis y de Pearson, donde la mejor métrica es la distancia de Mahalanobis. También se compara el rendimiento para la identificación con k NN, LDA y una red neuronal de 148 neuronas en su capa oculta con función de activación de base radial, donde el mejor resultado se obtiene con k NN.

El sistema de autenticación para 140 personas obtiene una EER de 4.88, 6.15 y 8.51 %, una TPR de 98.64, 98.25 y 97.37 % y una TNR de 94.79, 93.22 y 90.30 % para registros de 10, 5 y 3 s de duración de adquisición respectivamente en cada tasa mediante distancia Mahalanobis. Para el sistema de identificación de 140 personas se obtiene una IR de 94.63, 88.07 y 76.75 % para registros de 10, 5 y 3 s de duración de adquisición respectivamente mediante k NN ($k = 1$) con distancia Mahalanobis.

Los módulos de pre-procesamiento, extracción de características y métrica de asociación del sistema propuesto fueron implementados en VHDL con una representación numérica de punto fijo con formato 8.24. El sistema con adquisición de 10 s de señal ECG toma 189 093 ciclos de reloj para la ejecución del pre-procesamiento y extracción de características utilizando 50 630 LUT para lógica, 7816 LUT como memoria, 6451 registros y 240 DSP. El sistema con adquisi-

ción de 5 s de señal ECG toma 99 117 ciclos de reloj para la ejecución del pre-procesamiento y extracción de características utilizando 49 612 LUT para lógica, 4296 LUT como memoria, 6451 registros y 240 DSP. El sistema con adquisición de 3 s de señal ECG toma 63 375 ciclos de reloj para la ejecución del pre-procesamiento y extracción de características utilizando 49 142 LUT para lógica, 2536 LUT como memoria, 6451 registros y 240 DSP. Por último, el cálculo de la distancia Mahalanobis toma 159 ciclos de reloj y utiliza 2750 LUT para lógica, 48 LUT como memoria, 266 registros y 11 DSP.

Palabras claves: Biometría, biométrico, ECG, reconocimiento, autenticación, verificación, identificación, variabilidad, Mahalanobis, k NN, VDHL.

Planteamiento Metodológico

Contenidos del capítulo

- 1.1. Introducción
 - 1.2. Planteamiento del Problema
 - 1.3. Enfoque del problema
 - 1.4. Estado del Arte
 - 1.5. Justificación
 - 1.6. Objetivos
 - 1.7. Estructura del documento
-

1.1. Introducción

El aumento en el diseño y la difusión de dispositivos portátiles y de bajo costo para la adquisición y análisis de señales cardíacas, ha aumentado los posibles escenarios de aplicación de los sistemas biométricos basados en electrocardiografía (ECG), lo cual, ha generado el desarrollo de diversas investigaciones sobre la viabilidad de la señal cardíaca como rasgo biométrico. Tradicionalmente la señal cardíaca es usada para el diagnóstico médico y es adquirida con el sistema estándar médico de 12 derivaciones, estas 12 derivaciones son diferentes vistas eléctricas de la actividad del corazón. Para el diagnóstico médico computarizado la utilización de las 12 derivaciones es obligatoria [4], donde se implementan métodos estadísticos y redes neuronales artificiales para generar automáticamente el diagnóstico del estado de salud de la persona.

La señal cardíaca es por naturaleza una función cardiovascular que mide la vitalidad de la persona y es exclusiva en cada individuo, por lo tanto, es menos susceptible a la falsificación, dando más seguridad en los sistemas de reconocimiento. En el año 2001, se demostró que para fines biométricos es posible identificar a una persona mediante características extraídas de la señal cardíaca tomada con una sola derivación, siendo las extremidades superiores con la *derivación I*, la derivación más viable y cómoda para el desarrollo de procesos biométricos [5]. También se demostró hacia el año 2005, que las características extraídas de los puntos fiduciales del complejo cardíaco se distinguen de una persona a otra, además que son independientes de la ubicación del electrodo e invariantes a estados de ansiedad [6]. Dando como resultado que la

señal cardíaca sea uno de los rasgo biométricos más atractivos, prometedores y sobresalientes que hasta la actualidad aún se mantiene con respecto a las propiedades idóneas de las características biométricas [1, 5–10].

La señal cardíaca es uno de los rasgos biométricos más atractivos y alentadores para procesos de biometría y ha tenido múltiples investigaciones. Una corta línea de tiempo de los avances de los sistemas biométricos con señales ECG inicia hacia el año 2000, donde era común usar técnicas de correlación para clasificación de características fiduciales, luego, aproximadamente a partir de los años 2009 y 2010 hubieron grandes avances de forma masiva en técnicas fiduciales y no fiduciales con redes neuronales y clasificadores basados en métricas de distancia como sistemas de clasificación, después se paso de metodologías de aprendizaje automático (machine learning) a diversas metodologías de aprendizaje profundo (deep learning), aproximadamente a mediados del año 2016 y a tenido desde la fecha un gran número de aportes positivos a la investigación. La llegada al aprendizaje profundo fue producto de la indecisión entre las múltiples técnicas de extracción de características con sus ventajas y desventajas, por lo cual, se deja en manos del aprendizaje profundo el proceso de extracción y selección de características, que en algunos casos se toma como solución a la pregunta: ¿cuál es la mejor técnica de extracción de características?, pero teniendo presente que su costo en software y hardware aumenta considerablemente.

La señal cardíaca es un rasgo biológico bastante viable para procesos de biometría, en especial para estudios de rendimiento del sistema de reconocimiento ante diferentes técnicas de extracción de características y toma de decisión, donde es prudente tener en cuenta algunos aspectos: La condición física y de salud de las personas es un aspecto importante en los procesos de biometría con señales ECG, porque la señal ECG tiene índice de variabilidad a corto y largo plazo. La variabilidad a corto plazo, generalmente es causada por ejercicio físico y/o mental, por la postura al momento de tomar la señal, por fatiga, por emociones que generan variabilidad de la frecuencia cardíaca y por características y ubicación de los electrodos. En el caso de la variabilidad a largo plazo, es causada por los cambios en la anatomía del cuerpo a causa de la edad, el peso, la altura, las enfermedades, los tratamientos y medicamentos médicos, el estilo de vida, entre otros, lo que genera con el tiempo un cambio en la orientación del vector de conducción eléctrica del corazón, que significa una alteración de la forma de onda en la detección de la señal cardíaca. La variabilidad de la frecuencia cardíaca está fuertemente ligada al sistema nervioso autónomo del cuerpo humano, también tiene relación directa con el sistema respiratorio, en consecuencia, la forma de onda o morfología del complejo ECG sufre cambio livianamente ante escenarios de variabilidad a corto y largo plazo. En el ámbito de la biometría, una de las condiciones más estudiadas es la arritmia, que causa grandes variaciones en la frecuencia cardíaca a lo largo del tiempo y puede reducir constantemente el rendimiento de los sistemas biométricos basados en ECG [1].

El tipo, tamaño y número de electrodos utilizados al realizar el registro de la señal cardíaca también es importante en el proceso de biometría, además de si los electrodos son húmedos o secos, de contacto o no contacto y el posicionamiento en el pecho o las extremidades puede influir en el dominio del ruido y la forma de onda en la señal ECG. Por otra parte, la diversidad de personas y sus propias características pueden facilitar o dificultar el rendimiento de los sistemas biométricos, por lo cual, se ha demostrado que los sistemas o algoritmos de identificación

exitosos de vanguardia disminuyen su rendimiento significativamente cuando se evalúan bases de datos más grandes. La mayoría de las investigaciones de biometría con señales ECG reportan el uso de bases de datos de menos de 50 personas [1]. Lo anterior ha generado un nuevo reto al evaluar el rendimiento de los sistemas biométricos, consolidando bases de datos más grandes partiendo de las bases de datos públicas de señales cardíacas. En [11] realizaron una consolidación de señales cardíacas de bases de datos ya existentes, esta consolidación se realizó con el propósito de estudiar algoritmos de detección de la morfología QT en el complejo cardíaco en personas con varias condiciones de salud.

Se han desarrollado en los últimos años múltiples investigaciones con el propósito de implementar un sistema biométrico con orientación de desarrollo para sistemas de adquisición móviles o ambulatorios y de bajo costo, donde la duración del registro pueda ser de unos pocos segundos, además de tener la flexibilidad en movimiento, comodidad y robustez, desarrollando sistemas de adquisición *on-the-person* y *off-the-person* que permitan implementar y trabajar técnicas de extracción de características y toma de decisión adecuadas para construir un sistema biométrico basado en ECG de manera eficiente, accesible y de bajo costo.

1.2. Planteamiento del Problema

Con la utilización de técnicas de aprendizaje profundo, a la fecha parece estar completamente abarcado el estudio de los sistemas biométricos basado en señales ECG, pero la verdad es que no. Los sistemas biométricos basado en señales cardíacas se enfrenta a varios retos, la *seguridad* es uno de ellos, se refiere a la integridad del sistema ante ataques físicos o ciber-físicos que comprometan las señales o el sistema de biometría en general, afectando directamente el buen funcionamiento del mismo. La *privacidad* es otro de los retos, se relaciona a los aspectos legales y constitucionales de los derechos a la privacidad y al no reconocimiento público. Por último, están los retos relacionados al *rendimiento*, los cuales, se enfocan en aspectos como la exactitud, velocidad computacional, manejo de excepciones y costo del sistema en escenarios de autenticación e identificación. En esta investigación, por el momento solo nos interesa estudiar los retos de rendimiento, los cuales los agrupamos en tres grandes retos a atacar:

- **Reto 1:** Manejo de excepciones o vulnerabilidades a cambios en la señal ECG, que afectan directamente el rendimiento del sistema biométrico con respecto a la variabilidad a corto y largo plazo de la señal cardíaca con el tiempo o factores fisiológicos ante escenarios emocionales, el envejecimiento, la postura, la actividad física, la variabilidad normal del ritmo cardíaco o condiciones patológicas.
- **Reto 2:** El aumento del error de reconocimiento ante: (1) duraciones cortas de la ventana o registro de la señal adquirida para la extracción de características y (2) aumento en la cantidad de personas o sujetos a reconocer en el sistema biométrico.
- **Reto 3:** Velocidad y costo computacional para la implementación en software y hardware de las técnicas de procesamiento, segmentación, extracción de características y clasificación. Dicho costo es directamente proporcional a la longitud del vector de características.

Implementar metodologías de aprendizaje profundo ataca de manera eficiente el reto 1, pero se sabe de manera intuitiva que aumenta el costo computacional tanto en software como en hardware y además requiere de duraciones largas de la señal cardíaca para el entrenamiento de

los algoritmos. Registros de señal de larga duración generan robustez ante el reto 1, pero no atacan los demás retos. En el análisis cardíaco médico generalmente se estudian registros ECG de 10s, por lo tanto, se propone estudiar el rendimiento del sistema biométrico a registros de señal de menor duración. Estructurando así el planteamiento del problema para el reconocimiento biométrico con un solo rasgo biológico, en nuestro caso ECG, donde se planea atacar los 3 retos propuestos, buscando el estudio y elección de una técnica de pre-procesamiento, extracción de características y toma de decisión basado en un sistema de adquisición portátil, eficiente y de bajo costo para una base de datos grande, consolidada durante la investigación.

1.3. Enfoque del problema

Basados en la literatura existente sobre sistemas biométricos con ECG y analizando como atacan el planteamiento del problema, el enfoque de esta investigación se centra en responder a: *¿Qué técnica de pre-procesamiento, extracción de características y toma de decisión, tiene el mejor manejo ante los tres retos propuestos en el proceso de verificación e identificación de un sistema biométrico basado solo en ECG?*

1.4. Estado del Arte

La señal cardíaca es una señal generada por un órgano vital, que está siempre presente y disponible de manera continua, siendo un rasgo biométrico ubicuo durante la vida de las personas, que es difícil de imitar o falsificar. El ser humano por su naturaleza siempre esta evolucionando o adaptándose a las nuevas situaciones, por lo tanto, la señal ECG también; sufriendo adaptaciones, cambios o evoluciones a lo largo del tiempo, generando así un reto para la biometría. Esta adaptabilidad cardíaca a los hábitos, envejecimiento, estilos y condiciones de vida de las personas genera el problema de permanencia de los vectores de características extraídos y almacenados en los sistemas reconocimiento.

Por lo mencionado anteriormente y por los tres retos propuestos en el planteamiento, se realiza el estudio del estado del arte de las investigaciones realizadas hasta la fecha sobre biometría basada en ECG mediante metodologías de *aprendizaje supervisado*, con los siguientes criterios:

- Investigaciones con 50 o más sujetos a reconocer.
- Investigaciones que especifiquen la duración del registro ECG usado para la extracción de características, buscando registros por debajo de los 10s.
- Investigaciones que especifiquen la longitud del vector de características.
- Investigaciones que especifiquen el proceso implementado de extracción de características y proceso de toma de decisión.

Hasta la fecha no hay ninguna investigación que centre su atención en recopilar un estado del arte de investigaciones con más de 50 personas a reconocer, especificando la duración del registro de señal y la longitud del vector de características. El resultado de la investigación se refleja en la tabla 1.1, donde: **Invest.** se refiere a la investigación estudiada, especificando su año de publicación; **NS** es el número de sujetos usados en el sistema de reconocimiento; **TV** significa tiempo de registro, ventana o segmentación de la señal en s para la extracción de

características; **Ext. Caract.** para la técnica de extracción de características; **NC** es el número de características extraídas; **Toma de Decisión** es la técnica de toma de decisión; **IR** es el porcentaje de reconocimiento en el proceso de identificación y **EER** es la tasa de error igual de reconocimiento en el proceso de autenticación en su fase de entrenamiento.

Invest.	NS	TV [s]	Ext. Caract.	NC	Toma de Decisión	IR [%]	EER [%]
Barros (2020) [12]	1985	3	Fiducial del promedio de conjuntos de complejos PQRST	22	Random Forest	89.00	
Mancilla (2019) [13]	50	8.19	No fiducial: parámetros de forma + parámetros Hjorth, estadística descriptiva	6	dtw	82.14	10.83
Pal (2018) [14]	100	30	Fiducial del promedio de conjuntos de complejos PQRST	39	Distancia euclidiana		8.98
Lee (2018) [15]	55	10	Híbrida: segmentación temporal remuestreada de 3 intervalos RR	300	Distancia euclidiana	93.30	
Bassiouni (2018) [16]	90	10	Híbrida: fiducial + AC/DCT fusionadas con DWT	145	ANN	95.30	
Güven (2018) [17]	60	5	Híbrida: ensamble entre AC/DCT, MFCC y segmento temporal QRS	233	LDA + k NN ($k = 5$)	98.33	2.54
Tan (2017) [18]	184	≈ 10	Híbrida: fiducial + DWT (D2 a D5)	155	Random Forests + k NN	99.52	
Islam (2017) [19]	112	15	Híbrida: fiducial + coeficientes de AC + PCA	10	Distancia euclidiana		10.52
Louis (2016) [20]	1012	24	Híbrida: 1D multi-resolución LBP	2560	Bagging		7.89
Carreiras (2016) [21]	618	10	Fiducial del promedio de conjuntos de complejos PQRST	300	k NN ($k = 3$)	84.36	9.01

(Continúa en la página siguiente)

Invest.	NS	TV [s]	Ext. Caract.	NC	Toma de Decisión	IR [%]	EER [%]
Dar (2015) [22]	90	10	Híbrida: DWT (6 niveles, Haar) al complejo promedio PQRST	95	k NN	82.30	
Choudhary (2015) [23]	127	10	Fiducial del promedio de conjuntos de complejos PQRST	360	Correlación cruzada normalizada (NCC)		8.70
Brás (2015) [24]	52	20	Híbrida: Compresión relativa normalizada (NRC)	20	k NN ($k = 1$)	88.46	
Singh (2015) [25]	126	10	Híbrida: fiducial + coeficientes FFT	90	SVM		3.40
Coutinho (2013) [26]	51	10	Fiducial del promedio de conjuntos de complejos PQRST	53	k NN con distancia euclidiana + ZMCP	99.85	0.01
Belgacem (2013) [27]	120	60	Híbrida: fiducial + DWT (5 niveles, db3)	960	Random Forest (20 trees)	96.41	
Shen (2011) [28]	168	10	Fiducial del promedio de conjuntos de complejos PQRST	17	Correlación cruzada	95.30	
Safie (2011) [29]	112	10	Híbrida: Radio activo de pulso (PAR)	98	Distancia euclidiana		14.52
Odinaka (2010) [30]	269	15	Híbrida: STFT a promedio de conjuntos del complejo PQRST	2048	Modelos Gaussianos LLR	76.90	5.58
Fang (2009) [31]	100	15	Híbrida: Retrato de espacio de fase o reconstrucción de espacio de fase (PRS) del promedio de conjunto del complejo PQRST	8	RBFN (10 neuronas ocultas)	86.00	

(Continúa en la página siguiente)

Invest.	NS	TV [s]	Ext. Caract.	NC	Toma de Decisión	IR [%]	EER [%]
Narain (2009) [32]	50	8	Fiducial del promedio de conjuntos de complejos PQRST	19	Coficiente de correlación de Pearson		2.00
Wubbeler (2007) [33]	74	10	Híbrida: 2D del promedio de conjunto de complejos QRS	100	k NN	98.10	2.80
Zhang (2006) [34]	502	10	Fiducial del promedio de conjuntos de complejos PQRST	14	Clasificador basado en el teorema de Bayes	85.30	

Tabla 1.1: Estado de arte de investigaciones de biometría basada en ECG.

La tabla 1.1 refleja las investigaciones de vanguardia hasta el año 2020, con bases de datos superiores o iguales a 50 personas, sin incluir investigación con metodologías de aprendizaje profundo en procesos de biometría ECG. En [15] se mostró que la distancia euclidiana presenta mejores resultados entre técnicas de toma de decisión como distancia coseno, correlación cruzada y *city block*. El estado del arte de biometría ECG para más de 50 personas, evidencia que en los procesos de toma de decisión, las métricas de distancia basadas en umbrales (como es el caso de k NN) son las más utilizadas tanto para identificación como para autenticación, concluyendo que la distancia euclidiana es mejor técnica que dtw para vectores de longitud fija de características.

En [31] implementaron redes neuronales como técnica de toma de decisión para 100 personas, pero presentó mejor rendimiento las métricas de distancia, adicionalmente concluyeron que las redes neuronales con función de activación de base radial presentan mejores resultados en biometría ECG. Las técnicas de toma de decisión como SVM y k NN son las más comunes, han demostrado su superioridad en el rendimiento, pero se le apuesta a las redes neuronales. En [17] se concluye que la extracción de características con coeficientes cepstrales en las frecuencias de mel (MFCC) no es una técnica que presente resultados favorables para biometría ECG.

Las investigaciones y los resultados de la tabla 1.1 reflejan las siguientes observaciones de importancia para esta investigación:

- Las técnicas fiduciales de extracción de características compensan de mejor manera los efectos generados por las fuentes de variabilidad de las señal cardíaca, pero generan costo computacional por las técnicas o algoritmos de detección del complejo PQRST y puntos fiduciales.
- Las técnicas no fiduciales aplicadas en ventanas como vistas holísticas temporales (segmentación) reducen el costo computacional al no tener la necesidad de detectar los puntos fiduciales pero no atacan las fuentes de variabilidad cardíaca, lo que ha generado que las investigaciones en los últimos años se enfoquen en la detección del complejo PQRST para extraer características.
- La mejor forma de atacar las fuentes de variabilidad cardíaca es extraer características

del complejo PQRST promediado de varios latidos del corazón (complejos PQRST). Este proceso se puede denominar como extracción de segmento local.

- Un sistema de reconocimiento tiene mejor rendimiento extrayendo características del complejo PQRST total que solamente del complejo QRS [35].
- El alineamiento de complejos PQRST o QRS para extraer un complejo promedio se debe hacer con respecto al pico R.
- Los sistemas de reconocimiento multimodal, ya sea con otro rasgo biológico como por ejemplo, la huella dactilar, la señal PPG u otra derivación del registro cardíaco, aumentan el rendimiento de reconocimiento.
- Ante las fuentes de variabilidad de la frecuencia cardíaca como el ejercicio, donde la onda T se mueve hacia el complejo QRS al aumentar la frecuencia del ritmo cardíaco, el segmento QT es el más afectado.
- Entre más complejos PQRST o QRS se promedien, mayor eficiencia tendrán las características extraídas, porque transmiten mayor información corporal-estática de la persona para la toma de decisión.
- La morfología del complejo QRS es fuertemente estable a los cambios de frecuencia cardíaca y a los cambios a través de los años.
- La extracción de características no fiducial de espacio dimensional de fase, genera mayor discriminación entre sujetos al crear nuevas dimensiones de información con los datos presentes, pero es computacionalmente costosa.
- Una base de datos que contenga varias sesiones de grabación de la señal cardíaca por sujeto ayuda a que el sistemas biométrico disminuya la variabilidad intra-clase. Pero aumentar la cantidad de personas a reconocer y la cantidad de ventanas por sujeto en el sistema, aumenta el error de reconocimiento, especialmente afectando más al proceso de identificación; el rendimiento en proceso de autenticación solo se ve afectado por el aumento del número de ventanas o número de sesiones por sujeto.
- Las medidas de centralización, dispersión y forma (incluyendo los parámetros de Hjorth) de la estadística descriptiva son muy eficientes para la extracción de características del segmento local PQRST en los sistemas de reconocimiento.
- Los momentos estadísticos como extracción de características en un sistema de reconocimiento son muy eficientes. La aplicación del segundo momento estadístico, como la secuencia de autocorrelación es una de las técnicas más llamativas tanto en rendimiento como en costo computacional, siendo una extracción de características con invarianza a la fuentes de variabilidad cardíaca [36].

En la figura 1.1, se resumen las 23 investigaciones estudiadas en la tabla 1.1, resaltando la duración del registro ECG de adquisición, para su debido procesamiento y extracción de características fiducial, no fiducial o híbrida. De las investigaciones de la tabla 1.1, solo tres trabajos extraen 10 o menos características para el proceso de reconocimiento y la mayoría de las investigaciones se centran en el procesamiento de señales cardíacas de 10 s de duración o segmentación, siendo muy pocas las investigaciones que implementan extracción de características en segmentaciones de menos de 10 s. Estos resultados de análisis del estado del arte hacen bastante viable la investigación hacia un sistema de biometría de corto tiempo de duración del registro ECG y una longitud pequeña del vector de características extraído para una base de datos amplia.

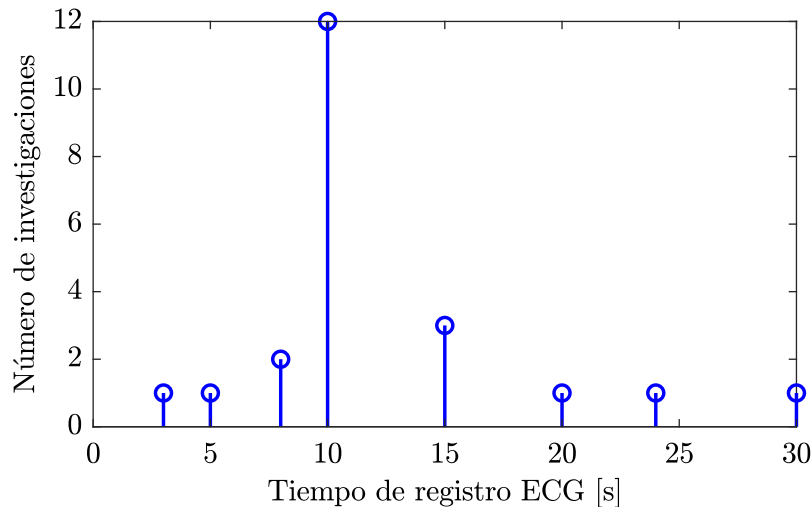


Figura 1.1: Número de investigaciones respecto al tiempo de registro ECG adquirido para la detección del complejo cardíaco y extracción de características en el estado del arte de sistemas biométricos con 50 o más personas a reconocer.

1.5. Justificación

Actualmente, la biometría basada en ECG se está enfrentando al reto de obtener el mejor rendimiento de reconocimiento en verificación como identificación, con la menor duración de adquisición o segmentación de la señal cardíaca posible en sistemas biométricos con bases de datos grandes y diferentes escenarios de adquisición, adicionalmente poder implementar en hardware dicho sistema, tanto de adquisición como de reconocimiento.

El enfrentar los retos propuestos basados en el estudio del estado del arte: orienta, motiva y justifica el aporte que se espera hacer con la investigación, dado que son muy pocas las investigaciones que han estudiado un posible sistema de biometría ECG con un número pequeño de características extraídas en registros cortos de tiempo de la señal cardíaca, con un procesamiento computacional viable hacia la implementación de forma accesible y económica, que esté desarrollado para ser compatible con sistemas de adquisición portátiles. Dado que hasta la fecha las investigaciones que han atacado los dos primeros retos propuestos, no satisfacen el tercer reto, ya sea por, una implementación de aprendizaje profundo o un costo computacional en tiempo y memoria considerable.

El consolidar una base de datos de señales ECG con varios escenarios de variabilidad a corto y largo plazo de personas sin ningún problema cardiovascular reportado, adquiridas con sistemas *on-the-person* y *off-the-person*, con la misma derivación y condiciones de adquisición en común, es un aporte considerable para la propia investigación y a los futuros estudios de biometría basados en ECG.

1.6. Objetivos

1.6.1. General

Analizar, estudiar e implementar una extracción de características híbrida y una técnica de toma de decisión para procesos de biometría en verificación e identificación basados solamente en ECG. Que permita combatir los errores generados por: la variabilidad a corto y largo plazo de la señal, la corta duración de señal adquirida y el aumento del número de personas en la base de datos, logrando un equilibrio entre rendimiento y costo computacional.

1.6.2. Específicos

- Consolidar una base de datos de registros ECG para el estudio de la variabilidad a corto y largo plazo de la señal cardíaca en personas sin ninguna enfermedad cardiovascular y con un sistema de adquisición portátil y de bajo costo que pueda ser replicado.
- Proponer una técnica de extracción de características híbrida para un proceso de biometría ECG, centrada en la detección fiducial del complejo PQRST, los momentos estadísticos de una serie temporal y los parámetros de un proceso autoregresivo.
- Estudiar y definir una métrica de asociación para procesos de verificación y una técnica de clasificación para procesos de identificación entre los vectores de características en la toma de decisión en un sistema biométrico basado en ECG.
- Diseñar e implementar en un sistema embebido con VHDL, los módulos de pre-procesamiento, extracción de características y la métrica de asociación para la toma de decisión del sistema biométrico propuesto.

1.7. Estructura del documento

El planteamiento para atacar los tres retos propuestos es: primero, consolidar mediante las bases de señales electrocardiográficas existentes y públicas, una base de datos amplia, con las mismas características de adquisición que permita tener varias grabaciones por sujeto, donde cada grabación esté asociada a un escenario de variabilidad a corto o largo plazo, segundo, elegir una extracción de características híbrida y de toma de decisión que ayude a atacar los tres retos, y tercero, implementar en un sistema embebido con VHDL los módulos de pre-procesamiento, extracción de características y métrica de asociación para la toma de decisión del sistema biométrico diseñado en su fase de prueba o test.

Para dicho planteamiento, el presente documento se estructura de la siguiente manera: el primer capítulo, es el planteamiento metodológico de la investigación incluyendo el estado del arte. El segundo capítulo, está centrado en la definición de un sistema biométrico basado en ECG, analizado a profundidad el marco teórico: del electrocardiograma, de las técnicas implementadas tanto para la extracción de características como para la toma de decisión en verificación como en identificación y sus métricas de rendimiento y evaluación. El tercer capítulo, está orientado al estudio, diseño, desarrollo, implementación y resultados del sistema biométrico en **Matlab**[®]. El cuarto capítulo, aborda la implementación en hardware del procesamiento realizado en el sistema biométrico en la fase de prueba o test en una tarjeta embebida *ZedBoard Zynq-7000*

SoC con FPGA de Xilinx[®], analizando su costo en recursos y tiempo para el procesamiento. Por último, se presentan las conclusiones y trabajos futuros de la investigación.

Sistema biométrico basado en señales electrocardiográficas

Contenidos del capítulo

- 2.1. Sistema biométrico
 - 2.2. Electrocardiograma (ECG)
 - 2.3. Pre-procesamiento
 - 2.4. Técnicas de extracción de características
 - 2.5. Técnicas de toma de decisión y evaluación
 - 2.6. Bases de datos ECG de dominio público
-

2.1. Sistema biométrico

En el mundo hay una gran diversidad de personas, pero lo que nos distingue de las demás es nuestra identidad. El poder determinar la identidad de una persona (identificación) o verificar el reclamo de dicha identidad (verificación o autenticación¹) se conoce como reconocimiento de personas. Una persona puede ser reconocida de tres formas: (1) por los conocimientos exclusivos de alguna información secreta, por ejemplo, el número de identificación personal o alguna clave/contraseña de identificación; (2) la posesión exclusiva de representaciones simbólicas, por ejemplo, una tarjeta de identidad, un pasaporte o un chip y (3) rasgos físicos o de comportamiento (reconocimiento biométrico), por ejemplo, la huella dactilar, la forma de caminar, el ADN, la voz, entre otros. Por lo tanto, el reconocimiento biométrico² se puede definir como la ciencia que busca establecer la identificación o la autenticación de un individuo basada en una (unimodal), en dos (bimodal) o más (multimodal) características físicas y/o de comportamiento de la persona, ya sea de manera totalmente automatizada o semiautomatizada [2].

Las dos primeras forma de reconocer a una persona mencionadas anteriormente, presentan ciertas desventajas, algunas de estas desventajas son la fácil falsificación, duplicación, alteración, robo y/o pérdida de la información o representación simbólica de la identidad, dando así una

¹Autenticación y autenticación son sinónimos, pero es más utilizada en biometría la palabra autenticación.

²La Organización Internacional de Normalización (ISO), define el reconocimiento biométrico o biometría como el reconocimiento automatizado de individuos basado en sus características biológicas y de comportamiento. Tomado de ISO/IEC 2382-37:2017 Information technology - Vocabulary - Part 37: Biometrics.

gran ventaja a la tercera forma de reconocimiento. El reconocimiento biométrico o simplemente biometría, ofrece un sistema natural y más confiable, ya que es más difícil falsificar, duplicar, robar, alterar, olvidar o perder estos rasgos o características fisiológicas o de comportamiento. Debido a que estos rasgos fisiológicos constituyen un vínculo fuerte y razonable a lo largo del tiempo entre una persona y su identidad, se está adoptando cada vez más el reconocimiento biométrico para reconocer a las personas en el gran mundo de aplicaciones que se tienen hoy en día con el avance tecnológico.

2.1.1. Propiedades de los rasgos biométricos

Los rasgos fisiológicos causan dificultades o beneficios en el rendimiento de los sistemas de reconocimiento, por lo tanto, con el fin de seleccionar los rasgos con mejores beneficios y la mejor idoneidad para determinada aplicación, se deben considerar siete propiedades de las características o rasgos biológicos:

- **Universalidad:** Todo individuo que acceda al sistema de reconocimiento debe poseer el rasgo.
- **Singularidad:** El rasgo debe ser lo suficientemente diferente entre individuos que comprende la población de usuarios.
- **Permanente:** El rasgo debe ser lo suficientemente invariable durante un período largo de tiempo y estar presente durante toda la vida de la persona.
- **Medibilidad:** Deber ser posible adquirir y cuantificar (digitalizar) el rasgo biométrico.
- **Rendimiento:** El rasgo debe ayudar a utilizar el menor número de recursos computacionales (almacenamiento y procesamiento) posible para alcanzar un nivel adecuado de rendimiento y robustez.
- **Aceptabilidad:** Las personas a reconocer deben estar dispuestas a presentar su rasgo biométrico al sistema.
- **Circunvención o nivel de seguridad:** El rasgo biológico debe tener un bajo porcentaje de probabilidad de ser imitado o alterado.

2.1.2. Estructura de un sistema biométrico

Un sistema o proceso de biometría consta de dos fases principales: la *inscripción* y el *reconocimiento*, como se observa en la figura 2.1. Durante la fase de inscripción, los datos biométricos se obtienen de las personas, se procesan para extraer características sobresalientes y se almacenan en una base de datos junto con sus identidades (etiquetas de clase). Durante la fase de reconocimiento, los datos biométricos se vuelven a adquirir de las personas y son comparados con los datos almacenados para determinar su identificación o autenticación. Así, un sistema biométrico es esencialmente un sistema de reconocimiento de patrones que consta de cuatro módulos básicos: (a) adquisición, (b) extracción de características, (c) base de datos y (d) toma de decisión. En la figura 2.1 se muestra el resultado de la recopilación de información sobre la estructura común de un sistema de biometría, construido a partir de las definiciones dadas en [1-3].

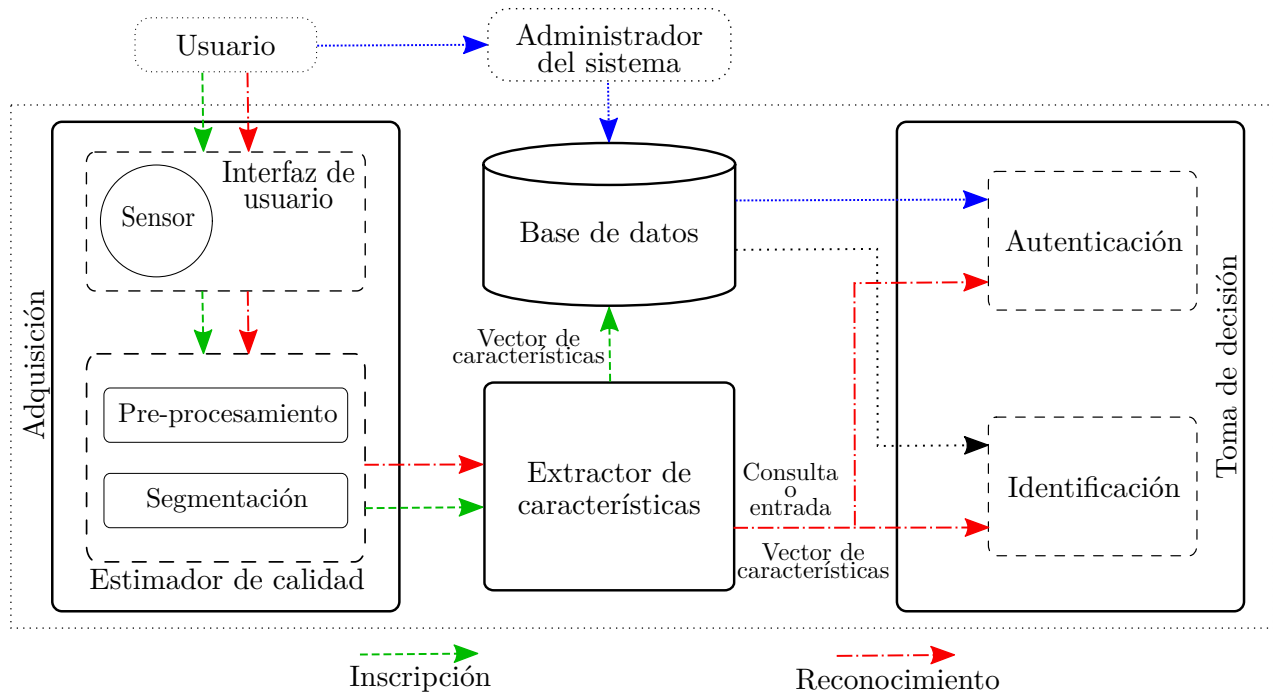


Figura 2.1: Estructura común de un sistema biométrico basado en [1–3].

En los siguientes párrafos se describe el sistema de reconocimiento mostrado en la figura 2.1. El módulo de adquisición se compone de dos bloques: un bloque de *interfaz de usuario*, que incorpora el sensor (sistema de captación, amplificación y digitalización) para registrar los datos fisiológicos y un bloque de *estimación de calidad*, donde se realiza un pre-procesamiento y una segmentación de las señales para mejorar su calidad y prepararlas para las técnicas de extracción de características. El diseño de una buena interfaz, un buen pre-procesamiento y una apropiada segmentación es fundamental para el buen rendimiento de un sistema biométrico. La interfaz de usuario debe ser intuitiva, ergonómica y fácil de usar. Además, las características y ubicación de los sensores facilitan la rápida adquisición y calidad de las señales. El pre-procesamiento busca una idoneidad en los datos, reduciendo las interferencias y el ruido durante la adquisición; la segmentación separa o divide las señales adquiridas en plantillas o ventanas de tiempo para extraer características. Generalmente, el pre-procesamiento y la segmentación depende del tipo de señales fisiológicas que se estén trabajando y están altamente relacionadas con los tipos o técnicas de extracción de características que se desean implementar. El bloque de estimación de calidad busca preparar y estimar la mejor calidad de las señales para su procesamiento o extracción de características.

El módulo extractor de características se encarga del procesamiento de las señales para generar una compacta pero expresiva representación digital de los rasgos biométricos, dicha representación se denomina *vector de características*, este vector se espera que contenga solo la información discriminativa relevante que es esencial para reconocer a las personas. En la fase de inscripción se almacenan estos vectores en la base de datos del sistema biométrico, en la fase de reconocimiento, se recuperan los vectores de características inscritos y se comparan con el conjunto de características extraídas de la nueva muestra biométrica adquirida del usuario, en la fase de reconocimiento a este último y nuevo vector mencionado se le denomina *vector de*

consulta o de entrada. El módulo de toma de decisión compara el vector de consulta con los vectores almacenados, para generar una puntuación o medida de coincidencia para validar una identidad reclamada o proporcionar una clasificación de las identidades inscritas para identificar a un individuo.

2.1.3. Modo de reconocimiento o funcionalidad biométrica

Un sistema biométrico puede proporcionar dos tipos de funcionalidades en el módulo de toma de decisión con respecto a la gestión de reconocimiento [2, 37]:

- **Identificación:** Un sistema de identificación responde a la pregunta ¿eres alguien conocido por el sistema?. El usuario intenta identificarse ante el sistema sin reclamar explícitamente una identidad, comparando o analizando la entrada o consulta biométrica del usuario con los vectores característicos de todas las personas inscritas en la base de datos, es una comparación *uno contra todos* y el sistema da como resultado la identidad de la persona cuyo vector tiene el mayor grado de coincidencia con la entrada del usuario (identificación positiva) o responde con una decisión que indica que el usuario que presenta la entrada no es un usuario inscrito en la base de datos (identificación negativa).
- **Verificación o autenticación:** El usuario reclama una identidad y el sistema verifica si la reclamación es genuina o no, es decir, el sistema responde a la pregunta ¿eres quién dices ser?. En este escenario, la consulta se compara solo con el vector de características correspondiente a la identidad reclamada, dicho vector es seleccionado en la base de datos por el administrador del sistema y es una comparación *uno contra uno*. Si el vector consulta del usuario y el vector en la base de datos de la identidad reclamada tienen un valor de coincidencia apropiado con respecto a un umbral óptimo de decisión, entonces el reclamo se acepta como genuino, de lo contrario, el reclamo es rechazado y el usuario se considera un impostor, siendo así la salida una decisión binaria, *aceptada:1* ó *rechazada:0*.

2.1.4. Aplicaciones de los sistemas de biometría

Un sistema de reconocimiento de patrones tiene dos tipos de funcionalidades que definen directamente el módulo de toma de decisión como se aprecia en la figura 2.1. Dependiendo de la aplicación se debe elegir entre un sistema de verificación y un sistema de identificación. Los sistemas de reconocimiento de personas se categorizan en tres grandes grupos según su aplicación [2, 37]:

- **Comercial:** Son aplicaciones para el control de acceso físico y/o lógico a servicios o recursos en los sectores: bancario, automatización y control, medicina, comunicación, seguridad, entre otros o alguna actividad relacionada con la tecnología e internet.
- **Gubernamental:** Aplicaciones para administrar el acceso físico y/o lógico y el control gubernamental de servicios o recursos en aspectos como: población, finanzas, impuestos, seguridad, control migratorio, entre otros.
- **Forense o criminalístico:** Aplicaciones de reconocimiento de personas pérdidas, desaparecidas o muertas y reconocimiento de personas involucradas en escenas de crímenes o actos de vandalismos.

2.2. Electrocardiograma (ECG)

Las señales biomédicas reflejan propiedades subyacentes de los sistemas biológicos que pueden ayudar a explicar o identificar varias condiciones de los seres vivos, especialmente las condiciones patológicas. La funcionalidad del cuerpo humano es asociada con señales eléctricas, químicas o acústicas. Estas señales transmiten y contienen información que a simple vista no puede ser percibida, pero está oculta en las señales. Dicha información debe ser decodificada o extraída de alguna forma para poder interpretarla y usar su significado en diversas aplicaciones.

El procesamiento de señales biomédicas, ayuda al conocimiento de la anatomía y fisiología del cuerpo humano y tiene como objetivo reducir la subjetividad de las medidas manuales para fines médicos. Dicho procesamiento está enfocado principalmente al diagnóstico, terapia (tratamiento) y monitoreo médico mediante procedimientos no invasivos. Adicionalmente, se tiene presente el tiempo de procesamiento y de adquisición, buscando extraer las características que ayuden a entender mejor la información contenida en dicha señal biomédica.

Electrocardiograma (ECG): Es una señal biológica, que se refleja mediante una representación gráfica de la actividad eléctrica del corazón, registrada por electrodos colocados en la superficie del cuerpo, especialmente en el pecho, brazos, piernas y/o manos. El ECG es una herramienta para el estudio de la anatomía y fisiología del sistema cardiovascular. El latido cardíaco o complejo cardíaco es un impulso que viaja a través del corazón a una determinada velocidad, causado por la contracción de los músculos del corazón para el bombeo de sangre a todo el cuerpo. La señal cardíaca es una señal que inherentemente detecta y refleja vitalidad o *liveliness*.

2.2.1. Anatomía y Fisiología del ECG

Las técnicas de procesamiento de señales biomédicas, se enfoca en el análisis de señales eléctricas adquiridas de la superficie del cuerpo, lo cual, se relaciona con la definición de señales bioeléctricas desde una perspectiva celular. Las señales bioeléctricas se fundamentan en los procesos iónicos, que son el resultado de la actividad electroquímica de un grupo especial de células que tienen la propiedad de excitabilidad, siendo importante en el procesamiento y transmisión de información del sistema nervioso al resto del cuerpo [38].

El corazón es un órgano muscular cuya función primaria es aspirar y bombear sangre rica en oxígeno a todo el cuerpo. El corazón humano se divide en mitad izquierda y derecha, cada una de la cuales consta de una aurícula y un ventrículo. De la figura 2.2(a), en la mitad derecha (azul), la aurícula recibe la sangre no oxigenada que proviene del cuerpo y el ventrículo impulsa la sangre hacia los pulmones; en la mitad izquierda (rojo), la aurícula recibe la sangre oxigenada que proviene de los pulmones y el ventrículo impulsa la sangre a todo el organismo. Esta actividad de circulación de sangre (aspiración y bombeo) se conoce como *ciclo cardíaco* y está compuesto por dos fases: activación y recuperación o en términos eléctricos como *despolarización* y *repolarización*, que es equivalente a la contracción y relajación mecánica de los músculos cardíacos. La anatomía de cada persona hace que la actividad eléctrica del corazón sea diferente en entre las personas.

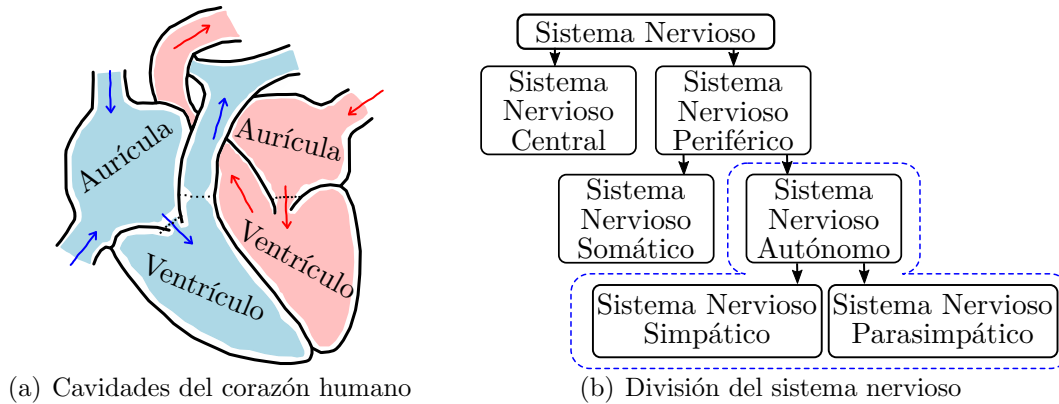


Figura 2.2: Aspectos importantes en la anatomía y fisiología del ECG. (a) División anatómica del corazón, en azul la mitad derecha y en rojo la mitad izquierda y (b) división del sistema nervioso.

El sistema nervioso es un conjunto de células especializadas en la conducción de señales eléctricas desde el cerebro y la médula espinal a los diversos sistemas y órganos del cuerpo, el objetivo del sistema nervioso es dirigir, supervisar y controlar todas las funciones y actividades. En la figura 2.2(b), se representa la estructura y división del sistema nervioso, que se divide anatómica y fisiológicamente en dos sistemas.

- **Sistema nervioso central (SNC):** Su función es percibir estímulos procedentes del mundo exterior, procesar la información y transmitir impulsos eléctricos a nervios y músculos para realizar determinadas actividades. Está conformado por el encéfalo (cerebro, cerebelo y tallo cerebral) y la médula espinal.
- **Sistema nervioso periférico (SNP):** Su función es conectar el sistema nervioso central con los demás sistemas y órganos del cuerpo. Está conformado por los nervios y ganglios nerviosos. Se divide en dos:
 - **Sistema nervioso somático (SNS):** Su función es transmitir información sensitiva y motora de manera bidireccional con el SNC. Está conformado por los nervios sensitivos, motores y mixtos.
 - **Sistema nervioso autónomo (SNA):** Su función es regular y coordinar las funciones que son involuntarias, inconscientes y automáticas. Está conformado por el sistema nervioso *simpático* y *parasimpático*.

Para el estudio del ECG, nos enfocamos en el sistema nervioso autónomo (SNA), como se resalta en la figura 2.2(b), ya que el ritmo y el ciclo cardíaco es una actividad involuntaria, inconsciente y automática del cuerpo. El sistema nervioso simpático se encarga de activar la mayor parte de los órganos del cuerpo para que trabajen de forma más intensa. Activando al organismo para situaciones de emergencia, generalmente aumentando la frecuencia cardíaca, la presión sanguínea, el ritmo respiratorio, elevando la concentración de glucosa en la sangre, estimulando la liberación de adrenalina y reprimiendo el funcionamiento de los sistemas que no participan en las situaciones de estrés o alerta, como el sistema digestivo. El sistema nervioso parasimpático se encarga de relajar la actividad de la mayoría de los órganos, regulando las actividades que

tienden a conservar energía en los periodos de descanso o recuperación, generalmente disminuyendo la frecuencia cardíaca o la actividad de los demás sistemas.

Las funciones del sistemas simpático y parasimpático son antagónicas, logrando así un balance funcional que tiende a mantener la *homeostasis* corporal o fisiológica. La homeostasis fisiológica es una propiedad de los organismos que consiste en la capacidad de mantener una condición interna estable. Se trata de una forma de equilibrio dinámico que se hace posible gracias a la retroalimentación o relación antagónica de los sistemas simpático y parasimpático, permitiendo mecanismos de autorregulación. Un ejemplo de homeostasis es la regulación de la temperatura corporal. El balance entre las partes simpáticas y parasimpáticas del sistema nervioso autónomo determinan el ritmo cardíaco. Para un incremento en la actividad parasimpática decrece el ritmo cardíaco, mientras un incremento en la actividad simpática incrementa el ritmo cardíaco [39,40].

2.2.2. Morfología ECG y ritmo cardíaco

La forma de onda producida durante la actividad de despolarización y repolarización se conoce como ciclo cardíaco o complejo PQRST. Dicho complejo es el resultado de los potenciales de acción auricular y ventricular en la aspiración y bombeo de sangre, con la intervención del sistema nervioso, respiratorio y cardiovascular. En la figura 2.3(a), se observa la morfología o forma de onda típica de un complejo cardíaco, que está compuesta por la onda P, la onda QRS y la onda T. Adicionalmente, en la figura 2.3(b), se observa la representación espectral típica de las tres ondas que conforman el complejo cardíaco.

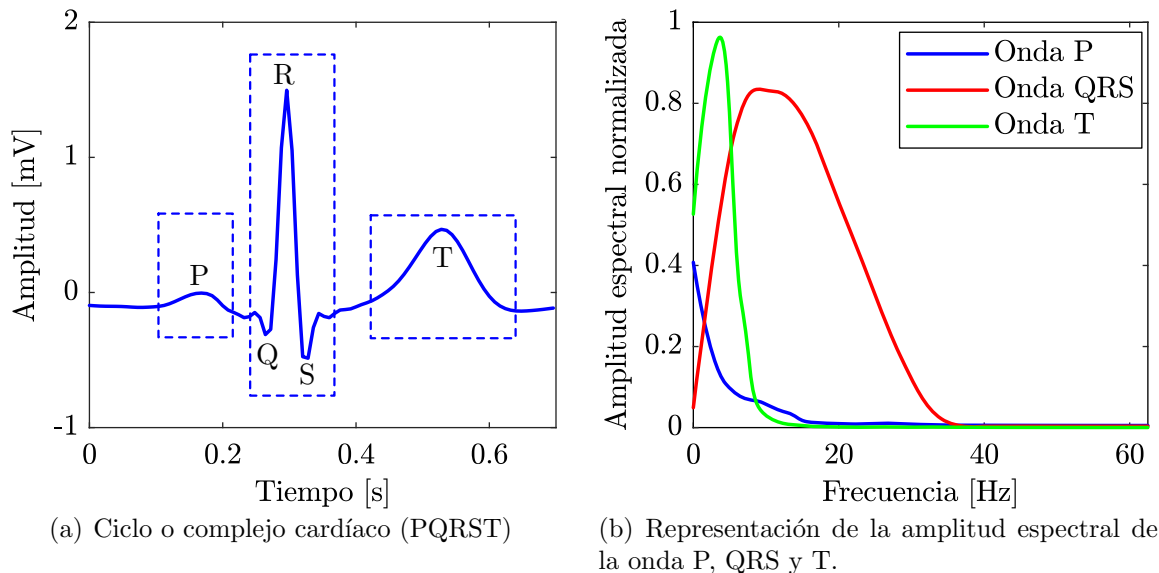


Figura 2.3: Ciclo o complejo cardíaco (PQRST) visto con la derivación I. (a) Complejo cardíaco en función del tiempo y (b) representación espectral de las tres ondas que conforman el complejo cardíaco.

El complejo cardíaco visto con la derivación I, como se muestra en la figura 2.3, está compuesto por: La onda P, que refleja la secuencia de despolarización auricular, su duración normalmente es menor a 120 ms, con una contribución espectral entre 0.05 a 15 Hz. La onda o complejo QRS que refleja la despolarización de los ventrículos, tiene una duración normal entre 70 a 110 ms y

su información espectral está entre 10 a 40 Hz. Por último, la onda T que refleja la repolarización ventricular, con una duración normal entre 150 a 200 ms y sus componentes espectrales están entre 0.05 a 10 Hz [41, 42].

El tiempo que hay entre picos R de los complejos cardíacos de una persona, se conoce como intervalo RR y es una medida del ritmo cardíaco fundamental en cualquier tipo de interpretación de ECG, se utiliza para estudiar la *variabilidad del ritmo cardíaco* (HRV), que es una medida de las variaciones o cambios continuos de las fluctuaciones latido a latido de la frecuencia cardíaca [43]. El ritmo cardíaco normalmente se encuentra entre los rangos de 50 a 100 lpm³, siendo el rango de frecuencia cardíaca normalmente de personas sanas denominado *ritmo sinusal normal*, donde la frecuencia cardíaca promedio típica está al rededor de 70 a 75 lpm. Una perturbación al ritmo sinusal normal es llamado *arritmia*. El ritmo cardíaco es constante la mayoría del tiempo, pero es perturbado por efectos externos como la actividad física o mental. Dicha variación se genera por el balance continuo de los dos componentes del sistema nervioso autónomo. La dinámica de la variabilidad del ritmo cardíaco, sirve como indicador para el pulso cardíaco, la respiración, la presión arterial y temperatura controlada por el cuerpo. Una arritmia es cualquier trastorno o cambio en el ritmo del latido del corazón, alterando así la formación de los impulsos eléctricos y existen dos tipos de alteraciones del ritmo normal cardíaco:

- **Bradicardia:** Es todo aquel ritmo o frecuencia cardíaca menor a 60 lpm.
- **Taquicardia:** Es toda aquella frecuencia cardíaca que sea mayor a 100 lpm

2.2.3. Sistemas de adquisición

Los sistemas de adquisición más populares en la actividad eléctrica del corazón son: el ECG de 12 derivaciones y el sistema de derivación ortogonal. El sistema de adquisición médico tradicionalmente utilizado en las actividades clínicas, es el sistema estándar de 12 derivaciones. Dicho sistema obtiene 12 vistas en diferentes ángulos (derivaciones) de la actividad eléctrica del corazón. Está compuesto por 10 electrodos que representan seis derivaciones en las extremidades en un plano frontal y seis derivaciones precordiales en un plano horizontal. Por otro lado, el sistema de derivación ortogonal representa la actividad eléctrica del corazón en tres direcciones perpendiculares xyz , obtenidas mediante 7 electrodos.

En el sistema estándar de 12 derivaciones se resaltan 3 derivaciones comunes. La derivación I, II y III, que son derivaciones en la extremidades y son bipolares. La derivación más importante es la derivación I, que representa la vista desde el electrodo colocado en el brazo izquierdo hacia el electrodo colocado en el brazo derecho. La morfología o forma del complejo cardíaco depende de la vista o derivación seleccionada, el posicionamiento del electrodo y a la postura en la que se encuentre la persona al momento de capturar la señal [4], la postura más utilizada en la derivación I es con la persona sentada. Además, el tipo, tamaño y ubicación de los electrodos utilizados también es importante en la forma de la onda [9, 44]:

- *In-the-person:* Se refiere a electrodos o dispositivos implantables (invasivos) en el cuerpo humano, como marcapasos o catéter cardíaco.

³lpm: latidos por minuto.

- *On-the-person*: Se refiere a los electrodos o dispositivos que se conectan al cuerpo de la persona, que generalmente son adhesivos y requieren de gel conductor o no, es decir, electrodos húmedos y secos respectivamente.
- *Off-the-person*: Se refiere a electrodos o dispositivos que están integrados en objetos o superficies con los que interactúan las personas, por ejemplo, un teclado de computadora.


2.2.4. Fuentes de variabilidad de la señal ECG

Las fuentes de variabilidad son todas aquellas causas que generan un cambio en la señal ECG a corto y largo plazo, las cuales se pueden clasificar en tres grupos [9, 44, 45]:


- **Artefactos y ruidos**: Son aspectos que generan una deformación, interferencia, saturación o ruido en segmentos de la señal cardíaca, por ejemplo: el material de los electrodos (cambios de impedancia eléctrica debido a la sudoración y respiración de la persona - modelo piel/electrodo), el movimiento de los electrodos debido a su colocación de contacto directo con la piel (ubicación), interferencia de la línea de alimentación eléctrica, línea base de deriva, artefactos de movimiento (EMG) y ruido generado por la instrumentación en general (procesos de filtrado, amplificación, convertidor analógico-digital y en algunos casos, proceso de comunicación inalámbrica de la señal digitalizada).
- **Variabilidad intra-sujeto**: Son aspectos o escenarios que generan cambios en la morfología de los complejos cardíacos de una misma persona, como por ejemplo: la variabilidad del ritmo cardíaco en su rango normal, el ejercicio físico o mental, los estados afectivos, la postura, las drogas o fármacos. Estos escenarios son producto de la variabilidad del nivel de oxígeno y/o glucosa en el cuerpo humano en la interacción entre el sistema nervioso, respiratorio y cardiovascular. Los escenarios mencionados anteriormente afectan generalmente el segmento QT del complejo. Por último, está el escenario de variabilidad del complejo ECG a lo largo del transcurso del tiempo, bajo los hábitos y estilo de vida de las personas.
- **Variabilidad inter-sujeto**: Son los aspectos que generan cambio en la señal cardíaca de un sujeto a otro, como la composición anatómica y fisiológica de cada persona: su peso, su altura, su edad, su estilo de vida, en general su vitalidad. La composición anatómica y fisiológica de cada persona generan diferentes geometrías, morfológicas y orientaciones eléctricas del corazón y por tanto de la señal cardíaca.

2.3. Pre-procesamiento


El objetivo del pre-procesamiento es prepara, corregir y mejorar la calidad de la señal para la extracción de características, maximizando así el rendimiento del sistema de biometría ante las fuentes de variabilidad vistas en la subsección 2.2.4. La calidad de la señal debe garantizar una homogeneidad entre observaciones de un mismo sujeto, tanto en rangos de amplitud como de longitud de adquisición. Luego, hay que suprimir las interferencias y ruidos que puede tener la señal ECG, para después proceder a la detección de puntos fiduciales de interés, como el pico R y el complejo PQRST.




(a) Señal ECG sin filtrar.



(b) Filtrado con fase lineal.



(c) Filtrado con fase no lineal.



(d) Filtrado con fase nula o fase cero.

Figura 2.4: Filtro pasa-banda de 1 a 30 Hz para una señal ECG de longitud finita de tiempo de adquisición. (a) Señal ECG sin filtrado, (b) filtrado con fase lineal de un filtro FIR, (c) filtrado con fase no lineal de un filtro IIR y (d) Filtrado con fase nula o fase cero mediante el algoritmo de filtrado hacia adelante y hacia atrás de un filtro IIR.

2.3.1. Filtrado

La señal cardíaca esta expuesta a ruidos y/o artefactos. Los ruidos y artefactos más comunes son lo siguientes [46]:

- **Línea base de deriva o vaga línea de base:** Son las componentes espectrales compuestas por señales inferiores a 0.5 Hz, en la literatura se elimina toda componente espectral inferior a 1 Hz, asociada generalmente a la actividad respiratoria, a la transpiración y al ruido generado por el contacto entre electrodo y piel.
- **Artefactos musculares:** Es toda aquella distorsión generada por los movimientos musculares y se atribuye aproximadamente a toda componente espectral superior a 30 Hz.
- **Interferencia de la línea eléctrica:** Es la componente espectral a 60 Hz de la línea eléctrica en México.

La respuesta de los sistemas lineales ante señales con una amplitud no uniforme como es el caso de la señal cardíaca, exhibe no linealidad de fase en rangos de frecuencia donde la respuesta de amplitud versus frecuencia cambia abrupta o rápidamente [47]. La onda del complejo cardíaco que tiene el rango de contribución espectral más bajo es la onda T y la mayor información espectral de la señal cardíaca está en la onda QRS como se observa en la figura 2.3(b). Cada una de las tres ondas del complejos cardíaco se asocian a una forma triangular, que sufren distorsión como se ve en al figura 2.4(c), ante un filtro IIR de fase no lineal a bajas frecuencias.

La distorsión de la fase no lineal del filtro afecta a la morfología cardíaca, en especial a la onda T y el segmento ST [38]. La asociación Americana del corazón (AHA) recomienda el filtrado de fase nula o fase cero para señales ECG [47]. Los filtros FIR poseen respuesta de fase lineal, pero generan desplazamientos en la señal filtrada como se observa en la figura 2.4(b). Idealmente se busca implementar un filtro de fase nula o fase cero para evitar distorsión y que no haya retardo o desplazamiento en ninguna componente de la señal como se aprecia en la figura 2.4(d). La mejor alternativa es el filtrado hacia adelante y hacia atrás con un filtro IIR de bajo orden, esta técnica de filtrado se considera un procesamiento en tiempo no real de la señal de entrada de duración finita con valores reales [48]. El filtrado hacia delante y hacia atrás con un filtro IIR lineal e invariante en el tiempo con respuesta al impulso $h[n]$, cumple el siguiente algoritmo para garantizar una respuesta de fase nula $x_f[n]$, en el filtrado de la señal cardíaca $\hat{x}[n]$ adquirida, mediante la operación de convolución:

$$\begin{aligned}
 z_1[n] &= h[n] * \hat{x}[n] \\
 z_2[n] &= h[n] * z_1[-n] \\
 \mathbf{x}_f &= x_f[n] = z_2[-n]
 \end{aligned}
 \tag{2.1}$$

Donde n toma valores enteros de 1 hasta N , siendo N el número de muestras tomadas en el registro cardíaco a una frecuencia de muestreo f_s . La serie temporal $x_f[n]$ es el vector \mathbf{x}_f que tiene N valores reales.

2.3.2. Normalización de amplitud

En biometría se comparan las características de las señales adquiridas en cada consulta tanto en identificación como en verificación. Generalmente, la colocación de los electrodos en la piel y la impedancia generada entre electrodo y piel, provocan en cada observación o consulta una variación en amplitud para señales de un mismo sujeto en diferentes momentos de adquisición, por lo cual, se busca escalar las señales para obtener un nivel idéntico o homogéneo en amplitud. Las normalizaciones de amplitud son transformaciones lineales que ayudan a disminuir

la variabilidad intra-sujeto en los diferentes escenarios. Las principales normalizaciones son las siguientes [1]:

$$\begin{aligned}
 \text{Normalización genérica: } \mathbf{x} &= \frac{\mathbf{x}_f}{\max(\mathbf{x}_f)} \\
 \text{Normalización min-max: } \mathbf{x} &= \frac{\mathbf{x}_f - \min(\mathbf{x}_f)}{\max(\mathbf{x}_f) - \min(\mathbf{x}_f)} \\
 \text{Teorema del límite central: } \mathbf{x} &= \frac{\mathbf{x}_f - \mu_{\mathbf{x}_f}}{\sigma_{\mathbf{x}_f}} \tag{2.2}
 \end{aligned}$$

Donde \mathbf{x}_f es la señal cardíaca filtrada y \mathbf{x} es la señal ECG ya normalizada. La segmentación en tiempo se refiere a definir la captura o longitud N de la señal adquirida en una ventana fija de tiempo, que estaría al rededor de los segundos. Para observaciones de series temporales de tiempo finito, existe en cada observación una media $\mu_{\mathbf{x}_f}$ y una desviación estándar $\sigma_{\mathbf{x}_f}$ con respecto a dicha media, por lo tanto, la distribución de los valores de amplitud se pueden normalizar con el teorema del límite central, aproximando los valores de las observaciones a valores normales con media cero y desviación estándar uno; dando estabilidad a las funciones de densidad de probabilidad para cada observación. Así, el teorema del límite central es la normalización más conveniente para un sistema de biometría.

2.3.3. Detección del pico R

Para detectar el complejo cardíaco o complejo PQRST en un ECG, se debe detectar el pico R y este procedimiento consiste en cinco pasos basado en el algoritmo desarrollado en [49] y [50] con las adecuaciones apropiadas para observaciones cardíacas adquiridas con la derivación I. Los cinco pasos son los siguientes:

1. **Filtro:** El objetivo es eliminar la contribución de las ondas P y T del complejo cardíaco para solo obtener la onda QRS \mathbf{x}_{QRS} , según la figura 2.3(b), la máxima contribución de la onda QRS se puede obtener aproximadamente a partir de 10 Hz, por lo cual, la adecuación más apropiada para el algoritmo es implementar un filtro pasa altas para frecuencias superiores a 10 Hz.
2. **Derivación:** Con el objetivo de detectar el pico R, que es frecuentemente la amplitud máxima del complejo cardíaco, se realiza la derivación de la respuesta del filtro para generar los cruces por cero de los máximos y mínimos valores de la serie temporal.

$$\mathbf{x}_{dQRS} = \frac{d(\mathbf{x}_{QRS})}{dn} \tag{2.3}$$

3. **Transformación no lineal:** Luego de la derivación, el objetivo es resaltar los cruces por cero de los máximos y mínimos del complejo cardíaco, los cuales, corresponden a los picos de la onda QRS, esto se realiza mediante la función cuadrática.

$$\mathbf{x}_{TNL} = (\mathbf{x}_{dQRS})^2 \tag{2.4}$$

4. **Dilatación matemática:** También conocida como integración \mathbf{x}_{DM} , el objetivo es suavizar y/o promediar los puntos de la forma de onda generada en la transformación no lineal, para resaltar la ubicación o segmento más viable de ubicación del pico R en el complejo cardíaco.

5. **Detección del pico R:** Teniendo la forma de onda generada por la dilatación matemática, se busca generar una señal digital $\mathbf{x}_{digital}$ entre cero y uno, donde la duración en uno indica la posición o ubicación de la onda R en el complejo cardíaco, dicha señal digital se define en uno, cuando la amplitud de la forma de onda de la dilatación matemática es superior a un umbral de decisión τ_{umbral} , dicho umbral es ajustable a cada observación y se calcula de la siguiente manera:

$$\tau_{umbral} = \mu_{\mathbf{x}_{DM}} + \sigma_{\mathbf{x}_{DM}} \quad (2.5)$$

definiendo la señal digital así:

$$\mathbf{x}_{digital} = \begin{cases} 1 & \text{si } \mathbf{x}_{DM} \geq \tau_{umbral} \\ 0 & \text{si } \mathbf{x}_{DM} < \tau_{umbral} \end{cases} \quad (2.6)$$

Teniendo ya $\mathbf{x}_{digital}$, se detecta el pico R como el valor máximo de la señal inicial \mathbf{x} dentro de la duración de $\mathbf{x}_{digital} = 1$, obteniendo un tren de impulsos digitales \mathbf{x}_R con la ubicación temporal del pico R, con valor en 2 en la muestra donde haya un pico R y en 0 donde no.

La detección del pico R, da lugar a la extracción fiducial como lo es la detección del complejo PQRST dentro de un registro ECG. Del complejo PQRST detectado se procede a extraer características para tomar decisiones según la aplicación del sistema biométrico.

2.4. Técnicas de extracción de características

Las técnicas de extracción de características tienen como objetivo extraer la información altamente descriptiva de la señal y traducir o transformar la señal segmentada en una representación que reduzca aún más los efectos de variabilidad intra-sujeto y al mismo tiempo resalte la variabilidad inter-sujeto para facilitar el proceso de decisión. Las técnicas de extracción de características se pueden agrupar en tres grupos:

- **Fiduciales:** Técnicas que extraen características directamente de los puntos fiduciales de referencia del complejo cardíaco, donde previamente se realiza una detección de dichos puntos o del complejo PQRST necesariamente. Estas técnicas toman medidas en tres aspectos: (1) temporales, (2) amplitudes y (3) forma o morfología, empleando la estadística descriptiva o medidas como duración, intervalos, medidas de nivel, área y ángulos de los puntos fiduciales como tal.
- **No Fiduciales:** Técnicas de extracción de características no de los puntos fiduciales, sino de la totalidad de datos, muestras o puntos intrínsecos en una ventana o segmentación de la señal. No se requiere la detección del complejo PQRST o puntos fiduciales. Generalmente estas técnicas se fundamentan en la existencia de energía finita y no de potencia en la señal, debido a su duración finita de adquisición. Partiendo de la definición de una señal estacionaria, estas técnicas se dividen en tres grupos: (1) técnicas paramétricas, (2) técnicas no paramétricas y (3) espacio dimensional de fase. Las técnicas no fiduciales también son usadas para la reducción de dimensionalidad del vector de característica.
- **Híbridas:** Es la combinación de técnicas fiduciales y no fiduciales, obliga a detectar el complejo PQRST o puntos fiduciales y luego a la detección o extracción fiducial aplicarle una técnica de extracción no fiducial para obtener el vector de características.

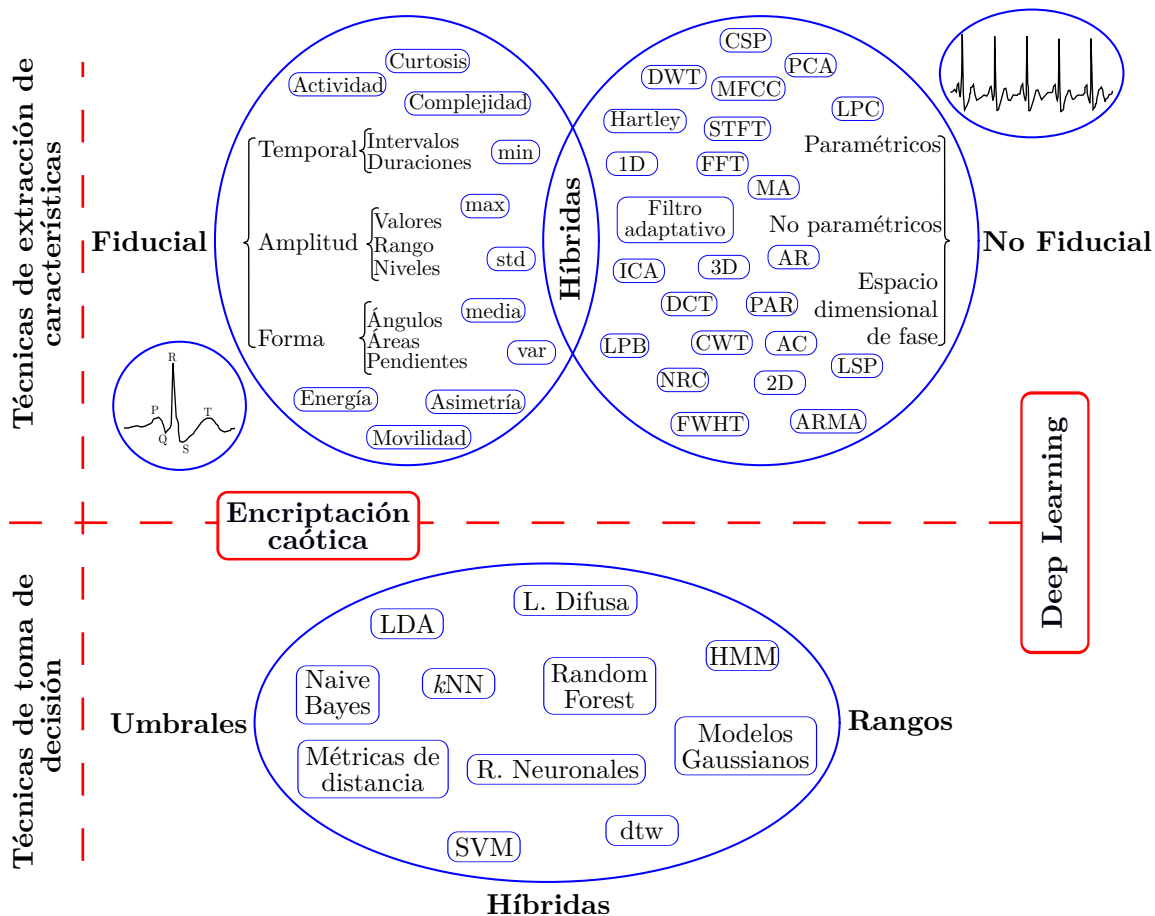


Figura 2.5: Resumen de técnicas de extracción de características y decisión.

Un reconocimiento eficiente y confiable generalmente se logra con una longitud larga del vector de características, pero genera más costo computacional. En la mayoría de los casos se debe aplicar la reducción de dimensionalidad del vector de características, cuyo objetivo es transformar, seleccionar o reducir su longitud a un número más viable desde el punto de vista de costo, manteniendo el máximo poder discriminante de reconocimiento. En la figura 2.5, se resume gráficamente las técnicas más usadas en el aprendizaje automatizado tanto en extracción de características como en la toma de decisión.

Dentro de las técnicas fiduciales más usadas están los métodos de correlación y estadística descriptiva de los puntos de referencia del complejo PQRST, donde su mayor reto se centra en las técnicas de detección del complejo PQRST [14]. En las técnicas no fiduciales tanto paramétricas como no paramétricas las más usadas son FFT, DCT, DWT, CWT, STFT, MFCC, LPC, PCA, AC (autocorrelación), ARMA, filtros adaptativos, entre otras y para el espacio dimensional de fase, están los espacios bidimensionales (2D) o tridimensionales (3D) creados con técnicas de retardo de tiempo de las señales [1, 8, 10].

2.4.1. Serie temporal y señal aleatoria

Una *señal* es definida como una secuencia de valores, cantidades (reales o complejas) o magnitudes físicas que varía con el tiempo, espacio o alguna otra variable o variables independientes. Adicionalmente, un *sistema* puede ser descrito como un dispositivo tanto en hardware como en software que realiza una operación en una señal. La señal ECG es una señal multicanal (captada con varios electrodos), obteniendo al final del proceso de adquisición un solo canal, dicha señal depende del tiempo (variable independiente), que es una señal unidimensional de valores reales; siendo en el proceso de adquisición analógico una señal de tiempo continuo y valores continuos, pero después del convertidor analógico-digital a una frecuencia de muestreo f_s , es transformada para el procesamiento matemático en una señal de tiempo discreto y valores discreto, por lo tanto, una *señal digital*.

Una señal de tiempo discreto o una *serie temporal* es un conjunto de valores observados secuencialmente en el tiempo de manera ordenada. Una señal discreta \mathbf{x} (vector) en el tiempo es una secuencia de números reales o complejos $x[n]$ llamados *muestras*. En este trabajo la variable entera n (independiente) se refiere a tiempo discreto, la variable n tomará valores enteros positivos $1, 2, \dots, N$, siendo N el número total de muestras tomadas en la observación o captura de la señal previamente filtrada y normalizada en amplitud.

$$\mathbf{x} = x[n] = [x_1, x_2, \dots, x_N] \quad (2.7)$$

El procesamiento y análisis matemático de señales, requiere disponer de una descripción matemática para la señal tratada, lo cual se llama *modelo de la señal*. Cuando la señal se puede describir de forma precisa mediante una expresión matemática explícita, se dice que es una *señal determinística*, destacando que los valores pasados, presentes y futuros de la serie temporal se conocen de forma precisa, sin error ni incertidumbre. Sin embargo en la vida real, la mayoría de las señales, por ejemplo, las señales biomédicas, no se pueden describir con un grado razonable de precisión mediante fórmulas matemáticas, por lo tanto, dichas señales evolucionan en el tiempo de manera no predecible, definiendo así las *señales aleatorias* o *estocásticas*. El grado de predicción es determinado por la dependencia o correlación entre los valores sucesivos de la serie. Las series o señales aleatorias se intentan describir usando la teoría de procesos estocásticos [51, 52]. La señal ECG es el resultado de un proceso estocástico, que es una señal aleatoria dependiente de las fuentes de variabilidad de la anatomía y fisiología del cuerpo humano.

El objetivo del análisis de señales aleatorias es el desarrollo de técnicas cuantitativas para el estudio de las propiedades de una señal, sus diferencias y similitudes entre dos o más señales de una misma o diferente fuente. Para caracterizar completamente un señal aleatoria, podemos describir la información de su función de densidad de probabilidad mediante la estadística descriptiva, que resume y describe características importantes de los datos de la señal, extrayendo medidas numéricas de centralización (tendencia central), dispersión y/o forma de la distribución de los datos temporales. La media o promedio $\mu_{\mathbf{x}}$ de los datos de una serie temporal, es una medida de centralización y ubicación de los datos, siendo el valor central al que tienen:

$$\bar{x} = \mu_{\mathbf{x}} = \frac{1}{N} \sum_{n=1}^N x[n]$$

La varianza de los datos es una medida de dispersión o variabilidad de dichos datos con respecto al valor de tendencia central o media:

$$\text{var}(\mathbf{x}) = \sigma_{\mathbf{x}}^2 = \frac{1}{N-1} \sum_{n=1}^N (x[n] - \mu_{\mathbf{x}})^2$$

2.4.2. Momentos estadísticos

Para una serie temporal aleatoria, sus valores de amplitud describen una función de densidad de probabilidad, de dicha función de densidad de probabilidad se pueden conocer algunas características de la distribución de los datos o valores de amplitud, estas características se llaman *medidas* o *momentos estadísticos* [52]. La estadística descriptiva, ayuda a describir la función de densidad mediante los momentos estadísticos, en la figura 2.6(a), se observa la serie temporal correspondiente a la detección del complejo cardíaco de una persona y en la figura 2.6(b), se observa la función de densidad de probabilidad de la distribución de las amplitudes de las muestras del complejo cardíaco detectado. La *esperanza matemática* o *valor promedio* está definido de la siguiente manera y describe el valor de tendencia de las amplitudes:

$$E\{\mathbf{x}\} = \sum_{n=1}^N x[n] \Delta p_n \quad (2.8)$$

Donde Δp_n es la probabilidad de cada muestra de la señal dentro de la función de densidad, generalmente $\Delta p_n = 1/N$.

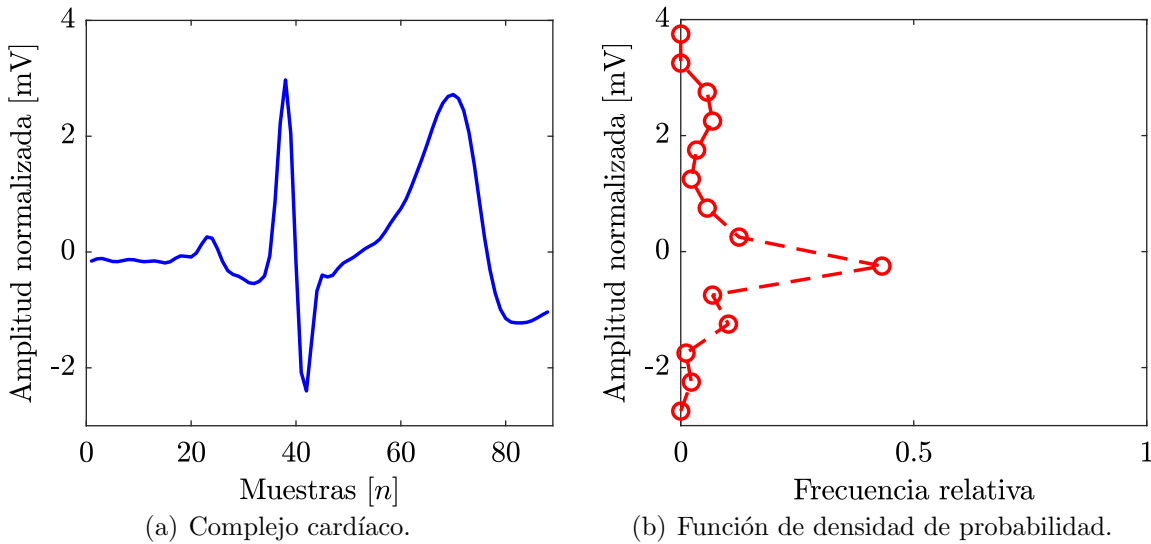


Figura 2.6: Aplicación de la estadística descriptiva al complejo cardíaco. (a) Serie temporal del complejo PQRST y (b) función de densidad de probabilidad de la distribución de amplitudes del complejo PQRST en rangos de 0.5 mV.

Los momentos estadísticos de una variable aleatoria describen información o aspectos útiles de la función de densidad de probabilidad, por lo tanto, el momento de orden m es definido así:

$$r_{\mathbf{x}}^m = E\{\mathbf{x}^m\} = \sum_{n=1}^N (x[n])^m \Delta p_i$$

Cuando $m = 1$ es la media estadística. Ahora, se define la esperanza mediante la tendencia central, por lo tanto, el momento central de orden m es:

$$r_{\mathbf{x}}^m = \mathbb{E} \left\{ \left(\mathbf{x} - \mu_{\mathbf{x}} \right)^m \right\} = \sum_{n=1}^N \left(x[n] - \mu_{\mathbf{x}} \right)^m \Delta p_n \quad (2.9)$$

El segundo momento $m = 2$, es la *varianza* estadística de la señal aleatoria o también conocido como el valor cuadrático medio, siendo $\Delta p_n = \frac{1}{N-1}$:

$$\text{var}(\mathbf{x}) = \sigma_{\mathbf{x}}^2 = \frac{1}{N-1} \sum_{n=1}^N \left(x[n] - \mu_{\mathbf{x}} \right)^2 = r_{\mathbf{x}}^{(2)} = \mathbb{E} \left\{ \left(\mathbf{x} - \mu_{\mathbf{x}} \right)^2 \right\} \quad (2.10)$$

El tercer momento $m = 3$ es la *asimetría*, que es una medida del grado de simetría de la distribución alrededor de la media, siendo una medida de forma o morfología de como se distribuyen los datos de la señal, normalizados con la varianza de la señal. Cuando la asimetría es cero, la función de densidad es simétrica con el valor de la media, si el valor es positivo, la curva o forma es sesgada hacia la derecha o hacía infinito positivo y si es negativo el valor de la asimetría, la forma es sesgada a la izquierda o hacía infinito negativo, siendo $\Delta p_n = 1/N$:

$$\text{Asimetría}(\mathbf{x}) = A_{\mathbf{x}} = \mathbb{E} \left\{ \left(\frac{\mathbf{x} - \mu_{\mathbf{x}}}{\sigma_{\mathbf{x}}} \right)^3 \right\} = \frac{1}{\sigma_{\mathbf{x}}^3} r_{\mathbf{x}}^{(3)} = \frac{1}{\sigma_{\mathbf{x}}^3} \frac{1}{N} \sum_{n=1}^N \left(x[n] - \mu_{\mathbf{x}} \right)^3 \quad (2.11)$$

El cuarto momento estadístico $m = 4$ es la *curtosis*, este valor mide la planitud relativa y altura del pico de la distribución sobre su media y también es una medida de forma de la distribución de los datos, siendo $\Delta p_n = 1/N$.

$$\text{Curtosis}(\mathbf{x}) = K_{\mathbf{x}} = \mathbb{E} \left\{ \left(\frac{\mathbf{x} - \mu_{\mathbf{x}}}{\sigma_{\mathbf{x}}} \right)^4 \right\} = \frac{1}{\sigma_{\mathbf{x}}^4} r_{\mathbf{x}}^{(4)} = \frac{1}{\sigma_{\mathbf{x}}^4} \frac{1}{N} \sum_{n=1}^N \left(x[n] - \mu_{\mathbf{x}} \right)^4 \quad (2.12)$$

2.4.3. Parámetros Hjorth

Hjorth definió tres parámetros que ayudan a obtener información estadística de una serie temporal, adicionalmente estos parámetros se conservan en el dominio de la frecuencias, siendo momentos estadísticos espectrales [53].

- **Actividad:** Se define como la varianza o energía promedio de la amplitud de los datos.

$$\text{Actividad}(\mathbf{x}) = \text{var}(\mathbf{x}) \quad (2.13)$$

- **Movilidad:** Representa la frecuencia media del espectro de la señal, este parámetro es proporcional a la desviación estándar del espectro de energía.

$$\text{Movilidad}(\mathbf{x}) = \sqrt{\frac{\text{var} \left(\frac{d\mathbf{x}}{dn} \right)}{\text{var}(\mathbf{x})}} \quad (2.14)$$

- **Complejidad:** Mide los cambios en la frecuencia, dando una estimación del ancho de banda de la señal.

$$\text{Complejidad}(\mathbf{x}) = \frac{\text{Movilidad} \left(\frac{d\mathbf{x}}{dn} \right)}{\text{Movilidad}(\mathbf{x})} \quad (2.15)$$

Los descriptores o parámetros de Hjorth están relacionados con los momentos estadísticos pares. La *actividad* asociada al segundo momento estadístico, la *movilidad* refleja en el dominio de la frecuencia la raíz cuadrada del segundo momento normalizado y el cuarto momento está relacionado en la definición del ancho de banda en términos de *complejidad* [38].

2.4.4. Proceso aleatorio estacionario

El proceso aleatorio \mathbf{x} es una observación realizada, que posee N valores reales. Cuando todas las observaciones producidas por una misma fuente, generan los mismos valores de medidas o momentos estadísticos, se dice que la señal aleatoria es *estacionaria*. Un proceso estocástico es llamado estacionario si los momentos o medidas estadísticas son iguales en cualquier observación o realización en el tiempo, en otras palabras, que las medidas estadísticas sean independientes del tiempo de observación. El complejo PQRST es altamente estacionario en cada observación por persona.

2.4.5. Autocorrelación

Los procesos estocásticos estacionarios son una herramienta para analizar las señales aleatorias partiendo del segundo momento estadístico, dado que la varianza da paso a la covarianza, la correlación y así, a la autocorrelación (AC) [54]. La función de autocorrelación de un proceso aleatorio es una medida estadística de retardos temporales que se usa para caracterizar estas señales. Las señales de duración finita, aperiódicas y discretas en el tiempo tienen energía finita definida de la siguiente manera:

$$E_x = \sum_{n=1}^N |x[n]|^2$$

Adicionalmente, la convolución es una herramienta potente en el análisis de sistemas lineales invariantes en el tiempo (LTI), que establece, que convolucionar dos señales en el dominio del tiempo es equivalente a multiplicar sus espectros en el dominio de la frecuencia. Definiendo la secuencia de convolución de dos señales de la siguiente manera:

$$h[k] = \sum_{n=-\infty}^{\infty} x_1[n]x_2[k-n] = x_1[k] * x_2[k] \quad (2.16)$$

siendo k un índice o parámetro de retardo (desplazamiento) de tiempo de la secuencia construida. Ahora, para dos observaciones o señales $x_1[n]$ y $x_2[n]$, con energía finita, la correlación cruzada se define:

$$r_{x_1x_2}[k] = \sum_{n=-\infty}^{\infty} x_1[n]x_2[n-k] = \sum_{n=-\infty}^{\infty} x_1[n+k]x_2[n]$$

Una propiedad de la correlación cruzada es:

$$r_{x_1x_2}[k] = r_{x_2x_1}[-k]$$

Por lo tanto, la secuencia de correlación cruzada se puede obtener de la secuencia de convolución definida en (2.16):

$$r_{x_1x_2}[k] = x_1[k] * x_2[-k]$$

Cuando $x_1[n] = x_2[n]$, se define la autocorrelación de la señal. La AC de una serie temporal, es la correlación de dicha serie con una versión desplazada en el tiempo de la propia serie. La AC resaltar patrones repetidos dentro de la serie temporal como la periodicidad de señales enmascaradas o componentes armónicos. Adicionalmente, la AC hace parte del segundo momento estadístico de un vector estocástico y se define de la siguiente manera:

$$r_{xx}[k] = \sum_{n=-\infty}^{\infty} x[n]x[n-k] = \sum_{n=-\infty}^{\infty} x[n+k]x[n]$$

de modo que;

$$r_{xx}[k] = r_{xx}[-k]$$

Como la duración de la señales es finita y la autocorrelación es una secuencia par, se obtiene:

$$\boxed{r_{xx}[k] = \sum_{n=1}^{N-k} x[n]x[n-k] = \sum_{n=1}^{N-k} x[n+k]x[n]} \quad (2.17)$$

El teorema de Wiener-Khintchine, nos indica que la densidad espectral de energía S_{xx} de una señal es la transformada de Fourier de su autocorrelación r_{xx} , por lo cual, la autocorrelación de una señal y su densidad espectral de energía contienen la misma información acerca de la amplitud de la señal, pero ninguna de las dos contiene información de su fase.

$$r_{xx}[k] \xleftrightarrow{F} S_{xx}(\omega)$$

$$S_{xx}(\omega) = |X(\omega)|^2$$

El teorema de Parseval nos indica que la energía en el dominio del tiempo es igual a la energía en el dominio de la frecuencia (densidad espectral de energía S_{xx}) y adicionalmente es igual al retardo cero ($k = 0$) de la AC, entonces:

$$E_x = r_{xx}[0] = \sum_{n=1}^N |x[n]|^2 = \frac{1}{2\pi} \int_{2\pi} |X(\omega)|^2 d\omega = \frac{1}{2\pi} \int_{2\pi} S_{xx}(\omega) d\omega$$

La forma o morfología de la secuencia de autocorrelación $r_{xx}[k]$ no cambia al aplicarle un factor de escala a la serie temporal $x[n]$, únicamente se modifica su amplitud en la misma escala. Dado que el cambio de amplitud no es significativo en la AC, se normaliza la secuencia en un rango comprendido entre -1 y 1 , simplemente dividiendo entre la energía de la señal $r_{xx}[0]$, por lo tanto, la AC normalizada se define:

$$\boxed{\gamma_{xx}[k] = \frac{r_{xx}[k]}{r_{xx}[0]} = \frac{r_{xx}[k]}{E_x}} \quad (2.18)$$

Por lo anterior, la función de autocorrelación depende solamente de los retardos de tiempo k y para un proceso real aleatorio estacionario, la función de autocorrelación se puede definir como [51]:

$$\gamma_{xx}[k] = E\{x[n]x^*[n-k]\} = E\{x[n+k]x^*[n]\} \quad (2.19)$$

Además, en los procesos estacionarios tenemos la forma especial, cuando $m = n - k$:

$$\gamma_{x_1x_2}[m-k] = E\{x_1[n-k]x_2^*[n-m]\} \quad (2.20)$$

La secuencia de AC ayuda a reducir el efecto de la variabilidad de la frecuencia cardíaca en procesos de reconocimiento con señales ECG [55–57].

2.4.6. Estimación espectral paramétrica

En la estimación espectral mediante un sistema LTI, la entrada $w[n]$ del sistema no es observable dado que se parte de un proceso estocástico, sin embargo, si los datos de salida $x[n]$ son caracterizados como un proceso aleatorio estacionario, entonces la señal de entrada $w[n]$, también es asumida como un proceso aleatorio estacionario, tal como se muestra en la figura 2.7, donde la densidad espectral de la señal observada es:

$$S_{xx}(\omega) = |H(\omega)|^2 S_{ww}(\omega)$$

El objetivo es estimar la densidad espectral $S_{xx}(\omega)$, por lo cual, es conveniente suponer que la secuencia de entrada $w[n]$ del sistema es la secuencia de ruido blanco con muestras incorrelacionadas, media cero y una densidad espectral plana.



Figura 2.7: Representación de un sistema LTI.

La autocorrelación de una secuencia de ruido blanco, tiene una densidad de energía constante definida de la siguiente manera:

$$\gamma_{ww}[m] = \sigma_w^2 \delta[m]$$

Un sistema LTI se puede clasificar como *causal* y *no causal*, se dice que un sistema es causal si la salida del sistema $x[n]$ en cualquier tiempo n depende solo de valores de la entrada presentes o pasados pero no depende de valores futuros de la entrada, en caso de depender de valores futuros de la entrada, el sistema es no causal. Un sistema discreto LTI causal y recursivo (que $x[n]$ depende de valores pasados de sí misma) puede ser modelado o representado de forma paramétrica en relación a la entrada y salida del sistema:

$$x[n] = -\sum_{k=1}^p a_k x[n-k] + \sum_{k=0}^q b_k w[n-k] \quad (2.21)$$

donde a_k y b_k son parámetros constantes específicos del sistema. Además k representa los retardos en unidad de la secuencia de muestreo y la memoria finita del sistema la determinan p y q .

El modelamiento con la estimación espectral busca describir los parámetros de un filtro lineal $H[z]$, que represente la estimación de la respuesta espectral del proceso aleatorio $x[n]$ a partir de la secuencia de ruido blanco $w[n]$ como se ilustra en la figura 2.7. De forma racional la respuesta del filtro se puede expresar en términos de los coeficientes a_k y b_k de longitud finita p y q respectivamente:

$$H[z] = \frac{\sum_{k=0}^q b_k z^{-k}}{1 + \sum_{k=1}^p a_k z^{-k}} \quad (2.22)$$

Los coeficientes del filtro determinan la ubicación de los ceros y los polos de $H[z]$. El filtro es causal, estable y de fase mínima si los las raíces del numerador y el denominador están dentro de la circunferencia unitaria del plano z . Si la densidad espectral de energía de un proceso aleatorio estacionario es una función racional, existe una relación básica entre la autocorrelación de la señal observada $\gamma_{xx}[m]$ y los parámetros a_k y b_k del filtro $H[z]$, que genera la estimación del proceso $x[n]$, filtrando el ruido blanco $w[n]$. Para encontrar la relación, se multiplica la ecuación (2.21) por $x^*[n-m]$ y se toma su valor esperando:

$$\mathbb{E}\{x[n]x^*[n-m]\} = -\sum_{k=1}^p a_k \mathbb{E}\{x[n-k]x^*[n-m]\} + \sum_{k=0}^q b_k \mathbb{E}\{w[n-k]x^*[n-m]\}$$

mediante las ecuaciones (2.19) y (2.20) se obtiene:

$$\gamma_{xx}[m] = -\sum_{k=1}^p a_k \gamma_{xx}[m-k] + \sum_{k=0}^q b_k \gamma_{wx}[m-k]$$

La correlación cruzada $\gamma_{wx}[m-k]$ está relacionada con la respuesta al impulso del filtro mediante la definición de convolución para un sistema LTI y teniendo presente que la entrada $w[n]$ al sistema es ruido blanco, por lo cual se tiene [51]:

$$\gamma_{wx}[m-k] = \gamma_{wx}[m] = \sigma_w^2 h[-m]$$

obteniendo entonces la estimación espectral:

$$\gamma_{xx}[m] = \begin{cases} -\sum_{k=1}^p a_k \gamma_{xx}[m-k] & \text{si } m > q \\ -\sum_{k=1}^p a_k \gamma_{xx}[m-k] + \sigma_w^2 \sum_{k=0}^{q-m} h[k] b_{k+m} & \text{si } 0 \leq m \leq q \\ \gamma_{xx}^*[-m] & \text{si } m < 0 \end{cases} \quad (2.23)$$

El filtro $h[k]$ en la ecuación (2.23) depende de los coeficientes a_k y b_k como se evidencia en la ecuación (2.22), por lo cual, la ecuación (2.23) no es lineal.

En la ecuación (2.21), cuando $p = 0$ el modelo es llamado *media móvil* (MA) y cuando $q = 0$ con $b_0 \neq 0$, el modelo es llamado *autoregresivo* (AR). Se buscan modelos de memoria corta, por lo cual, los sistemas AR son más usados en aplicaciones, por ser más fáciles de analizar y tener una representación lineal, además los parámetros de un modelo AR se relaciona directamente con los coeficientes de un predictor lineal (LPC). Un sistema AR se define:

$$H[z] = \frac{b_0}{1 + \sum_{k=1}^p a_k z^{-k}}$$

donde b_0 es la ganancia del sistema y p es el orden del modelo. Como la entrada del sistema es ruido blanco, $b_0 = \sigma_w^2$, entonces para un sistema AR, la estimación espectral es:

$$\gamma_{xx}[m] = \begin{cases} -\sum_{k=1}^p a_k \gamma_{xx}[m-k] & \text{si } m > 0 \\ -\sum_{k=1}^p a_k \gamma_{xx}[m-k] + \sigma_w^2 & \text{si } m = 0 \\ \gamma_{xx}^*[-m] & \text{si } m < 0 \end{cases} \quad (2.24)$$

De la ecuación (2.24) se pueden obtener los parámetros a_k de un modelo AR con relación lineal a la secuencia $\gamma_{xx}[m]$, mediante la solución de las ecuaciones de Yule-Walker o ecuaciones normales ($m > 0$):

$$\begin{bmatrix} \gamma_{xx}[0] & \gamma_{xx}[-1] & \vdots & \gamma_{xx}[-p+1] \\ \gamma_{xx}[1] & \gamma_{xx}[0] & \vdots & \gamma_{xx}[-p+2] \\ \dots & \dots & \vdots & \vdots \\ \gamma_{xx}[p-1] & \gamma_{xx}[p-2] & \vdots & \gamma_{xx}[0] \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = - \begin{bmatrix} \gamma_{xx}[1] \\ \gamma_{xx}[2] \\ \vdots \\ \gamma_{xx}[p] \end{bmatrix} \quad (2.25)$$

con la varianza de la señal de entrada definida ($m = 0$):

$$\sigma_w^2 = \gamma_{xx}[0] + \sum_{k=1}^p a_k \gamma_{xx}[-k] \quad (2.26)$$

Finalmente, las ecuaciones (2.25) y (2.26) son combinadas dentro de una misma ecuación matricial, obteniendo:

$$\underbrace{\begin{bmatrix} \gamma_{xx}[0] & \gamma_{xx}[-1] & \vdots & \gamma_{xx}[-p] \\ \gamma_{xx}[1] & \gamma_{xx}[0] & \vdots & \gamma_{xx}[-p+1] \\ \dots & \dots & \vdots & \vdots \\ \gamma_{xx}[p] & \gamma_{xx}[p-1] & \vdots & \gamma_{xx}[0] \end{bmatrix}}_{\mathbf{R}_\gamma} \underbrace{\begin{bmatrix} 1 \\ a_1 \\ \vdots \\ a_p \end{bmatrix}}_{\mathbf{a}} = \underbrace{\begin{bmatrix} \sigma_w^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix}}_{\mathbf{r}_w} \quad (2.27)$$

La ecuación (2.27) es lineal y además la matriz cuadrada \mathbf{R}_γ es toeplitz, en la cual, todos los elementos de una diagonal dada son idénticos e igual a la función de autocorrelación en dicho

retardo de tiempo. La matriz toeplitz, es una propiedad de las matrices de correlación de un proceso estacionario y permite aplicar métodos eficientes de estimación espectral. Los vectores \mathbf{a} y \mathbf{r}_w son de longitud $p + 1$ e igual para el tamaño de la matriz cuadrada \mathbf{R}_γ . Toda matriz toeplitz es invertible, por lo cual, el modelo AR es fácilmente determinado conociendo la secuencia de autocorrelación $\gamma_{xx}[m]$ para $0 \leq m \leq p$, donde p es el orden del proceso AR [51,52,58].

Para este trabajo se desarrollará e implementará el método de estimación de los parámetros AR mediante el método de Yule-Walker, que consiste en estimar la autocorrelación $\gamma_{xx}[m]$ mediante las ecuaciones (2.17) y (2.18) a partir de los datos observados, luego con $\gamma_{xx}[m]$, se obtiene la matriz \mathbf{R}_γ y finalmente se soluciona la ecuación (2.27) para obtener los parámetros del modelo AR, basándose en el algoritmo de Levinson-Durbin. El otro método sobresaliente en la literatura es el método de Burg para la estimación de los parámetros del modelo AR, puede interpretarse como un método de orden recursivo de mínimo cuadrados en celosía, basado en minimizar los errores directos e inversos de los predictores lineales, mediante el cálculo de los coeficientes de reflexión de la estructura en celosía equivalente. La estimación de Burg es asociada con la estimación espectral de máxima entropía.

2.5. Técnicas de toma de decisión y evaluación

Como se estudio en las subsecciones 2.1.2 y 2.1.3, los sistemas biométricos tienen dos funcionalidades en el módulo de toma de decisión según su aplicación: *autenticación* e *identificación* de personas. Un proceso de autenticación tiene una respuesta *aceptada-genuino* (1) o *rechazada-impostor* (0) ante una consulta dada. Un proceso de identificación tiene una respuesta *positiva* (1), si la etiqueta de clase de la consulta presentada coincide y está en la base de datos, determina la etiqueta de clase de dicha consulta, identificando así a la persona; pero también puede tener una respuesta *negativa* (0), cuando la etiqueta de clase de la consulta presentada no está inscrita en la base de datos [59].

Los sistemas de reconocimiento adicionalmente tienen dos conceptos importantes: *mundo abierto* y *mundo cerrado*. El concepto de mundo abierto se refiere al posible uso de patrones o vectores de características con etiquetas de clase no necesariamente inscritas en la base de datos, es decir, la posibilidad de someter el sistema de reconocimiento a consultas de etiquetas de clase no inscritas, donde dicho sistema, debe estar en condiciones de responder ya sea, reconociendo un impostor (autenticación rechazada “0”) o identificando que la etiqueta de dicha consulta o entrada no está inscrita en la base de datos (identificación negativa “0”) y el concepto de mundo cerrado se refiere a la restricción de único uso de muestras de entrada o consultas con etiquetas de clase necesariamente inscritas en la base de datos del sistema. En esta investigación nos centramos en procesos de biometría con aprendizaje automatizado y con el concepto de mundo cerrado.

El módulo de toma de decisión se fundamenta en procesos de comparación que permiten obtener una medida de coincidencia o asociación entre los vectores característicos tanto en procesos *uno contra uno* como en procesos *uno contra todos*, respecto a las características almacenadas de los sujetos durante la inscripción. Ya con las medidas o métricas de similitud y/o disimilitud, se implementan procesos de decisión que permitan validar o identificar a una persona. Los pro-

cesos de comparación centran su atención en métricas de distancias o similitud y los procesos de decisión centran su atención en la optimización de la pérdida o error de reconocimiento, dichas técnicas buscan tomar la decisión de reconocimiento optimizando al máximo el error de verificación e identificación. La definición del error depende de la formulación de la hipótesis del proceso de comparación para cada modalidad y aplicación de reconocimiento, además como se mencionó antes, se manejará un reconocimiento positivo o de mundo cerrado (reconocimiento tipo I), definiendo las siguientes hipótesis:

- **Hipótesis nula H_o :** Coincidencia entre dos vectores de características.
- **Hipótesis alternativa H_a :** No coincidencia entre dos vectores de características.

2.5.1. Matriz de confusión

Una matriz de confusión o matriz de contingencia en el campo de la inteligencia artificial, se enfrenta al problema de clasificación o reconocimiento estadístico. La matriz de confusión permite visualizar el desempeño de un algoritmo en el aprendizaje supervisado, analizando los resultados de las predicciones de las clases, con respecto a las etiquetas de las clases reales. La diagonal de dicha matriz representa las clasificaciones correctas, por lo tanto, todo aquello que esté por fuera de la diagonal indica un error cometido en el reconocimiento de dicha clase. En la figura 2.8, se observa que existen 4 posibles resultados [60]:

- Cuando la clase real es positiva y clasificada mediante su predicción como positiva, se define el resultado como *verdadero positivo (TP)*.
- Cuando la clase real es positiva y clasificada mediante su predicción como negativa, se define el resultado como *falso negativo (FN)*.
- Cuando la clase real es negativa y clasificada mediante su predicción como positiva, se define el resultado como *falso positivo (FP)*.
- Cuando la clase real es negativa y clasificada mediante su predicción como negativa, se define el resultado como *verdadero negativo (TN)*.

		Clase real	
		Positivo	Negativo
Predicción de clase	Positivo	TP	FP
	Negativo	FN	TN

Figura 2.8: Matriz de confusión para verificación e identificación.

Tanto en verificación como en identificación se tomará: *verificación genuina e identificación correcta*, cuando la predicción de clase sea positiva y la clase real también. Adicional, de los resultados de la figura 2.8, se definen medidas de evaluación o rendimiento:

- **Exactitud:** Representa el porcentaje de predicciones correctas, tanto positivas como negativas del número total de clases reales presentadas y está relacionada con el sesgo de estimación.

$$\text{Exactitud} = \frac{TP + TN}{TP + FP + FN + TN} \quad (2.28)$$

- **Precisión:** Representa el porcentaje de la predicción de clases positivas que fueron correctas.

$$\text{Precisión} = \frac{TP}{TP + FP} \quad (2.29)$$

- **Tasa de falsos negativos (FNR ó FRR):** También conocida como tasa de falso rechazo (FRR) o la tasa de falsa no coincidencia (FNMR), representa el porcentaje de clases positivas reales que fueron clasificadas de manera negativa. Es decir, es el número de veces que el sistema no reconoce que un vector de características proviene del mismo individuo que produjo la referencia. El sistema decide en el proceso de comparación H_a cuando H_o es verdad.

$$FNR = FRR = FNMR = \frac{FN}{TP + FN} \quad (2.30)$$

- **Sensitividad o Tasa de verdaderos positivos (TPR):** Representa el porcentaje de clases positivas reales que fueron clasificadas correctamente.

$$\text{Sensitividad} = TPR = \frac{TP}{TP + FN} = 1 - FRR \quad (2.31)$$

- **Tasa de falsos positivos (FPR ó FAR):** También conocida como tasa de falsa aceptación (FAR) o la tasa de falsa coincidencia (FMR), representa el porcentaje de clases negativas reales que fueron clasificadas de manera positiva. Es decir, es el número de veces que el sistema reconoce incorrectamente un vector de características de una persona con un vector de otra. El sistema decide en el proceso de comparación H_o cuando H_a es verdad.

$$FPR = FAR = FMR = \frac{FP}{FP + TN} \quad (2.32)$$

- **Especificidad o Tasa de verdaderos negativos (TNR):** Representa el porcentaje de clases negativas reales que fueron clasificadas correctamente.

$$\text{Especificidad} = TNR = \frac{TN}{FP + TN} = 1 - FAR \quad (2.33)$$

Las tasas FRR y FAR , son parámetros que evalúan el rendimiento de un sistema de reconocimiento biométrico tanto en autenticación como en identificación y toman su importancia en la definición de las hipótesis. De la matriz de confusión, para los procesos de decisión basados en umbrales se define la curva ROC [3, 60], que es una precisa y completa especificación del rendimiento de un sistema de reconocimiento biométrico, reflejando el resultado de la optimización del error en las técnicas de toma de decisión de las medidas de asociación, producto de los procesos de comparación. La curva ROC proporciona información sobre la definición del un límite o sesgo de decisión (umbral), optimizando su rendimiento en el punto o *tasa de error igual EER*. Dicha tasa, es un indicador biométrico o punto de operación apropiado para evaluar la calidad de las técnicas de comparación, especialmente en los procesos de verificación, obteniendo un punto de mínimo error eficiente esperado, donde $FRR = FAR = EER$ a un determinado umbral de decisión, denominado *umbral óptimo*.

2.5.2. Medidas de asociación: distancia y similitud

La teoría de *clustering* es un conjunto de técnicas de análisis multivariante que se fundamenta en el problema de agrupamiento-clasificación de objetos, vectores característicos o individuos según su similitud mutua o homogeneidad, donde dicho agrupamiento está relacionado con los métodos de estimación de densidad de probabilidad de los valores cuantitativos de las observaciones como parámetros del modelo, permitiendo así el reconocimiento de un conjunto finito de categorías, etiquetas de clase, poblaciones o grupos que son descritos por las características extraídas de los señales o registros de datos observados. Entonces el objetivo de la teoría de agrupamiento es determinar la agrupación intrínseca de los conjuntos de datos sin etiquetar, donde existen dos tipos de medidas de asociación de los vectores de características: los criterios basados en homogeneidad (similitud) y los basados en disimilitudes [61–63].

Métricas de proximidad, similitud o semejanza

Miden el grado de semejanza entre dos objetos o vectores de características (\mathbf{A} y \mathbf{B}); entre mayor es su valor, mayor es el grado de semejanza y mayor probabilidad que la decisión los incluya en la misma etiqueta de clase. Sus métricas más representativas son: el coeficiente de correlación de Pearson, el coeficiente de distancia coseno, los coeficientes de correlación por rangos de Kendall y Spearman y coeficientes de asociación.

La covarianza de dos vectores \mathbf{A} y \mathbf{B} de longitud de muestras N , está definida de la siguiente manera:

$$\delta_{\mathbf{AB}} = \frac{1}{N-1} \sum_{i=1}^N (A[i] - \mu_{\mathbf{A}}) (B[i] - \mu_{\mathbf{B}})$$

Por lo tanto, la covarianza normalizada con la multiplicación entre la desviación estándar de cada vector, es la definición del *coeficiente de correlación de Pearson*. Se define la distancia de correlación, donde, entre más cerca esté dicho valor de cero, más similitud existe entre el vector inscrito y el vector de consulta:

$$d_{corr}(\mathbf{A}, \mathbf{B}) = 1 - \frac{\delta_{\mathbf{AB}}}{\delta_{\mathbf{A}}\delta_{\mathbf{B}}} \quad (2.34)$$

Métricas de disimilitud, desemejanza o distancia:

Miden la distancia entre dos objetos o vectores de características (\mathbf{A} y \mathbf{B}); entre mayor sea su valor, más diferentes son los objetos y menos probabilidad que la decisión los incluya en la misma etiqueta de clase. Sus métricas más representativas son: la distancia euclidiana, la distancia Mahalanobis y distancia dtw (dynamic time warping), esta última distancia se estudia de [64].

La definición de métrica de distancia punto a punto de dos vectores más relevante es la distancia Minkowski, que es la siguiente:

$$d(\mathbf{A}, \mathbf{B}) = \|\mathbf{A} - \mathbf{B}\|_g = \left(\sum_{n=1}^N |A[n] - B[n]|^g \right)^{1/g}$$

Cuando $g = 1$, se obtiene la distancia *city block* o distancia Manhattan. Cuando $g = 2$, se obtiene una distancia que permite definir la distancia euclidiana, Mahalanobis y de Pearson, descrita de la siguiente manera:

$$d(\mathbf{A}, \mathbf{B}) = \sqrt{(\mathbf{A} - \mathbf{B}) \mathbf{\Gamma} (\mathbf{A} - \mathbf{B})^T}$$

La matriz $\mathbf{\Gamma}$ es una matriz cuadrada, donde su tamaño está definido por la longitud de los vectores de características. Cuando la matriz $\mathbf{\Gamma}$ es la matriz identidad \mathbf{I} , se define la distancia euclidiana:

$$d_{eucl}(\mathbf{A}, \mathbf{B}) = \sqrt{(\mathbf{A} - \mathbf{B}) \mathbf{I} (\mathbf{A} - \mathbf{B})^T} \quad (2.35)$$

Si los valores de los vectores de características no están correlacionados entre si, es posible definir la distancia Mahalanobis, que no es sensible a la variación de la escala de los valores de amplitud de las muestras y tiene presente la corrección de los vectores de características de la población total, siendo definida con la siguiente ecuación:

$$d_{mahl}(\mathbf{A}, \mathbf{B}) = \sqrt{(\mathbf{A} - \mathbf{B}) \mathbf{\Sigma}^{-1} (\mathbf{A} - \mathbf{B})^T} \quad (2.36)$$

Mediante el análisis canónico de poblaciones, la matriz $\mathbf{\Sigma}$ es definida como la matriz de covarianza dentro de las poblaciones o simplemente como la *matriz de covarianza poblacional* y se estima de la siguiente manera [65]:

$$\mathbf{\Sigma} \approx \hat{\mathbf{\Sigma}} = \frac{1}{\text{obs} - K} \sum_{i=1}^K (\alpha_i - 1) \mathbf{S}_i \quad (2.37)$$

Cada población tiene un número igual de observaciones $\alpha_i = \alpha$, siendo K el número total de poblaciones o etiquetas de clases presentes y \mathbf{S}_i , la matriz de covarianza de todas las observaciones α de la población i , por lo tanto, el número de observaciones totales de la población de etiquetas de clase es:

$$\text{obs} = \sum_{i=1}^K \alpha_i \rightarrow \text{obs} = \alpha K \quad (2.38)$$

Reemplazando la definición de (2.38) en la estimación de la ecuación (2.37) y simplificando se obtiene:

$$\begin{aligned} \hat{\mathbf{\Sigma}} &= \frac{1}{(\alpha K) - K} \sum_{i=1}^K (\alpha - 1) \mathbf{S}_i \\ &= \frac{(\alpha - 1)}{(\alpha - 1) K} \sum_{i=1}^K \mathbf{S}_i \end{aligned}$$

por lo tanto, la estimación de la matriz de covarianza poblacional es:

$$\boxed{\mathbf{\Sigma} \approx \hat{\mathbf{\Sigma}} = \frac{1}{K} \sum_{i=1}^K \mathbf{S}_i} \quad (2.39)$$

La matriz de covarianza poblacional $\Sigma \approx \hat{\Sigma}$ es una matriz simétrica cuadrada invertible, donde su tamaño esta dado por la longitud del vector de características obtenido de la técnica de extracción aplicada.

En una matriz de covarianza, su diagonal es el vector de varianzas, por lo cual, solo tomando la diagonal de la matriz de covarianza poblacional se define la distancia de Pearson:

$$d_{pear}(\mathbf{A}, \mathbf{B}) = \sqrt{(\mathbf{A} - \mathbf{B}) \text{diag}(\Sigma^{-1}) (\mathbf{A} - \mathbf{B})^T} \quad (2.40)$$

2.5.3. Métricas de rendimiento para procesos de Autenticación

El objetivo de las técnicas de decisión en procesos de autenticación es verificar la reclamación de una identidad o etiqueta de clase mediante métricas de asociación. A partir de la matriz de confusión, la curva ROC y las tasas de error, se evalúa el porcentaje de *conveniencia* y *seguridad* de un sistema de autenticación en su fase de entrenamiento y de prueba como [3]:

$$\begin{aligned} \text{Conveniencia} &= TPR = 1 - FRR \\ \text{Seguridad} &= TNR = 1 - FAR \end{aligned}$$

En la fase de entrenamiento se define $EER = FRR = FAR$ y el *área bajo la curva* (AUC), donde, el AUC es la probabilidad que se clasifique una etiqueta de clase positiva aleatoria de manera más adecuada que una etiqueta de clase negativa. En la fase de prueba o test, se define el rendimiento del sistema con la *tasa de verificación* (VR) [32, 35]:

$$VR = \frac{\text{Conveniencia} + \text{Seguridad}}{2} = 1 - \frac{FRR + FAR}{2} \quad (2.41)$$

De la ecuación (2.41), se evidencia que en el entrenamiento $VR = 1 - EER$.

2.5.4. Métricas de rendimiento para procesos de Identificación

La decisión en procesos de identificación consisten en técnicas de clasificación entre múltiples clases. A partir de las métricas de evaluación de la matriz de confusión en los procesos de identificación biométrica se evalúa el rendimiento con el porcentaje de *fiabilidad* Rel, de que tan bien clasifican los vectores consulta y que tan seguro o confiable es el sistema en el reconocimiento. La tasa o porcentaje de fiabilidad es igual a la sensibilidad, por lo cual, la *tasa de identificación* (IR) es:

$$IR = \text{Rel} = TPR = 1 - FRR \quad (2.42)$$

En la fase de entrenamiento se definen y construyen los parámetros del modelo de clasificación y en la fase de prueba o test se evalúa el rendimiento de identificación con la ecuación (2.42). Las técnicas de decisión más usuales son las redes neuronales, k vecinos más cercanos, máquinas de vectores de soporte, análisis de discriminante lineal, métrica dtw, redes bayesianas, árboles de decisión, random forests, modelo oculto de Márkov, lógica difusa, entre otros. [55, 66, 67].

2.5.5. Técnicas de clasificación

El reconocimiento de patrones con aprendizaje supervisado en su fase de identificación, tiene como objetivo predecir una categoría o etiqueta de clase para una entrada dada. En la fase de entrenamiento, se definen los parámetros de los algoritmos o técnicas de clasificación para predecir una categoría y no un número. Se definen los tres clasificadores estudiados en esta investigación [63, 68]:

k vecinos más cercanos (k NN)

Es el método de clasificación supervisada más usado en el reconocimiento biométrico basado en ECG, es un método de clasificación no paramétrico, destacado por la métrica de asociación utilizada y el número de vecinos más cercanos elegido. Su algoritmo está fundamentado en las métricas de distancia y similitud, que involucra comparar un vector de consulta con los vectores almacenados del proceso de inscripción durante el entrenamiento y seleccionar la etiqueta de clase que produzca mejor coincidencia en los k vectores (vecinos) más cercanos al mejor puntaje de similitud o distancia, es decir, eligiendo la etiqueta de clase más frecuente y viable entre los k vecinos más cercanos según la métrica de asociación utilizada.

Análisis de discriminante lineal (LDA)

La clasificación con LDA hace uso del teorema de Bayes, seleccionando la etiqueta de clase k con el valor de probabilidad $\hat{\delta}_k(\mathbf{x})$ más alto dado del vector de consulta \mathbf{x} . La variable cuantitativa o de probabilidad para el algoritmo LDA multiclase se define de la siguiente manera:

$$\hat{\delta}_k(\mathbf{x}) = \log\left(P(k|\mathbf{x})\right) = \mathbf{x}\Sigma^{-1}\boldsymbol{\mu}_k^T - \frac{1}{2}\boldsymbol{\mu}_k^T\Sigma^{-1}\boldsymbol{\mu}_k^T + \log(\pi_k) \quad (2.43)$$

Donde $\boldsymbol{\mu}_k$ es el vector promedio de los vectores de características de la clase k , la probabilidad de cada etiqueta de clase está definida por π_k y Σ es la matriz de covarianza poblacional. La estimación de los parámetros del modelo se realiza mediante el análisis discriminante canónico para k clases. LDA también a sido utilizado por varios estudios en la literatura biométrica con ECG.

Red neuronal artificial (ANN)

Una red neuronal artificial combina diversas capas de procesamiento y utiliza elementos simples que operan en paralelo. Están constituidas por una capa de entrada, una o varias capas ocultas y una capa de salida. Las capas están interconectadas mediante *neuronas*, utilizando la salida de la capa anterior como entrada, la cual, es multiplicada por un *valor de peso*. A la salida de cada neurona, existe una función limitadora que modifica el valor resultante, imponiendo un límite que no se debe sobrepasar antes de propagarse a la siguiente neurona, esta función se conoce como *función de activación* o *función de transferencia* $f(x)$. Las funciones de activación o transferencia son funciones no lineales que transforman los valores de entrada en valores de salida en los rangos de $(0, 1)$ ó $(-1, 1)$ y las funciones más comunes son:

- Función de transferencia sigmoidea tangente hiperbólica:

$$f(x) = \text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (2.44)$$

- Función de transferencia de base radial:

$$f(x) = \text{radbas}(x) = e^{-x^2} \quad (2.45)$$

Las redes neuronales, generalmente son entrenadas a través de la retropropagación del error, es decir, *backpropagation*. Además, determinar el número necesario de capas ocultas y de neuronas en las capas ocultas es generalmente un proceso empírico, pero el número de neuronas nN_h de una capa oculta puede ser intuitivo mediante la regla piramidal o regla de la pirámide geométrica:

$$nN_h = \sqrt{(nN_{in})(nN_{out})} \quad (2.46)$$

Donde nN_{in} es el número de neuronas de la capa anterior o de entrada y nN_{out} es el número de neuronas de la capa siguiente o de salida.

2.6. Bases de datos ECG de dominio público

Se estudian las bases de datos de investigaciones médicas disponibles públicamente en el sitio web de *PhysioNet*⁴, administrado por el laboratorio de fisiología computacional del MIT. Dicho estudio se registra en la tabla 2.1, siendo: **NS** (Número de sujetos), **f_s** (Frecuencia de muestreo en Hz), **T. E.** (Tipo de electrodo: Húmedo (**H**) o seco (**S**)), **Ubic. elect.** (Ubicación de electrodos, se consideran tres lugares; **P**: Electrodo colocado en el pecho de la persona, **AB**: Electrodo colocado en los antebrazos de la persona, incluye las zonas de los codos y las muñecas y **D**: Electrodo colocado en los dedos de la persona), **Cond. salud** (Condición de salud de las personas, **Sanos**: totalmente sanos y **Varias**: Varias condiciones de salud), **Esc. T.** (Varios escenarios de tiempo, sesiones de grabación adquiridas en diferentes días, semanas o meses), **Esc. C. P.** (Escenarios de grabación ante situaciones de variabilidad a corto plazo), **Inf.** (Información sobre la edad y sexo de las personas, además de la fecha de grabación de las señales) y **Dur.** (Duración de las señales adquiridas).

Las bases de datos descritas en la tabla 2.1, son creadas bajo ciertas condiciones y con aplicaciones en específico:

- Diagnóstico o clasificación de enfermedades y arritmias.
- Estudio de la estimación de la frecuencia respiratoria a partir de la señal ECG.
- Estudio del efecto del sistema nervioso y respiratorio en la variabilidad del ritmo cardíaco.
- Estudio de variabilidad de la morfología del complejo cardíaco ante la postura, emociones, estrés físico o mental y envejecimiento en procesos biométricos.

⁴*Physionet databases*: <https://archive.physionet.org/cgi-bin/atm/ATM>

Base de datos	NS	f_s [Hz]	T. E.	Ubic. elect.	Cond. salud	Esc. T	Esc. C. P.	Inf.	Dur. [min]
<i>BD propia</i> ⁵	32+	125	H	AB	Sanos	No	Sí	Sí	8
<i>BIDMC PPG</i> [69]	53	125	H	P	Varias	No	No	Sí	8
<i>CYBHi</i> ⁶ [70]	128	1000	S	AB - D	Sanos	Sí	Sí	Sí	1 a 5
<i>CEBS</i> [71]	20	5000	H	P - AB	Sanos	No	Sí	No	3 : 20
<i>ECG-ID</i>	90	500	H	AB	Sanos	Sí	No	Sí	0 : 20
<i>Fantasia</i>	40	250	-	-	Sanos	No	Sí	Sí	60
<i>MGH/MF</i>	250	360	H	P - AB	Varias	No	No	Sí	12 a 86
<i>PTB</i>	290	1000	H	P - AB	Varias	No	No	Sí	0 : 38
<i>BD QT</i> [11]	105	250	H	P	Varias	No	No	Sí	15
<i>E. ST-T</i>	79	250	H	P	Varias	No	No	Sí	120
<i>MIT-BIH</i>	47	360	H	P	Varias	No	No	Sí	30
<i>L. T-ST</i>	80	250	H	P	Varias	No	No	Sí	60
<i>STAFF III</i>	104	1000	H	P - AB	Varias	No	Sí	Sí	5
<i>SHAREE</i>	139	128	H	P	Varias	No	No	No	120
<i>Apnea-ECG</i>	35	100	H	P	Sanos	Sí	Sí	No	166
<i>BD Driver</i>	9	456	H	P	Sanos	Sí	Sí	No	60
<i>ECGRDVQ</i> [72]	22	1000	H	P	Sanos	Sí	Sí	No	0 : 10
<i>MACECGDB</i>	1	500	H	P	Sanos	No	Sí	Sí	0 : 08
<i>Wrist</i>	9	256	H	P	Sanos	No	Sí	No	6 a 9
<i>PRCP</i>	10	250	H	P	Sanos	No	Sí	Sí	55

Tabla 2.1: Resumen de las características de las bases de datos con señales cardíacas más relevantes disponibles públicamente.

⁵Base de datos propia: *BD propia*, desarrollada en el grupo de investigación con señales ECG y PPG.

⁶*CYBHi database*: <https://zenodo.org/record/2381823#.XT2Ik9VKG2w>

Desarrollo experimental en Software

Contenidos del capítulo

- 3.1. Construcción de la base datos para el proceso de biometría ECG
 - 3.2. Implementación en software de la etapa de pre-procesamiento
 - 3.3. Planteamiento de validación cruzada mediante combinaciones
 - 3.4. Desarrollo del sistema de Autenticación
 - 3.5. Desarrollo del sistema de identificación
-

3.1. Construcción de la base datos para el proceso de biometría ECG

Se desea analizar y seleccionar un conjunto de bases de datos de señales cardíacas con sistemas de adquisición no tradicional (no médico), fácil de repetir y eficientes, que permitan construir una base de datos consolidada para el proceso de biometría desarrollado en esta investigación. La construcción de la base de datos tiene como objetivo permitir el estudio y análisis del rendimiento del sistema de reconocimiento ante las diversas fuentes de variabilidad cardíaca, el número elevado de personas inscritas en la base de datos y diferentes tiempos de adquisición de la señal ECG.

3.1.1. Selección de bases de datos ECG

Con el fin mencionado anteriormente, se consideran bases de datos que contengan registros de personas sanas, tomando la señal cardíaca en las extremidades superiores (AB y D) y que suministren la información de sexo, edad y fecha de adquisición. Del análisis de las bases de datos de la tabla 2.1, se obtiene como resultado la selección de las bases de datos: *BD propia*, *CYBHi* y *ECG-ID*, que son descritas a continuación:

La base de datos *BD propia*: Es el conjunto de señales cardíacas tomadas en los antebrazos (zona del codo) con el sensor AD8232 de Sparkfun® y señales PPG tomadas en el dedo anular de la mano derecha con el sensor Spo2 g de tec®, que se está desarrollando en el grupo de investigación con el propósito de procesos biométricos. La base de datos consiste en tomar

8 min de grabación de las señales en un escenario tranquilo, donde la persona en condición sana está sentada viendo un vídeo divertido o relajante (baja excitación emocional), sin presentar escenarios de tiempo o algún otro estímulo de variabilidad a corto plazo.

La base de datos *CYBHi* [70]: Es una base de datos desarrollada para el análisis y estudio de procesos biométricos con señales ECG con sistema de adquisición *on-the-person* y *off-the-person*, tomando la señal cardíaca en los antebrazos (muñecas) con electrodos secos *Ag-AgCl* y en los dedos con electrodos *electrolycras*, esta base de datos presenta dos fases:

1. *Escenarios a corto plazo*: Se toman las señales cardíacas en las muñecas con electrodos secos *Ag-AgCl* y en los dedos con *electrolycras* a un grupo de 65 personas sanas, bajo 3 escenarios de estímulos emocionales:
 - CI: Escenario neutral, donde se toman las señales en un escenario tranquilo mientras se da conocimiento informativo del experimento.
 - A1: La persona ve un vídeo divertido y afectivo (baja excitación emocional) con audio, el vídeo dura 1 min.
 - A2: La persona ve un vídeo afectivo y de terror (alta excitación emocional) con audio, el vídeo dura 1 min.
2. *Escenarios a largo plazo*: Se toman 2 registros de señales para 63 personas sanas y diferentes a las del experimento de escenarios a corto plazo, cada grabación fue tomada con una distancia de tiempo aproximadamente de 3 meses. Solo se toman la señal cardíaca con electrodos secos *Ag-AgCl* ubicados en los dedos.

Las grabaciones tienen una duración entre 1 a 5 min, donde todos los registros tienen mínimo 1 min de grabación.

La base de datos *ECG-ID* [73]: Es un conjunto de señales cardíacas tomas en los antebrazos para procesos biométricos de 90 personas sanas. Esta base de datos presenta escenarios de tiempo y el número de registros para cada persona varía de 2 capturas de señal durante un día a 20 capturas periódicamente durante 6 meses, todos los registros tienen una duración de 20 s.

La tabla 3.1 resalta aspectos importantes de las bases de datos seleccionadas para consolidar un conjunto de datos más amplio, estas señales deben ser llevadas a una misma frecuencia de muestreo (125 Hz). Las 3 bases de datos seleccionadas presentan diversos escenarios de variabilidad de la señal cardíaca ante estímulos audiovisuales y de tiempo. Además, poseen la misma postura, la misma zona de ubicación de los electrodos (extremidades superiores) y sistemas de adquisición similares.

Base de datos	NS	f_s [Hz]	T. E.	Ubic. elect.	Postura	Resolución ADC	Dur. mínima [min]
<i>BD propia</i>	32+	125	H	AB	Sentados	12 bits	8
<i>CYBHi</i>	128	1000	S	AB - D	Sentados	12 bits	1
<i>ECG-ID</i>	90	500	H	AB	Sentados	12 bits	0 : 20

Tabla 3.1: Información de las bases de datos seleccionadas para la consolidación.

3.1.2. Consolidación de la base de datos ECG

En los retos y objetivos propuestos de esta investigación se plantea consolidar una base de datos para el estudio de la variabilidad a corto y largo plazo de la señal ECG, debido a lo cual, se estudian las 3 bases de datos de la tabla 3.1, buscando tener varios registros por persona en diferentes escenarios de variabilidad. Después de realizar una observación y análisis manual de cada uno de los registros de las bases de datos seleccionadas, se obtiene como resultado 10 registros viables por persona con duración de 10s cada uno, donde los registros ECG cumplen con un control de calidad de no presencia de ruidos musculares fuertes, atenuaciones y/o saturaciones en su proceso de adquisición. Obteniendo un conjunto de señales disponible de 140 personas de la población total de las 3 bases de datos, dicho resultado se logra seleccionando 20 personas de la base de datos *ECG-ID*, 91 personas de la base de datos *CYBHi* y 29 de la base de datos *BD propia*, que cumplen lo mencionado anteriormente.

La base de datos consolidada (*BDC*), posee un total de 1400 registros ECG a una frecuencia de muestreo de 125 Hz de la derivación I, para una población de 140 personas entre 18 y 62 años de edad, con un promedio de 29 años. La base de datos está conformada por 89 hombres y 51 mujeres en condición sana de salud y sin problemas cardíacos reportados. Las características de dicha base de datos se presentan en la tabla 3.2.

Base de datos	NS	f_s [Hz]	Ubicación de los electrodos	Cond. salud	Postura	Resol. ADC	Obs. por sujeto	Dur. [s]
<i>BDC</i>	140	125	Extremidades superiores	Sanos	Sentados	12 bits	10	10

Tabla 3.2: Base de datos consolidada para biometría ECG.

Con las señales de la base de datos consolidada se plantea la obtención y procesamiento digital de señales a diferentes tiempo de adquisición, es decir, la base de datos posee registros de 10s de duración, siendo este tiempo, el tiempo máximo de adquisición para el desarrollo de esta investigación y se propone adicionalmente tomar ventanas aleatoria de 3 y 5 s en cada observación disponible de la base de datos. Así se realiza un estudio más compacto y robusto de los retos propuestos. Cada registro de señal posee una longitud de N muestras adquiridas en una ventana fija de tiempo, como se resume en la tabla 3.3. Inicialmente la base de datos fue consolidada con el fin de poder realizar segmentaciones de tiempo a las señales adquiridas para estudiar el rendimiento de las diferentes técnicas de extracción y toma de decisión de los procesos de autenticación e identificación biométrica con señales cardíacas.

Tiempo de adquisición	Muestras N
3 s	375
5 s	625
10 s	1250

Tabla 3.3: Longitudes de tiempo de la señal ECG para el reconocimiento biométrico.

3.2. Implementación en software de la etapa de pre-procesamiento

En esta sección se estudia la implementación y resultado de la teoría descrita en la sección 2.3.

3.2.1. Desarrollo de la fase de filtrado y normalización de amplitud

En la subsección 2.3.1, se analizó que el mejor filtrado para la señal cardíaca es el filtrado de fase cero o fase nula. De la sección 2.2, se concluye que el rango de frecuencia más conveniente para el filtrado de los ruidos y artefactos de variabilidad presentes en los procesos de adquisición de la señal cardíaca, es el rango entre 1 y 30 Hz, con dicho rango de frecuencia se diseña un filtro pasa-banda Butterworth, dando como resultado para su implementación un filtro digital de orden 8 detallado en la tabla 3.4. Con los coeficientes del filtro digital IIR diseñado, se implementa en `Matlab`[®] el filtrado de fase nula descrito en la ecuación (2.1), posteriormente a la respuesta del proceso de filtrado se le realiza la normalización de amplitud con el teorema del límite central descrita en la ecuación (2.2).

a	Valor	b	Valor
a_0	1	b_0	0.074324
a_1	-4.083749	b_1	0
a_2	6.973090	b_2	-0.297296
a_3	-6.922522	b_3	0
a_4	4.851108	b_4	0.445945
a_5	-2.499756	b_5	0
a_6	0.792980	b_6	-0.297296
a_7	-0.130344	b_7	0
a_8	0.019202	b_8	0.074324

Tabla 3.4: Coeficientes del filtro IIR pasa-banda de 1 a 30 Hz.

3.2.2. Desarrollo de la detección del pico R

Para la detección del pico R, se implementan los 5 pasos descritos en la subsección 2.3.3:

1. El filtro para la detección de \mathbf{x}_{QRS} , es un filtro IIR pasa altas para frecuencias superiores a 10 Hz, diseñado como un filtro digital Butterworth de orden 4 detallado en la tabla 3.5, que también es implementado bajo el algoritmo de filtrado de fase nula o fase cero.
2. La señal \mathbf{x}_{dQRS} , que es el resultado de la derivación de la señal filtrada \mathbf{x}_{QRS} , como se detalla en la ecuación (2.3), dicha derivación se implementa mediante un filtro IIR con coeficientes $\mathbf{a} = [1, 0]$ y $\mathbf{b} = [1, -1]$. En la figura 3.1, se ilustran los resultados de la implementación del paso 1 y 2 de la detección del pico R.
3. La transformación no lineal \mathbf{x}_{TNL} , es el resultado de elevar al cuadrado los valores de la señal derivada \mathbf{x}_{dQRS} , como se indica en la ecuación (2.4).

a	Valor	b	Valor
a_0	1	b_0	0.514246
a_1	-2.692610	b_1	-2.056987
a_2	2.867399	b_2	3.085481
a_3	-1.403484	b_3	-2.056987
a_4	0.264454	b_4	0.514246

Tabla 3.5: Coeficientes del filtro IIR pasa altas a 10Hz.

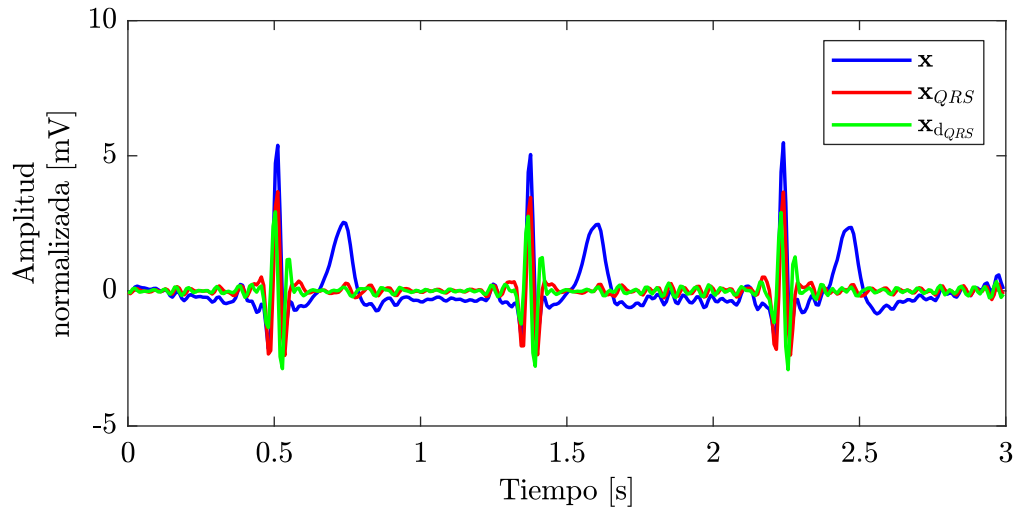


Figura 3.1: Obtención de x_{QRS} y x_{dQRS} .




Figura 3.2: Obtención de x_{TNL} , x_{DM} y $\tau_{umbrales}$.

- La dilatación matemática x_{DM} , se obtiene mediante la implementación de un filtro IIR de suavizado con coeficientes $\mathbf{a} = [3, 0, 0]$ y $\mathbf{b} = [1, 1, 1]$, el filtro cumple con el promedio de

datos tomados o media móvil. Tanto el filtro de derivación como de dilatación matemática son implementados normalmente, no son implementados con el algoritmo de fase nula. En la figura 3.2, se presentan los resultados de la implementación de los pasos 3 y 4 para la detección del pico R y además se ilustra el umbral de decisión para la creación de la señal $\mathbf{x}_{digital}$, descrita en el paso 5.

5. Ya obteniendo la señal \mathbf{x}_{TNL} , se calcula τ_{umbral} mediante la ecuación (2.5), para luego obtener $\mathbf{x}_{digital}$ con la ecuación (2.6) y así finalmente construir el tren de impulsos \mathbf{x}_R , con pulsos digitales en la ubicación temporal del pico R como se observa en la figura 3.3.




Figura 3.3: Obtención de $\mathbf{x}_{digital}$ y el tren de impulsos \mathbf{x}_R .

3.2.3. Detección fiducial del complejo PQRST promedio

Una de las técnicas más robusta para atacar los efectos generados por las fuentes de variabilidad cardíaca a corto y largo plazo es la detección o extracción fiducial del complejo PQRST. Teniendo la detección de los picos R dentro de una grabación o registro de señal cardíaca, se procede a detectar los complejos PQRST presentes en el registro y promediar todos los complejos detectados para obtener un complejo PQRST promedio o complejo PQRST modelo del registro de señal adquirida.

A partir de la ubicación temporal del pico R, es decir, con el tren de impulsos \mathbf{x}_R se toma un segmento de 300 ms a la izquierda del pico R para detectar así la onda P y a la derecha se toma un segmento de 400 ms para detectar la onda T. Los segmentos o complejos PQRST detectados se alinean con respecto al pico R y así se promedian, obteniendo la extracción fiducial del complejo PQRST de la señal adquirida [18,22,45,74,75]. Sin importar la duración de la señal cardíaca, ya sea 3, 5 ó 10 s de adquisición, se obtendrá siempre un segmento correspondiente al complejo PQRST promedio de 700 ms, equivalente a 88 muestras a una frecuencia de muestreo de 125 Hz como se observa en la figura 3.4. En la figura 3.4(a), se alinean con respecto al pico R, 11 complejos PQRST detectados para esta observación en particular, de esta alineación se obtiene un complejo PQRST promedio como se visualiza en la figura 3.4(b), siendo la extracción fiducial del módulo de pre-procesamiento.




Figura 3.4: Detección de complejos PQRST de una observación cardíaca de 10s para un sujeto seleccionado de forma aleatoria. (a) Alineamiento de 11 complejos PQRST detectados y (b) complejo PQRST promedio.

3.3. Planteamiento de validación cruzada mediante combinaciones

En la figura 3.4(a), se muestra el alineamiento de los complejos PQRST detectados dentro de una misma observación. En cambio, en la figura 3.5 se muestra el alineamiento de los complejos PQRST promedio de cada una de las 10 observaciones por persona en diferentes escenarios de variabilidad. Los complejos PQRST de las 4 personas mostrados en la figura 3.5, ilustran que la morfología del complejo es afectada por diferentes escenarios de variabilidad cardíaca a corto plazo, dichos efectos se estabilizan o se regulan después de un tiempo, al dejar de ser excitados con dicha fuente de variabilidad. La presencia de estos escenarios fue el motivo por el cual se consolidó la base de datos, buscando contrarrestar estos efectos en el rendimiento del sistema de reconocimiento, mediante el estudio y diseño de las técnicas de procesamiento digital en los módulos de extracción de características y toma de decisión.

3.3.1. Combinaciones posibles de la base de datos

La diversidad de observaciones obtenidas en la base de datos consolidada, presenta diferentes escenarios de variabilidad cardíaca evidente para algunas personas y para otras no mucho. Existen 10 observaciones de señal por persona y se desea realizar las combinaciones posibles sin importar el orden de agrupamiento, haciendo uso de la teoría de combinaciones.

- Las combinaciones:** Son agrupaciones en las que el contenido importa pero el orden no. El número de combinaciones posibles, tomando k observaciones de las n observaciones disponibles se describe por la siguiente ecuación:

$$nCk = \frac{n!}{k!(n-k)!} \quad (3.1)$$

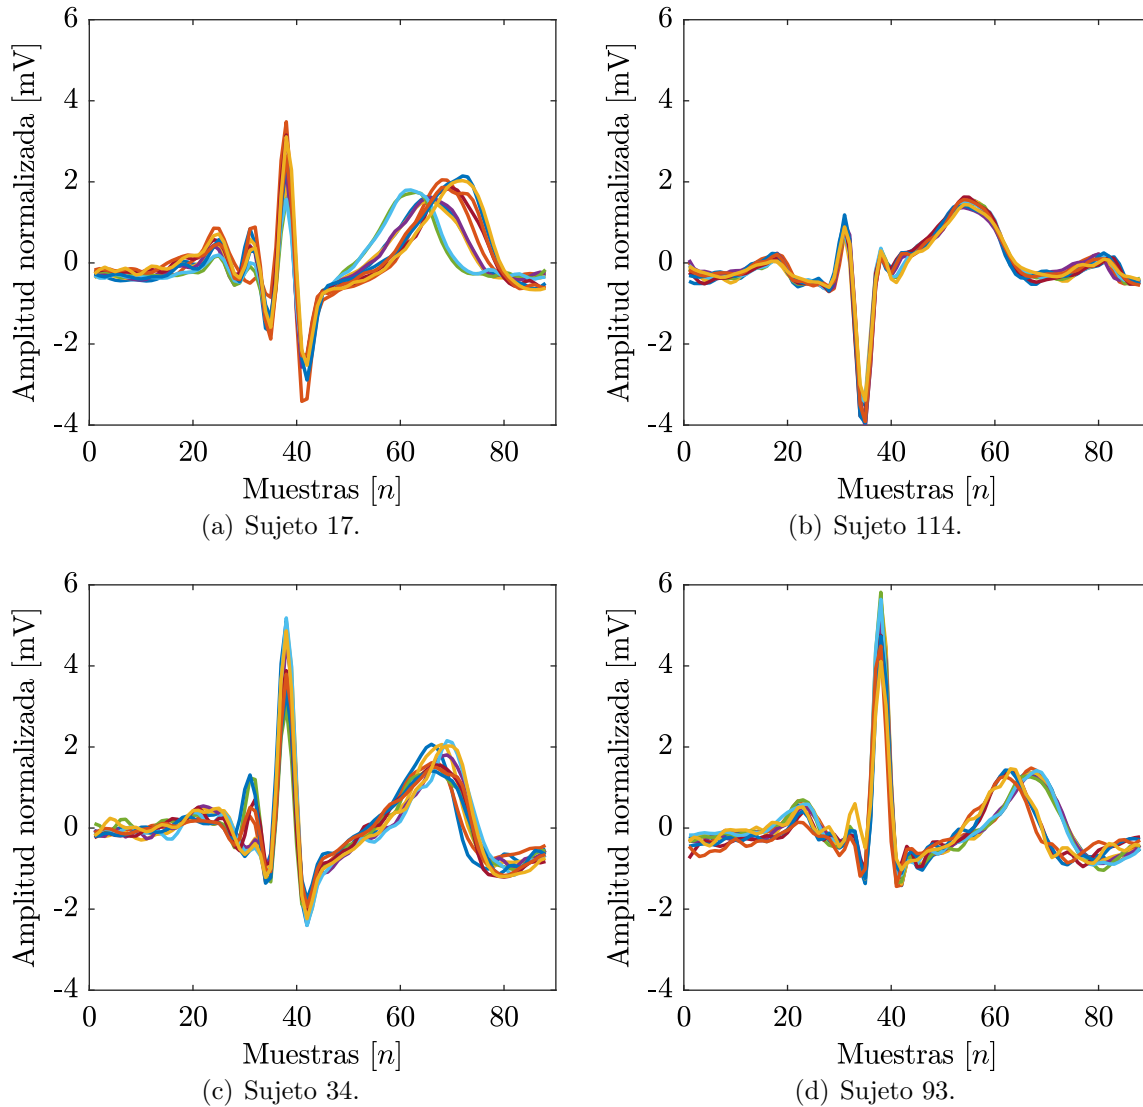


Figura 3.5: Detección de complejos PQRST promedio para las 10 observaciones de 4 personas de la base de datos consolidada, tomando registros de 5 s de duración.

La validación cruzada es una técnica utilizada para evaluar los resultados de los sistemas entre datos de entrenamiento y prueba; consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes combinaciones o particiones. Para esta investigación se tomará la validación cruzada con un 70 % de la base de datos para el entrenamiento y el 30 % para prueba.

Los porcentajes de validación cruzada corresponden a 7 y 3 observaciones por sujeto, aplicando la ecuación (3.1) obtenemos:

$$10C7 = 120 = 10C3$$

Tanto en entrenamiento como en prueba es posible realizar 120 combinaciones por sujeto, evaluando así toda posibilidad de combinaciones entre las observaciones disponibles en la base de datos.

3.4. Desarrollo del sistema de Autenticación

La investigación centra su interés en la extracción de características directamente del complejo PQRST, partiendo de la distribución de los datos de dicho complejo. Se procede en esta sección a realizar un estudio de los momentos estadísticos y los parámetros de Hjorth visto en las subsecciones 2.4.2 y 2.4.3 respectivamente. Además, se estudia la ampliación del segundo momento estadístico mediante la estimación espectral con un proceso autoregresivo (AR). El estudio de estas técnicas de extracción de características se van a comparar con algunas técnicas utilizadas frecuentemente en la literatura. La comparación es con el fin de ver los efectos de rendimiento con respecto al costo o longitud del vector de características extraído. Dicha comparación de las técnicas de extracción de características se realiza con las métricas de asociación descritas en la subsección 2.5.2, permitiendo así el estudio del rendimiento de las técnicas de extracción y las medidas de asociación para la toma de decisión ante los retos propuestos para esta investigación en un sistema biométrico de autenticación.

3.4.1. Métricas de asociación

En la subsección 2.5.2, se estudiaron algunas métricas de asociación, las cuales se desean desarrollar para la comparación de los vectores obtenidos del proceso de extracción de características y así ver su rendimiento en la implementación del sistema, dichas métricas son las siguientes:

- Distancia dtw: $d_{dtw}(\mathbf{A}, \mathbf{B})$, definida en [64].
- Distancia de correlación: $d_{corr}(\mathbf{A}, \mathbf{B})$, definida en la ecuación (2.34).
- Distancia Euclidiana: $d_{eucl}(\mathbf{A}, \mathbf{B})$, definida en la ecuación (2.35).
- Distancia Mahalanobis: $d_{mahl}(\mathbf{A}, \mathbf{B})$, definida en la ecuación (2.36).
- Distancia de Pearson: $d_{pear}(\mathbf{A}, \mathbf{B})$, definida en la ecuación (2.40).

3.4.2. Parámetros de forma

Con el fin de describir la distribución de los datos de la morfología del complejo PQRST, se toman los momentos estadísticos y los parámetros de Hjorth para definir la extracción de características con los siguientes 5 parámetros de forma de la distribución de datos según las subsecciones 2.4.2 y 2.4.3:

- Asimetría (\mathbf{x}), definida en la ecuación (2.11).
- Curtosis (\mathbf{x}), definida en la ecuación (2.12).
- Actividad (\mathbf{x}), definida en la ecuación (2.13).
- Movilidad (\mathbf{x}), definida en la ecuación (2.14).
- Complejidad (\mathbf{x}), definida en la ecuación (2.15).

La base de datos consolidada posee 1400 observaciones en total, es decir, se obtienen 1400 valores para cada parámetro de forma, 10 por persona. En la figura 3.6, se visualizan las combinaciones posibles en dos dimensiones de los 5 parámetros de forma, mostrando así la dispersión de las características extraídas de la población total de observaciones con duración de 10s de adquisición. En [13] se concluyó mediante un estudio de análisis de la varianza ANOVA, que los dos mejores parámetros de forma para procesos biométricos con señales cardíacas son: *movilidad* y *curtosis*, los cuales se pueden observar mediante su gráfica de dispersión en la figura 3.6(f).

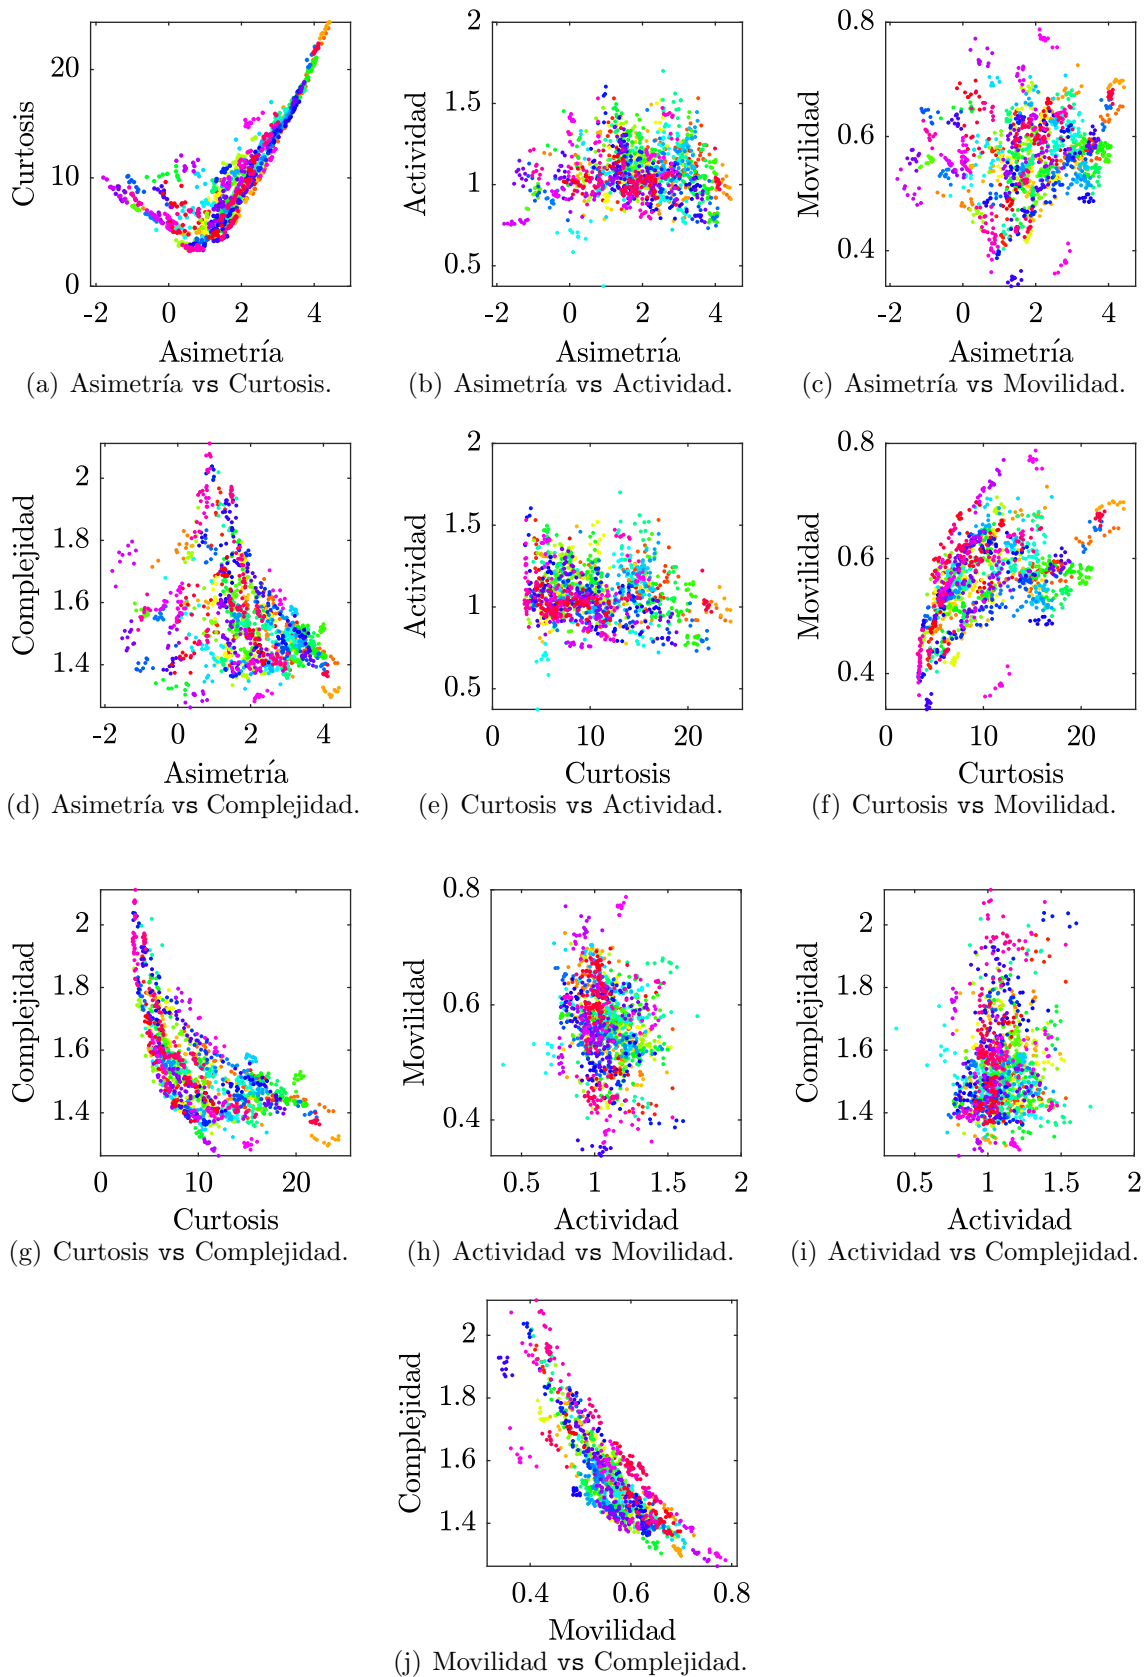


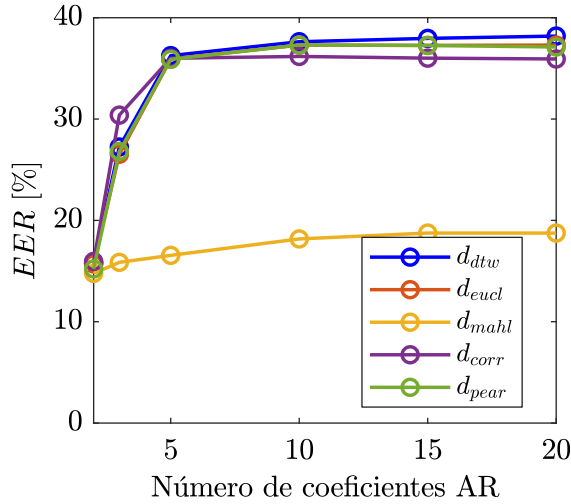
Figura 3.6: Gráficas de dispersión de las combinaciones posibles en dos dimensiones de los 5 parámetros de forma para las 1400 observaciones con duración de 10s cada una.

3.4.3. Proceso AC/AR


La señal cardíaca se modela como una señal aleatoria y estacionaria, como se estudió en el capítulo anterior. Permitiendo la estimación espectral del proceso aleatorio mediante un sistema LTI, específicamente mediante un modelo AR. En la subsección 2.4.5, se resaltó los beneficios de la secuencia de AC para una señal aleatoria y estacionaria. Por lo tanto, se propone estudiar el rendimiento del sistema de autenticación, evaluado con la EER , para la estimación de un proceso AR tanto con el método de Yule-Walker como con el método de Burg, teniendo como señal a estimar: (1) el complejo PQRST promedio y (2) la secuencia de AC del complejo PQRST promedio descrita en la ecuación (2.18). En este estudio se busca resolver cuál método genera la EER más baja ante la variación de número de coeficientes del proceso AR. El estudio se desarrolla para las 5 métricas mencionadas en la subsección 3.4.1 y para la estimación del proceso AR se utilizan los comandos `aryule` y `arburg` en `Matlab`[®], variando el número de coeficientes estimados para el modelo y tomado las señales cardíacas de la base de datos consolidada para las 140 personas con duración de 3 s de adquisición. Los resultados de este estudio se registran en la tabla 3.6 y en la figura 3.7.

Señal a estimar	Método AR	Métrica	EER [%]					
			Coeficientes AR(p)					
			2	3	5	10	15	20
Complejo PQRST promedio	Yule-Walker	d_{dtw}	15.78	27.24	36.26	37.63	37.96	38.19
		d_{eucl}	15.70	26.53	35.93	37.30	37.27	37.30
		d_{mahl}	14.77	15.86	16.55	18.17	18.17	18.75
		d_{corr}	15.95	30.39	36.00	36.18	36.18	35.93
		d_{pear}	15.21	26.80	35.89	37.31	37.31	37.11
	Burg	d_{dtw}	15.58	22.29	26.55	30.39	30.11	25.50
		d_{eucl}	15.75	22.30	26.63	30.29	29.99	28.41
		d_{mahl}	14.22	13.24	13.48	14.83	16.36	19.12
		d_{corr}	15.14	25.44	25.17	31.22	32.12	32.41
		d_{pear}	14.54	22.58	26.93	30.35	30.05	28.42
AC del Complejo PQRST promedio	Yule-Walker	d_{dtw}	16.49	14.80	12.76	12.45	12.32	12.92
		d_{eucl}	16.07	13.99	12.39	11.91	11.63	11.88
		d_{mahl}	15.42	13.45	11.85	12.68	13.59	14.22
		d_{corr}	15.22	21.29	16.54	14.37	13.14	12.53
		d_{pear}	15.80	14.59	13.18	17.08	22.12	22.98
	Burg	d_{dtw}	18.69	19.91	27.69	30.06	34.93	35.21
		d_{eucl}	18.63	19.88	27.65	30.04	34.80	35.04
		d_{mahl}	15.79	13.78	15.22	18.93	20.76	22.38
		d_{corr}	17.74	26.86	26.06	29.01	33.79	34.95
		d_{pear}	17.11	19.84	27.88	30.00	34.92	35.06

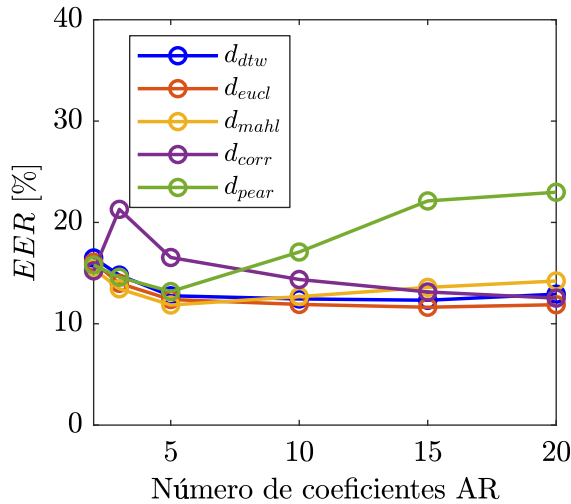
Tabla 3.6: Resultados del estudio de la variación de la señal a estimar y el número de coeficientes del proceso AR, implementando los métodos de Yule-Walker y Burg para la estimación, en observaciones con duración de 3 s de adquisición para 140 personas.




(a) Estimación del complejo con el método Yule-Walker.



(b) Estimación del complejo con el método Burg.



(c) Estimación de la AC con el método Yule-Walker.



(d) Estimación de la AC con el método Burg.

Figura 3.7: Gráficas de los resultados del estudio para procesos AR indicados en la tabla 3.6.

En la tabla 3.6 y en la figura 3.7, se observa que los menores valores de la EER se obtienen con la estimación de la secuencia de autocorrelación utilizando el método de Yule-Walker, este resultado se puede apreciar con más detalle en la figura 3.7(c). Para este caso, los valores de la EER se intentan mantener constante en la mayoría de la métricas de asociación a partir de un proceso AR de orden 5, en consecuencia y teniendo presente los retos propuestos en la investigación, se considera entonces de forma apropiada la selección de un proceso AR de orden 5 ($p = 5$). Definiendo así el proceso AC/AR como una técnica de extracción de características viable. El vector entregado por el proceso AR(5), es un vector de 6 coeficientes $\mathbf{a} = [a_0, a_1, a_2, a_3, a_4, a_5]$, el coeficiente a_0 es siempre igual a 1, lo que no facilita la identificación o diferenciación de las mismas personas dentro de la población, de modo que se tomará solo los últimos 5 coeficientes AR, es decir, $[a_1, a_2, a_3, a_4, a_5]$.

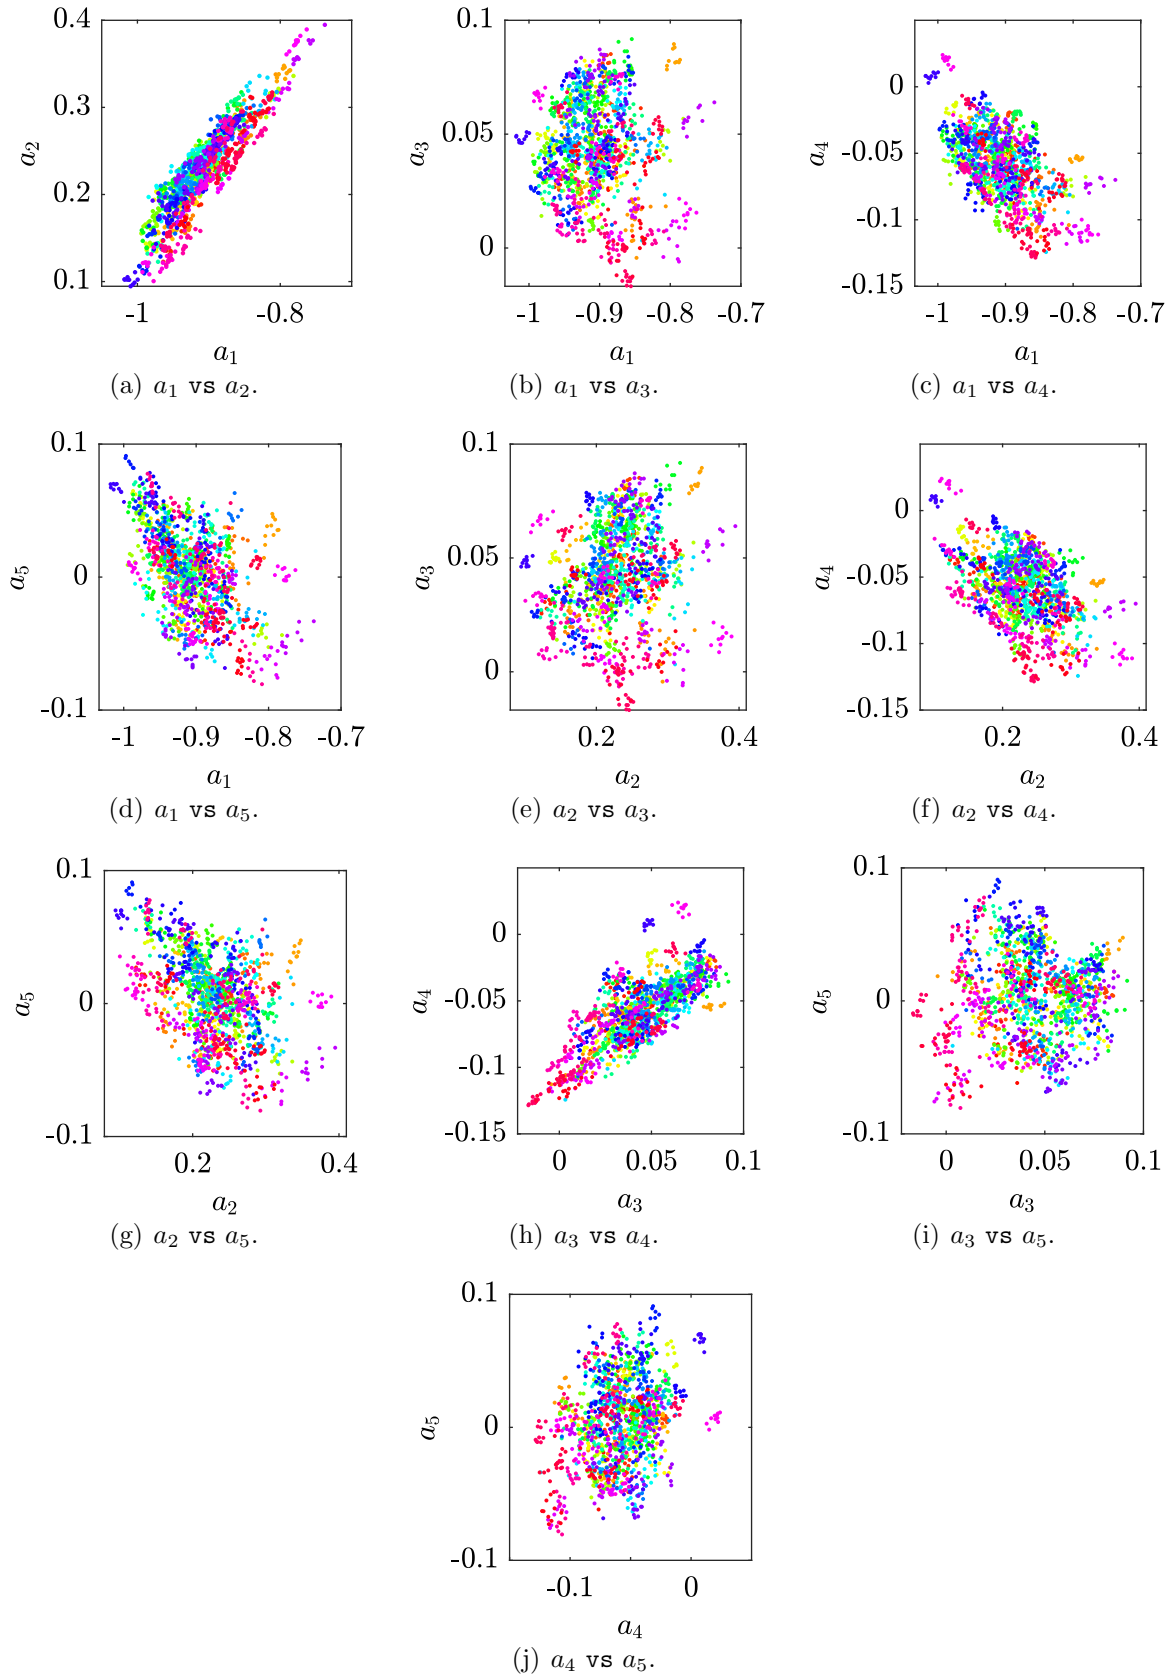


Figura 3.8: Gráficas de dispersión de las combinaciones posibles en dos dimensiones de los 5 coeficientes del proceso AC/AR para las 1400 observaciones con duración de 10s cada una.

A las 1400 observaciones con duración de 10 s de adquisición, se les extraen los 5 coeficientes mediante el proceso AC/AR seleccionado y descrito anteriormente, visualizando en la figura 3.8 la dispersión de las combinaciones posibles en dos dimensiones. Se observa diversidad en las formas de dispersión de los coeficientes del proceso AC/AR.

3.4.4. Comparación de técnicas de extracción de características y métricas

Se han definido las técnicas de extracción de características de parámetros de forma y proceso AC/AR, los cuales se quieren comparar con la transformada rápida de Fourier (FFT) y la transformada discreta del coseno aplicada a la secuencia de autocorrelación (AC/DCT), buscando una comparación entre la longitud del vector de características obtenido y el rendimiento alcanzado por el sistema de autenticación. Esta comparación es evaluada en su fase de entrenamiento con la *EER* para las 5 métricas de asociación mencionadas en la subsección 3.4.1. Se parte de una extracción fiducial del complejo PQRST promedio en cada observación, el vector obtenido con dicha extracción fiducial tiene una longitud de 88 muestras o coeficientes.

Del vector de extracción fiducial de 88 coeficientes, se obtiene un vector de características con una longitud de 5 coeficientes, tanto para la extracción de los parámetros de forma como para el proceso AC/AR. Por otro lado, al realizar un submuestreo de 2 al vector de extracción fiducial, se obtiene un nuevo vector con una longitud de 44 coeficientes. Al aplicar FFT al vector submuestreado del complejo PQRST promedio de 44 coeficientes, se obtiene un vector de características de 22 coeficientes y al realizar el mismo procedimiento con AC/DCT, se obtiene un vector de características de 44 coeficientes. Por último, para esta comparación se toma un vector de 10 coeficientes conformado por los 5 parámetros de forma y los 5 coeficientes del proceso AC/AR. Los resultados de esta comparación se presentan en la tabla 3.7, donde se realizó la comparación para la base de datos consolidada mediante la validación cruzada propuesta y los tres tiempos de adquisición de la señal, es decir, 3, 5 y 10 s.

Los resultados de la tabla 3.7, indican que la mejor métrica de asociación es la distancia Mahalanobis d_{mahl} , gracias a considerar la correlación de los vectores de características de la población total mediante el cálculo de su matriz de covarianza poblacional. Se evidencia además, que a mayor tiempo de adquisición mejor rendimiento tiene el sistema, esto se debe a obtener más información fiducial en robustez de la morfología del complejo PQRST por persona. La conclusión más importante de los resultados, es que la mejor técnica de extracción de características es la unión entre los parámetros de forma y los coeficientes de proceso AC/AR, que es la propuesta de esta investigación.

Los resultados obtenidos para la extracción propuesta, obtienen la *EER* más baja en los tres tiempos de adquisición y con una longitud de 10 coeficientes del vector de características. En la técnica propuesta, a la hora de realizar la métrica de asociación de Mahalanobis y de Pearson, lo que se hace es obtener una matriz de covarianza poblacional para los parámetros de forma y otra matriz para los coeficientes del proceso AC/AR, calculado las dos distancias en el proceso de comparación y sumando dichas distancias se obtiene una métrica de asociación para la toma de decisión de la técnica propuesta. Esto se realiza para disminuir los costos de almacenamiento


de la matriz de covarianza poblacional y además, este procedimiento tiene mejores resultados en el rendimiento del sistema.

Técnica de ext. características	Número de Coef.	Métrica	Train 70 %		
			10 s <i>EER</i> [%]	5 s <i>EER</i> [%]	3 s <i>EER</i> [%]
AC/DCT	44	d_{dtw}	11.90	15.19	20.84
		d_{eucl}	8.77	10.71	14.10
		d_{mahl}	8.51	14.09	19.28
		d_{corr}	6.19	7.51	9.66
		d_{pear}	7.90	9.85	13.45
FFT	22	d_{dtw}	9.59	12.19	16.40
		d_{eucl}	7.17	8.56	11.43
		d_{mahl}	4.96	8.38	12.27
		d_{corr}	6.99	8.54	11.10
		d_{pear}	6.65	8.89	12.51
Parámetros de forma	5	d_{dtw}	12.82	14.48	16.62
		d_{eucl}	14.18	15.82	18.08
		d_{mahl}	5.80	7.10	9.76
		d_{corr}	17.16	19.39	21.15
		d_{pear}	7.79	9.05	10.91
AC/AR	5	d_{dtw}	7.46	9.81	12.76
		d_{eucl}	7.17	9.47	12.39
		d_{mahl}	6.33	8.66	11.85
		d_{corr}	10.88	13.40	16.54
		d_{pear}	7.76	10.11	13.18
Propuesta [Parámetros de forma + AC/AR]	10	d_{dtw}	12.20	13.82	15.92
		d_{eucl}	13.74	15.40	17.65
		d_{mahl}	4.88	6.15	8.51
		d_{corr}	11.37	13.46	15.21
		d_{pear}	5.87	7.13	9.19


Tabla 3.7: Resultados del estudio de comparación de técnicas de extracción de características y métricas de asociación para el proceso de autenticación de la base de datos de 140 personas.

3.4.5. Sistema biométrico de autenticación propuesto

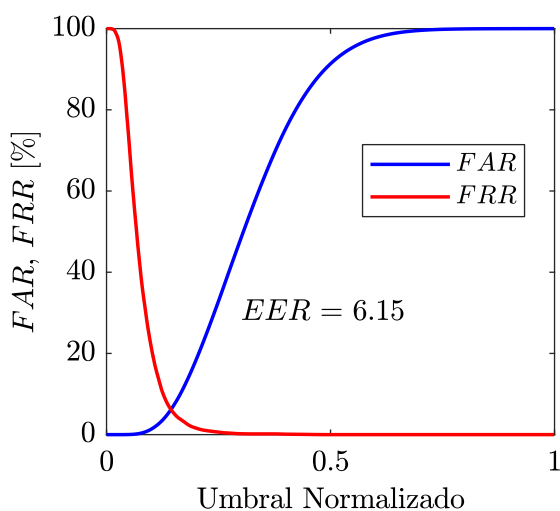
Para el sistema de reconocimiento desarrollado en esta investigación en su funcionalidad como sistema de verificación o autenticación, se propone una extracción de características híbrida de la detección fiducial del complejo PQRST promedio, del cual, se le extraen los parámetros de forma y los coeficientes del proceso AC/AR, obteniendo un vector de 10 características. En su módulo de toma de decisión se utiliza la distancia de Mahalanobis como métrica de asociación, obteniendo en la tabla 3.8, los resultados de la fase de entrenamiento y de la fase de prueba del sistema para la autenticación de 140 personas.




(a) *EER* con adquisición de 10 s de ECG.




(b) Curva ROC con adquisición de 10 s de ECG.




(c) *EER* con adquisición de 5 s de ECG..



(d) Curva ROC con adquisición de 5 s de ECG.



(e) *EER* con adquisición de 3 s de ECG.



(f) Curva ROC con adquisición de 3 s de ECG.

Figura 3.9: Gráficas de los resultados del sistema de autenticación para su fase de entrenamiento con adquisición de señales de 3, 5 y 10 s.

Tiempo ECG [s]	Train 70 %		Test 30 %		
	AUC	EER	VR	TPR	TNR
	[%]	[%]	[%]	[%]	[%]
10	99.03	4.88	96.72	98.64	94.79
5	98.34	6.15	95.73	98.25	93.22
3	97.24	8.51	93.83	97.37	90.30

Tabla 3.8: Resultados del proceso de autenticación propuesto para 140 personas con una extracción de características de 10 coeficientes y la distancia de Mahalanobis como métrica de asociación.

De los resultados de la tabla 3.8, se obtienen las tasas de conveniencia y seguridad para la fase de entrenamiento y prueba del sistema de autenticación, dichas tasas de rendimiento se definieron en la subsección 2.5.3. Además de la tabla se puede apreciar que al disminuir la duración de las señales ECG de 10 a 3s: la tasa de conveniencia tiene una diferencia de 1.27%, existe un decaimiento de 4.49% en la tasa de seguridad del sistema y hay un aumento en la *EER* del 3.63%. El sistema biométrico de autenticación con adquisición de 3s de la señal, es viable para su implementación en hardware. En la figura 3.9, se muestra los resultados de la fase de entrenamiento para la intersección de las tasas de error que definen el umbral óptimo de decisión y así la *EER*, además se muestran las curvas ROC para los tres tiempo de adquisición.

En la tabla 3.8 y en la figura 3.9, se registran los resultados del sistema de autenticación ECG propuesto en la investigación, donde se estudió el reto de las diferentes longitudes de la señal adquirida, evidenciando que a mayor tiempo de adquisición, la extracción de características es más robusta para el sistema de reconocimiento. Ahora, se estudia el rendimiento del sistema de autenticación ante la variación del tamaño de la población de la base de datos. En la tabla 3.9, se registran los resultados obtenidos del sistema de autenticación para una población de 20 a 140 personas, reportando la *EER* obtenida en la fase de entrenamiento, el estudio se realizó igual para los tres tiempo de adquisición.

Tiempo ECG [s]	Train 70 % - Número de sujetos <i>NS</i>						
	20	40	60	80	100	120	140
	<i>EER</i>	<i>EER</i>	<i>EER</i>	<i>EER</i>	<i>EER</i>	<i>EER</i>	<i>EER</i>
	[%]	[%]	[%]	[%]	[%]	[%]	[%]
10	8.43	5.76	5.24	5.88	6.26	5.54	4.88
5	9.21	6.90	6.05	7.36	7.55	6.64	6.15
3	11.21	9.75	8.76	10.33	9.88	9.23	8.51

Tabla 3.9: Resultados del proceso de autenticación para diferentes longitudes de población de la base de datos en los tres tiempo de adquisición, con una extracción de características de 10 coeficientes y la distancia de Mahalanobis como métrica de asociación.

Los resultados de la tabla 3.9, muestran un comportamiento del rendimiento del sistema de autenticación de forma oscilante cerca de un valor constante ante la variación de la longitud de la población de la base de datos, lo que indica que en las comparaciones *uno contra uno*, el tamaño de la base de datos no afecta demasiado el rendimiento del sistema. Las tasas de la

EER para el sistema de autenticación ante duraciones de señal ECG a 10 s tienen un valor medio igual a 5.99%, para duraciones de 5 s igual a 7.12% y para 3 s igual a 9.66%. Los resultados de la tabla 3.9 se ilustran en la figura 3.10, evidenciando un poco mejor el comportamiento mencionado.




Figura 3.10: Resultados del proceso de autenticación para diferentes longitudes de población de la base de datos en los tres tiempo de adquisición indicados en la tabla 3.9.

3.5. Desarrollo del sistema de identificación

Para el sistema de identificación se adoptan las mismas técnicas de pre-procesamiento y extracción de características desarrolladas para el proceso de autenticación, hablamos de la detección fiducial del complejo PQRST promedio y a dicha extracción fiducial, la extracción de los parámetros de forma y los coeficientes del proceso AC/AR. En esta sección, se estudia el rendimiento del sistema ante diferentes técnicas de clasificación, entre ellas: LDA, redes neuronales y k NN, vistas en la subsección 2.5.5, proponiendo al final una técnica y un modelo de sistema de identificación.

3.5.1. Identificación con LDA

En la subsección 3.3, se realizó un planteamiento de validación cruzada, donde el entrenamiento toma el 70 % de la información de la base de datos para diseñar y realizar el modelo del clasificador. Definiendo los parámetros de un clasificador LDA multiclase descrito mediante la ecuación (2.43). En la tabla 3.10, se registran los resultados del sistema de identificación para 140 personas, extrayendo un vector de 10 características por observación, 5 de esas características son los parámetros de forma y las otras 5, los coeficientes del proceso AC/AR. La identificación con LDA se realiza para los tres tiempo de adquisición de la señal ECG y el rendimiento del sistema se evalúa con la métrica definida en la subsección 2.5.4.

Tiempo ECG [s]	Test 30 % IR [%]
10	92.41
5	86.25
3	75.95

Tabla 3.10: Resultados del proceso de identificación con LDA para 140 personas, con la extracción de características propuesta de 10 coeficientes.

3.5.2. Identificación con una red neuronal

Función de activación $f(x)$	Número de neuronas en capa oculta	Tiempo ECG [s]	Test 30 % IR [%]
Sigmoidea tangente hiperbólica: tansig(x)	148	10	93.91
		5	85.52
		3	71.72
	111	10	93.80
		5	85.34
		3	71.42
	74	10	93.54
		5	84.59
		3	70.78
	37	10	92.23
		5	82.62
		3	67.75
Base radial: radbas(x)	148	10	94.26
		5	85.51
		3	70.88
	111	10	94.04
		5	85.24
		3	70.46
	74	10	93.52
		5	84.66
		3	69.88
	37	10	92.17
		5	82.93
		3	67.95

Tabla 3.11: Resultados del proceso de identificación con la red neuronal para 140 personas, con la extracción de características propuesta de 10 coeficientes.

Siguiendo el procedimiento descrito para la identificación con LDA, ahora se estudia la identificación con una red neuronal de 3 capas: *entrada*, *capa oculta* y *salida*. Se desea identificar a 140 personas con un vector de entrada de 10 coeficientes de características, por lo tanto, en la capa de entrada se tendrá 10 neuronas y en la capa de salida 140 neuronas. Se realiza un estudio a diferentes números de neuronas en la capa oculta, escalando el resultado de la ecuación (2.46) y adicionalmente, se implementa la red neuronal con las dos funciones de activación descritas en la subsección 2.5.5: función de transferencia sigmoidea tangente hiperbólica descrita por la ecuación (2.44), y función de transferencia de base radial descrita por la ecuación (2.45). El estudio planteado para la identificación con la red neuronal, se realiza para los tres tiempo de adquisición de la señal cardíaca, entrenando la red de reconocimiento de patrones con la función de retropropagación del gradiente conjugado escalado. Los resultados de dicho estudio se presentan en la tabla 3.11, concluyendo que la red neuronal con la función de activación de base radial tiene el mejor resultado para el proceso de identificación, dicho resultado se logra con la adquisición de señal ECG de 10s de duración y con 148 neuronas en su capa oculta.


3.5.3. Identificación con k NN

De los resultados del proceso de verificación se incorpora para identificación la métrica de distancia de Mahalanobis para determinar el vecino más cercano. Se plantea la identificación con $k = 1$, definiendo la etiqueta de clase con un único vecino más cercano, para ello, de las 7 observaciones o ventanas por sujeto disponibles para el entrenamiento, se promedian y se obtienen al final solo 2 observaciones por sujeto, siendo este el modelo de entrenamiento para el clasificador 1NN con distancia de Mahalanobis como de métrica de asociación.


Al igual que con el proceso de verificación, al aplicar la distancia de Mahalanobis, se aplica tanto para los parámetros de forma como para los coeficientes del proceso AC/AR, es decir, se obtiene una matriz de covarianza poblacional de 5x5 para los parámetros de forma y otra matriz de covarianza poblacional de 5x5 para los coeficientes del proceso AC/AR, donde al final se calculan las dos distancias para cada técnica de extracción de características y se suman dichas distancias para obtener la métrica o distancia con la que se toma la decisión de identificar la etiqueta de clase mediante k NN. En la tabla 3.12, se exponen los resultados de la identificación de 140 personas con k NN para los tres tiempo de adquisición de la señal cardíaca.

Tiempo ECG [s]	Test 30 % IR [%]
10	94.63
5	88.07
3	76.75


Tabla 3.12: Resultados del proceso de identificación con k NN para 140 personas, con la extracción de características propuesta de 10 coeficientes y la distancia de Mahalanobis como métrica de asociación.



(a) Matriz de confusión para identificación con 10 s de ECG.



(b) Matriz de confusión para identificación con 5 s de ECG



(c) Matriz de confusión para identificación con 3 s de ECG.

Figura 3.11: Matrices de confusión normalizadas de la evaluación en la fase de prueba del proceso de identificación con k NN para 140 personas, resultados finales indicados en la tabla 3.12.

3.5.4. Sistema biométrico de identificación propuesto

El mejor resultado de las tablas 3.10, 3.11 y 3.12 para la identificación de 140 personas se obtiene con la clasificación mediante k NN. Los mejores resultados para los tres diferentes tiempo de adquisición de la señal cardíaca se encuentran en la tabla 3.12. Por lo tanto, k NN es la técnica de clasificación propuesta y definida para el desarrollo de la investigación.

En la figura 3.11, se ilustran las matrices de confusión normalizadas de la evaluación en la fase de prueba del sistema de identificación con k NN usando la distancia Mahalanobis, donde el color amarillo (IR normalizado) representa el mejor resultado acumulado de identificación del sistema ante las consultas presentadas mediante la validación cruzada planeada con las clases reales, obteniendo las predicciones de clases para los 140 sujetos de la base de datos. Idealmente solo la diagonal con pendiente negativa debe estar coloreada de color amarillo para cada matriz de confusión, sin presentar ningún color que no sea el azul fuera de dicha diagonal. Siendo el sistema de identificación con adquisiciones de 10 s, el mejor sistema de identificación obtenido como se observa en la figura 3.11(a). Los resultados de la tabla 3.12, se obtienen de la métrica de evaluación final de la matrices de confusión mostradas en la figura 3.11.

La tabla 3.12 y la figura 3.11, registran los resultados del sistema biométrico de identificación para 140 personas en sus tres tiempos de adquisición. Ahora, se procede a estudiar el rendimiento del sistema de identificación con k NN para diferentes longitudes de población de la base de datos, estos resultado se registran en la tabla 3.13, donde se define EID como el error de identificación: $EID[\%] = 100 - IR$.

Tiempo ECG [s]	Test 30 % - Número de sujetos NS						
	20	40	60	80	100	120	140
	EID [%]	EID [%]	EID [%]	EID [%]	EID [%]	EID [%]	EID [%]
10	3.71	3.83	3.96	4.75	6.10	5.66	5.37
5	5.24	7.65	7.54	10.05	13.19	12.00	11.93
3	9.88	12.94	12.59	18.93	21.88	23.22	23.25

Tabla 3.13: Resultados del proceso de identificación con k NN para diferentes longitudes de población de la base de datos en los tres tiempo de adquisición, con una extracción de características de 10 coeficientes y la distancia de Mahalanobis como métrica de asociación.

De la tabla 3.13, se evidencia que al aumentar la longitud de la población de la base de datos aumenta EID . Se sabe que para procesos de identificación en su módulo de toma de decisión, se realizan comparaciones *uno contra todos* para determinar con los vectores de características la identidad de una persona, de ahí, que al aumentar el número de personas se afecta la variabilidad inter-sujetos de la base de datos, generando así degradación en el rendimiento del sistema de identificación. En la figura 3.12, se grafican los resultados de la tabla 3.13, donde se visualiza que el sistema de identificación con señales de 10 s de adquisición, tiene un rendimiento que se comporta de manera aceptable ante la variación de la longitud de la población de la base de datos y al disminuir el tiempo de adquisición, el rendimiento del sistema de identificación se degrada.




Figura 3.12: Resultados del proceso de identificación con k NN para diferentes longitudes de población de la base de datos en los tres tiempo de adquisición indicados en la tabla 3.13.

Implementación en Hardware

Contenidos del capítulo

- 4.1. Sistemas digitales
 - 4.2. Lógica programable
 - 4.3. Lenguajes de descripción de hardware (HDL)
 - 4.4. Sistema embebido con FPGA
 - 4.5. Desarrollo en hardware
 - 4.6. Tiempos de ejecución
 - 4.7. Recursos utilizados
-

4.1. Sistemas digitales

En la electrónica, un *sistema digital* es un conjunto de dispositivos semiconductores destinados a la comunicación, procesamiento y almacenamiento de señales digitales generadas o adquiridas del medio exterior mediante sensores en valores discretos de amplitud y tiempo. Para el análisis y síntesis del procesamiento digital se utilizan los sistemas binarios mediante la utilización del álgebra de Boole, obteniendo sistemas con lógica combinacional y secuencial. Los sistemas combinacionales dependen solamente del estado actual de sus entradas, no necesitan unidades de memoria, por otro lado, los sistemas secuenciales dependen de los estados actuales y previos de sus entradas, haciendo necesario el uso de elementos de memoria.

Para la comunicación, el procesamiento y el almacenamiento de señales digitales se requiere una forma de representar la información, denominada *código*. Tradicionalmente se usa la representación numérica de base 10, por lo tanto, dicho código es un conjunto de símbolos y reglas para la representación numérica con una base y un formato, siendo las cifras máximas que pueden ser utilizadas en una representación. El sistema binario es el utilizado en la electrónica digital, tiene como principal restricción el uso exclusivo de dos símbolos: 0 y 1. El signo y la parte decimal se representan con los diferentes estilos de formatos. Las representaciones numéricas más sobresalientes son:

- Representación numérica de enteros positivos.
- Representación numérica de enteros con signo.

- Representación numérica de punto fijo.
- Representación numérica de punto flotante.

Para las operaciones aritméticas en un sistema digital se debe tener presente la representación numérica utilizada. En este trabajo se implementa la representación numérica de punto fijo.

Representación numérica de punto fijo: Todos los números representados tienen signo, indicado con un bit en uno para un número negativo y en cero para un número positivo, la parte entera tiene al menos un bit significativo, el punto decimal está implícito y fijo, la parte fraccionaria está representada por el resto de los bits.

En los sistemas digitales es importante el concepto de *máquina de estados finitos* para los diseños a implementar, haciendo uso de combinaciones lógicas con elementos de memoria. El uso de máquinas de estados es la característica principal de los circuitos secuenciales, existiendo estructura de máquina de estados de Mealy y Moore. Además se dice que un sistema digital puede ser síncrono o asíncrono. Con todo lo mencionado anteriormente, se define un *sistema digital* como la unión de dos o más máquinas secuenciales trabajando en conjunto [76]. En este trabajo se desarrolla la lógica secuencial con la estructura de máquina de estados de Moore.

4.2. Lógica programable

Los sistemas digitales son implementados en circuitos integrados (IC) que corresponden a un circuito formado por dispositivos electrónicos activos y pasivos conectados entre tensión de alimentación y tierra. Los circuitos integrados dan lugar a la lógica programable, que hace referencia a la posibilidad de establecer la operación lógica de un circuito digital descrito por medio de un lenguaje y que puede posteriormente ser traducido para su implementación. La ventaja que supone el uso de circuitos programables se debe a que con un solo dispositivo genérico se pueden sintetizar diferentes funciones lógicas.

La lógica programada a nivel de hardware es la implementación del diseño de un sistema digital, es decir, una vez definida la descripción del sistema digital, se aplica al dispositivo lógico dándole la forma física a su comportamiento de manera que no necesitará leer previamente unas instrucciones e ir ejecutándolas sino que habrá quedado establecido su funcionamiento físicamente, definiendo así *la lógica programada por hardware*. Por otra parte, la lógica usada en los microcontroladores, en los elementos de procesamiento digital de señales (DSP) o en los microprocesadores es *la lógica programada por software*, donde el funcionamiento consiste en la lectura y ejecución de unas instrucciones almacenadas o programadas en una memoria.

En la lógica programada por hardware, el hardware usado es de tipo genérico, donde a los circuitos integrados se les conoce como *dispositivos lógicos programables* o PLD (programmable logic device), que se fabrican sin almacenar ninguna lógica y que es necesario definirla o programarla antes de utilizarlos. Y el software usado suele expresarse a alto nivel conforme a un *lenguaje de descripción de hardware* o HDL (hardware description language). El proceso de obtención de la información que permite implementar la lógica en los circuitos integrados se denomina *síntesis*.

Cuando el hardware es de tipo específico se denominan *circuitos integrados de aplicación específica* o ASIC (application specific integrated circuit), básicamente los ASIC se entregan definidos de fábrica. Los dispositivos lógicos programables se clasifican en volátiles y no volátiles. Los dispositivos de tipo volátil dependen de la energía de alimentación para conservar la estructura o funcionamiento implementado. Los dispositivos de tipo volátil están basados en celdas RAM (random access memory) y los no volátiles están basados en celdas ROM (read only memory). Las precursoras de los PLD fueron las memorias ROM, luego llegaron los *arreglos lógicos programables* o PAL (programmable array logic), que fueron los primeros PLD. Todas las tecnologías de PLD se agrupan en la actualidad en el grupo de los denominados *dispositivos lógicos programables sencillos* o SPLD (simple programmable logic device), sencillos en el sentido de disponer solo de unas pocas puertas lógicas. La evolución de las SPLD son los *dispositivos lógicos programables complejos* o CPLD (complex programmable logic device), que son dispositivos que integran varios PLD con conectividad adicional [76, 77].

4.2.1. Arreglos de compuertas programables en campos (FPGA)

El representante más moderno de los PLD son los *arreglos de compuertas programables en campos* o FPGA (field programmable gate array), que busca optimizar aún más los recursos de los bloques digitales disponibles en los dispositivos programables. Los FPGA se fundamentan en tres tipos de bloques básicos:

- **Bloque lógico:** Son *bloques lógicos configurables* o CLB (configurable logic block), que permiten implementar cualquier tipo de lógica combinacional o secuencial.
- **Bloque de entrada-salida:** Proporciona conectividad dentro del FPGA y al exterior.
- **Bloque de distribución o interconexión programable:** Administra el enrutamiento o canales de ruteo de las señales entre diferentes CLB.

Los CLB están conformados por multiplexores, flip-flops y *tablas de búsqueda* o LUT (look up table). Los multiplexores se pueden considerar como conmutadores. Los flip-flops se utilizan como registros o elementos de memoria y almacenan un solo bit. Las LUT permiten almacenar valores arbitrarios que corresponden al resultado o salida de una función lógica de determinados valores de entrada, almacenando la lógica como una tabla de verdad. Toda lógica combinacional se implementa utilizando tablas de búsqueda, también llamadas generadores de funciones. Además, las LUT son las componentes básicas de la lógica y se utilizan para implementar la mayoría de las funciones lógicas del diseño. Adicionalmente, los FPGA cuentan con bloques de memoria (BRAM) y elementos de procesamiento digital de señales (DSP). Los bloques de memoria permiten guardar más cantidad de información que con tablas de búsqueda o registros. Los DSP son bloques lógicos dedicados para operaciones lógicas y aritméticas.

Los circuitos lógicos programables desarrollados por Xilinx® para *7-Series* FPGA y *ZedBoard Zynq-7000 SoC*, se fundamentan en una estructura de LUT de 6 entradas que puede ser utilizada para la implementación de funciones lógicas o como memoria ROM asíncrona de 64 bits. Los registros son flip-flops tipo D con activación de reloj y por último, la unidad DSP es un bloque aritmético multifuncional de 48 bits, que permite realizar operaciones aritméticas como multiplicación, suma, resta, acumulación, desplazamiento, operaciones lógicas y detección de patrones [78].

4.3. Lenguajes de descripción de hardware (HDL)

Los lenguajes utilizados para describir los sistemas digitales en los dispositivos de lógica programada se suelen llamar *lenguajes de descripción de hardware* (HDL), dichos lenguajes describen a detalle el comportamiento del sistema digital en los dispositivos lógicos, las conexiones de entradas y/o salidas y las operaciones lógicas que se realizan.

Los dos lenguajes de descripción de hardware más utilizados en la actualidad son VHDL (combinación de dos acrónimos: VHSIC - Very high speed integrated circuit y HDL) y Verilog (unión de verification y logic). VHDL es un lenguaje estándar definido por la IEEE para describir circuitos digitales y para la automatización de diseños electrónicos.

Los HDL permiten definir bloques de código con un comportamiento autónomo del resto de la descripción predefinida de por los fabricantes, describiendo de manera cómoda y legible operaciones no genéricas sin límite de complejidad y reutilizables en otros diseños, a estos bloques se les conoce como bloques de *propiedad intelectual* (IP). También se encuentran lenguajes con un nivel más alto de abstracción conocidos como HLS (high level synthesis), donde se pueden utilizar lenguajes de programación como C o C++ para describir los algoritmos que se desean implementar y esto se traduce a un lenguaje HDL. Con VHDL se puede diseñar un mismo circuito de manera funcional, estructural, mediante flujo de datos o mezcla de alguna de las anteriores, además permite la implementación de máquinas de estado, filtros digitales y banco de pruebas. Siendo VHDL el lenguaje de descripción de hardware utilizado en este trabajo.

4.4. Sistema embebido con FPGA

Un sistema embebido o SoC (system on chip) es un sistema electrónico que contiene una unidad de control, unidades de memoria, unidades de entrada-salida y periféricos para tareas específicas. Los sistemas embebidos en la actualidad se caracterizan por la fiabilidad y la personalización, esto último se refiere a la posibilidad de modificar el sistema de acuerdo a las necesidades del proceso, intentando combinar lo mejor del mundo del software y del hardware, con la facilidad de programar un procesador y al mismo tiempo de diseñar módulos por hardware (bloques IP). Obteniendo la integración de un sistema embebido y la lógica programable mediante FPGA, para una arquitectura de dos secciones:

- **Lógica programable (PL):** Consiste en un conjunto de bloques lógicos configurables (CLB) unidos entre sí por una matriz de conexiones programables, multiplexores y bloques de entrada/salida.
- **Sistema de procesamiento (PS):** Donde se localiza el procesador, encargado de ejecutar las aplicaciones de usuario y/o el sistema operativo, además gestiona los periféricos de entrada/salida y los bloques IP creados con la lógica programable.

La comunicación entre PS y PL se realiza mediante conexiones de propósito generalmente AXI (advanced extensible interface).

4.5. Desarrollo en hardware

Uno de los objetivos de esta investigación es implementar en un sistema embebido con VHDL el procesamiento digital estudiado y desarrollado en los capítulos 2 y 3, dicha implementación consiste en cuatro módulos:

- Filtrado de fase cero y normalización de amplitud.
- Detección y alineamiento de los complejos PQRST.
- Extracción de características con los parámetros de forma y el proceso AC/AR.
- Cálculo de la distancia Mahalanobis.

Estos módulos son diseñados e implementados en lenguaje de descripción de hardware, siendo la lógica programable desarrollada. Los tres primeros módulos hacen parte del empaquetamiento IP del pre-procesamiento y extracción de características, dicho módulo IP hace uso de 6 registros del bus AXI y el módulo IP del cálculo de la distancia Mahalanobis hace uso de 9 registros del bus AXI. En la figura 4.1, se observan los bloques de implementación del sistema embebido, donde el módulo de toma de decisión y adquisición por comunicación UART son implementados en lenguaje C desde el sistema de procesamiento.

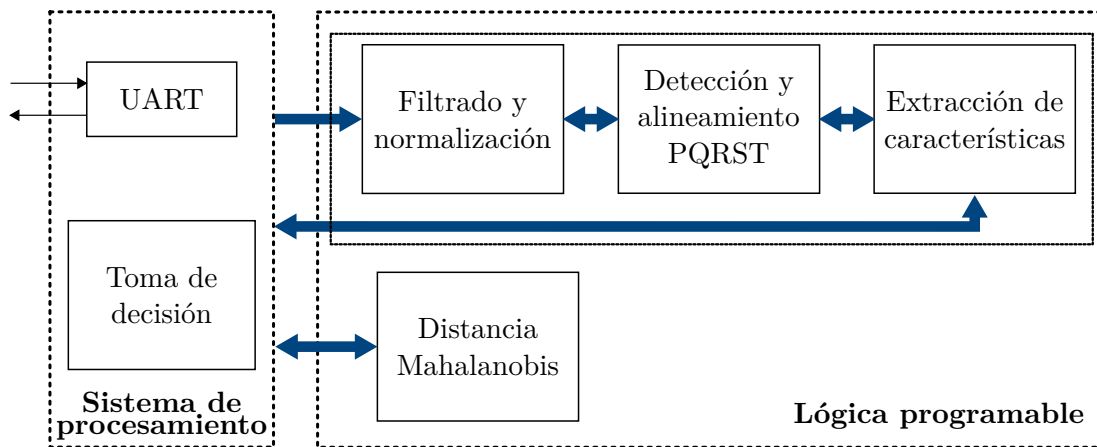


Figura 4.1: Diagrama de bloques del sistema biométrico implementado en un sistema embebido con FPGA.

La implementación fue desarrollada en Vivado[®] 2017.4, que es la herramienta para el diseño de proyectos en FPGA de Xilinx[®], que incluye la capacidad para el diseño de sistemas embebidos mediante la lógica programable y el diseño de aplicaciones del sistema de procesamiento utilizando el kit de desarrollo de software SDK[®]. Los módulos descritos en la figura 4.1 son implementados de forma individual en el sistema embebido ZedBoard Zynq-7000, que integra la capacidad de programación de software con un procesador basado en ARM y la capacidad de programación de hardware de un FPGA. Dicho sistema gestiona el protocolo de comunicación AXI4-Lite entre PS y PL.

Como se mencionó al inicio de este capítulo, la representación numérica utilizada en este trabajo es punto fijo con formato 8.24, representando la parte entera con 7 bits y la parte decimal con 24 bits, adicional del bit de signo, para un total de 32 bits para la representación numérica de un dato de la señal ECG.

4.5.1. Adquisición - Comunicación UART

Para los diferentes tiempo de adquisición de la señal ECG como se ha mencionado en los capítulos anteriores, se utiliza la comunicación UART con el estándar RS-232 a una tasa de transmisión de 115 200 baudios por segundo. En el sistema de procesamiento se utiliza el UART1, trasmitiendo 4 bytes desde el sistema de adquisición correspondientes a los 32 bits de la representación numérica por cada dato de señal ECG adquirida a una frecuencia de muestreo de 125 Hz, como se describe en la subsección 3.1.2. Cada dato de 32 bits es recibido en el módulo de filtrado y almacenado en una posición de memoria RAM de forma síncrona con su llegada.

4.5.2. Filtrado de fase cero y normalización de amplitud

Se implementa el algoritmo de filtrado de fase cero o nula mediante un filtro IIR y la normalización de amplitud descritos en la subsección 3.2.1, los coeficientes del filtro se implementan con la representación numérica de punto fijo 8.24. El diagrama esquemático del diseño de implementación se muestra en la figura 4.2, almacenando en la memoria RAM2 la señal filtrada y normalizada, dicha memoria es leída por el módulo de detección y alineamiento de los complejos PQRST.

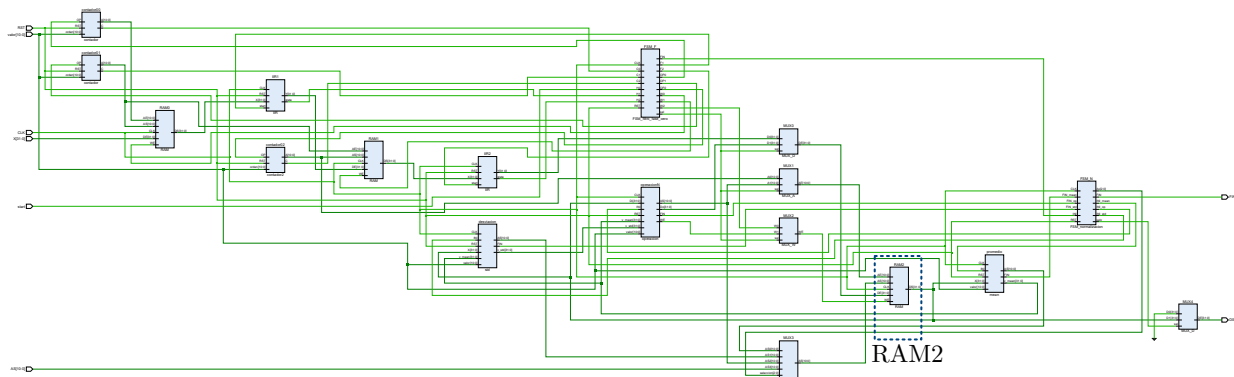


Figura 4.2: Esquemático del análisis RTL de la implementación del módulo de filtrado de fase cero y normalización de amplitud.

La implementación del cálculo de la raíz cuadrada en la desviación estándar se desarrolló con el algoritmo babilónico. En la implementación, primero se ejecuta la máquina de estados del filtrado y luego la de la normalización.

4.5.3. Detección y alineamiento de los complejos PQRST

Se desarrolla la implementación de la detección del pico R descrita en la subsección 3.2.2 y el alineamiento de los complejos PQRST descrito en la subsección 3.2.3, los coeficientes de los filtros descritos en estas secciones también se implementan con la representación numérica de punto fijo en formato 8.24. El diagrama esquemático del diseño de implementación se muestra en la figura 4.3. El bloque PQRST (DUT16) almacena en una memoria RAM de 127 posiciones los 88 valores de extracción fiducial correspondientes al complejo PQRST promedio de la observación ECG adquirida.

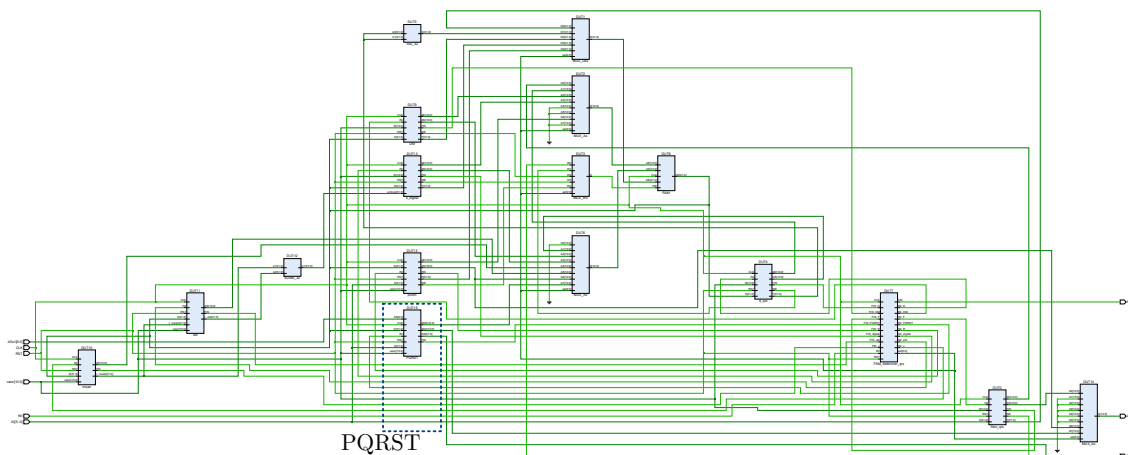


Figura 4.3: Esquemático del análisis RTL de la implementación del módulo de detección y alineamiento de los complejos PQRST.

4.5.4. Extracción de características

La extracción de características se realiza leyendo la memoria RAM donde se encuentra el complejo PQRST promedio hallado en el módulo descrito anteriormente. Los parámetros de forma del complejo PQRST estudiados en la subsección 3.4.2, son implementados siguiendo las ecuaciones mencionadas. Para la extracción de los coeficientes del proceso AC/AR, se implementa la teoría estudiada en la subsección 2.4.6, resolviendo la ecuación (2.27) obtenida de la AC del complejo PQRST como se especifica en la subsección 3.4.3. La matriz \mathbf{R}_γ , es una matriz de 6×6 y además es toeplitz, lo cual, facilita el cálculo de su matriz inversa en hardware al existir su determinante y facilitar el cálculo de la matriz transpuesta. El proceso AR es invariante al escalamiento de amplitud [58], por lo cual, el cálculo de la matriz inversa se reduce a solo a calcular los coeficientes de la primera columna de la matriz adjunta. El cálculo de la matriz adjunta fue el reto a implementar en hardware, dicho cálculo se realiza con la recursividad del algoritmo del determinante de una matriz de 3×3 . El diagrama esquemático del diseño de implementación se muestra en la figura 4.4, donde se observa un bloque para cada parámetros de forma y un bloque exclusivo para los coeficientes del proceso AC/AR.

4.5.5. Distancia Mahalanobis

Tanto para autenticación en la comparación uno a uno, como en identificación en la comparación uno a todos con k NN, se implementa la distancia de Mahalanobis descrita por la ecuación (2.36), calculando primero la distancia con la matriz de covarianza poblacional de los parámetros de forma y luego la distancia con la matriz de covarianza poblacional de los coeficientes del proceso AC/AR, donde la distancia final entregada por este módulo es la suma de las dos distancias mencionadas, como se describe en las subsecciones 3.4.4 y 3.5.3. El esquemático del bloque IP implementado se observa en la figura 4.5, donde este bloque lee el vector de características obtenido del procesamiento de la señal adquirida, llamado *vector consulta* y el vector modelo almacenado en la base de datos del sistema para realizar la comparación, al igual que las matrices de covarianza de entrenamiento tanto para verificación como para identificación, dicha información es suministrada desde el sistema de procesamiento, al cual, se le suministra la distancia calculada.

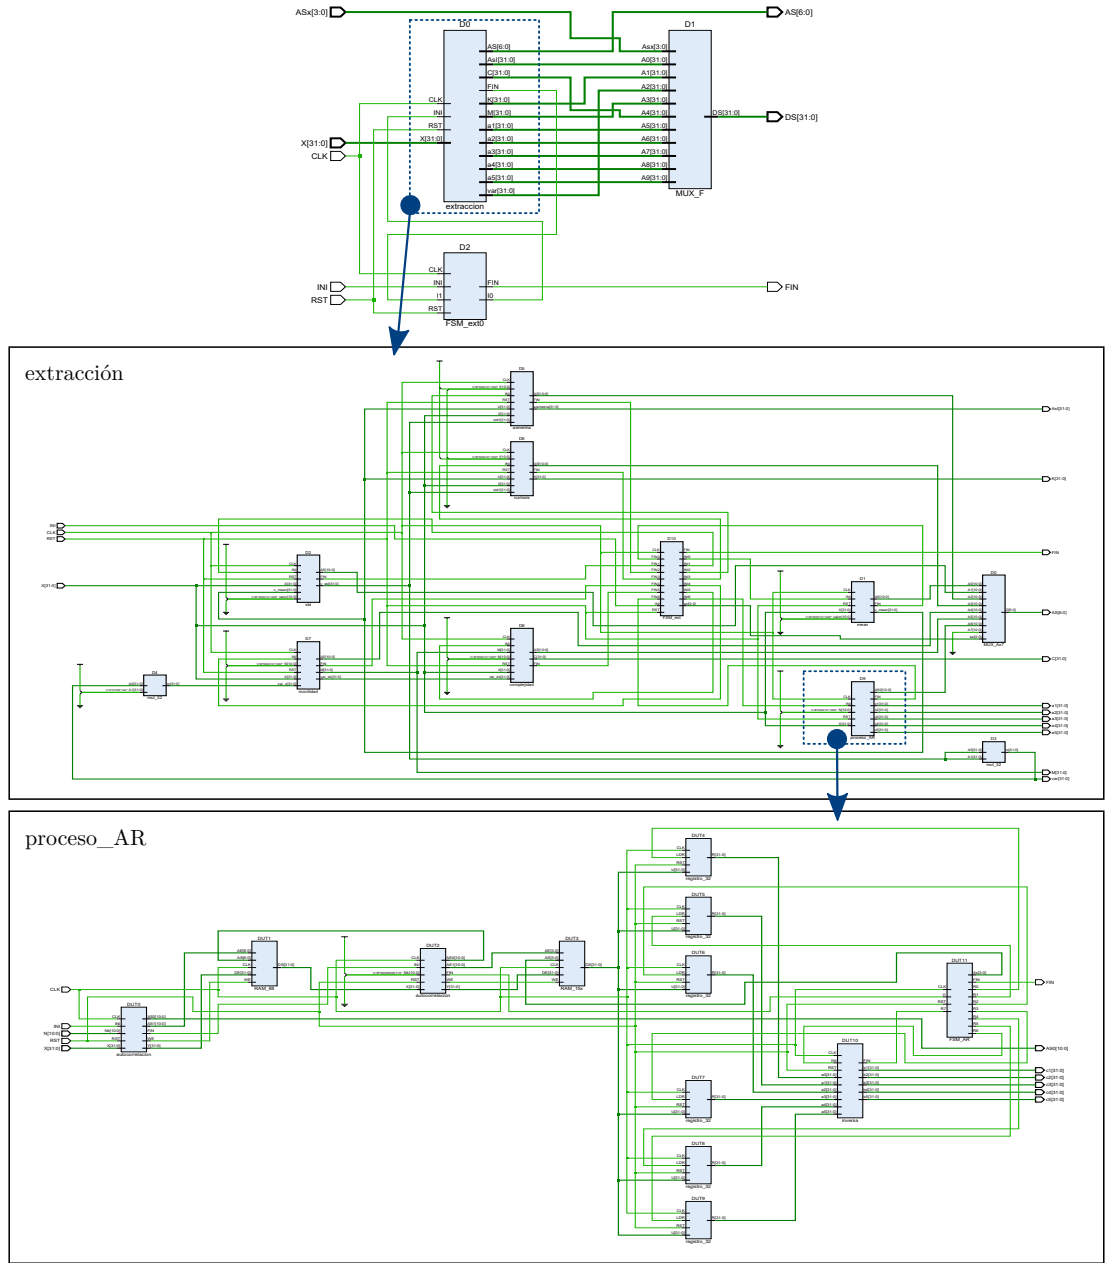


Figura 4.4: Esquemáticos del análisis RTL de la implementación de la extracción de características.

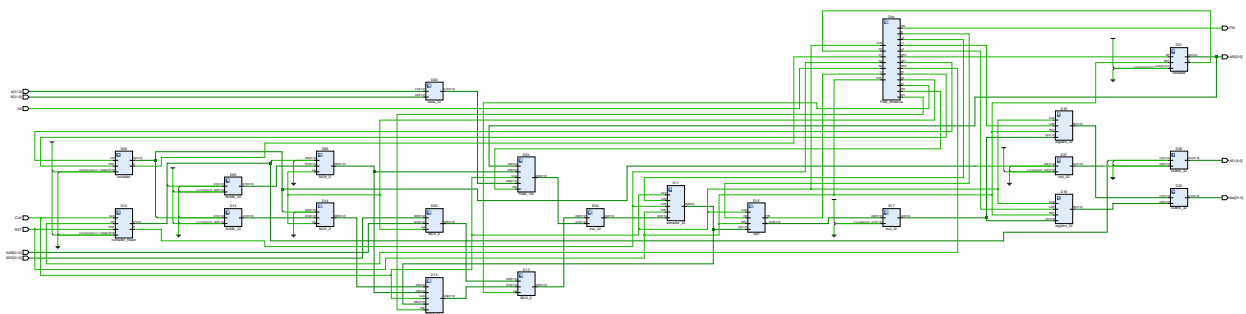


Figura 4.5: Esquemático del análisis RTL de la implementación del cálculo de la distancia Mahalanobis.

4.5.6. Toma de decisión

El módulo es desarrollado en C en el sistema de procesamiento, encargado de realizar el proceso de comparación y toma de decisión en la fase de prueba para autenticación e identificación, mediante los datos de entrenamiento y los datos suministrados por los módulos descritos anteriormente ante una consulta dada. Este módulo tiene la posibilidad abierta a enlazar la base de datos de entrenamiento del sistema mediante interfaz ethernet, USB y SD Card. Este módulo entrega las matrices de covarianza poblacional y el vector a comparar al bloque IP de distancia Mahalanobis, obteniendo la distancia calculada como respuesta.

4.6. Tiempos de ejecución

Los tiempos de ejecución de cada módulo diseñado se midieron en ciclos de reloj para generalizar la comparación a futuro, ya que la frecuencia del oscilador varía de un dispositivo a otro. El sistema embebido *ZedBoard Zynq-7000* posee un oscilador de 100 MHz para LP y un oscilador de 33.333 MHz para PS.

Los tiempos obtenidos se muestran en la tabla 4.1. Cuando se adquiere una señal cardíaca de 10 s equivalente a 1250 muestras, la implementación del pre-procesamiento y la extracción de características tarda un tiempo de 1.89 ms en realizar todo el procesamiento. Cuando la señal es de 625 muestras la implementación tarda 0.991 ms y cuando la señal es de 3 s, es decir 375 muestras la implementación tarda 0.63 ms. El proceso que más tiempo toma es la detección y alineamiento de los complejos PQRST. Los tiempos de ejecución de la tabla 4.1 son medidos después de almacenar todos los datos de entrada por comunicación UART. Para la toma de decisión se hace uso de la implementación del cálculo de la distancia Mahalanobis de dos vectores de características, dicho cálculo tarda 1.59 μ s. En procesos de verificación este sería el tiempo aproximado para la toma de decisión, ya que la autenticación es un proceso de comparación uno contra uno, por otro lado, para el proceso de identificación este tiempo sería multiplicado por el número de sujetos en la base de datos, ya que la identificación es un proceso de comparación uno contra todos.

Módulo	Tiempo ECG		
	10 s	5 s	3 s
	Ciclos de reloj		
Filtrado de fase cero y normalización	80027	40027	24027
Detección y alineamiento PQRST	99806	49830	30088
Ext. de características	Parámetros de forma	3182	3182
	Proceso AC/AR	6078	6078
Total de ciclos de reloj	189093	99117	63375
Tiempo de ejecución [ms]	1.89093	0.99117	0.63375
Distancia Mahalanobis	159	159	159
Tiempo de ejecución [μs]	1.59	1.59	1.59

Tabla 4.1: Tiempos de ejecución en ciclos de reloj para la implementación en la lógica programable del pre-procesamiento, extracción de características y cálculo de la distancia Mahalanobis.

4.7. Recursos utilizados

El planteamiento del problema de esta investigación impulsó el desarrollo de un sistema de biometría basado en ECG, que tuviera una técnica de extracción de características eficiente en las tasas de verificación e identificación ante los retos propuestos, al igual que tuviera un costo computacional aceptable. En la subsección 4.2.1, se mencionó como están conformados los CLB o bloques principales de un FPGA, por lo tanto, se obtuvo el número de elementos que se utilizaron en la implementación en VHDL de cada uno de los módulos vistos en este capítulo. En la tabla 4.2 se registran las LUT utilizadas como funciones lógicas y como memoria, también los registros y los DSP utilizados.

Tiempo ECG	Módulo	LUT Lógica	LUT Memoria	Registros	DSP	
10 s	Filtrado de fase cero y normalización	7579	4224	1814	24	
	Detección y alineamiento PQRST	6703	3040	1790	36	
	Ext. de características	Parámetros de forma	26632	264	1811	112
		Proceso AC/AR	9716	288	1036	68
	Total	50630	7816	6451	240	
5 s	Filtrado de fase cero y normalización	6946	2112	1814	24	
	Detección y alineamiento PQRST	6318	1632	1790	36	
	Ext. de características	Parámetros de forma	26632	264	1811	112
		Proceso AC/AR	9716	288	1036	68
	Total	49612	4296	6451	240	
3 s	Filtrado de fase cero y normalización	6660	1056	1814	24	
	Detección y alineamiento PQRST	6134	928	1790	36	
	Ext. de características	Parámetros de forma	26632	264	1811	112
		Proceso AC/AR	9716	288	1036	68
	Total	49142	2536	6451	240	
	Distancia Mahalanobis	2750	48	266	11	

Tabla 4.2: Recursos utilizados para la implementación en la lógica programable del pre-procesamiento, extracción de características y cálculo de la distancia Mahalanobis.

El módulo de extracción de características tiene el mismo costo en hardware para las tres implementaciones de longitud de la señal ECG, esto se debe a que el módulo de detección y alineamiento PQRST entrega siempre un vector de 88 muestras del complejo PQRST promedio de cada observación, como se describe en la subsección 3.2.3. También se observa que ante las tres diferentes implementaciones, el número de elementos que solo cambia es el de las LUT, debido a las diferentes longitudes de las memorias RAM. Los datos de la tabla 4.2 validan que la extracción de características mediante el proceso AC/AR es mucho más económico que

la extracción mediante los parámetros de forma. Por último, también se registra el costo en hardware de la implementación de la distancia Mahalanobis para el proceso de toma de decisión tanto en autenticación como en identificación.

Conclusiones y trabajo futuro

En función de los retos propuesto se aporta un estudio del estado del arte de biometría basada en ECG con investigaciones que reporten 50 o más personas a reconocer, que reporten la longitud de la señal ECG utilizada para la extracción de características, la longitud del vector de características extraído y que especifiquen el proceso de extracción y toma de decisión.

La consolidación de la base de datos ante diferentes fuentes de variabilidad cardíaca de 1400 registros ECG de 140 personas en condición sana de salud, donde cada persona tiene 10 observaciones, permitió desarrollar el estudio de los retos propuestos, implementando un pre-procesamiento de filtrado de fase cero o fase nula para no distorsionar la morfología del complejo cardíaco y la normalización en amplitud con el teorema del límite central para disminuir la variabilidad intra-sujeto, al igual que implementar una técnica de extracción de características híbrida que ataque de la mejor manera a las fuentes de variabilidad cardíaca, dicha técnica de extracción híbrida consiste en la detección y alineamiento de los complejos PQRST como extracción fiducial y la extracción de los parámetros de forma y los coeficientes de un proceso AC/AR como extracción no fiducial.

Los momentos estadísticos, en especial la *varianza*, la *asimetría*, la *curtosis* y los *descriptores de Hjorth* son una técnica de extracción de características bastante eficiente ante las fuentes de variabilidad, al igual que la ampliación del segundo momento estadístico, como es el caso de la *autocorrelación*. El teorema de Wiener-Khinchine es la introducción al desarrollo de la extracción de característica mediante el proceso AC/AR. En la subsección 3.4.3, mediante el estudio realizado para determinar el orden adecuado de un proceso AR y la señal apropiada para estimar, se determinó que la secuencia de autocorrelación del complejo PQRST presenta mejor resultado para el reconocimiento con un proceso AR de orden 5, solucionando el proceso AR con el método de Yule-Walker y no con el método de Burg.

La extracción de característica de 10 coeficientes propuesta, donde 5 coeficientes son los parámetros de forma y los otros 5 son los coeficientes de un proceso AC/AR, obtiene el mejor resultado en el proceso de verificación comparada con la extracción de característica mediante la FFT y el proceso AC/DCT de un submuestreo de 2 del complejo PQRST promedio. Además, la distancia de Mahalanobis es la mejor métrica de asociación para procesos de reconocimiento, comparada con la distancia de correlación, dtw, euclidiana y de Pearson, dichos resultados se evidencian en la tabla 3.7.

Con la base de datos consolidada se desarrolla la validación cruzada para autenticación e identificación, con el 70 % de los registros para entrenamiento y el 30 % para prueba, realizando adicionalmente 120 combinaciones de los registros por sujeto.

El proceso de autenticación de 140 personas es implementado para tres diferentes longitudes de la señal ECG adquirida, obteniendo en la fase de entrenamiento una *EER* de 4.88, 6.15 y 8.51 % para adquisiciones de 10, 5 y 3s respectivamente. En la fase de prueba se alcanza una *VR* de 96.72, 95.73 y 93.83 % para adquisiciones de 10, 5 y 3s respectivamente. Las tasas de conveniencia del sistema son 98.64, 98.25 y 97.37 % para adquisiciones de 10, 5 y 3s respectivamente y para las tasas de seguridad se consigue 94.79, 93.22 y 90.30 % para adquisiciones de 10, 5 y 3s respectivamente. Por lo anterior, según la relación entre la tasa de conveniencia y seguridad, la autenticación con adquisición de 3s es viable para enfrentar los retos propuestos como se reporta en la tabla 3.8. El sistema de autenticación propuesto, además presenta un buen rendimiento ante la variación del tamaño de la población de la base datos como se observa en la tabla 3.9.

El mejor clasificador para el proceso de biometría en identificación es *k*NN, comparado contra LDA y una red neuronal de 148 neuronas en la capa oculta y función de activación de base radial. La red neuronal tiene mejor rendimiento con la función de activación de base radial que con la función sigmoidea tangente hiperbólica.

El sistema biométrico propuesto para identificación con *k*NN, donde $k = 1$ y la distancia de Mahalanobis es la métrica de asociación, obtiene para la identificación de 140 personas una *IR* de 94.63, 88.07 y 76.75 % para adquisiciones de 10, 5 y 3s respectivamente. La *IR* se degrada al aumentar la longitud de la base de datos como se evidencia en la tabla 3.13, donde el mejor resultado de identificación se logra para la adquisición ECG de 10s.

Se implementa en hardware el pre-procesamiento, la extracción de características y la métrica de asociación con representación numérica de punto fijo en formato 8.24, obteniendo que la ejecución del pre-procesamiento y la extracción de características tarda 189 093, 99 117 y 63 375 ciclos de reloj para la implementación con adquisiciones ECG de 1250, 625 y 375 muestras respectivamente, siendo la detección y alineamiento PQRST el procesamiento que más ciclos de reloj gasta. El cálculo de la distancia Mahalanobis tarda 159 ciclos de reloj para ejecutarse, dichos resultados se reportan en la tabla 4.1. Los recursos utilizados en hardware de las implementaciones se reportan en la tabla 4.2, donde la extracción de características de los parámetros de forma tiene mayor costo que la extracción con el proceso AC/AR.

Los resultados obtenidos para la autenticación e identificación de 140 personas con una extracción de 10 características son bastante buenos, dado que se está realizando el reconocimiento con una base de datos que presenta registros ECG adquiridos bajo fuentes de variabilidad cardíaca, además, se está haciendo el estudio del rendimiento antes diferentes tiempo de adquisición de la señal y diferentes longitudes de la base de datos a reconocer. Concluyendo que la extracción de características y la métrica de asociación es viable para su implementación en hardware.

Como trabajos futuros se plantea explorar técnicas de *aprendizaje profundo* para la extracción de características, además, realizar un análisis de la varianza (ANOVA) para ver los coeficientes

más significativos de los 10 propuestos como vector de características, adicionalmente, explorar el rendimiento del sistema biométrico como sistema bimodal o multimodal. También se propone optimizar la implementación en hardware con técnicas más avanzadas de diseño y re-utilización óptima de módulos en el procesamiento.



Bibliografía

- [1] João Ribeiro Pinto, Jaime S Cardoso, and André Lourenço. Evolution, current challenges, and future possibilities in ecg biometrics. *IEEE Access*, 6:34746–34776, 2018.
- [2] Anil K Jain, Arun A Ross, and Karthik Nandakumar. *Introduction to biometrics*. Springer Science & Business Media, 2011.
- [3] Ruud M Bolle, Jonathan H Connell, Sharath Pankanti, Nalini K Ratha, and Andrew W Senior. *Guide to biometrics*. Springer Science & Business Media, 2013.
- [4] Bob JA Schijvenaars, Jan A Kors, Gerard van Herpen, Fred Kornreich, and Jan H van Bommel. Effect of electrode positioning on ecg interpretation by computer. *Journal of electrocardiology*, 30(3):247–256, 1997.
- [5] Lena Biel, Ola Pettersson, Lennart Philipson, and Peter Wide. Ecg analysis: a new approach in human identification. *IEEE Transactions on Instrumentation and Measurement*, 50(3):808–812, 2001.
- [6] Steven A Israel, John M Irvine, Andrew Cheng, Mark D Wiederhold, and Brenda K Wiederhold. Ecg to identify individuals. *Pattern recognition*, 38(1):133–142, 2005.
- [7] Mohammed Abo-Zahhad, Sabah M Ahmed, and Sherif N Abbas. Biometric authentication based on pcg and ecg signals: present status and future directions. *Signal, Image and Video Processing*, 8(4):739–751, 2014.
- [8] Antonio Fratini, Mario Sansone, Paolo Bifulco, and Mario Cesarelli. Individual identification via electrocardiogram analysis. *Biomedical engineering online*, 14(1):78, 2015.
- [9] Mario Merone, Paolo Soda, Mario Sansone, and Carlo Sansone. Ecg databases for biometric systems: A systematic review. *Expert Systems with Applications*, 67:189–202, 2017.
- [10] Gagandeep Kaur, Gurpreet Singh, and Vineet Kumar. A review on biometric recognition. *International Journal of Bio-Science and Bio-Technology*, 6(4):69–76, 2014.
- [11] Pablo Laguna, Roger G Mark, A Goldberg, and George B Moody. A database for evaluation of algorithms for measurement of qt and other waveform intervals in the ecg. In *Computers in cardiology 1997*, pages 673–676. IEEE, 1997.

- [12] Alex Barros, Paulo Resque, João Almeida, Renato Mota, Helder Oliveira, Denis Rosário, and Eduardo Cerqueira. Data improvement model based on ecg biometric for user authentication and identification. *Sensors*, 20(10):2920, 2020.
- [13] D. E. Mancilla Palestina. Análisis de características estadísticamente significativas en el dominio temporal de señales ecg y ppg para identificación biométrica bimodal. Master's thesis, Instituto Nacional de Astrofísica, Óptica y Electrónica, México, 2019.
- [14] Anita Pal and Yogendra Narain Singh. Ecg biometric recognition. In *International Conference on Mathematics and Computing*, pages 61–73. Springer, 2018.
- [15] Wonki Lee, Seulgee Kim, and Daeun Kim. Individual biometric identification using multi-cycle electrocardiographic waveform patterns. *Sensors*, 18(4):1005, 2018.
- [16] Mahmoud M Bassiouni, El-Sayed A El-Dahshan, Wael Khalefa, and Abdelbadeeh M Salem. Intelligent hybrid approaches for human ecg signals identification. *Signal, Image and Video Processing*, 12(5):941–949, 2018.
- [17] Gokhan Guven, Hakan Gürkan, and Umit Guz. Biometric identification using fingertip electrocardiogram signals. *Signal, Image and Video Processing*, 12(5):933–940, 2018.
- [18] Robin Tan and Marek Perkowski. Toward improving electrocardiogram (ecg) biometric verification using mobile sensors: A two stage classifier approach. *Sensors*, 17(2):410, 2017.
- [19] Md Saiful Islam and Naif Alajlan. Biometric template extraction from a heartbeat signal captured from fingers. *Multimedia Tools and Applications*, 76(10):12709–12733, 2017.
- [20] Wael Louis, Majid Komeili, and Dimitrios Hatzinakos. Continuous authentication using one-dimensional multi-resolution local binary patterns (1dmrlbp) in ecg biometrics. *IEEE Transactions on Information Forensics and Security*, 11(12):2818–2832, 2016.
- [21] Carlos Carreiras, André Lourenço, Hugo Silva, Ana Fred, and Rui Ferreira. Evaluating template uniqueness in ecg biometrics. In *Informatics in Control, Automation and Robotics*, pages 111–123. Springer, 2016.
- [22] Muhammad Najam Dar, M Usman Akram, Anam Usman, and Shoab A Khan. Ecg biometric identification for general population using multiresolution analysis of dwt based features. In *2015 Second International Conference on Information Security and Cyber Forensics (InfoSec)*, pages 5–10. IEEE, 2015.
- [23] Tilendra Choudhary and M Sabarimalai Manikandan. A novel unified framework for noise-robust ecg-based biometric authentication. In *2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN)*, pages 186–191. IEEE, 2015.
- [24] Susana Brás and Armando J Pinho. Ecg biometric identification: A compression based approach. In *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 5838–5841. IEEE, 2015.

-
- [25] Karan Singh, Akshit Singhvi, and Vinod Pathangay. Dry contact fingertip ecg-based authentication system using time, frequency domain features and support vector machine. In *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 526–529. IEEE, 2015.
- [26] David Pereira Coutinho, Hugo Silva, Hugo Gamboa, Ana Fred, and Mario Figueiredo. Novel fiducial and non-fiducial approaches to electrocardiogram-based biometric systems. *IET biometrics*, 2(2):64–75, 2013.
- [27] Nouredine Belgacem, A Nait-Ali, R Fournier, and Fethi Bereksi-Reguig. Ecg based human identification using random forests. In *Proc. Int. Conf. E-Technol. Bus. Web (EBW)*, 2013.
- [28] Tsu-Wang Shen, Willis J Tompkins, and Yu Hen Hu. Implementation of a one-lead ecg human identification system on a normal population. *Journal of Engineering and Computer Innovations*, 2(1):12–21, 2011.
- [29] Sairul I Safie, John J Soraghan, and Lykourgos Petropoulakis. Electrocardiogram (ecg) biometric authentication using pulse active ratio (par). *IEEE Transactions on Information Forensics and Security*, 6(4):1315–1322, 2011.
- [30] Ikenna Odinaka, Po-Hsiang Lai, Alan D Kaplan, Joseph A O’Sullivan, Erik J Sirevaag, Sean D Kristjansson, Amanda K Sheffield, and John W Rohrbaugh. Ecg biometrics: A robust short-time frequency analysis. In *2010 IEEE International Workshop on Information Forensics and Security*, pages 1–6. IEEE, 2010.
- [31] Shih-Chin Fang and Hsiao-Lung Chan. Human identification by quantifying similarity and dissimilarity in electrocardiogram phase space. *Pattern Recognition*, 42(9):1824–1831, 2009.
- [32] Yogendra Narain Singh and Phalguni Gupta. Biometrics method for human identification using electrocardiogram. In *International Conference on Biometrics*, pages 1270–1279. Springer, 2009.
- [33] Gerd Wübbeler, Manuel Stavridis, Dieter Kreiseler, Ralf-Dieter Bousseljot, and Clemens Elster. Verification of humans using the electrocardiogram. *Pattern Recognition Letters*, 28(10):1172–1175, 2007.
- [34] Zhaomin Zhang and Daming Wei. A new ecg identification method using bayes’ theorem. In *TENCON 2006-2006 IEEE Region 10 Conference*, pages 1–4. IEEE, 2006.
- [35] Vessela Krasteva, Irena Jekova, and Roger Abächerli. Biometric verification by cross-correlation analysis of 12-lead ecg patterns: Ranking of the most reliable peripheral and chest leads. *Journal of electrocardiology*, 50(6):847–854, 2017.
- [36] Foteini Agrafioti and Dimitrios Hatzinakos. Ecg biometric analysis in cardiac irregularity conditions. *Signal, Image and Video Processing*, 3(4):329, 2009.
- [37] Salil Prabhakar, Sharath Pankanti, and Anil K Jain. Biometric recognition: Security and privacy concerns. *IEEE security & privacy*, 1(2):33–42, 2003.

- [38] Leif Sörnmo and Pablo Laguna. *Bioelectrical signal processing in cardiac and neurological applications*, volume 8 of *Biomedical Engineering*. Academic Press, 1 edition, 2005.
- [39] Dee Unglaub Silverthorn, William C Ober, Claire W Garrison, Andrew C Silverthorn, and Bruce R Johnson. *Human physiology: an integrated approach*. Pearson/Benjamin Cummings San Francisco, 2010.
- [40] Jiri Pumprla, Kinga Howorka, David Groves, Michael Chester, and James Nolan. Functional assessment of heart rate variability: physiological basis and practical applications. *International journal of cardiology*, 84(1):1–14, 2002.
- [41] Foteini Agrafioti, Jiexin Gao, Dimitrios Hatzinakos, and Jucheng Yang. Heart biometrics: Theory, methods and applications. In *Biometrics*, pages 199–216. InTech Shanghai, China, 2011.
- [42] Foteini Agrafioti, Dimitris Hatzinakos, and Adam K Anderson. Ecg pattern analysis for emotion detection. *IEEE Transactions on affective computing*, 3(1):102–115, 2011.
- [43] Brian W Johnston, Richard Barrett-Jolley, Anton Krige, and Ingeborg D Welters. Heart rate variability: Measurement and emerging use in critical care medicine. *Journal of the Intensive Care Society*, 21(2):148–157, 2020.
- [44] Bob Schijvenaars. *Intra-individual Variability of the Electrocardiogram: Assessment and exploitation in computerized ECG analysis*. 2000.
- [45] Saeid Wahabi, Shahrzad Pouryayevali, Siddarth Hari, and Dimitrios Hatzinakos. On evaluating ecg biometric systems: session-dependence and body posture. *IEEE Transactions on Information Forensics and Security*, 9(11):2002–2013, 2014.
- [46] Balwinder Singh, Preeti Singh, and Sumit Budhiraja. Various approaches to minimise noises in ecg signal: A survey. In *2015 Fifth International Conference on Advanced Computing & Communication Technologies*, pages 131–137. IEEE, 2015.
- [47] James J Bailey, Alan S Berson, Arthur Garson Jr, Leo G Horan, Peter W Macfarlane, David W Mortara, and Christoph Zywietz. Recommendations for standardization and specifications in automated electrocardiography: bandwidth and digital signal processing. a report for health professionals by an ad hoc writing group of the committee on electrocardiography and cardiac electrophysiology of the council on clinical cardiology, american heart association. *Circulation*, 81(2):730–739, 1990.
- [48] Ramaswamy Palaniappan and Shankar M Krishnan. Identifying individuals using ecg beats. In *2004 International Conference on Signal Processing and Communications, 2004. SPCOM'04.*, pages 569–572. IEEE, 2004.
- [49] Jiapu Pan and Willis J Tompkins. A real-time qrs detection algorithm. *IEEE transactions on biomedical engineering*, (3):230–236, 1985.
- [50] Sahar A El-Rahman. Biometric human recognition system based on ecg. *Multimedia Tools and Applications*, 78(13):17555–17572, 2019.

-
- [51] Dimitris K Manolakis John G. Proakis. *Digital Signal Processing: Principles, Algorithms and Applications*. Prentice Hall, 3rd edition, 1995.
- [52] Vinay Ingle, Stephen Kogon, and Dimitris Manolakis. *Statistical and Adaptive Signal Processing*. Artech, 2005.
- [53] Bo Hjorth. Eeg analysis based on time domain properties. *Electroencephalography and clinical neurophysiology*, 29(3):306–310, 1970.
- [54] Foteini Agrafioti and Dimitrios Hatzinakos. Ecg based recognition using second order statistics. In *6th Annual Communication Networks and Services Research Conference (cnsr 2008)*, pages 82–87. IEEE, 2008.
- [55] Ikenna Odinaka, Po-Hsiang Lai, Alan D Kaplan, Joseph A O’Sullivan, Erik J Sirevaag, and John W Rohrbaugh. Ecg biometric recognition: A comparative analysis. *IEEE Transactions on Information Forensics and Security*, 7(6):1812–1824, 2012.
- [56] Konstantinos N Plataniotis, Dimitrios Hatzinakos, and Jimmy KM Lee. Ecg biometric recognition without fiducial detection. In *2006 Biometrics symposium: Special session on research at the biometric consortium conference*, pages 1–6. IEEE, 2006.
- [57] Shaikh Anowarul Fattah, Celia Shahnaz, Abu Shafin Mohammad Mahdee Jameel, and Rajib Goswami. Ecg signal based human identification method using features in temporal and wavelet domains. In *TENCON 2012 IEEE Region 10 Conference*, pages 1–4. IEEE, 2012.
- [58] Alexander D Poularikas and Zayed M Ramadan. *Adaptive filtering primer with MATLAB*. CRC Press, 2006.
- [59] Fabienne Porée, Gaëlle Kervio, and Guy Carrault. Ecg biometric analysis in different physiological recording conditions. *Signal, image and video processing*, 10(2):267–276, 2016.
- [60] Tom Fawcett. An introduction to roc analysis. *Pattern recognition letters*, 27(8):861–874, 2006.
- [61] Sławomir T Wierzchoń and Mieczysław Kłopotek. *Modern algorithms of cluster analysis*. Springer, 2018.
- [62] Janos Abonyi and Balazs Feil. *Cluster analysis for data mining and system identification*. Springer Science & Business Media, 2007.
- [63] Christopher M Bishop. *Pattern recognition and machine learning*. springer, 2006.
- [64] Donald J Berndt and James Clifford. Using dynamic time warping to find patterns in time series. In *KDD workshop*, volume 10, pages 359–370. Seattle, WA, USA:, 1994.
- [65] Carlos María Cuadras. *Nuevos métodos de análisis multivariante*. CMC editions Barcelona, 2007.

- [66] João Ribeiro Pinto, Jaime S Cardoso, André Lourenço, and Carlos Carreiras. Towards a continuous biometric system based on ecg signals acquired on the steering wheel. *Sensors*, 17(10):2228, 2017.
- [67] Khairul Azami Sidek, Vu Mai, and Ibrahim Khalil. Data mining in mobile ecg based biometric identification. *Journal of Network and Computer Applications*, 44:83–91, 2014.
- [68] James Gareth, Witten Daniela, Hastie Trevor, and Tibshirani Robert. *An introduction to statistical learning: with applications in R*. Springer, 2013.
- [69] Marco AF Pimentel, Alistair EW Johnson, Peter H Charlton, Drew Birrenkott, Peter J Watkinson, Lionel Tarassenko, and David A Clifton. Toward a robust estimation of respiratory rate from pulse oximeters. *IEEE Transactions on Biomedical Engineering*, 64(8):1914–1923, 2016.
- [70] Hugo Plácido Da Silva, André Lourenço, Ana Fred, Nuno Raposo, and Marta Aires-de Sousa. Check your biosignals here: A new dataset for off-the-person ecg biometrics. *Computer methods and programs in biomedicine*, 113(2):503–514, 2014.
- [71] MA García-González, A Argelagós, Mireya Fernández-Chimeno, and J Ramos-Castro. Differences in qrs locations due to ecg lead: relationship with breathing. In *XIII Mediterranean Conference on Medical and Biological Engineering and Computing 2013*, pages 962–964. Springer, 2014.
- [72] Jose Vicente, Lars Johannesen, Jay W Mason, William J Crumb, Esther Pueyo, Norman Stockbridge, and David G Strauss. Comprehensive t wave morphology assessment in a randomized clinical study of dofetilide, quinidine, ranolazine, and verapamil. *Journal of the American Heart Association*, 4(4):e001615, 2015.
- [73] TS Lugovaya. Biometric human identification based on electrocardiogram. *Master’s thesis, Faculty of Computing Technologies and Informatics, Electrotechnical University ‘LETI’, Saint-Petersburg, Russian Federation*, 2005.
- [74] Yongjin Wang, Foteini Agrafioti, Dimitrios Hatzinakos, and Konstantinos N Plataniotis. Analysis of human electrocardiogram for biometric recognition. *EURASIP journal on Advances in Signal Processing*, 2008(1):148658, 2007.
- [75] Antonio Fratini, Mario Sansone, Paolo Bifulco, Maria Romano, Alessandro Pepino, Mario Cesarelli, and Giovanni D’Addio. Individual identification using electrocardiogram morphology. In *2013 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, pages 107–110. IEEE, 2013.
- [76] René de F Romero Troncoso. *Electrónica digital y lógica programable*. Universidad de Guanajuato, 2007.
- [77] Roger Woods, John McAllister, Gaye Lightbody, and Ying Yi. *FPGA-based implementation of signal processing systems*. Wiley Online Library, 2017.
- [78] Xilinx. *Vivado Design Suite 7 Series FPGA and Zynq-7000 SoC Libraries Guide*. Xilinx Support-documentation, 2019.