

PROYECTO FIN DE GRADO

TÍTULO: Identificación Biométrica basada en ECG usando Redes Neuronales Convolucionales

AUTOR/A: Cristina Sevilla Muñoz

TITULACIÓN: Grado en Ingeniería de Sistemas de Telecomunicación

TUTOR/A: David Luengo García

DEPARTAMENTO: Ingeniería Audiovisual y Comunicaciones

Miembros del Tribunal Calificador:

PRESIDENTE/A: Margarita Martínez Núñez

TUTOR/A: David Luengo García

SECRETARIO/A: David Meltzer Camino

Fecha de lectura: Julio 2024

Calificación:

El Secretario/La Secretaria,



RESUMEN

El reconocimiento biométrico surge ante la necesidad de implementar métodos de identificación o autenticación más robustos y seguros que los métodos tradicionales, ya que estos se basan en contraseñas o tarjetas identificativas, que pueden olvidarse, perderse o falsificarse con facilidad. La biometría está basada en características intrínsecas de los individuos, físicas o conductuales, como pueden ser el iris, la huella dactilar, la forma de hablar o incluso la forma de escribir. Sin embargo, estas características tampoco eliminan al completo el problema de los sistemas tradicionales, ya que se pueden copiar o falsificar. Es por ello que, en la actualidad, las investigaciones proponen rasgos biométricos alternativos como el electrocardiograma (ECG). La señal del ECG refleja la actividad eléctrica del corazón, y su inherente medida de vida asegura que el sistema biométrico no está siendo atacado. Destaca por su universalidad, unicidad y carácter continuo, además de presentar variaciones significativas entre individuos, debido a la geometría del corazón, los atributos individuales de cada sujeto o su estado de salud.

Este proyecto propone desarrollar un método robusto para el reconocimiento biométrico basado en el ECG donde se prescinde de la localización de puntos fiduciaros en la forma de onda de la señal. El método desarrollado se basa en una versión simplificada de la red neuronal convolucional VGGNet, la cual recibe como parámetros de entrada diferentes representaciones tiempo - frecuencia de las señales de los pacientes sanos presentes en la base de datos elegida. Estas representaciones se basan en la Transformada de Fourier de Tiempo Reducido (STFT) y sus versiones a escala logarítmica y escala de Mel, obteniendo así el espectrograma, espectrograma logarítmico y espectrograma de Mel. Durante la ejecución del modelo, se realizarán iteraciones (con un máximo de 100 épocas) hasta que este considere que la mejora en la precisión (*accuracy*) de validación es mínima, momento en que se para el entrenamiento de la red.

Tras realizar estas simulaciones y analizar los resultados, se concluye que la red ofrece altos rendimientos, sin problemas de *overfitting* cuando los parámetros de entrada están representados con el espectrograma de Mel. Esto abre la posibilidad a que futuros estudiantes puedan desarrollar un algoritmo que acabe con este problema en las otras representaciones e incluso realicen simulaciones con la base de datos completa, no solo los pacientes de control.

ABSTRACT

Biometric recognition arises from the need to implement identification or authentication methods that are more robust and secure than traditional methods, since they are based on passwords or identification cards, which can be easily forgotten, lost or forged. Biometrics is based on intrinsic physical or behavioral characteristics of individuals, such as iris, fingerprint, speech or even handwriting. However, these characteristics do not completely eliminate the problem of traditional systems, since they can be copied or falsified. This is why researchers are now proposing alternative biometric features such as the electrocardiogram (ECG). The ECG signal reflects the electrical activity of the heart, and its inherent measure of life ensures that the biometric system is not under attack. It stands out for its universality, uniqueness and continuous nature, in addition to presenting significant variations between individuals, due to the geometry of the heart, the individual attributes of each subject or their state of health.

This project proposes to develop a robust method of ECG-based biometric recognition where the localization of fiduciary points in signal waveform is dispensed with. The developed method consists of a simplified version of the convolutional neural network VGGNet, which receives as input parameter different time – frequency representations of the signals of the healthy patients present in the chosen database. These representations are based on the Short-time Fourier transform (STFT) and its logarithmic scale and Mel scale versions, thus obtaining the spectrogram, logarithmic spectrogram and Mel spectrogram. During the execution of the model, iterations (with a maximum of 100) will be carried out until the model considers that the improvement in the validation accuracy is minimal.

After performing these simulations and analyzing the results, it is concluded that the network offers high performances, without overfitting problems when the input parameters are represented with Mel spectrogram. This opens the possibility for future students to develop an algorithm that will solve this problem in the other representations and even perform simulations with the complete database, not only the control patients.

AGRADECIMIENTOS

Para todos aquellos que tuvieron paciencia y comprensión durante el proceso.

ÍNDICE DE CONTENIDO

CAPÍTULO 1: INTRODUCCIÓN	1
1.1 Biometría	1
1.2 Objetivos	2
1.3 Especificaciones y restricciones de diseño	3
1.4 Metodología de trabajo propuesta	3
1.5 Desglose de tareas y cronograma	3
1.6 Recursos previstos	4
1.7 Estructura de la memoria	4
CAPÍTULO 2: BIOMETRÍA	7
2.1 Introducción	7
2.2 Historia de la biometría	8
2.3 Comparativa con sistemas tradicionales	14
2.4 Arquitectura de un sistema biométrico	15
2.5 Funcionalidades de un sistema biométrico	17
2.6 Medidas de rendimiento de un sistema biométrico	18
2.7 Requisitos de los rasgos biométricos	21
2.8 Sistemas multibiométricos	23
2.9 Discusión	24
CAPÍTULO 3: SEÑALES BIOMÉDICAS	25
3.1 Introducción	25
3.1.1 Objetivos	25
3.1.2 Contexto	26
3.2 Clasificación	27
3.3 Señales bioeléctricas	29
3.3.1 Potenciales de Acción	29
3.3.2 Clases de Señales Bioeléctricas	30
3.3.3 Ruido e Interferencias	32
3.4 Electrocardiograma	33
3.4.1 Anatomía y fisiología del corazón	33
3.4.2 Actividad eléctrica del corazón	34
3.4.3 Principales ondas y segmentos del ECG	35
3.4.4 Artefactos y ruido en el ECG	36
3.5 Discusión	39

CAPÍTULO 4: BIOMETRÍA BASADA EN ECG	41
4.1 Justificación	41
4.2 Variabilidad de la señal <i>intra-sujeto e inter-sujeto</i>	43
4.3 Adquisición de señales de ECG	45
4.3.1 Adquisición en ámbito médico	45
4.3.2 Sistemas Holter	46
4.3.3 Configuraciones <i>off-the-person</i>	46
4.3.4 Sistemas de adquisición integrados	47
4.3.5 Escenarios futuros	47
4.4 Bases de datos en biometría basada en ECG	48
4.4.1 Principales bases de datos públicas	49
4.5 Técnicas para la extracción de información y características	50
4.5.1 Métodos fiduciaros	50
4.5.2 Métodos no fiduciaros	51
4.5.3 Reducción de dimensionalidad	51
4.6 Clasificadores	52
4.7 Propiedades de ECG como rasgo biométrico	54
4.8 Discusión	54
CAPÍTULO 5: DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS	57
5.1 Base de datos	57
5.1.1 Carga	57
5.1.2 Representaciones tiempo-frecuencia	58
5.1.3 Segmentado	61
5.2 Extracción de características y clasificación	61
5.2.1 Carga de datos	61
5.2.2 Preprocesado	62
5.2.3 Arquitectura de red	63
5.2.4 Entrenamiento y evaluación	65
5.3 Resultados	66
5.3.1 Simulaciones con espectrogramas	67
5.3.2 Simulaciones con espectrogramas logarítmicos	69
5.3.3 Simulaciones con espectrogramas de Mel	71
5.4 Discusión	73
CAPÍTULO 6: CONCLUSIÓN Y LÍNEAS FUTURAS	75

CAPÍTULO 7: PRESUPUESTO	77
7.1 Costes físicos	77
7.2 Costes indirectos	77
7.3 Costes humanos	77
7.4 Coste total	78
CAPÍTULO 8: IMPACTO DEL PROYECTO	79
REFERENCIAS BIBLIOGRÁFICAS	81

ÍNDICE DE FIGURAS

Figura 1. Diagrama de Gantt correspondiente al cronograma seguido para la realización del proyecto.	4
Figura 2. Rasgos biométricos más comunes: (a) huella dactilar ²⁷ , (b) reconocimiento facial ²⁸ , (c) voz ²⁹ , (d) iris ³⁰	13
Figura 3. Características comunes extraídas de la huella dactilar, el iris y el rostro [17].	15
Figura 4. Funcionamiento básico del enrollment (versión modificada de la Figura 1 de [9]).	16
Figura 5. Diagrama de bloques de un sistema de reconocimiento biométrico	16
Figura 6. Ejemplo de señal biomecánica, modificada a partir de [22].	27
Figura 7. Ejemplo de una señal bioacústica, modificada a partir de [23].	27
Figura 8. Ejemplo de señal biomagnética [24].	28
Figura 9. Potencial de acción y etapas en las que se divide [56].	29
Figura 10. Amplitud y duración de los potenciales de acción para los diferentes tipos de células (motoras, esqueléticas y cardíacas). Imagen modificada a partir de [20].	30
Figura 11. Disposición común de los electrodos para la medición del EEG [58].	30
Figura 12. Izquierda: disposición de electrodos según el estándar de 12 derivaciones [25].	31
Figura 13. Izquierda: Disposición de electrodos para obtener el electrooculograma [26]. Derecha: señal electrooculográfica para detección de movimientos verticales. Imagen modificada a partir de [27].	31
Figura 14. Izquierda: disposición de electrodos para obtener el electrogastrograma [28].	32
Figura 15. Izquierda: toma electromiográfica de aguja ³¹	32
Figura 16. Partes del corazón ³²	33
Figura 17. Ciclo cardíaco [25].	34
Figura 18. Propagación de impulsos eléctricos a través del miocardio [31].	35
Figura 19. Artefactos comunes en el ECG: a) señal limpia, b) baseline wander, c) powerline interference, d) electromyographic noise [33].	38
Figura 20. Algoritmo basado en la evolución de variables latentes con una red entrenada [35].	41
Figura 21. Variabilidad intra-subject.	44
Figura 22. Variabilidad inter-subject.	44
Figura 23. Configuraciones estándar para la toma del ECG [25].	45
Figura 24. Dispositivo Holter con 5 electrodos [25].	46
Figura 25. Configuraciones off-the-person para la adquisición del ECG [25].	46
Figura 26. Sensores incorporados en objetos comunes o wearables [25].	47
Figura 27. Principales puntos fiduciaros ³⁴	50
Figura 28. Support Vector Machines ³⁵	52
Figura 29. k-Nearest Neighbors ³⁶	53
Figura 30. Artificial Neural Network ³⁷	53
Figura 31. Descarga de la base de datos al directorio local.	57
Figura 32. Diferentes representaciones tiempo-frecuencia.	59
Figura 33. Espectrograma del paciente 174.	59
Figura 34. Espectrograma filtrado del paciente 174.	60
Figura 35. Espectrograma logarítmico y espectrograma de Mel filtrados del paciente 174.	60
Figura 36. Diagrama de bloques simplificado.	61
Figura 37. Arquitectura de la CNN para imágenes a color.	65
Figura 38. Evolución de la precisión y pérdida de la configuración óptima usando espectrogramas.	68
Figura 39. Evolución de la precisión y pérdida para la peor configuración usando espectrogramas.	68
Figura 40. Evolución de la precisión y pérdida de la configuración óptima usando espectrogramas logarítmicos.	70
Figura 41. Evolución de la precisión y pérdida para la peor configuración usando espectrogramas logarítmicos.	70
Figura 42. Evolución de la precisión y pérdida de la configuración óptima usando espectrogramas de Mel.	72
Figura 43. Evolución de la precisión y pérdida para la peor configuración usando espectrogramas de Mel.	72

ÍNDICE DE TABLAS

Tabla 1. Historia de la biometría.....	12
Tabla 2. Ejemplo sencillo de matriz de confusión.	18
Tabla 3. Descripción de los parámetros de rendimiento.	20
Tabla 4. Medidas de rendimiento de un usuario.	20
Tabla 5. Medidas de rendimiento general [19].	21
Tabla 6. Rasgos biométricos y grado de adecuación [9].....	22
Tabla 7. Principales artefactos presentes en el ECG.....	37
Tabla 8. Ventajas e inconvenientes de varios rasgos biométricos [25]......	42
Tabla 9. Parámetros variables en las simulaciones.	66
Tabla 10. Resultados obtenidos con las distintas configuraciones de simulación usando espectrogramas.	67
Tabla 11. Resultados obtenidos con las distintas configuraciones de simulación usando espectrogramas logarítmicos.	69
Tabla 12. Resultados obtenidos con las distintas configuraciones de simulación usando espectrogramas de Mel.	71
Tabla 13. Costes físicos.....	77
Tabla 14. Costes indirectos.....	77
Tabla 15. Coste total del proyecto.....	78

CAPÍTULO 1: INTRODUCCIÓN

1.1 Biometría

Hoy en día resulta de gran importancia tener un buen sistema de seguridad, bien sea para proteger información personal, páginas web, instituciones públicas o incluso a las personas. Debido a que los sistemas tradicionales, basados en contraseñas o tarjetas identificativas, son fácilmente falsificables o pueden olvidarse, surge la necesidad de implementar nuevos métodos que resuelvan estos problemas; aquí es donde cobra gran importancia la biometría.

La biometría es la tecnología que analiza las características físicas o del comportamiento, propias de cada individuo, con el fin de autenticar su identidad [1]. Esta se basa en el principio de inmutabilidad, que afirma que algunos rasgos específicos producidos por un ser humano pueden generar ciertos patrones únicos a la hora de tomar muestras cuantificadas [2].

Los rasgos biométricos se pueden clasificar en dos grandes grupos: físicos y conductuales. El primer grupo está basado en rasgos relacionados con las características anatómicas o morfológicas, como pueden ser el iris, la huella dactilar o el rostro. En cambio, los conductuales son aquellos que se basan en patrones propios de cada persona, como pueden ser la forma de caminar, hablar o incluso escribir [3]. También podemos encontrar rasgos que comparten aspectos físicos y del comportamiento, como puede ser la voz [4].

Pese a que los rasgos físicos son más robustos que los conductuales, ya que estos últimos, o no proporcionan una elevada tasa de acierto en el reconocimiento o no son lo suficientemente robustos contra su falsificación, no deja de existir este riesgo. Por ejemplo, el rostro puede ser recreado de forma artificial realizando un modelo en 3D o, en el caso del iris, se puede hacer uso de lentes de contacto con los rasgos oculares impresos [36]. Además, en caso de que se produjese el robo de los patrones correspondientes a alguna de estas características físicas, el daño podría ser irreversible, puesto que no pueden ser cambiadas como una clave o tarjeta de identificación. Por ello, se planteó utilizar ciertas señales biomédicas como rasgos biométricos, entre las que se encuentra el electrocardiograma (ECG).

Las señales biomédicas son aquellas que proporcionan información sobre los diferentes procesos fisiológicos que tienen lugar en el cuerpo humano. Estos procesos suelen asociarse con señales de origen eléctrico, químico o acústico, las cuales transportan información que se encuentra oculta en su estructura. De entre ellas, el ECG se ha convertido en uno de los rasgos biométricos más prometedores, destacando en gran parte de las características que definen la calidad de un rasgo biométrico [2].

El ECG habitualmente es utilizado para medir la frecuencia cardiaca, para detectar cualquier anomalía o comportamiento ante medicamentos o dispositivos que regulan el latido del corazón, como puede ser un marcapasos. Pero también puede ser utilizado en biometría, debido a que depende del estado y la geometría del cuerpo, como pueden ser el peso, la altura y el comportamiento; por lo que se puede afirmar que estas señales son únicas para cada individuo [5].

INTRODUCCIÓN

El ECG se convierte en un rasgo de vital importancia en la biometría, especialmente en aplicaciones de seguridad, puesto que el corazón está situado dentro del cuerpo y está siempre en funcionamiento mientras el sujeto está vivo, lo que lo hace especialmente difícil de falsificar. Sin embargo, pese a ser un método bastante robusto y con gran eficiencia computacional, presenta varios inconvenientes relacionados con el ruido de la señal y su variabilidad con el paso del tiempo.

Por otra parte, cabe destacar que la eficiencia de estos métodos de seguridad basados en biometría tiene un límite. Es por ello que se están desarrollando nuevos algoritmos que ayuden a mejorar la eficiencia, basados en el *machine learning* y el *deep learning*.

El *machine learning* o aprendizaje automático describe la capacidad de aprendizaje de los sistemas a partir de datos de entrenamiento específicos en relación a un problema, sin intervención humana, para automatizar el proceso de análisis y resolución de tareas [6]. Este evolucionó hasta convertirse en lo que se conoce como *deep learning* o aprendizaje profundo, conformando una manera más potente y eficiente de tratar grandes cantidades de datos, puesto que hace uso de redes neuronales que imitan el proceso de aprendizaje del cerebro humano [7].

La finalidad de este proyecto es el desarrollo de métodos robustos para biometría basada en ECG que proporcionen la mayor tasa de acierto posible. Para ello se considerarán métodos no fiduciarios, es decir, métodos que no se basan en la detección de los puntos relevantes de la señal (esto es, los puntos fiduciarios). Se llevará a cabo el desarrollo de algoritmos inspirados en la red neuronal convolucional VGGNet y su programación en lenguaje Python. Para probar el correcto funcionamiento de estos, se hará uso de la base de datos *PTB Diagnostic ECG Database* (ptbdb), disponible en el repositorio público Physionet¹, utilizando únicamente los pacientes de control (sanos).

1.2 Objetivos

En el proyecto se persiguen los siguientes objetivos:

- Revisión del estado del arte en algoritmos de biometría basada en el ECG.
- Desarrollo de algoritmos específicos para la identificación de individuos a partir de señales de ECG utilizando métodos no fiduciarios.
- Programación y depuración de algoritmos los desarrollados en Python.
- Simulación de los algoritmos utilizando señales reales, verificando que cumplen con las especificaciones requeridas y analizando sus limitaciones.

¹ <https://physionet.org/>

1.3 Especificaciones y restricciones de diseño

A la hora de comenzar con el proyecto, se parte de las siguientes limitaciones de diseño:

- El algoritmo debe contar con la capacidad de trabajar con diferentes números de señales, frecuencias de muestreo, número de canales, etc.
- Aunque no es necesario que funcione en tiempo real, el algoritmo debe procesar la información de forma rápida y efectiva.
- La tasa de errores, es decir, la identificación incorrecta de individuos, debe ser lo más reducida posible.
- Se debe probar la eficacia del algoritmo con el mayor número de individuos posible, tanto sujetos sanos como con patologías.

No existe ninguna normativa ni estándar aceptado en relación con la identificación o autenticación biométrica basada en el ECG.

1.4 Metodología de trabajo propuesta

En este proyecto se ha seguido una metodología de trabajo cíclica. Comenzando por seleccionar una clase de redes neuronales convolucionales, para después desarrollar y simular algoritmos, en lenguaje Python, basados en dicho método. Tras analizar los resultados obtenidos, procederíamos a ajustar el algoritmo, en caso de ser admisibles, o, en caso contrario, a la elección de una nueva familia de redes; volviendo así al inicio del proceso descrito.

A la hora de realizar la simulación del código, se hará uso de señales reales que se encuentran disponibles en las bases de datos de Physionet, las cuales son tanto de sujetos sanos como con patologías.

1.5 Desglose de tareas y cronograma

Se ha desarrollado el proyecto a lo largo de 6 meses con dedicación a tiempo parcial. El desglose de tareas es el siguiente:

- **Tarea 1 (Semanas 1 - 8):** revisión del estado del arte en biometría basada en ECG. Tiempo dedicado estimado: 60 horas.
- **Tarea 2 (Semanas 9 - 18):** desarrollo de algoritmos, en Python, para biometría basada en ECG. Tiempo dedicado estimado: 90 horas.
- **Tarea 3 (Semanas 14 - 24):** simulación de los algoritmos desarrollados, validándolos con sujetos sanos y con patologías. Tiempo dedicado estimado: 90 horas.
- **Tarea 4 (Semanas 1 - 26):** redacción de la memoria del proyecto y preparación de la presentación. Tiempo dedicado estimado: 84 horas.

INTRODUCCIÓN




Figura 1. Diagrama de Gantt correspondiente al cronograma seguido para la realización del proyecto.

Se prevé que el tiempo total dedicado a este proyecto no sea superior a 324 horas.

1.6 Recursos previstos

Los recursos necesarios para la realización de este PFG son un ordenador personal, el entorno de programación en lenguaje Python y las bases de datos a utilizar descargadas de Physionet (<https://physionet.org>).

1.7 Estructura de la memoria

La memoria está dividida en 10 capítulos que cubren los siguientes contenidos:

- En el **capítulo actual** se realiza una breve introducción de los objetivos perseguidos a lo largo del proyecto, así como de las metodologías implementadas y el cronograma seguido para conseguirlos.
- En el **segundo capítulo** se dará una definición de biometría y se justificará su uso frente a sistemas de identificación tradicionales; también se estudiarán las principales estructuras de un sistema biométrico y las diferentes medidas que se pueden obtener.
- En el **tercer capítulo** se presenta una definición de las principales señales biomédicas y su clasificación, profundizando en las señales bioeléctricas y las diferentes formas de onda que forman el ECG.
- En el **cuarto capítulo** se enumeran las variaciones que pueden estar presentes en el ECG y las distintas formas de adquisición. Al final se justifica la viabilidad del ECG como rasgo biométrico.
- En el **quinto capítulo** se describe bloque a bloque el sistema propuesto.
- En el **sexto capítulo** se describen los diferentes grupos de simulaciones, junto a la configuración elegida, y se interpretan los resultados obtenidos.

- En el **séptimo capítulo** se exponen las conclusiones finales, teniendo en cuenta los resultados, y se plantean posibles líneas de trabajo en el futuro.
- En el **octavo capítulo** se elabora un presupuesto genérico de la inversión que supone realizar este proyecto.
- En el **noveno capítulo** se describe el impacto del proyecto, así como su aportación a los ODS.
- Finalmente, se listan las fuentes de información consultadas durante la elaboración de este documento.

INTRODUCCIÓN

CAPÍTULO 2: BIOMETRÍA

2.1 Introducción

El concepto de biometría proviene de las palabras bio (vida) y metría (medida), por lo que se deduce que un equipo biométrico mide e identifica alguna característica propia de un individuo [8].

De esta forma, podemos decir que la biometría es la ciencia que se dedica a la identificación y/o autenticación de individuos mediante rasgos biológicos específicos. Esta pretende cuantificar estos rasgos, bien sean físicos o conductuales, para después realizar un análisis estadístico y así poder verificar la identidad personal de los sujetos.

A partir del siglo XX comienzan a surgir grandes avances tecnológicos y, de forma paralela, el interés por los sistemas biométricos. Este interés se manifiesta gracias al desarrollo de los sistemas de procesamiento de información, debido a una creciente necesidad de encontrar sistemas de identificación de individuos que sean robustos ante el robo y la falsificación de identidad. Dicha necesidad se puede encontrar en lugares como puntos de control fronterizos, donde el tránsito de personas es bastante elevado, o en operaciones más sofisticadas como la firma de pagos electrónicos.

Como ya hemos mencionado, los fundamentos de la biometría consideran que es posible reconocer a un sujeto en función de ciertos rasgos específicos que genera, ya que pueden ser debidamente cuantificados y repetidos a lo largo del tiempo con varianzas mínimas o incluso nulas. Basándonos en esto, un sistema biométrico es, en esencia, una comparación de la cuantificación de un rasgo biométrico de un individuo frente a una cuantificación previa de ese mismo rasgo en otro instante de tiempo anterior. Por tanto, la identificación biométrica implica la necesidad de almacenar los rasgos cuantificados de un individuo.

Un rasgo cuantificado, o un grupo de rasgos, también puede denominarse como **patrón**. Por lo que podemos decir, en otras palabras, que la biometría se centra en el concepto de reconocimiento o comparación de patrones de una característica biológica o conductual concreta para su posterior uso en un proceso de identificación y/o autenticación [9].

2.2 Historia de la biometría

Entendiendo el concepto de biometría en términos muy amplios, podemos decir que esta se practica desde el principio de los tiempos. El ser humano siempre se ha esforzado en aprender a identificar patrones utilizando los sentidos. Por ejemplo, al escuchar la voz de una persona sin tenerla en nuestro rango de visión, nuestro cerebro intenta comprobar si se asemeja a alguna de las muchas voces que hemos escuchado a lo largo de nuestra vida. No solo los seres humanos, sino también los animales identifican a otros individuos en función de características biométricas como el olor, el tacto o el sonido [8].

A continuación, se muestran de forma resumida los principales acontecimientos de la historia de la biometría en la *Tabla 1*:


En cuevas podemos encontrar pinturas prehistóricas con numerosas huellas de manos alrededor, a modo de firma de su autor².



En el año 500 a.C., el imperio de Babilonia registraba las transacciones comerciales en tabillas de arcilla que incluían huellas dactilares³.



Marcello Malpighi⁴, profesor de anatomía en la Universidad de Bolonia, mencionó en 1686 las crestas espirales y bucles de las huellas dactilares. Realizó un estudio sobre la clasificación de las capas de la piel⁵.



En 1788, el anatomista y médico alemán Johann Christoph Andreas Mayer⁶ fue el primero en declarar que la huella dactilar es única para cada individuo [10].



En 1823, Johaness Evangelista Purkinje publica una tesis que reconocía los tipos de patrones formados en las huellas dactilares, clasificándolos en 9 grupos [11].



² https://www.tangol.com/blog/eng/cueva-de-las-manos_post_244


³ <https://76909078.weebly.com/fingerprinting-career.html>

⁴ <https://www.italyonthisday.com/2022/03/marcello-malpighi-scientist.html>


⁵ <https://oriong.weebly.com/cienciasdelavida/la-piel>

⁶ <https://www.bbaw.de/die-akademie/akademie-historische-aspekte/mitglieder-historisch/historisches-mitglied-johann-christoph-andreas-mayer-1773>


Henry Faulds fue el primero en publicar el valor de las crestas⁷ de fricción en la piel, especialmente en su uso como evidencia ante crímenes [11].



En 1882, el policía francés Alphonse Bertillon⁸ presentó el primer sistema de identificación de las personas basado en rasgos biométricos, y lo denominó **antropometría**. Es considerado el primer sistema científico usado por la policía para identificar criminales [12].



En 1892, Francis Galton⁹ escribió un estudio detallado de las huellas dactilares en el que presentaba un nuevo sistema de clasificación. Enunció las 3 leyes fundamentales de la dactiloscopia: perennidad, inmutabilidad y diversidad infinita de características.



Edward Henry¹⁰ buscó desarrollar un método de identificación que pudiera compaginarse con la antropometría, o sustituirla. Uno de sus empleados, Azizul Haque, desarrolló un método de clasificación y almacenamiento de información, para que la búsqueda fuera rápida y eficaz. Conseguido esto, Henry estableció en Londres los primeros archivos británicos de huellas dactilares. Más tarde, en 1901, se creó la Subdivisión de Huellas Dactilares de New Scotland Yard utilizando el Sistema Henry de Clasificación de Huellas Dactilares¹¹ [10]. Este sistema se convirtió en la base del Sistema Automatizado de Identificación Dactilar (AFIS).



⁷ <https://www.timetoast.com/timelines/historia-de-las-huellas-dactilares-fd369796-d781-4427-89a2-76bcb420ce4d>

⁸ https://es.wikipedia.org/wiki/Alphonse_Bertillon

⁹ https://es.wikipedia.org/wiki/Francis_Galton

¹⁰ <https://www.wikidata.org/wiki/Q3719966>

¹¹ <https://x.com/RelatocuriosoK/status/1771741344819536135>

BIOMETRÍA


Debido a la necesidad de la policía de un depósito nacional y un centro de intercambio de registros de huellas dactilares, se instauró una ley del Congreso el 1 de julio de 1921, por la que se estableció la División de Identificación del FBI¹² [10].



En 1936, el oftalmólogo Frank Burch propuso el concepto de utilizar los patrones del iris¹³ para la identificación personal.



Woodrow Wilson Bledsoe¹⁴ crea en 1960, por encargo del Gobierno estadounidense, el primer sistema semiautomático de reconocimiento facial. El sistema se basaba en la capacidad de extraer puntos de rasgos utilizables [10]. El siguiente paso fue introducir una tableta RAND¹⁵, con la que el operario podía dibujar con un lápiz óptico y producir una imagen legible por ordenador [13].



En 1969, el *Federal Bureau of Investigation (FBI)* centró sus esfuerzos en desarrollar un sistema automatizado que permitiera la clasificación, búsqueda y concordancia de las huellas dactilares. Para ello, contrataron al *National Bureau of Standards (NBS)*, actualmente conocido como *National Institute of Standards and Technology (NIST)*¹⁶ [14].



¹² <https://es.wikipedia.org/wiki/FBI>

¹³ <https://directorio.org.es/biometria-seguridad-o-ficcion/>

¹⁴ https://en.wikipedia.org/wiki/Woody_Bledsoe

¹⁵ <https://www.lanacion.com.ar/tecnologia/reconocimiento-facial-como-nacio-tableta-decada-del-nid2421334/>


¹⁶ <https://www.nist.gov/image/nsf-and-nist-logo>

En 1970 se emite una solicitud de propuesta para la construcción de un prototipo de lector de huellas dactilares. Tras unos años de pruebas, en 1974, Rockwell International¹⁷, Inc., construyó varios sistemas modelo de lectura automática de huellas dactilares. Estos lectores, llamados Finder¹⁸, fueron entregados al FBI en 1975.



Rockwell International




En la década de los 70, Goldstein, Harmon y Lesk pudieron incrementar la precisión de un sistema de reconocimiento facial manual¹⁹. Usaron 21 marcadores específicos que incluían el grosor de los labios y el color del cabello.



En 1987, dos oftalmólogos americanos patentaron el concepto de utilizar el patrón del iris para identificar sujetos. Esto les llevó a contactar con John G. Daugman²⁰ para que desarrollase los algoritmos necesarios, los cuales fueron finalmente patentados en 1994 [15].



En 1994, con el propósito de encontrar nuevos rasgos que permitan la clasificación de sujetos, en EE. UU. comenzaron a investigar nuevas técnicas de reconocimiento de patrones y redes neuronales²¹ desarrolladas en los lenguajes *Assembler* y *Fortran*.



¹⁷ https://es.wikipedia.org/wiki/Rockwell_International

¹⁸ <https://www.amazon.es/ZKTeco-ACC-USB-SLK20R-Unisex-ni%C3%B1os-Color/dp/B0CBKVG5T>


¹⁹ <https://spotcloud.medium.com/una-breve-historia-del-reconocimiento-facial-vision-blog-5a76fdfe4865>

²⁰ <https://www.cl.cam.ac.uk/~jgd1000/>

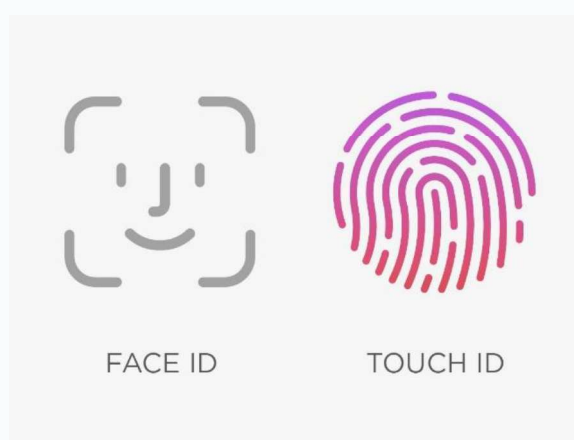
²¹ <https://www.digitaltrends.com/computing/what-is-an-artificial-neural-network/>

BIOMETRÍA

En 2004, el Departamento de Defensa de EE. UU. implantó el primer ABIS²² (*Automated Biometric Identification System*) para rastrear e identificar amenazas a la seguridad nacional. Este sistema permite realizar búsquedas utilizando múltiples tipos de datos biométricos; las modalidades no se limitan a las huellas dactilares, sino que también hace uso del rostro y el iris [16].



En 2013, Apple fue la primera empresa en introducir en sus dispositivos móviles lo que se conoce como el *Touch ID*²³, un sensor de huellas dactilares que aportaba al usuario fiabilidad a la hora de desbloquear su smartphone. Desde entonces, el mercado se llenó de dispositivos electrónicos con reconocimiento biométrico, ya fuera mediante huella digital, rostro u otros métodos.



En 2016, Android²⁴ introdujo soporte nativo para lectores de huellas dactilares, provocando una adopción masiva de la autenticación biométrica en teléfonos inteligentes.



En 2020, debido a la pandemia, se impulsó el uso de tecnologías sin contacto, incluyendo el reconocimiento facial²⁵ y la autenticación por voz, para reducir el riesgo de contagio mediante superficies táctiles.



En 2022, los teléfonos inteligentes y otros dispositivos empezaron a incorporar sensores²⁶ de huellas dactilares debajo de las pantallas, eliminando la necesidad de botones físicos.



Tabla 1. Historia de la biometría.

Hoy en día, los métodos de identificación biométrica más utilizados y confiables son los mencionados en la tabla anterior (*Tabla 1*) y mostrados en la *Figura 2*: (a) el reconocimiento mediante la huella digital, (b) el rostro, (c) la voz o (d) el iris. Sin embargo, pese a ser sistemas muy avanzados que se han ido desarrollando durante décadas, pueden ser vulnerables frente a la falsificación. Es por ello que actualmente se trabaja en la investigación de nuevos métodos de identificación, como pueden ser aquellos que se basan en el electrocardiograma (ECG), el encefalograma (EEG), o en características conductuales como la forma de caminar [25].




Figura 2. Rasgos biométricos más comunes: (a) huella dactilar²⁷, (b) reconocimiento facial²⁸, (c) voz²⁹, (d) iris³⁰.

²² <https://www.aware.com/automated-biometric-identification-system/>

²³ <https://bluumi.net/face-id-y-touch-id/>

²⁴ <https://www.xatakandroid.com/sistema-operativo/android-6-0-marshmallow-todas-sus-novedades>

²⁵ <https://www.computing.es/informes/la-covid-19-incrementa-un-77-el-uso-de-las-tecnologias-sin-contacto/>

²⁶ <https://www.xatakandroid.com/aplicaciones-android/seis-aplicaciones-para-lector-huellas-tu-android-haz-mucho-que-desbloquearlo>

²⁷ <https://www.ctxdetectives.com/wp-content/uploads/2022/07/huella-digital-detectives-privados-ctx.png>

²⁸ <https://www.revistaabogacia.com/reconocimiento-facial-entre-la-seguridad-y-la-privacidad/>

²⁹ <https://stores.onlinesale2024best.com/content?c=herramientas+de+reconocimiento+de+voz&id=25>

³⁰ <https://www.entelgy.com/en/divisions/digital/news-digital/articulos-digital/sistemas-biometricos-la-identificacion-del-futuro-ya-esta-aqui>

2.3 Comparativa con sistemas tradicionales

Con el fin de destacar las ventajas que supone el uso de los sistemas de autenticación biométricos frente a otros más tradicionales, en este apartado se va a realizar una comparativa entre ambos.

Actualmente, existen tres métodos básicos por los que un individuo puede ser identificado: aportando una prueba de determinados conocimientos, demostrando la posesión de un elemento físico o lógico, o a través de rasgos personales intrínsecos esenciales. Estos sistemas de identificación han sido denominados de conocimiento, propiedad e inherencia, es decir, lo que el individuo sabe, lo que posee y lo que es [9]:

❖ **Identificación basada en el conocimiento**

Es un método que depende de la capacidad del individuo para exponer un conocimiento determinado o generar una prueba de posesión de dicho conocimiento. Por ejemplo, mediante una contraseña alfanumérica para desbloquear el ordenador, o emitiendo una firma digital utilizando una clave privada en un criptosistema asimétrico.

❖ **Identificación basada en la posesión de un elemento**

Este tipo de identificación depende de la capacidad del individuo para dar uso al objeto poseído o para generar una prueba de posesión del mismo. Al objeto en posesión del individuo se le conoce como *token*. Por ejemplo, utilizando una llave física para abrir una puerta o un pin de seguridad a la hora autorizar una transacción online de una tarjeta de crédito.

❖ **Identificación basada en un rasgo intrínseco**

Al contrario que los dos métodos anteriores, basados en la capacidad del individuo de utilizar cierto conocimiento adquirido o *token*, la identificación biométrica cuenta con la capacidad inherente de los individuos para generar rasgos o características únicas que sean cuantificables y no presenten grandes cambios con el paso del tiempo. Como ya se comentó anteriormente, dada la naturaleza de los rasgos biométricos individuales, resulta mucho más difícil su duplicación o manipulación.

En resumen, los sistemas de identificación basados en el conocimiento o la posesión de un elemento presentan menos robustez y, por tanto, son más vulnerables frente a amenazas o ataques externos. Una contraseña o pin puede ser olvidada, robada o adivinada por sujetos distintos a su propietario; así como una tarjeta de acceso puede ser extraviada o usurpada sin mucha dificultad. Además, cabe la posibilidad de que el individuo poseedor de dicho conocimiento o *token* niegue haber realizado actos de identificación bajo la excusa de pérdida o robo. Es por ello que la biometría aparece como un intento de mitigar dichos riesgos, en forma de apoyo a los métodos tradicionales (doble o múltiple autenticación) o como una sustitución de los mismos.

2.4 Arquitectura de un sistema biométrico

Un sistema biométrico consiste en una combinación de elementos que, vistos como un conjunto, permiten la identificación personal de individuos o la validación de sus identidades. A este primer fin se le denomina autenticación o autentificación.

Su principal función consiste en cuantificar uno o varios rasgos físicos o conductuales del individuo, con el fin de determinar o verificar su identidad. El proceso llevado a cabo puede diferenciarse en dos fases: registro del patrón (*enrollment*), es decir, se obtienen los patrones y se almacenan en una base de datos; la otra fase es de reconocimiento (*recognition*), coincidencia de patrones o *pattern matching*, en la cual se vuelve a adquirir un rasgo biométrico y se relaciona la identidad del individuo con el rasgo biométrico registrado [9, 17]. Por ello, un sistema biométrico es, principalmente, un sistema de reconocimiento de patrones que consta de 4 bloques:

❖ Sensor

El sensor biométrico es el encargado de registrar los datos en crudo del usuario, es decir, debe ser capaz de grabar o cuantificar el rasgo biométrico del usuario. Su diseño es fundamental para una implementación exitosa del sistema biométrico; una interfaz intuitiva, ergonómica y fácil de usar favorece que la adquisición de muestras sea de mayor calidad [17].

❖ Módulo extractor de características

Antes de poder extraer sus características, los datos biométricos procedentes del sensor deben someterse a operaciones de preprocesado. Los tres pasos principales son [17]:

- ◆ Evaluación de calidad: consiste en discernir si el dato recogido tiene la suficiente calidad para continuar con el procesado posterior o es necesario volver a grabarlo.
- ◆ Segmentación: el objetivo de este paso es separar los datos biométricos útiles del ruido de fondo.
- ◆ Mejora: los datos segmentados se someten a un algoritmo de mejora de calidad que reduce aún más el ruido.

La extracción de características es el proceso por el cual se genera una representación digital compacta del rasgo biométrico que se está utilizando, llamada *template* o plantilla. Esta contiene únicamente la información discriminatoria más destacada que permite reconocer a la persona. En la siguiente figura se pueden ver algunos ejemplos de *templates* generados a partir de la huella dactilar, el iris o el rostro.




Figura 3. Características comunes extraídas de la huella dactilar, el iris y el rostro [17].

❖ **Base de datos**

La base de datos del sistema es un repositorio de la información biométrica. Durante el proceso de *enrollment*, y a la salida de la fase de extracción de características, la plantilla o *template* se almacena en la base de datos, junto con cierta información adicional del individuo, como el nombre o un número de identificación personal (PIN).

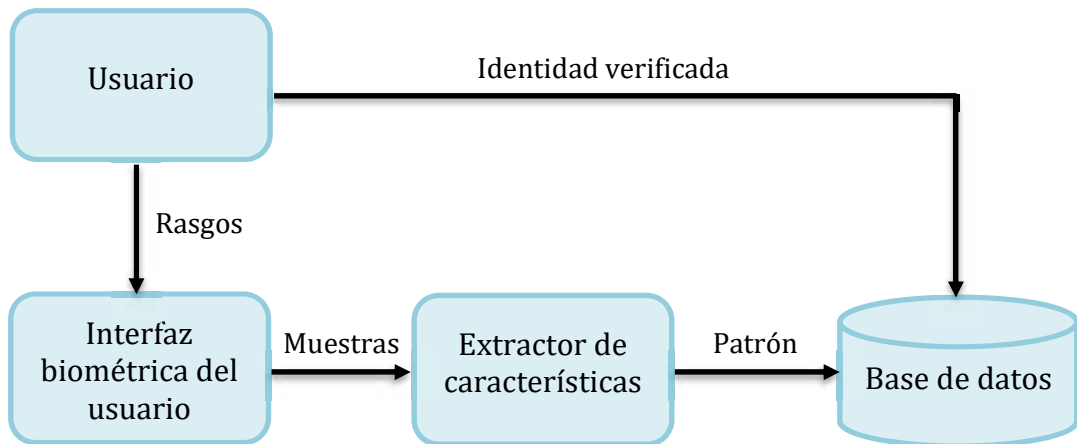


Figura 4. Funcionamiento básico del enrollment (versión modificada de la Figura 1 de [9]).

❖ **Comparador biométrico**

En esta fase, también conocida como *pattern matching*, se comparan las características del rasgo biométrico con las plantillas almacenadas en la base de datos para generar una tasa de coincidencia. Dicha tasa es una medida de la similitud entre la plantilla y el rasgo del individuo a identificar, por lo que un mayor número indica una mayor similitud. Este bloque también incluye un módulo de toma de decisiones, en el que las puntuaciones de coincidencia se utilizan para validar una identidad o para identificar a un individuo.

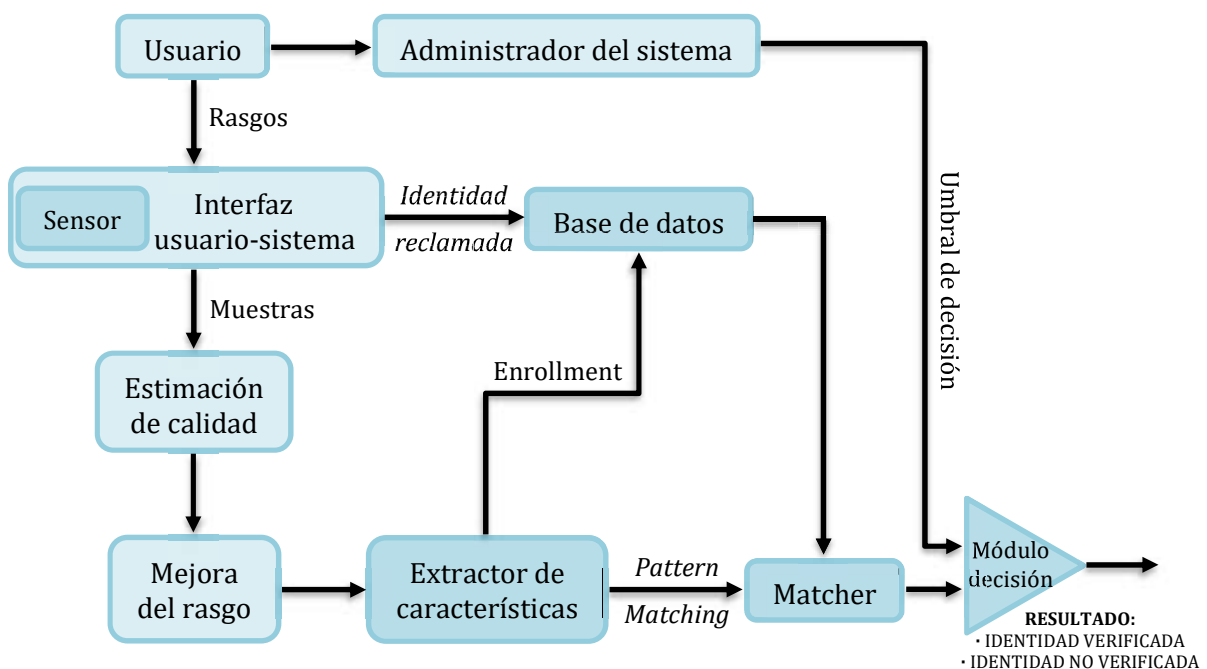


Figura 5. Diagrama de bloques de un sistema de reconocimiento biométrico (versión modificada de la Figura 1.3 de [17]).

2.5 Funcionalidades de un sistema biométrico

Un sistema biométrico puede ofrecer dos tipos de funcionalidades de gestión de la identidad, la verificación o autenticación y la identificación [17].

- ❖ **Verificación:** el usuario reclama una identidad y el sistema verifica si es correcta o no. Para ello, el rasgo biométrico consultado se compara únicamente con el almacenado en la base de datos del sistema correspondiente al individuo. Si entre el rasgo de entrada del usuario y el patrón guardado existe un alto grado de coincidencia, la verificación es correcta; en caso contrario, se rechaza la solicitud de autenticación y el usuario es considerado un “impostor”. Esta funcionalidad suele utilizarse en aplicaciones cuyo objetivo es impedir que personas no autorizadas accedan a determinados servicios.
- ❖ **Identificación:** esta funcionalidad puede a su vez dividirse en identificación positiva e identificación negativa. En la identificación positiva, el usuario trata de identificarse ante un sistema sin la necesidad de reclamar explícitamente una identidad, es decir, el sistema debe determinar la identidad del usuario a partir de un conjunto de identidades almacenadas. Por el contrario, en la identificación negativa se considera que el usuario oculta su verdadera identidad al sistema; se conoce como *screening* y el objetivo es averiguar quién es el usuario. Este último tipo se usa para evitar que una misma persona utilice varias identidades.

En ambos tipos, el rasgo biométrico de entrada se compara con todas las plantillas (*templates*) almacenadas en la base de datos, de forma que la salida del sistema es la identidad del sujeto cuya plantilla presenta mayor grado de similitud con la entrada, en caso de identidad verificada, o un mensaje indicando que el usuario no está registrado en la base datos en caso contrario.

2.6 Medidas de rendimiento de un sistema biométrico

Como ya se ha mencionado, el *pattern matching* consiste en cuantificar la similitud entre dos patrones. Esta medida se conoce como puntuación de coincidencia, y nos indica lo lejos o cerca que está el individuo de ser identificado o autenticado. Las razones por las que es viable utilizar la cuantificación son dos [9]:

- ◆ Los rasgos son únicos para cada individuo (unicidad).
- ◆ Los rasgos son permanentes en el tiempo (permanencia).

Sin embargo, cuando se trata de considerar técnicas y sistemas biométricos reales, estas características no pueden ser consideradas como inmutables; ya que dependen de cambios en las características del cuerpo, variaciones en las medidas, las técnicas biométricas y sensores utilizados, etc. [9].

La herramienta con la que se realizan las medidas de rendimiento de un sistema biométrico se conoce como matriz de confusión o **tabla de contingencia**. En dicha tabla, cada fila representa a cada uno de los sujetos que se han predicho, mientras que las columnas son los sujetos reales. Para poder entender mejor las medidas de rendimiento que se obtienen de la matriz, nos vamos a ayudar del siguiente ejemplo, representado en la *Tabla 2*:







		USUARIOS REALES		
				
USUARIOS PREDICHOS		10	2	1
		0	14	5
		2	3	11

Tabla 2. Ejemplo sencillo de matriz de confusión.

Si hacemos un análisis visual de la tabla de contingencia mostrada, podemos ver (en la fila 1) que el usuario 'panda' ha sido predicho como 'panda' en 10 ocasiones, 2 como 'panda rojo' y 1 como 'mapache'.

A la vista de los resultados, existen una serie de medidas que pueden calcularse sobre la matriz y que nos permiten ver con más detalle el funcionamiento del sistema. Dichas medidas son, entre otras, las siguientes [19]:

- Verdaderos positivos (**TP**): número de casos en los que el usuario predicho coincide con el usuario real, es decir, el resultado indica correctamente que existe una coincidencia de patrones.
- Verdaderos negativos (**TN**): número de casos en los que el usuario real se ha predicho como otros usuarios, es decir, para un usuario determinado, el número de casos en los que el usuario real es otro y no se ha confundido con dicho usuario.
- Falsos positivos (**FP**): número de casos en los que el usuario real no coincide con el usuario predicho. En otras palabras, los patrones del usuario a predecir han sido declarados coincidentes con un usuario distinto.
- Falsos negativos (**FN**): número de casos en los que algún otro usuario del sistema ha sido predicho como el usuario de referencia. Es decir, los patrones de algún otro usuario se han declarado como los más similares a los del usuario a predecir.
- Condición positiva (**P**): número de casos positivos reales entre los datos. También se puede expresar como la suma de TP más FN.
- Condición negativa (**N**): número de casos negativos reales entre los datos. También se puede expresar como la suma de TN más FP.

Las siguientes ecuaciones resaltan cada una de las medidas anteriores:

- La exactitud del sistema o *accuracy* (**ACC**) se calcula como:

$$ACC = \frac{TP+TN}{P+N} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- La tasa de verdaderos positivos o *true positive rate* (**TPR**) se calcula como:

$$TPR = \frac{TP}{P} = \frac{TP}{TP+FN} = 1 - FNR \quad (2)$$

- La tasa de verdaderos negativos o *true negative* (**TNR**) se calcula como:

$$TNR = \frac{TN}{N} = \frac{TN}{TN+FP} = 1 - FPR \quad (3)$$

- La precisión, valor predictivo positivo o *positive predictive value* (**PPV**) se calcula como:

$$PPV = \frac{TP}{TP+FP} = 1 - FDR \quad (4)$$

- El valor negativo predictivo o *negative predictive value* (**NPV**) se calcula como:

$$NPV = \frac{TN}{TN+FN} = 1 - FOR \quad (5)$$

- La tasa de falsos negativos o *false negative rate* (**FNR**) se calcula como:

$$FNR = \frac{FN}{P} = \frac{FN}{FN+TP} = 1 - TPR \quad (6)$$

- La tasa de falsos positivos o *false positive rate* (**FPR**) se calcula como:

$$FPR = \frac{FP}{N} = \frac{FP}{FP+TN} = 1 - TNR \quad (7)$$

BIOMETRÍA







- La tasa de falso descubrimiento o *false discovery rate* (**FDR**) se calcula como:

$$FDR = \frac{FP}{FP+TP} = 1 - PPV \quad (8)$$

- La tasa de falsa omisión o *false omission rate* (**FOR**) se calcula como:

$$FOR = \frac{FN}{FN+TN} = 1 - NPV \quad (9)$$

Como bien podemos ver en las ecuaciones, todas ellas se basan en el conocimiento de los parámetros P, N, TP, TN, FP y FN. Con el fin de aclarar el significado de estos términos, continuando con el ejemplo anterior, en la siguiente tabla se va a señalar con qué se corresponde cada uno, desde el punto de vista del usuario 'panda'.

		USUARIOS REALES		
				
USUARIOS PREDICHOS		10	2	1
		0	14	5
		2	3	11





 **TP** (points to 10)
 **FP** (points to 1)
 **FN** (points to 0)
 **TN** (points to 5)

Tabla 3. Descripción de los parámetros de rendimiento.

Sumando los valores de los recuadros, obtenemos los siguientes resultados para el usuario 'panda'.







		USUARIOS REALES	
			 
USUARIOS PREDICHOS		10 TP	3 FP
	 	2 FN	33 TN

Tabla 4. Medidas de rendimiento de un usuario.

De esta forma, el usuario ‘panda’ ha sido identificado como tal 10 veces (**TP = 10**), mientras que ha sido 3 veces falsamente identificado como tal (**FP = 3**). En cuanto a la identificación del resto de usuarios, el sistema los ha identificado erróneamente como ‘panda’ 2 veces (**FN = 2**), y 33 veces como usuarios distintos (**TN = 33**).

Para obtener los parámetros de rendimiento generales, basta con aplicar sumatorios a las fórmulas anteriores, de forma que obtenemos la siguiente tabla:

		Condición verdadera		$ACC = \frac{\sum TP + \sum TN}{\sum TP + \sum TN + \sum FP + \sum FN}$	
		Condición positiva	Condición negativa		
Condición predicha	Condición predicha positiva	TP	FP	$PPV = \frac{\sum TP}{\sum TP + \sum FP}$	$NPV = \frac{\sum TN}{\sum TN + \sum FN}$
	Condición predicha negativa	FN	TN	$FOR = \frac{\sum FN}{\sum TN + \sum FN}$	$FDR = \frac{\sum FP}{\sum TP + \sum FP}$
		$TPR = \frac{\sum TP}{\sum TP + \sum FN}$	$FPR = \frac{\sum FP}{\sum FP + \sum TN}$		
		$FNR = \frac{\sum FN}{\sum FN + \sum TP}$	$TNR = \frac{\sum TN}{\sum TN + \sum FP}$		

Tabla 5. Medidas de rendimiento general [19].

A continuación, se calculan las distintas medidas de rendimiento para el ejemplo de la *Tabla 4*.

- *Accuracy* → **ACC** = $\frac{TP+TN}{P+N} = \frac{TP+TN}{TP+TN+FP+FN} = \frac{10+33}{10+33+3+2} = \frac{43}{48} = \mathbf{0,895833}$
- Tasa de verdaderos positivos → **TPR** = $\frac{TP}{P} = \frac{TP}{TP+FN} = \frac{10}{10+2} = \frac{5}{6} = \mathbf{0,83333}$
- Tasa de verdaderos negativos → **TNR** = $\frac{TN}{N} = \frac{TN}{TN+FP} = \frac{33}{33+3} = \frac{11}{12} = \mathbf{0,91666}$
- Valor predictivo positivo → **PPV** = $\frac{TP}{TP+FP} = \frac{10}{10+3} = \frac{10}{13} = \mathbf{0,769230}$
- Valor predictivo negativo → **NPV** = $\frac{TN}{TN+FN} = \frac{33}{33+2} = \frac{33}{35} = \mathbf{0,9428571}$
- Tasa de falsos negativos → **FNR** = $\frac{FN}{P} = \frac{FN}{FN+TP} = \frac{2}{2+10} = \frac{1}{6} = \mathbf{0,1666}$
- Tasa de falsos positivos → **FPR** = $\frac{FP}{N} = \frac{FP}{FP+TN} = \frac{3}{3+33} = \frac{1}{12} = \mathbf{0,08333}$
- Tasa de falso descubrimiento → **FDR** = $\frac{FP}{FP+TP} = \frac{3}{3+10} = \frac{3}{13} = \mathbf{0,230769}$
- Tasa de falsa omisión → **FOR** = $\frac{FN}{FN+TN} = \frac{2}{2+33} = \frac{2}{35} = \mathbf{0,0571428}$

2.7 Requisitos de los rasgos biométricos

A la hora de seleccionar un rasgo o un grupo de rasgos para una aplicación biométrica, hay que tener en cuenta varios factores. Para ser considerado rasgo biométrico, este debe cumplir en mayor o menor medida las siguientes características [9, 17]:

- **Universalidad:** todos los individuos deben poseer ese rasgo.
- **Singularidad:** el rasgo debe ser lo suficientemente distinto entre individuos como para poder considerarse único.
- **Permanencia:** debe ser invariante durante el tiempo que viva el sujeto.
- **Cuantificable:** debe ser posible medir y digitalizar el rasgo, utilizando dispositivos que no causen molestias indebidas al individuo.
- **Rendimiento:** debe ser preciso en el reconocimiento y rápido computacionalmente.
- **Aceptabilidad:** el conjunto de usuarios susceptible de utilizar la aplicación deber aprobar el uso del rasgo biométrico.
- **Usurpación:** debe presentar gran resistencia frente a técnicas fraudulentas.

En resumen, para que un rasgo sea aceptado para su uso en una aplicación específica, este debe presentar una buena precisión en el reconocimiento junto a una buena eficiencia computacional; debe ser aceptado y entendido por los usuarios y demostrar una sólida resistencia a falsificaciones.

A continuación, se muestra una tabla con posibles rasgos biométricos, indicando su grado de adecuación a las características mencionadas más arriba. Este grado de adecuación se mide con los valores Alto (*high*), Medio (*medium*) y Bajo (*low*), representados con las letras H, M y L respectivamente [9].

Rasgo biométrico	Universalidad	Singularidad	Permanencia	Cuantificable	Rendimiento	Aceptabilidad	Usurpación
Huella dactilar	M	H	H	M	H	M	H
Rostro	H	L	M	H	L	H	L
Geometría de la mano	M	M	M	H	M	M	M
Frecuencia de tecleo	L	L	L	M	L	M	M
Venas de la mano	M	M	M	M	M	M	H
Iris	H	H	H	M	H	L	M
Escáner de retina	H	H	M	L	H	L	H
Firma	L	L	L	H	L	H	L
Voz	M	L	L	M	L	H	L
Termografía facial	H	H	L	H	M	H	H
Olor	H	H	H	L	L	M	L
ADN	H	H	H	L	H	L	L
Forma de andar	M	L	L	H	L	H	M
Canal auditivo	M	L	L	G	L	H	M
ECG	H	H	M	H	M	M	H

Tabla 6. Rasgos biométricos y grado de adecuación [9].

Podemos observar que aparecen rasgos tanto físicos como conductuales, y son estos primeros los que presentan un mayor grado de adecuación. Esto se debe a que los rasgos conductuales sufren una mayor variación con el paso del tiempo.

2.8 Sistemas multibiométricos

Los sistemas que dependen de varias fuentes de información biométrica para determinar de forma fiable la identidad de un individuo reciben el nombre de sistemas multibiométricos o multimodales. La finalidad de utilizar estos sistemas es atenuar las limitaciones presentes en sistemas que utilizan un solo rasgo biométrico (unibiométricos o unimodales). Los sistemas multibiométricos pueden ofrecer las siguientes ventajas frente a los unimodales [18]:

- Combinar los rasgos obtenidos de distintas fuentes, como el rostro, iris o huella dactilar, puede mejorar significativamente la precisión global del sistema.
- Pueden acabar con el problema de la no universalidad
- Pueden ofrecer cierto grado de flexibilidad en la autenticación, permitiendo al usuario elegir con qué rasgo quiere autenticarse en cada momento.
- La disponibilidad de múltiples fuentes de información reduce considerablemente el ruido en los datos obtenidos, es decir, aunque la muestra biométrica obtenida en una de las fuentes no tenga suficiente calidad, el resto de muestras van a seguir permitiendo una identificación fiable.
- Proporcionan una capacidad de búsqueda computacionalmente eficiente. Esto es posible si en primer lugar se realiza una búsqueda sencilla, aunque menos precisa, que depure la base de datos, para después utilizar una modalidad de búsqueda más compleja y precisa que permita la identificación final.
- Los sistemas multibiométricos son más resistentes ante ataques de falsificación. Además, pueden incorporar un mecanismo *challenge – response*, es decir, durante la adquisición biométrica se le impone al usuario cierto orden. Este mecanismo garantiza que el sistema está interactuando con un sujeto vivo y/o real.

Por otra parte, los sistemas multibiométricos pueden ser categorizados de la siguiente manera, en base a cómo utilizan las fuentes de datos [9]:

- ♦ **Sistemas multisensoriales:** utilizan múltiples sensores para adquirir los rasgos personales del mismo tipo.
- ♦ **Sistemas multi-instancia:** adquieren múltiples muestras del mismo rasgo cada vez que se ejecuta un proceso de inscripción, verificación o identificación.
- ♦ **Sistemas multi-muestra:** en este tipo de sistemas, cada vez que el usuario interactúa con la interfaz usuario-sistema, se recogen múltiples muestras del mismo rasgo, de forma que se obtiene información sobre posibles variaciones.

- ♦ **Sistemas multialgorítmicos:** hacen uso de los mismos rasgos muestreados para diferentes extractores de características, generando así diferentes patrones para un mismo rasgo.
- ♦ **Sistemas multimodales:** se adquieren varios tipos de rasgos para cada usuario. Con esto se consigue mejorar la fiabilidad del sistema.
- ♦ **Sistemas híbridos:** esta categoría incluye sistemas que incorporan dos o más de las técnicas mencionadas en este apartado.

2.9 Discusión

La biometría es la ciencia que identifica o autentica a individuos mediante la medida y cuantificación de sus rasgos biológicos, que pueden ser físicos o conductuales.

El concepto de biometría tiene su origen en la prehistoria, cuando se firmaban las pinturas de las cuevas con la huella de la mano; y más adelante, el Imperio de Babilonia usaba las huellas dactilares en transacciones comerciales. La biometría moderna se origina en el siglo XIX, cuando Alphonse Bertillon presentó un sistema de identificación de individuos basado en rasgos biométricos, denominado antropometría. Con el paso de los años, se realizaron múltiples estudios con el fin de agilizar estos sistemas o sustituirlos por otros mejores, además de incorporar nuevos rasgos biométricos que pudieran generar resultados óptimos. En la actualidad, los rasgos biométricos más utilizados son la huella dactilar, el rostro, la voz y el iris.

El ECG se ha convertido en un rasgo biométrico muy prometedor debido a su alta universalidad, singularidad, cuantificabilidad y resistencia a la usurpación, aunque aún presenta varios desafíos en términos de permanencia, rendimiento y estabilidad.

Un sistema biométrico consta de **sensores** que cuantifican el rasgo, un **extractor de características** que genera el *template*, una **base de datos** donde se almacenan los *templates* y un comparador biométrico o *pattern matching* en el que se identifica al sujeto. Finalmente, si se quiere dotar al sistema de mayor robustez y seguridad, se pueden combinar varios rasgos biométricos, lo que se conoce como **multibiometría**.

CAPÍTULO 3: SEÑALES BIOMÉDICAS

3.1 Introducción

La mayoría de las funciones del cuerpo humano están asociadas a señales eléctricas, químicas o acústicas. Estas señales contienen información que está oculta en su estructura, por lo que es necesario realizar un tratamiento de las mismas para poder extraer la información. Estas señales son conocidas como **señales biomédicas** y reflejan las propiedades de los sistemas fisiológicos de los que provienen, por lo que han resultado muy útiles a la hora de explicar e identificar patologías de múltiples enfermedades [20].

La complejidad de una señal de estas características es considerable, por lo que el procesado de señales biomédicas es indispensable para extraer información clínica con un significado claro. Los progresos en el procesado de señales biomédicas se han hecho, principalmente, gracias al análisis **unimodal**, es decir, de un solo tipo de señal o rasgo. Sin embargo, la tendencia actual es utilizar el análisis **multimodal**. Este último explica con más detalle cómo los diferentes subsistemas fisiológicos interactúan entre ellos; por ejemplo, la presión arterial y la frecuencia cardiaca en el sistema cardiovascular. Estudiar la información conjunta de ambas señales ayudará a conseguir un mejor diagnóstico y una mejor toma de decisiones [20].

3.1.1 Objetivos

Históricamente, las señales biomédicas se analizaban visualmente, de forma que se obtenían unos resultados bastante pobres que podían desembocar en diagnósticos erróneos. Por ello, uno de los objetivos fundamentales del procesado de señales biomédicas es reducir o **acabar con la subjetividad de las medidas**. Con la aparición de los primeros ordenadores surgieron métodos de cuantificación que mejoraban la precisión de la toma de medidas. En relación con este primer objetivo, se persigue desarrollar métodos capaces de **extraer características** que ayuden a interpretar y comprender la información contenida en las señales, además de extraer información que no se obtiene fácilmente mediante una evaluación visual [20].

En muchas ocasiones, la señal tomada puede estar alterada por diferentes tipos de ruido o interferencias, que incluso pueden ser causadas por otros procesos fisiológicos del cuerpo. Por ello, la **reducción de ruido** representa un objetivo vital en el procesado de señales biomédicas [20].

Para algunos procedimientos de diagnóstico es necesario que la señal se grabe durante un largo periodo de tiempo. Estas grabaciones requieren mucho espacio de almacenamiento, por lo que la **compresión** de la señal digitalizada es esencial. Sin embargo, no es posible comprimir la señal sin más, ya que se pueden producir pérdidas de información importante; por ello, aplicar un algoritmo de compresión adecuado suele ser una tarea crítica [20].

Finalmente, la **simulación** y el **modelado** matemático de una señal biomédica es otro de los objetivos que se persiguen, ya que ayuda a entender el proceso fisiológico que sustenta a esa señal. Con las ecuaciones adecuadas sería posible simular señales que se asemejen a la original, tanto a nivel celular como a nivel del tejido. La complejidad de estos modelos depende siempre del problema que se quiera resolver, pero, afortunadamente, en la mayoría de los casos no es necesario desarrollar un modelo multinivel que abarque desde un nivel celular hasta un nivel de propagación de la corriente sobre el tejido u otro tipo de propiedad biológica [20].

3.1.2 Contexto

Los contextos clínicos más relevantes en los que se diseñan algoritmos de procesamiento de señales biomédicas son **diagnóstico**, **terapia** y **monitorización** [20]. En los últimos años ha surgido un nuevo propósito: **biometría**.

- **Diagnóstico:** las decisiones médicas se toman gracias a la extracción significativa de información de las señales biomédicas. Estas señales reflejan las funciones de órganos como el cerebro o el corazón, junto con las patologías que pueda tener el paciente. Generalmente, estas señales se obtienen con técnicas no invasivas, con lo que el impacto causado en el sujeto es menor. Por otra parte, muchos de los procedimientos de análisis y diagnóstico se pueden realizar con tecnologías de bajo coste, y no necesitan un resultado inmediato. Esto permite que el análisis pueda llevarse a cabo *off-line*, desde un ordenador personal, añadiendo un *Digital Signal Processor* (DSP) para mejorar la eficiencia, si fuese necesario.
- **Terapia:** se define como el tratamiento de una enfermedad que puede incluir la toma de medicamentos o una cirugía. En este caso, se hace uso de estos algoritmos en dispositivos que modifican el comportamiento de procesos fisiológicos, como hacen los marcapasos con la actividad cardiaca. A diferencia del contexto de diagnóstico, estos dispositivos deben trabajar en tiempo real y tener un bajo consumo de energía, lo que implica que los algoritmos deban ser eficientes a nivel computacional.
- **Monitorización:** los sistemas de monitorización están diseñados para detectar cambios en las funciones cardiacas y neuronales, y predecir peligros de muerte en pacientes graves. La señal se procesa durante la monitorización de manera secuencial, de modo que las muestras en instantes anteriores son la base para tomar una decisión. Además, deben operar muy rápidamente para que una posible anomalía pueda ser atendida en el menor tiempo posible.
- **Biometría:** al igual que en casos anteriores, el retardo en los algoritmos de procesamiento debe ser pequeño, para poder identificar a los sujetos de forma rápida. El diseño de filtros para el procesamiento de estas señales cumple un papel importante, ya que eliminan el posible ruido que contienen las señales. La elección del tipo de filtro adecuado implica un mejor rendimiento del sistema y una mejor clasificación de sujetos.

3.2 Clasificación

Las señales biomédicas se pueden clasificar atendiendo a varios criterios: el origen del proceso fisiológico, la naturaleza de la señal o las características que presentan. En este caso, se van a estudiar las diferentes señales existentes en función de los procesos fisiológicos que generan las señales [21].

- ♦ **Señales biomecánicas:** extraen información sobre los procesos mecánicos del sistema biológico, e incluyen señales de movimiento y desplazamiento, de presión y tensión o de flujo, entre otras. La *Figura 6* muestra la medida de la presión arterial, que permite detectar patologías como la hipertensión.

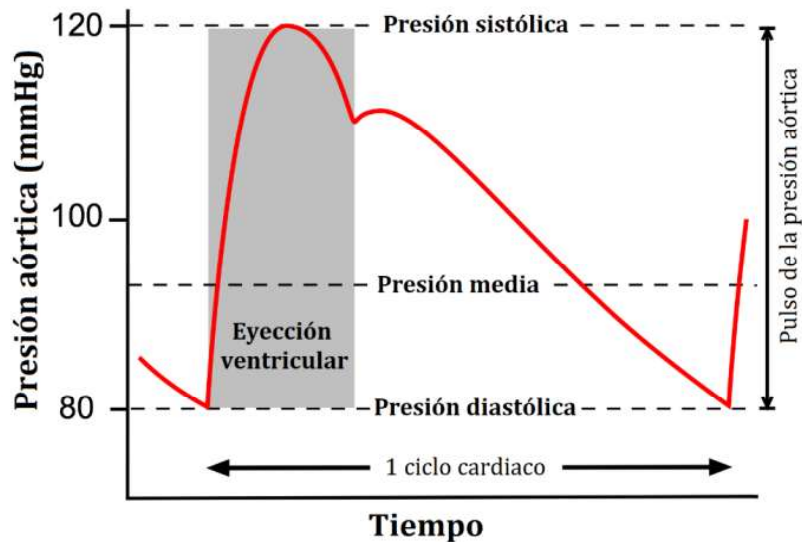


Figura 6. Ejemplo de señal biomecánica, modificada a partir de [22].

- ♦ **Señales bioacústicas:** derivan de las señales biomecánicas, y en ellas se miden aquellos procesos que producen vibraciones. Las principales señales bioacústicas existentes son las que proceden del corazón o del sistema respiratorio, pero también podemos encontrarlas en el aparato digestivo, las articulaciones o los músculos. En la *Figura 7* se muestra un fonocardiograma, el cual recoge las vibraciones producidas por la apertura y cierre de las válvulas del corazón, y puede revelar información sobre cardiopatías.




Figura 7. Ejemplo de una señal bioacústica, modificada a partir de [23].

- ♦ **Señales bioquímicas:** recogen información sobre los componentes químicos presentes en los órganos o tejidos vivos. Estas señales ayudan a conocer el nivel de componentes como el oxígeno o la glucosa en sangre.
- ♦ **Señales biomagnéticas:** miden los campos magnéticos producidos por órganos como el cerebro, el corazón o los pulmones. La *Figura 8* muestra una magnetocardiografía, en la que se pueden evaluar los campos magnéticos generados por la actividad eléctrica del corazón.




Figura 8. Ejemplo de señal biomagnética [24].

- ♦ **Señales de bioimpedancia:** revelan las propiedades eléctricas de un tejido al aplicarle una pequeña corriente. Mediante la impedancia medida se pueden determinar biomarcadores como el volumen sanguíneo o la cantidad de masa corporal libre de grasa.
- ♦ **Señales bioeléctricas:** recogen los campos eléctricos generados en procesos fisiológicos como la contracción muscular, el latido del corazón o la actividad cerebral. Las señales que se van a analizar y procesar en este proyecto pertenecen a este grupo, por lo que se van a describir con mayor profundidad en la siguiente sección.

3.3 Señales bioeléctricas

3.3.1 Potenciales de Acción

Las señales bioeléctricas se generan como resultado de cambios electroquímicos que tienen lugar en un grupo especial de células que tienen la propiedad de **excitabilidad** [20]. Cuando estas células se estimulan con una corriente que excede un umbral determinado se genera un **potencial de acción**, el cual se propaga por las células colindantes. Cuando el estímulo no alcanza el umbral, la célula se queda en estado de reposo. El potencial de acción permite la propagación de la actividad eléctrica generada a través del tejido. Este proceso ocurre de forma similar en los distintos tipos de células excitables (células del corazón, músculos o cerebro).




Figura 9. Potencial de acción y etapas en las que se divide [56].

Si atendemos a la *Figura 9*, podemos distinguir las siguientes etapas del potencial de acción [57]:

- **Reposo:** estado de inactividad en el que se encuentra la célula anterior y posteriormente a la generación del potencial de acción.
- **Estímulo:** la célula se excita con una corriente, si el nivel de esta supera el umbral se genera el potencial de acción. En caso de no superar el umbral, la célula permanece en reposo; a esta situación se le denomina “inicios fallidos”.
- **Despolarización:** el potencial de la membrana pasa de negativo (reposo) a positivo, alcanzando un máximo.
- **Repolarización:** una vez alcanzado el pico del potencial de acción, la célula vuelve al estado de reposo; pasando de un potencial positivo a negativo.
- **Periodo refractario:** periodo de tiempo durante el que la célula excitable no es capaz de producir otro potencial de acción.

La amplitud máxima que alcanza el potencial de acción se rige por el **principio de “todo o nada”** [20]. Según este principio, es indiferente el nivel de corriente con el que el estímulo recibido supera el umbral, ya que, una vez es alcanzado, el potencial de acción llegará a la misma amplitud máxima en todos los casos.

Sin embargo, la **duración del potencial de acción** varía en función del tipo de célula analizada. Como podemos ver en la *Figura 10*, el conjunto de fases que constituyen el potencial de acción puede durar desde 2 milisegundos en las células cerebrales (también conocidas como neuronas motoras) hasta 200 milisegundos en las células cardiacas, pasando por 5 milisegundos en las células musculares (también llamadas esqueléticas).




Figura 10. Amplitud y duración de los potenciales de acción para los diferentes tipos de células (motoras, esqueléticas y cardiacas). Imagen modificada a partir de [20].

3.3.2 Clases de Señales Bioeléctricas

Una vez analizado el origen de las señales bioeléctricas, podemos estudiar los criterios de clasificación. Existen diferentes señales en función del evento que pretenden medir, si la actividad recogida es espontánea o responde a un estímulo externo, o si la técnica de obtención utilizada es invasiva para el paciente o no. En función de las técnicas actuales, se distinguen las siguientes señales [20]:

- ♦ **Electroencefalograma (EEG):** recoge la actividad eléctrica generada por los procesos fisiológicos que tienen lugar en el cerebro. Es una técnica no invasiva en la que se registra la señal mediante la disposición de distintos electrodos en el cuero cabelludo. Esta señal ayuda a evaluar trastornos del sueño o enfermedades cerebrales como la epilepsia. Por otra parte, la señal también puede recogerse de forma invasiva durante una intervención quirúrgica, colocando los electrodos directamente sobre la superficie del cerebro. La señal grabada de esta forma se conoce como **electrocorticograma (ECoG)**. La *Figura 11* muestra la disposición típica de los electrodos para obtener el EEG de forma no invasiva.




Figura 11. Disposición común de los electrodos para la medición del EEG [58].

- ♦ **Electrocardiograma (ECG):** recoge la actividad eléctrica del corazón y se obtiene de forma no invasiva colocando electrodos en el pecho, brazos y piernas. Esta señal ayuda a detectar enfermedades cardiovasculares como el infarto de miocardio. Al igual que en el caso anterior, existe una técnica de medición invasiva por la que se obtiene la señal denominada **electrograma (EGM)**. Con esta técnica, se colocan electrodos dentro del corazón, y es usada en dispositivos implantables como los marcapasos. En la *Figura 12* puede verse una disposición de electrodos estándar para obtener el ECG de forma no invasiva, y la señal que se obtendría en condiciones normales.




Figura 12. Izquierda: disposición de electrodos según el estándar de 12 derivaciones [25]. Derecha: Electrocardiograma obtenido en condiciones normales [25].

- ♦ **Electrooculograma (EOG):** recoge la actividad eléctrica generada en la retina ante los movimientos verticales y horizontales que realiza el ojo. Generalmente, se utiliza una técnica no invasiva que emplea cinco electrodos: uno encima del ojo y otro debajo para medir movimientos verticales, así como otros dos a la izquierda y a la derecha para medir movimientos horizontales, y un último electrodo de referencia en la frente; tal y como se muestra en la *Figura 13*. El estudio de esta señal permite detectar patologías oculares asociadas a la retina, y también es usada en el desarrollo de interfaces cerebro-ordenador.




Figura 13. Izquierda: Disposición de electrodos para obtener el electrooculograma [26]. Derecha: señal electrooculográfica para detección de movimientos verticales. Imagen modificada a partir de [27].

- ♦ **Electrogastrograma (EGG):** recoge la actividad eléctrica producida por la contracción de los músculos estomacales. Utiliza una técnica no invasiva, colocando electrodos sobre el estómago del paciente. Permite detectar patologías que provocan un mal funcionamiento del sistema digestivo.




Figura 14. *Izquierda:* disposición de electrodos para obtener el electrogastrograma [28].
Derecha: evolución de una señal electrogástrica en una simulación de conducción [29].

- ♦ **Electromiograma (EMG):** recoge la actividad eléctrica generada por los músculos esqueléticos al realizar movimientos y sirve para detectar anomalías en la actividad muscular como distrofia muscular, inflamación de los músculos o lesiones en terminaciones nerviosas de brazos y piernas. La señal puede obtenerse de dos formas: mediante una técnica no invasiva (uso de electrodos de superficie) o a través de una técnica invasiva (uso de electrodos de aguja que entran en contacto directo con el músculo).




Figura 15. *Izquierda:* toma electromiográfica de aguja³¹.
Derecha: funcionamiento simplificado de la electromiografía de superficie [30].

3.3.3 Ruido e Interferencias

Pese a la evolución tecnológica de los equipos de medida de estas señales, incrementando la calidad y precisión de las señales adquiridas, estas siguen viéndose afectadas por diferentes fuentes de interferencias, tanto internas como externas al propio sistema biológico. Aunque cada señal bioeléctrica se ve afectada por interferencias diferentes, las fuentes de ruido más comunes son las siguientes [20]:

- **Interferencia de la red eléctrica:** los dispositivos electrónicos que se encuentran en funcionamiento en la misma sala donde se realizan las medidas, o incluso la propia conexión del instrumento a la red eléctrica, producen contaminación en la señal.

³¹ <https://chsalud.es/blog/electromiograma/que-es-un-electromiograma/>


- **Interferencia de otra señal bioeléctrica:** las señales pueden verse contaminadas si se toman en una zona en la que conviven diferentes señales bioeléctricas. Por ejemplo, la mayor interferencia del electroencefalograma es la señal electrooculográfica provocada por el movimiento ocular del sujeto, especialmente en el lóbulo frontal.
- **Movimiento de los electrodos:** un mal contacto entre el electrodo y la piel genera ruido en la señal adquirida, e incluso la pérdida completa de la señal si se produce una desconexión momentánea de ambos.

3.4 Electrocardiograma

Para evaluar adecuadamente las señales procesadas en el proyecto, en esta sección se analiza el origen de los impulsos eléctricos que generan el electrocardiograma, las técnicas existentes para su adquisición y los principales artefactos que interfieren en sus medidas.

3.4.1 Anatomía y fisiología del corazón

El corazón es un músculo cuya función principal es bombear sangre rica en oxígeno a todo el cuerpo. Una pared muscular, denominada septo, lo divide en dos secciones simétricas, izquierda y derecha, las cuales bombean la sangre de forma sincronizada y rítmica. Cada lado del corazón, a su vez, está dividido en dos secciones: aurícula, donde entra la sangre procedente del resto del cuerpo, y ventrículo, donde la sangre sale del corazón para continuar su circulación. La dirección del flujo sanguíneo está controlada por cuatro válvulas diferentes, situadas entre las aurículas y los ventrículos y entre los ventrículos y las arterias [20]. La *Figura 16* muestra la disposición de las partes de corazón mencionadas.



*Figura 16. Partes del corazón*³².

El tejido muscular que rodea el corazón se denomina **miocardio** y está principalmente compuesto por células musculares que reaccionan a impulsos eléctricos, siendo capaces de producir la fuerza mecánica necesaria para llevar a cabo la contracción del corazón, dando así lugar al ciclo cardiaco.

³² <https://es.wikipedia.org/wiki/Cardiolog%C3%ADa>

Cada ciclo cardiaco puede ser dividido en dos fases: **despolarización** y **repolarización**, desde el punto de vista eléctrico, o **contracción** y **relajación**, desde el punto de vista mecánico. La despolarización se genera al activarse los potenciales de acción, y la repolarización ocurre inmediatamente después, de forma que las células vuelven a su estado de reposo inicial y el ciclo vuelve a empezar [20].

La señal resultante en cada ciclo (latido) estaría formada por cinco deflexiones reconocibles: las ondas **P**, **Q**, **R**, **S** y **T**. En la *Figura 17* pueden verse las fases del ciclo cardiaco y las deflexiones comentadas.




Figura 17. Ciclo cardiaco [25].

3.4.2 Actividad eléctrica del corazón

El ciclo cardiaco se inicia gracias a un conjunto de células que tienen la capacidad de generar impulsos eléctricos. Este conjunto de células forman el denominado nodo sinoatrial o sinoauricular (nodo SA), que está situado en la parte superior de la aurícula derecha. El impulso eléctrico se propaga a través del sistema de conducción, provocando la contracción y relajación auricular y ventricular. Cuando las aurículas se han vaciado de sangre completamente, el nodo auriculoventricular (nodo AV) propaga la señal provocada por el nodo SA a través del haz de His (grupo de fibras que comunican aurícula y ventrículo). Este haz se ramifica hacia los ventrículos derecho e izquierdo, propagando el impulso hasta llegar a las fibras de Purkinje. El tamaño que tienen los ventrículos requiere un impulso eléctrico más rápido para iniciar la contracción simultánea. La velocidad de propagación de los impulsos eléctricos dentro del corazón varía desde 0.05 m/s en el nodo AV, hasta 4 m/s en las fibras de Purkinje [20]. En la *Figura 18* muestra la propagación de los impulsos eléctricos a través del miocardio.




Figura 18. Propagación de impulsos eléctricos a través del miocardio [31].

3.4.3 Principales ondas y segmentos del ECG

La señal ECG está formada por el siguiente conjunto de formas de onda: **onda P**, **complejo QRS** y la **onda T** [20, 32]:

- ♦ La **onda P** describe la despolarización auricular. La amplitud de esta onda es positiva y relativamente pequeña ($<300 \mu\text{V}$), tiene una duración típica de 120 ms y las componentes espectrales son de baja frecuencia (10 – 15 Hz). Si la onda P no apareciera, puede indicar que el ritmo cardiaco tiene su origen en los ventrículos; y si tuviera componentes en frecuencias muy altas, podría indicar una arritmia de origen atrial.
- ♦ El **complejo QRS** representa la despolarización ventricular, y varía en función del lugar donde se origina el latido. Tiene una duración de 70 – 110 ms y, debido a las pendientes pronunciadas que delinean el conjunto, suele tener componentes espectrales de alta frecuencia (10 – 40 Hz). La primera deflexión (**onda Q**) es negativa, la siguiente (**onda R**) positiva, y la última de ellas (**onda S**) negativa de nuevo.
- ♦ El **segmento PR** representa la diferencia de tiempo entre la activación auricular y ventricular. Abarca desde el final de la onda P hasta el inicio del complejo QRS y es isoelectrico (esto es, se corresponde con un valor constante de voltaje).
- ♦ La **onda T** describe la repolarización ventricular. Su amplitud es menor que la del complejo QRS y, por lo general, aparece 300 ms después de este. La posición de la onda depende del ritmo cardiaco: cuanto más rápido sea, más cerca estará del complejo QRS.
- ♦ El **segmento ST** representa el tiempo que los ventrículos están en estado de despolarización. Abarca desde el final del complejo QRS hasta el inicio de la onda T y es isoelectrico.

Mientras que los segmentos electrocardiográficos unen unas ondas con otras, sin incluir ninguna de ellas, un intervalo está formado por un segmento y una o más ondas. En el ECG podemos encontrar los siguientes [32]:

- ♦ El **intervalo R-R** se mide desde el pico de una onda R hasta el pico de la onda R siguiente y determina la frecuencia ventricular.
- ♦ El **intervalo P-P** es la medida entre dos ondas P sucesivas, tomada desde el punto más elevado de ambas. Determina la frecuencia auricular y, en condiciones normales, debería coincidir con la frecuencia ventricular.
- ♦ El **intervalo PR** abarca desde el comienzo de la onda P hasta el final del complejo QRS, y mide el tiempo de conducción auriculo-ventricular. Este intervalo aumenta con la edad y disminuye con la frecuencia cardíaca.
- ♦ El **intervalo QT** abarca desde el comienzo del complejo QRS hasta el final de la onda T, y mide el tiempo que pasa entre la despolarización y la repolarización ventricular. Su medida depende directamente de la frecuencia cardíaca.

3.4.4 Artefactos y ruido en el ECG

Gracias al gran conocimiento de las propiedades de las señales bioeléctricas, su ruido y artefactos, es posible mejorar la calidad de las señales grabadas con ayuda de algoritmos de procesado. A continuación, se describen los principales artefactos y fuentes de ruido presentes en el electrocardiograma [20]:

- ♦ **Baseline wander (bw) o fluctuaciones en la línea de base:** esta interferencia añade componentes a baja frecuencia e interfiere con el análisis de la señal. La fuente suele ser la respiración del sujeto, movimientos del cuerpo o un mal contacto de los electrodos con la piel. La magnitud del bw puede llegar a ser mucho mayor que la del complejo QRS. Su contenido espectral está muy por debajo de 1 Hz pero, en ocasiones, puede contener frecuencias más altas. La solución para suprimir este artefacto es un **filtro paso alto** con una frecuencia de corte $f_c < 0.5$ Hz.
- ♦ **Powerline interference (pw) o interferencia de la línea eléctrica:** se produce por el acoplamiento de la red eléctrica y tiene componentes espectrales de gran amplitud en 50 o 60 Hz. Suele afectar a los algoritmos de detección del complejo QRS y es posible eliminarla mediante el uso de un **filtro de banda eliminada** o **filtro notch**. Sin embargo, un filtro notch muy estrecho causa pequeñas oscilaciones en el transitorio (**ringing**). Para solucionarlo, a veces se recurre a técnicas de **filtrado no lineal** o **estimación-substracción**.
- ♦ **Electrode motion artifacts (em) o artefactos producidos por el movimiento de los electrodos:** la principal causa es el cambio de impedancia de la piel alrededor del electrodo al producirse el roce entre ambos. Tiene las mismas características que el *baseline wander* pero es más difícil de eliminar, ya que su contenido espectral (rango 1 – 10 Hz) se superpone con el de la señal ECG (complejo P-QRS-T). Este artefacto debe ser considerado en procesos de monitorización del ECG, ya que puede causar un análisis erróneo de la señal. Una posible solución sería el uso de un **filtro**

paso bajo de respuesta en frecuencia variable. Este tipo de filtros están diseñados para permitir el paso de frecuencias bajas mientras atenúa las frecuencias altas, con la característica especial de que su frecuencia de corte puede variar en función del tiempo o de ciertas condiciones, adaptándose dinámicamente a las características de la señal o a las necesidades específicas del procesamiento de la señal en un momento dado [59].

- ♦ **Electromyographic noise (EMG noise) o ruido electromiográfico:** se produce por la actividad eléctrica de los músculos al contraerse. Aparece en procesos de monitorización de ECGs durante largos periodos de tiempo y es causado por el propio sujeto, ya que puede realizar movimientos voluntarios o involuntarios. Las componentes espectrales se solapan con las del complejo QRS y van hasta frecuencias más altas. Una de las soluciones posibles, al igual que en el caso anterior (em), sería el uso de un filtro paso bajo de frecuencia variable.
- ♦ **Lead reversal:** una disposición de los electrodos incorrecta provoca errores en la medida de los potenciales, de forma que se produce una inversión en la amplitud de algunas formas de onda.
- ♦ **Interferencia de marcapasos:** las señales de los marcapasos pueden grabarse en conjunto con el ECG, por lo que podrían aparecer formas de onda extrañas como picos cortos antes de la onda S.

La *Tabla 7* muestra un resumen de los principales artefactos presentes en el ECG:

	<i>Baseline wander</i>	<i>Powerline interference</i>	<i>Electrode motion artifacts</i>	<i>EMG noise</i>
Contenido espectral	< 1 Hz	50/60 Hz	1 – 10 Hz	40 – 250 Hz
Causa	Respiración, movimientos o mal contacto	Acoplamiento de la red eléctrica	Cambio de impedancia de la piel	Actividad eléctrica en la contracción muscular
Consecuencia	Fluctuaciones de baja frecuencia en el ECG	Dificultad en la detección del QRS	Falsa detección del complejo QRS	Falsa detección del complejo QRS
Solución	Filtro paso alto	Filtro Notch/técnicas de filtrado no lineal	Filtro paso bajo de frecuencia variable	Filtro paso bajo de frecuencia variable

Tabla 7. Principales artefactos presentes en el ECG.

BIOMETRÍA BASADA EN ECG

A continuación, la *Figura 19* muestra las distintas señales electrocardiográficas. La primera de ellas está libre de ruido y las demás están contaminadas por alguno de los artefactos mencionados:




Figura 19. Artefactos comunes en el ECG: a) señal limpia, b) baseline wander, c) powerline interference, d) electromyographic noise [33].

3.5 Discusión

Las señales biomédicas son aquellas que se generan en el interior del cuerpo y contienen información acerca del estado y funcionamiento de los **sistemas fisiológicos**. En la mayoría de los casos, esta información se encuentra oculta y es necesario extraerla mediante **técnicas de procesamiento de señales**, las cuales han ido evolucionando con el paso de los años, pero siguen necesitando mejorar sus características. Algunos de los objetivos de mejora que se persiguen son la **reducción de ruido**, la **disminución de errores** en las medidas o la **compresión** de la señal digitalizada, entre otros.

Por otra parte, existen diversas bioseñales en función del órgano o tejido que se pretenda estudiar, pudiendo distinguirse entre aquellas que poseen naturaleza química, mecánica o eléctrica (siendo este último grupo en el que se realiza el estudio detallado). Para ello, es necesario caracterizar el origen del impulso eléctrico a nivel celular mediante la definición del potencial de acción, su propagación a través del tejido y los diferentes tipos de señales bioeléctricas existentes en función del órgano donde son generadas.

El ECG, EEG o EMG son señales eléctricas que reflejan la actividad eléctrica del corazón, el cerebro y los músculos, respectivamente. La señal de ECG es una repetición cíclica de cinco ondas: **P, Q, R, S y T**, comúnmente conocido como latido. Estas deflexiones son causadas por las fases del ciclo cardiaco: **despolarización** y **repolarización**.

Además, la identificación y el tratamiento de las interferencias y ruidos presentes en las señales biomédicas, como el *baseline wander* (causado por la respiración del sujeto) o el *powerline interference* (causado por la línea eléctrica), es esencial para garantizar la calidad y precisión de los datos obtenidos. El conocimiento de los artefactos comunes y su mitigación mediante filtros adecuados es fundamental para el análisis correcto de las señales.

En resumen, el estudio de las señales biomédicas implica una combinación de técnicas de procesamiento de señales y un profundo entendimiento de la fisiología del cuerpo humano. La mejora continua en estas áreas permitirá avances significativos en la identificación y tratamiento de diversas patologías mediante el análisis de señales bioeléctricas.

CAPÍTULO 4: BIOMETRÍA BASADA EN ECG

4.1 Justificación

La biometría es la ciencia que establece la identidad de un individuo basándose en rasgos físicos o conductuales del mismo. Su importancia en la sociedad se ha incrementado en gran medida, ya que la mayoría de los servicios que utilizamos en nuestro día a día requieren sistemas de identificación o autenticación robustos y precisos para protegernos a nosotros y nuestra información. Gran parte de estos servicios aún se apoyan en sistemas de reconocimiento tradicionales, basados en características extrínsecas como las tarjetas de identificación o contraseñas, que pueden ser olvidadas, perderse, robarse o copiarse con facilidad. Es por ello que la biometría surge como solución a estos problemas, ya que se basa en características intrínsecas de los individuos, como la huella dactilar o el iris. Además, pueden complementarse con tarjetas o claves, por ejemplo, para obtener sistemas más robustos conocidos como sistemas multibiométricos (multibiometría) [25, 34].

La biometría ofrece algunas ventajas adicionales como el reconocimiento negativo y el no repudio. El reconocimiento negativo es un proceso por el que el sistema determina que cierto individuo está en la base de datos del sistema, aunque este pueda negarlo. El no repudio impide que un usuario niegue haber accedido a un determinado servicio [34].

Aun con los avances tecnológicos de estos sistemas, siguen apareciendo nuevas dificultades y vulnerabilidades. A continuación, se va a hablar de algunas de ellas:

Respecto a los sistemas biométricos basados en **huella dactilar**, uno de los rasgos biométricos más utilizados en la actualidad debido a su gran rendimiento y exactitud, los investigadores han demostrado que existe una gran vulnerabilidad de ataques con diccionarios de huellas digitales sintéticas, capaces de reproducir artificialmente una huella digital mediante algoritmos de Aprendizaje Profundo [35].

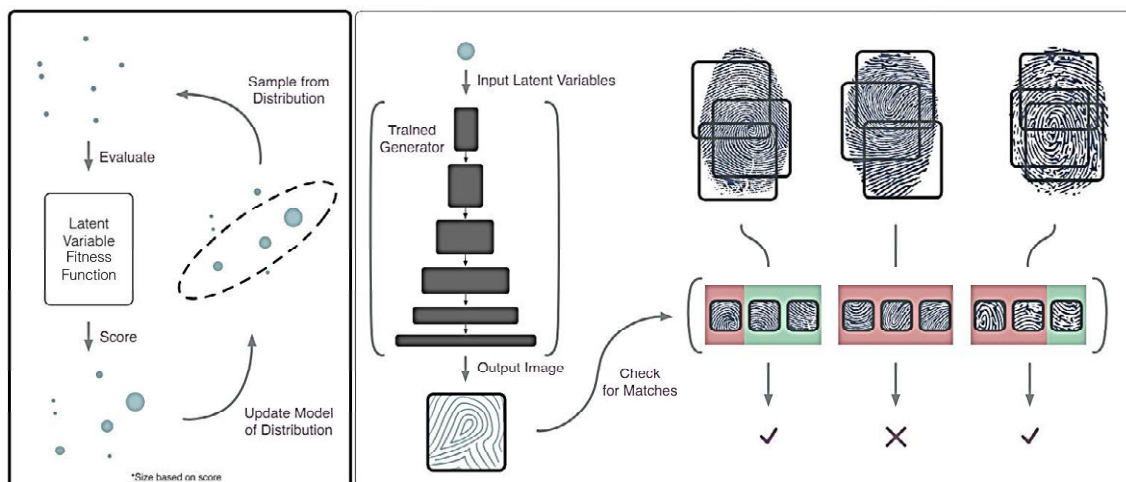


Figura 20. Algoritmo basado en la evolución de variables latentes con una red entrenada [35].

En el caso del **iris**, es posible la falsificación mediante el uso de lentes de contacto con los rasgos impresos, aunque se han desarrollado algoritmos robustos para su detección [36].

El **reconocimiento facial** carga con el reto de desarrollar técnicas que sean capaces de reconocer rostros pese al envejecimiento, distintas expresiones faciales, luz ambiental, accesorios o incluso distinguir entre gemelos [37].

Finalmente, la **voz** es una característica invariante en los individuos, pero hay una parte conductual que puede cambiar debido a enfermedades, el estado emocional o el ruido de fondo. Actualmente, se ha convertido en un rasgo muy vulnerable a la suplantación o falsificación de identidad, ya que se han conseguido crear algoritmos de *machine learning* capaces de sintetizar voces con gran calidad [38].

Todo esto ha llevado a investigar alternativas de rasgos biométricos que sean más robustos, entre los cuales han destacado los llamados **rasgos biométricos médicos**. Dentro de este grupo, el ECG ha resultado ser el más prometedor, ya que su naturaleza oculta hace casi imposible su falsificación y su inherente medida de vida (presencia sólo en sujetos vivos) asegura que el sistema no está siendo atacado. El único inconveniente que presenta es la variabilidad a lo largo del tiempo y la presencia de artefactos [25].

La *Tabla 8* muestra un resumen de las ventajas e inconvenientes de algunos de los principales rasgos biométricos.

Rasgo biométrico	Ventajas	Inconvenientes
Electrocardiograma (ECG)	Universalidad Naturaleza oculta Adquisición simple	Requiere contacto Variabilidad con el tiempo
Electroencefalograma (EEG)	Universalidad Naturaleza oculta	Equipos de medida caros Vulnerable al ruido Variabilidad con el tiempo
Huella dactilar	Alto rendimiento Permanente en el tiempo	Requiere contacto
Iris	Alto rendimiento	Equipos de medida caros
Rostro	Fácil de medir Equipos de medida asequibles	Falsificación fácil Depende de la visibilidad y luz ambiental Carga computacional alta
Voz	Equipos de medida asequibles	Bajo rendimiento
Forma de andar	Fácil de medir Equipos de medida asequibles	Bajo rendimiento Variabilidad con el tiempo
Palma de la mano	Fácil de medir Permanente en el tiempo	Requiere contacto
Fotopleletismograma (PPG)	Fácil de medir Naturaleza oculta Equipos de medida asequibles	Bajo rendimiento Variabilidad con el tiempo

Tabla 8. Ventajas e inconvenientes de varios rasgos biométricos [25].

4.2 Variabilidad de la señal *intra-sujeto* e *inter-sujeto*

La señal de ECG, en condiciones normales, está formada por una onda P, un complejo QRS y una onda T; y es así para todos los sujetos en cualquier instante de tiempo, pero con un alto grado de variabilidad. Esta variabilidad de señal se divide en dos tipos: ***intra-subject*** (en el sujeto) representa la variación entre latidos de un mismo sujeto y se explora en el contexto de la monitorización y diagnóstico médico, o ***inter-subject*** (entre sujetos) determina las variaciones entre latidos de diferentes sujetos y es especialmente útil para discriminar entre usuarios de un sistema biométrico. Ambas variabilidades pueden originarse por varios factores, de los cuales, los más destacados son los siguientes [25]:

- **Geometría del corazón:** el tamaño o forma del corazón o el grosor del miocardio determinan los caminos a seguir por la corriente eléctrica dentro del mismo, la cantidad de células musculares que se despolarizan y el tiempo que conlleva. Por ejemplo, los atletas suelen tener corazones más grandes y un miocardio más grueso, debido a sus altos entrenamientos físicos, lo que produce un latido cardiaco de mayor amplitud y, por tanto, frecuencias cardiacas más bajas.
- **Atributos intrínsecos:** la edad, el peso o el embarazo son algunas características individuales que producen cambios en la posición y/u orientación del corazón. Este desplazamiento cambia los vectores de conducción de la corriente eléctrica, implicando, por tanto, que los electrodos detecten la señal desde una perspectiva diferente y el ECG se vea alterado.
- **Ejercicio físico o meditación:** la duración y los intervalos de las ondas que forman el ECG varían con la frecuencia cardiaca. Estos cambios se ven especialmente reflejados entre el complejo QRS y la onda T en situaciones de taquicardia (ritmo cardiaco más alto) o bradicardia (ritmo cardiaco más bajo), ya que el incremento de frecuencia produce un acercamiento de la onda T hacia el complejo QRS.
- **Patologías:** las condiciones médicas del corazón, como desórdenes congénitos o alteraciones genéticas, interfieren en la propagación del impulso eléctrico y generan variabilidad. Una de las afecciones más estudiadas en la biometría es la arritmia, ya que causa grandes variaciones en la frecuencia cardiaca y puede reducir el rendimiento de los sistemas biométricos basados en ECG.
- **Postura:** la posición y forma de los órganos internos difiere mucho en función de la postura que adopte el individuo (en pie, acostado, sentado...). Por tanto, el corazón puede cambiar su posición de referencia con respecto al electrodo, causando variaciones en la señal ECG medida.
- **Emociones o fatiga:** los sistemas simpático y parasimpático del sistema nervioso trabajan variando el ritmo cardiaco, y están bajo la influencia directa de los estados psicológicos. Por tanto, el ECG se puede ver modificado por el estrés, miedo u otras emociones fuertes, o por la fatiga y somnolencia.
- **Características y disposición de electrodos:** el tipo, tamaño y número de electrodos, además de su disposición en el cuerpo, pueden influir en el predominio del ruido de la señal.

BIOMETRÍA BASADA EN ECG

Los dos primeros factores mencionados afectan principalmente a la variabilidad *inter-subject* y apoyan el uso de la señal ECG como rasgo biométrico, mientras que los demás originan variabilidad *intra-subject* y deterioran el uso del ECG para el mismo propósito. Por tanto, a la hora de adquirir el ECG, ya sea para fines médicos o biométricos, es de suma importancia tener en cuenta todos los factores y la forma en que pueden facilitar o dificultar su propósito.

A continuación, se muestran unas imágenes que reflejan la toma de la señal ECG con variabilidad *intra-subject* e *inter-subject*:




Figura 21. Variabilidad *intra-subject*.

En la *Figura 21* se observan las diferencias de los mismos ciclos cardiacos de un sujeto, pero grabados con distintos electrodos, por tanto, se observa la variabilidad *intra-subject*. En cambio, en la *Figura 22* se muestran las diferencias de los ciclos cardiacos de dos sujetos distintos, grabados con el mismo canal, es decir, la variabilidad *inter-subject*.

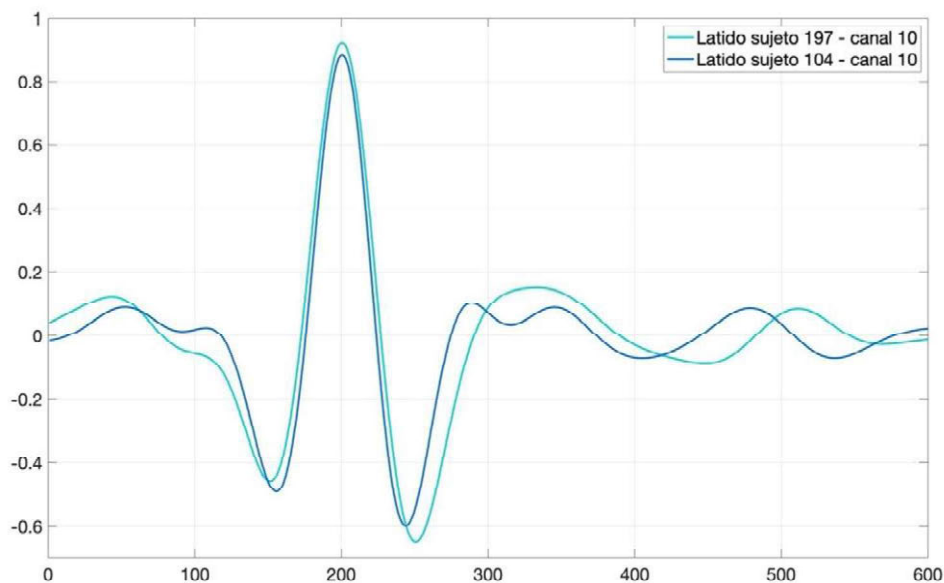


Figura 22. Variabilidad *inter-subject*.

4.3 Adquisición de señales de ECG

Desde los primeros usos del electrocardiograma en el ámbito biométrico, se ha visto que las configuraciones para la adquisición de esta señal han evolucionado gradualmente; partiendo del uso de electrodos húmedos hasta llegar a métodos menos invasivos como las configuraciones *off-the-person*, cuyo objetivo es mejorar la aceptabilidad del ECG como rasgo biométrico [25]. A continuación, se describen las diferentes etapas de esta evolución.

4.3.1 Adquisición en ámbito médico

Existen una serie de configuraciones de electrodos definidas para la toma de la señal de ECG con propósito médico. La configuración estándar se conoce como registro de 12 derivaciones o **12-Lead Configuration**, el cual consiste en colocar 10 electrodos por el cuerpo de la forma que vemos en la *Figura 23*, a partir de los cuales se obtienen las 12 derivaciones (señales): 3 bipolares y 3 monopares en las extremidades, y 6 electrodos monopares en el pecho. De esta forma se obtendría el ECG a través de 12 canales distintos. Otro estándar de configuración se conoce como **Frank Leads** o configuración ortogonal corregida, el cual permite la adquisición de la señal con 7 electrodos cuya disposición espacial en el cuerpo permite capturar el dipolo del corazón en 3 dimensiones [25].




Figura 23. Configuraciones estándar para la toma del ECG [25].

En la biometría basada en ECG es común hacer uso de ambas configuraciones estándar para el desarrollo y la evaluación de algoritmos. Aunque, en los últimos años, se ha popularizado el uso de derivaciones concretas de estas configuraciones, especialmente la primera derivación (*Lead I*), debido a la mayor aceptabilidad de la colocación de electrodos en las muñecas, pero también la segunda derivación (*Lead II*) o derivaciones torácicas [25].

Desafortunadamente, las configuraciones médicas requieren un gran número de electrodos para obtener la señal, lo que dificulta el movimiento del sujeto durante el proceso, y las grabaciones exigen un gran periodo de tiempo. Es por ello que estos métodos de adquisición no son los más adecuados para el desarrollo de sistemas biométricos robustos [25].

4.3.2 Sistemas Holter

Con el fin de eliminar las restricciones presentes en los métodos de adquisición médicos, algunos investigadores optaron por el uso de dispositivos que requerían menos electrodos y no restringían el movimiento, a cambio de sesiones de mayor duración. El ejemplo más famoso es el uso de dispositivos Holter, que están preparados para adquirir la señal ECG durante 24 horas o más, mientras el individuo realiza sus tareas diarias. Sin embargo, como vemos en la *Figura 24*, requiere la disposición de 5 electrodos en el torso, por lo que el confort y la aceptabilidad de este método como sistema biométrico se reduce considerablemente [25].




Figura 24. Dispositivo Holter con 5 electrodos [25].

4.3.3 Configuraciones off-the-person

Para mejorar la aceptabilidad y el confort en la adquisición de ECG, los electrodos húmedos fueron reemplazados por electrodos metálicos secos, se redujo su número a 2 o 3, y se situaron en las extremidades superiores, especialmente en muñecas, manos o dedos, tal como se muestra en la *Figura 25* [25].




Figura 25. Configuraciones off-the-person para la adquisición del ECG [25].

Desafortunadamente, este tipo de configuraciones siguen necesitando que el usuario ponga alguna parte de su cuerpo en contacto con los electrodos, por lo que seguiría teniendo restricciones y pondría al ECG en desventaja frente a otros rasgos biométricos. Además, el uso de electrodos secos en ubicaciones más alejadas del corazón provoca un aumento de vulnerabilidad a interferencias en la adquisición de la señal [25].

4.3.4 Sistemas de adquisición integrados

Posteriormente se llevaron a cabo algunas iniciativas para mejorar las configuraciones *off-the-person* y así acercarse a un entorno sin restricciones en la adquisición de la señal ECG. Para mejorar la aceptabilidad de los usuarios, se hace uso de tecnologías portátiles y se integran sensores en objetos comunes como teléfonos móviles o relojes inteligentes [25], tal como se ve en la *Figura 26*.




Figura 26. Sensores incorporados en objetos comunes o wearables [25].

Sin embargo, seguimos encontrando inconvenientes en dispositivos como el *CardioWheel*, que puede presentar un gran dominio del ruido o pérdidas frecuentes de la señal, debido a que el usuario mueve o retira sus manos de los electrodos. En el caso de la pulsera *Nymi*, los usuarios siguen precisando llevarla durante un largo periodo de tiempo para adquirir la señal. Por tanto, estos problemas deben abordarse y resolverse adecuadamente para obtener sistemas biométricos basados en ECG comercialmente viables [25].

4.3.5 Escenarios futuros

Con el fin de abordar los problemas de aceptabilidad e interferencias que presentan los dispositivos de adquisición, algunos investigadores han propuesto entornos de adquisición de un solo brazo, planteando nuevas posibilidades para los dispositivos portátiles. Otros investigadores desarrollaron electrodos que no necesitaban estar en contacto con la piel, ya que adquirirían el ECG a través de capas de plástico o la ropa [25]. Además, para aplicaciones que no requieren mucha información para la identificación o autenticación de los sujetos, se proponen técnicas para medir la frecuencia cardíaca usando sensores Doppler de microondas a una distancia determinada, prescindiendo completamente del contacto directo con el sujeto [25, 39]. Estos estudios de mejora abren paso a futuras tecnologías de implementación de sistemas biométricos robustos capaces de adquirir el ECG a corta distancia de la mano del sujeto y sin pérdidas de señal, o dispositivos integrados de monitorización continua que solo necesiten contacto con una de las muñecas.

4.4 Bases de datos en biometría basada en ECG

En los últimos años, los investigadores que trabajan con señales de ECG han visto incrementada su necesidad de conjuntos de datos cada vez más completos, con más sujetos, diferentes condiciones médicas, tomados en distintas sesiones, distribuidos en periodos de tiempo más amplios y bajo diferentes condiciones de postura y actividad. Por tanto, se ha tomado consciencia de la importancia de las colecciones públicas de datos, las cuales también permiten la comparación y evaluación cooperativa de algoritmos. A continuación, se mencionan algunos aspectos importantes para la creación de una colección o base de datos de señales ECG bien estructurada y apropiada para el desarrollo de sistemas biométricos [25]:

- **Número de electrodos:** un menor número de electrodos o canales genera configuraciones con resultados similares a los obtenidos con *wearables*.
- **Posición de los electrodos:** los electrodos situados en partes del cuerpo más lejanas al corazón presentan menor calidad de señal y, por tanto, reducen el rendimiento del sistema.
- **Frecuencia de muestreo:** influye en el detalle o resolución de la señal medida. A menor frecuencia de muestreo, menor resolución, lo que provoca la pérdida de información relevante y aumenta el riesgo de ruido de alta frecuencia, por ejemplo, el ruido electromiográfico.
- **Postura, actividad y fatiga:** tienen un impacto negativo en el rendimiento de los sistemas de reconocimiento, si estos no han sido entrenados en consecuencia.
- **Salud del sujeto:** algunos problemas de salud, como la arritmia, pueden generar variabilidad *intra-subject* y dificultar el proceso de reconocimiento. Por tanto, los sistemas que se hayan enfrentado a este tipo de anomalías en su fase de entrenamiento tendrán mejor rendimiento.
- **Número de sujetos:** la diversidad de individuos y sus propias características aumentan la variabilidad *inter-subject*, por lo que los algoritmos de identificación biométrica deberían verse beneficiados. No obstante, se ha visto que el rendimiento de los algoritmos ha sido significativamente peor cuando se han probado con un número de sujetos elevado.
- **Sesiones:** la variabilidad de la señal ECG puede provocar errores en los sistemas incluso en un periodo de 24 horas. Por tanto, deben ser entrenados con datos recogidos en diferentes sesiones, con semanas o meses de diferencia, de forma que se garantice la robustez del sistema.

4.4.1 Principales bases de datos públicas

Actualmente, existe un gran número de colecciones públicas disponibles para el desarrollo de sistemas biométricos basados en ECG, y que intentan cubrir la mayoría de los factores de creación de bases de datos mencionados previamente. Muchas de ellas se encuentran en **PhysioNet**³³ mientras que otras han sido cedidas por sus creadores. A continuación, se mencionan algunas de las colecciones más relevantes [25]:

- ◆ **AHA Database Sample Excluded Record:** AHA (*American Heart Association*) creó esta base de datos en 1982 para entrenar a profesionales médicos sobre el diagnóstico de arritmias. Está formada por 154 grabaciones de pacientes reales, cada una de ellas tomada desde 2 canales y con una duración de 3 horas. Además, los últimos 30 minutos de cada señal están anotados para 7 tipos de arritmia.
- ◆ **ECG – ID Database:** se centra íntegramente en la biometría. Contiene un total de 310 grabaciones recogidas de 90 sujetos, cada una de ellas con una duración de 20 segundos. Las señales fueron adquiridas de la primera derivación, colocando electrodos de sujeción en las muñecas.
- ◆ **European ST-T Database:** fue creada para el estudio de los cambios producidos en la onda T y el segmento ST. Consta de 90 extractos de 2 horas de grabaciones de 79 sujetos, tomadas con 2 canales. Además, las señales incluyen anomalías cardíacas como isquemia miocárdica, hipertensión, discinesia ventricular y efectos de medicación.
- ◆ **QT Database:** tiene el objetivo de ayudar al desarrollo de métodos automáticos de medida del intervalo QT. Reúne 105 extractos de grabaciones relevantes, de 15 minutos cada una, de otras bases de datos públicas.
- ◆ **MIT-BIH Arrhythmia Database:** el centro médico *Beth Israel Deaconess* y el MIT (*Massachusetts Institute of Technology*) crearon esta base de datos, y es una de las más utilizadas en la investigación de la biometría basada en ECG. Contiene 48 señales ECG de 30 minutos de duración, obtenidas con 2 canales de 48 sujetos seleccionados de tal forma que hubiera gran variedad de arritmias.
- ◆ **PTB Diagnostic ECG Database:** contiene un total de 549 grabaciones de 15 derivaciones de alta resolución (12 derivaciones estándar junto con las derivaciones Frank XYZ). Hay disponibles de 1 a 5 grabaciones para cada uno de los 294 sujetos, que pueden estar sanos o tener patologías como el infarto de miocardio, arritmia, hipertrofia o insuficiencia cardíaca.

Esta última colección, aparte de ser una de las más utilizadas en estudios y publicaciones relacionadas con la biometría basada en ECG, será la que se utilice para entrenar el algoritmo desarrollado en este proyecto.

³³ <https://physionet.org/>

4.5 Técnicas para la extracción de información y características

Según el esquema básico representado en la *Figura 4* del Capítulo 2, una vez obtenidas las muestras deben pasar por un módulo extractor de características. El objetivo principal de esta etapa es convertir la señal ECG en un patrón que identifique al sujeto, reduciendo el ruido y la variabilidad *intra-subject*, al mismo tiempo que realza la variabilidad *inter-subject* para facilitar el proceso de decisión. Se han propuesto varios métodos de extracción de características biométricas del ECG, que se pueden clasificar en 2 tipos: **fiduciaros** y **no fiduciaros**. Adicionalmente a la extracción de características, sería conveniente aplicar una **reducción de dimensionalidad** de los datos para mejorar el rendimiento del sistema [25]. A continuación, se comentan algunos de los métodos más importantes para la extracción de características, tanto fiduciaros como no fiduciaros, y se describe también brevemente la reducción de dimensionalidad.

4.5.1 Métodos fiduciaros

Los métodos fiduciaros extraen información de la señal de ECG mediante el uso de puntos de referencia, de cada latido, en el dominio del tiempo. Una vez se tienen estas localizaciones en tiempo, se calculan los puntos fiduciaros, que pueden ser temporales, de amplitud o ambos.

El algoritmo de **Pan – Tompkins** es una de las mejores opciones para la extracción de puntos fiduciaros y fue desarrollado para reconocer complejos QRS en tiempo real en la señal del electrocardiograma [40]. El algoritmo consiste en la reducción de ruido de la señal mediante un filtro paso banda, seguido de un filtro diferenciador para obtener la señal derivada, que destacará la información de pendientes rápidas, coincidentes con el complejo QRS del ECG. Posteriormente, se realiza una transformación no lineal, que consiste en elevar la señal al cuadrado para acentuar las altas frecuencias correspondientes al QRS y, por último, se aplica una ventana de integración móvil que aporta información de las formas de onda para poder aplicar un umbral adaptativo que identifica las posiciones del pico R [41, 42].

La transformada discreta de Wavelet o **DWT** (*Discrete Wavelet Transform*) es otra opción para determinar la ubicación de los puntos fiduciaros y trazar las formas de onda del latido. Tras la reducción de ruido, la DWS aísla los complejos QRS, cuya energía se encuentra mayoritariamente en el rango de 3 – 40 Hz. Los picos R se detectan al encontrar módulos máximos en la señal resultante, mientras que los picos Q y S se ubican buscando módulos máximos de signo opuesto dentro de una ventana centrada en R [43].




Figura 27. Principales puntos fiduciaros³⁴.

³⁴ <https://es.wikipedia.org/wiki/Electrocardiograma>

Sin embargo, la localización de puntos fiduciaros en la señal del ECG, destacados en la *Figura 27*, no es compatible con la tendencia de adquisición de muestras con dispositivos *off-the-person*, ya que estos dispositivos introducen gran cantidad de ruido, lo cual deteriora la fiabilidad de los puntos de referencia escogidos. Por tanto, la extracción de características mediante métodos fiduciaros ha perdido relevancia en los trabajos de investigación y se utilizan únicamente cuando se han realizado adquisiciones de señal *on-the-person* [25].

4.5.2 Métodos no fiduciaros

Puesto que la nueva tendencia en investigación son las configuraciones *off-the-person* y los métodos fiduciaros son poco fiables para este fin, los expertos buscaron la posibilidad de utilizar algoritmos que prescindieran de estos puntos de referencia, es decir, métodos no fiduciaros. Estos utilizan la totalidad de la señal (o segmentos de ella) para extraer características relacionadas con la forma de onda [25].

Sachia et al. fueron pioneros en aplicar la transformada de Fourier (TF) al latido completo (segmento PQRST) y a cada forma de onda por separado (P, QRS y T). desde ese momento, la transformada de Fourier y la de Wavelet se han utilizado en numerosas ocasiones [44, 45]. *Plataniotis et al.* lograron prescindir completamente de los puntos fiduciaros, sustituyéndolos por coeficientes de autocorrelación (AC) de segmentos temporales de la señal ECG [46].

Louis et al. tuvieron el objetivo de evitar los efectos del ruido a través de la aplicación de patrones binarios para la extracción de características de la señal locales y globales [47]. Incluso algunos métodos más recientes utilizan latidos segmentados o segmentos entre picos R como conjuntos de características para tomar decisiones, eliminando la etapa de extracción de características [48].

Estos métodos, a diferencia de los basados en puntos fiduciaros, no requieren una etapa de preprocesado para la eliminación de ruido; simplemente hay que llevar a cabo una detección robusta del pico R para así segmentar los diferentes latidos presentes en la señal de ECG.

4.5.3 Reducción de dimensionalidad

La reducción de dimensionalidad tiene gran importancia en los sistemas biométricos, ya que se extraen una alta cantidad de características que puede llegar a ser redundantes. Por tanto, estas técnicas de reducción seleccionan las características extraídas de cada sujeto, reduciéndolas a una cantidad computacionalmente viable y mejorando así la eficiencia del sistema [25].

Biel et al. fueron los pioneros en proponer el reconocimiento biométrico basado en ECG, y consiguieron reducir la dimensionalidad utilizando matrices de correlación para seleccionar entre 10 y 30 características de la primera derivación, de un total de 360 características extraídas mediante la configuración estándar [49]. *Israel et al.* seleccionaron entre 12 y 15 características fiduciaras utilizando el método lambda de Wilks [50].

Plataniotis et al. utilizaron la transformada discreta del coseno (DCT, según sus siglas en inglés) para reducir el número de características extraídas con las ventanas de autocorrelación [46]. Posteriormente, *Agrafioti y Hatzinakos* consiguieron mejores resultados aplicando el análisis discriminante lineal (LDA, según sus siglas en inglés), también para las características de autocorrelación [51]. *Hejazi et al.*,

además de LDA, utilizaron el análisis de componentes principales (PCA, según sus siglas en inglés) y el análisis de componentes principales con “Kernel” (KPCA, según sus siglas en inglés) para la reducción de dimensionalidad, concluyendo que KPCA otorgaba mejores resultados de rendimiento [52].

En los últimos años, han aparecido alternativas mejores que el LDA, como el método KPCA no lineal, mencionado anteriormente, dando así a entender a los investigadores la importancia que tiene el desarrollo de métodos de reducción de dimensionalidad más sofisticados. También habría que profundizar en el estudio de las metodologías *deep-learning*, como las redes neuronales convolucionales, que pueden ajustarse para realizar reducciones optimizadas de la dimensionalidad de modo no lineal [25].

4.6 Clasificadores

El módulo de decisión tiene dos posibles objetivos: la atribución de una de las identidades almacenadas en el sistema biométrico al usuario, en caso de la identificación; o aceptar o rechazar la identidad reclamada por el usuario, en el caso de la autenticación. Generalmente, en el caso de la autenticación, el módulo de decisión consta de un clasificador, mientras que, para la identificación, estaría basado en un umbral de referencia aplicado a la puntuación de predicción de la identidad reclamada [25].

Como se acaba de mencionar, el bloque de decisión puede consistir en un clasificador, el cual deberá ser entrenado con los patrones de los individuos registrados en el sistema para proporcionar una identificación precisa al extraerse nuevos patrones de un sujeto. Los clasificadores más utilizados en tareas de identificación son los siguientes [25]:

- ♦ **Support Vector Machines (SVM):** es un clasificador capaz de manejar grandes dimensiones de datos, y su objetivo principal es encontrar un hiperplano que separe los datos de las diferentes clases a clasificar, asegurando el margen máximo entre los alrededores de cada clase con las muestras de las clases vecinas. Las dos clases más cercanas son conocidas como vectores de soporte (*support vectors*) y determinan la posición del hiperplano de separación. Para los casos en que los datos no son linealmente separables en el espacio, este algoritmo recurre a una herramienta llamada *kernel-functions*, que transforma los datos a un espacio de mayor dimensión donde se pueda encontrar un hiperplano óptimo. Una vez encontrado, se utiliza para clasificar nuevos datos en este espacio en función del lado del hiperplano en el que caen [53]. La *Figura 28* muestra un ejemplo del funcionamiento de este algoritmo.




Figura 28. Support Vector Machines³⁵.

³⁵ <https://www.analyticsvidhya.com/blog/2021/10/support-vector-machinessvm-a-complete-guide-for-beginners/>

- ♦ **K-Nearest Neighbors (kNN):** toma el vector de características (muestras de entrada), calcula la distancia Euclídea que hay con las k clases más cercanas, y se somete a un proceso de votación. La clase que más votos obtenga entre los k vecinos será la que se asigne a las muestras de entrada. El k -NN es un método que no necesita volver a entrenar al clasificador cuando llegan nuevas muestras de entrada, por lo que es fácil de utilizar. Además, es un método no paramétrico, esto quiere decir que no hace suposiciones sobre la distribución de los datos [54]. En la *Figura 29* se muestra el funcionamiento del clasificador KNN.




Figura 29. k-Nearest Neighbors³⁶.

Se calcula la distancia del nuevo dato con los k vecinos más cercanos, siendo k un número entero en impar en este caso (clasificación binaria), y se decide a qué clase pertenece el nuevo dato. En este caso, la clase sería la B.

- ♦ **Artificial Neural Networks (ANN):** está inspirado en la estructura biológica del cerebro, consistente en una agrupación de neuronas interconectadas que reciben una señal de entrada, la analizan, modifican y transmiten hasta alcanzar su objetivo (un órgano o tejido). Estos clasificadores también están compuestos por unidades básicas llamadas neuronas (o nodos) organizadas en capas: una capa de entrada, una o más capas ocultas y una capa de salida. Los datos de entrada se procesan en las capas ocultas, donde los nodos tienen funciones de activación no lineales que permiten ponderar sus conexiones para guiar la clasificación final, emitida por la capa de salida. El entrenamiento de estos clasificadores debe realizarse intentando reducir al máximo el error del algoritmo, utilizando métodos como el descenso del gradiente [55]. La *Figura 30* muestra una arquitectura de ANN con solo dos capas ocultas.




Figura 30. Artificial Neural Network³⁷.

³⁶ <https://www.kdnuggets.com/2022/04/nearest-neighbors-classification.html>

³⁷ <https://openwebinars.net/blog/que-son-las-redes-neuronales-y-sus-aplicaciones/>

4.7 Propiedades de ECG como rasgo biométrico

Para concluir el presente capítulo, se debe analizar si la señal de ECG puede considerarse un rasgo válido para un sistema biométrico. Para ello, hay que recordar los requisitos expuestos en la Sección 2.7:

- **Universalidad:** el ECG es una señal vital, por lo que forma parte de todos los seres vivos.
- **Singularidad:** el ECG es único para cada individuo, debido a las variaciones anatómicas y fisiológicas del corazón.
- **Permanencia:** el ECG puede verse afectado por factores como el ejercicio, estrés o enfermedades, creándose así a variabilidad *intra-subject* e *inter-subject*. Sin embargo, existen algoritmos basados en puntos no fiduciaros que son capaces de minimizar la variabilidad *intra-subject* y maximizar la variabilidad *inter-subject*, llegando así a resultados de alto rendimiento.
- **Cuantificable:** existen algoritmos que obtienen patrones cuantificables, tanto si se usan métodos fiduciaros como no fiduciaros.
- **Rendimiento:** los métodos de reducción de dimensionalidad ayudan a reducir el coste computacional.
- **Aceptabilidad:** gracias a la investigación de configuraciones de adquisición *off-the-person*, se han conseguido varias soluciones que podrían tener éxito en el mercado.
- **Usurpación:** la inherente medida de vida de la señal de ECG lo convierte en un rasgo muy robusto frente a otros, además de ser extremadamente difícil de falsificar o imitar.

4.8 Discusión

La importancia de la biometría ha incrementado debido a la necesidad de sistemas robustos de identificación o autenticación por parte de la sociedad, evitando así posibles falsificaciones de identidad. Los sistemas actuales, como los basados en huellas dactilares, pueden ser fácilmente falsificados con huellas sintéticas; y el reconocimiento facial o por voz aún no es capaz de enfrenarse a los posibles cambios que sufran estos rasgos. Sin embargo, el ECG ha demostrado ser un rasgo biométrico muy prometedor debido a su naturaleza oculta y su fácil adquisición, entre otras características. Debido a la geometría del corazón, el estado de salud, la postura, las emociones o la calidad de los electrodos con los que se toma la señal, entre otras causas, esta señal puede presentar dos tipos de variabilidad: *intra-subject*, diferencias entre latidos de un mismo sujeto, e *inter-subject*, variaciones entre latidos de sujetos distintos. Las principales configuraciones de grabación del ECG son *Standard 12-Lead*, *Frank Leads* y *Holter*, además de configuraciones *off-the-person* o pulseras inteligentes. La extracción de características de estas señales para generar patrones puede realizarse a través de métodos fiduciaros, que obtienen puntos de referencia de cada latido, o de métodos no fiduciaros, que extraen características relacionadas con la forma de onda aplicando técnicas como la Transformada de Fourier.

Finalmente, para el módulo de decisión de un sistema biométrico, se puede contar con clasificadores como *Support Vector Machines*, *k-Nearest Neighbors* o *Artificial Neural Networks*.

CAPÍTULO 5: DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS

En este apartado se describirá en detalle el sistema biométrico llevado a cabo en el proyecto. Este sistema consta de 2 grandes bloques: **base de datos** y algoritmo de **extracción de características y clasificación**; bloques que pueden verse en la *Figura 4* del Capítulo 2. Para la construcción de este tipo de arquitectura se ha utilizado el lenguaje de programación PYTHON³⁸. Por último, cabe destacar que un sistema biométrico tiene dos finalidades: identificar o autenticar, ambas detalladas en el documento. Sin embargo, el sistema biométrico a construir en este proyecto, se va a concentrar en tareas de identificación.

5.1 Base de datos

5.1.1 Carga

El primer lugar, es necesario descargar las señales de la base de datos PTBDB³⁹, que se pueden encontrar en Physionet⁴⁰, y almacenarlas en un directorio local. Para este proyecto, la descarga se ha realizado manualmente, ya que el repositorio contiene señales tanto de pacientes sanos (o de control) como con patologías, y únicamente se va a hacer uso de los primeros mencionados. Seguidamente, en el código generado, se crea una función que lee una a una las señales del directorio y las almacena en una lista con la que poder trabajar después. La *Figura 31* muestra el diagrama de bloques de la descarga.



Figura 31. Descarga de la base de datos al directorio local.

Tras realizar la descarga correctamente, se puede comprobar que contamos con 52 pacientes sanos y un total de 80 sesiones, la frecuencia de muestreo es de 1000 Hz, la duración de cada grabación es de 2 minutos aproximadamente y, para cada sesión, se cuenta con 15 grabaciones simultáneas distintas, correspondientes a los 15 electrodos con los que se graba el ECG.

Es importante resaltar que, en este proyecto, el tratamiento de estas señales se hará únicamente para la primera derivación.

³⁸ <https://aws.amazon.com/es/what-is/python/>

³⁹ <https://physionet.org/content/ptbdb/1.0.0/>

⁴⁰ <https://physionet.org/>

5.1.2 Representaciones tiempo-frecuencia

Para comparar los resultados obtenidos, se considerarán tres representaciones tiempo-frecuencia: espectrograma, espectrograma logarítmico y espectrograma de Mel.

- **Espectrograma:** se basa en la Transformada de Fourier de Tiempo Reducido (*Short-Time Fourier Transform*, STFT), utilizada para determinar el contenido en frecuencia, dividiendo en varias secciones una señal que cambia con el tiempo [5]. En la práctica, la STFT divide una señal de larga duración en segmentos más cortos de igual longitud y aplica la transformada de Fourier a cada segmento, generando una representación tiempo-frecuencia de la señal. Matemáticamente, puede expresarse con la siguiente ecuación:

$$X(\tau, \omega) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega t} dt \quad (10)$$

Donde τ es el desplazamiento temporal de las ventanas, ω es la frecuencia angular ($\omega = 2\pi f$) y $w(t - \tau)$ es la función de ventana utilizada. Por defecto, la función 'stft' de Python utiliza la ventana de Hann, ya que es la más común.

- **Espectrograma logarítmico:** es una versión a escala logarítmica del espectrograma basado en la STFT. La escala logarítmica enfatiza las bajas frecuencias, donde está contenida la información importante del ECG, y resta información al ruido presente en las altas frecuencias. Esta transformación a escala logarítmica puede expresarse matemáticamente mediante la siguiente ecuación:

$$Y(\tau, \omega) = \log(X(\tau, \omega)) \quad (11)$$

Donde $X(\tau, \omega)$ es el espectrograma calculado usando la ecuación (10).

- **Espectrograma de Mel:** es una versión en escala de Mel [60], que presenta las mismas características que el espectrograma logarítmico. Para transformar el espectrograma logarítmico a la escala de Mel, se utilizan bancos de filtros de Mel; donde cada filtro del banco es triangular y se centra en una frecuencia de Mel específica (m). La relación entre la frecuencia f y la frecuencia m puede expresarse matemáticamente con la ecuación:

$$m = 2595 \log\left(1 + \frac{f}{700}\right) \quad (12)$$

Cada filtro se aplica al espectrograma sumando la energía en las bandas de frecuencia ponderadas por la respuesta del filtro, y el resultado sería el espectrograma de Mel, expresado por la siguiente ecuación:

$$S_{mel}(m, i) = \sum_{k=0}^{N-1} |X(m, k)|^2 H_i(k) \quad (13)$$

Donde $S_{mel}(m, i)$ es el espectrograma de Mel en el tiempo m y el filtro de Mel i , y $H_i(k)$ es la respuesta del filtro triangular i en la frecuencia k .

DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS

La *Figura 32* muestra las imágenes generadas por las representaciones mencionadas, en este caso, para el paciente 174 de nuestra base de datos local:




Figura 32. Diferentes representaciones tiempo-frecuencia.

Como se ha comentado previamente, la información importante de la señal ECG se encuentra en la banda de baja frecuencia, lo cual se puede comprobar notablemente en la imagen obtenida del espectrograma, ya que la mayor parte de ella es contenido vacío. Esto puede provocar muchos problemas a la hora de realizar las tareas de identificación, por lo que se va a establecer una frecuencia máxima que utilizar en las imágenes usadas. Para establecer este límite nos fijamos en la amplitud máxima presente en el espectrograma de la *Figura 33*, viéndose que por encima de $f_{\text{máx}} \approx 40$ Hz, $|X(\tau, \omega)| \approx 0$.

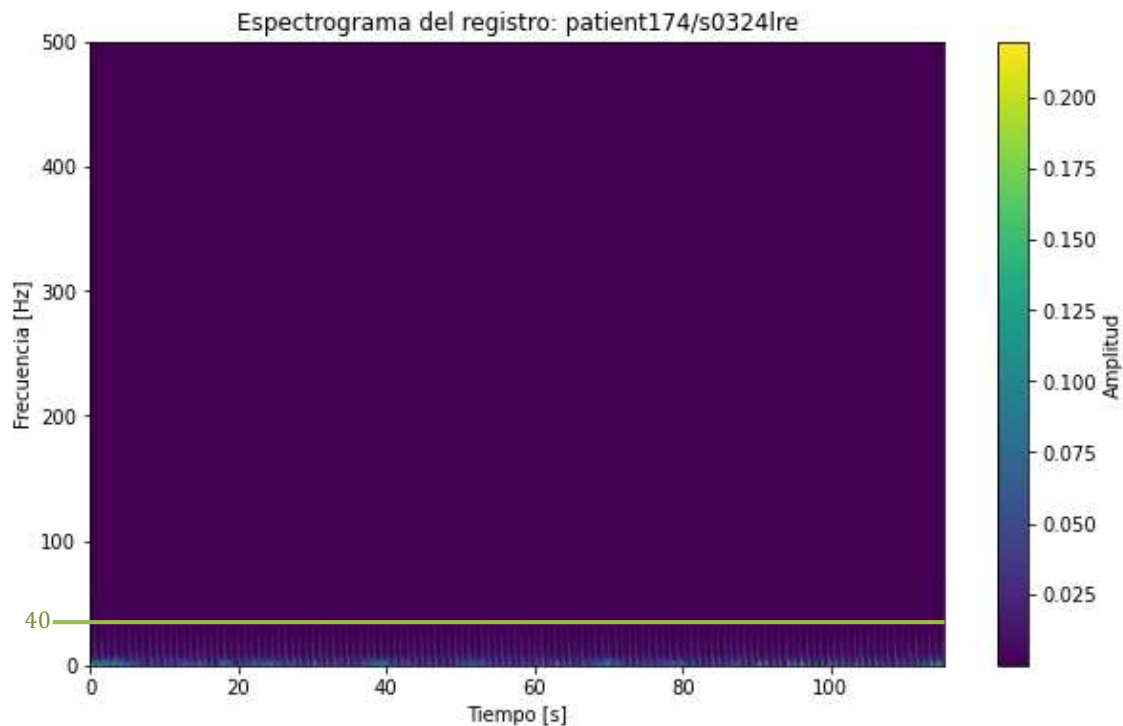


Figura 33. Espectrograma del paciente 174.

DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS

Filtrando por el rango de frecuencias 0 – 40 Hz, las representaciones resultantes serían las mostradas en las *Figura 34 y 35*:

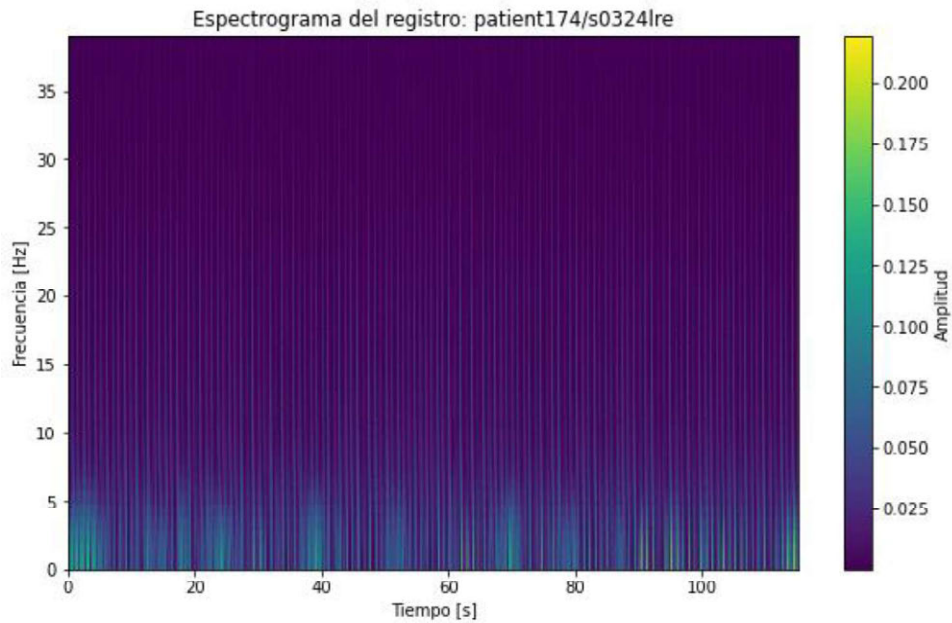


Figura 34. Espectrograma filtrado del paciente 174.




Figura 35. Espectrograma logarítmico y espectrograma de Mel filtrados del paciente 174.

Como puede apreciarse, el uso del logaritmo resalta notablemente las amplitudes en frecuencia.

Por otra parte, al conocer el valor de la frecuencia de corte $f_{\text{máx}}$ podemos calcular el número de puntos (k) que se utilizarán al calcular la Transformada de Fourier para tener frecuencias de 0 – 40 Hz. Los cálculos necesarios son los siguientes:

$$X(k) = X(f)|_{f=\frac{k \cdot f_s}{M}}, \quad \text{siendo } \begin{cases} \text{Tamaño de la ventana: } N = 256 \\ \text{Nº de puntos de la STFT (} M \geq N \text{): } M = 1024 \\ f_{\text{máx}} = 40 \text{ Hz, } f_s = 1000 \text{ Hz} \end{cases}$$


$$\rightarrow f_{\text{máx}} = 40 = \frac{k_{\text{máx}} \cdot 1000}{1024} \rightarrow k_{\text{máx}} = 40.96 \rightarrow k_{\text{máx}} = 40 \rightarrow k = 0, 1, 2, \dots, 39$$

5.1.3 Segmentado


Una vez aplicado el filtro se reducen posibles obstáculos en pasos posteriores. Sin embargo, la cantidad de datos por paciente es bastante reducida, obteniéndose entre 1 y 7 imágenes para cada uno de ellos.

Con el fin de aumentar la cantidad de información por paciente, las imágenes generadas se dividen en 12 partes iguales, atendiendo a los siguientes cálculos:

$$\rightarrow T_{\omega} = N \cdot T_s = \frac{N}{f_s} = \frac{256}{1000} = 256 \cdot 10^{-3} \rightarrow T_{\omega} = 250 \text{ ms}$$



$$\rightarrow \frac{T}{T_{\omega}} = \frac{120}{250 \cdot 10^{-3}} = 480 \text{ ventanas}$$



$$f_{\text{máx}} = 40 \text{ Hz}$$

$$\rightarrow \frac{480}{40} = 12 \text{ segmentos} \quad \rightarrow \frac{120 \text{ s}}{12} = 10 \text{ s/segmento}$$

5.2 Extracción de características y clasificación

Los datos generados en el bloque anterior sirven de entrada para este nuevo bloque, en el que se extraerán patrones para la identificación de sujetos. La *Figura 36* muestra el diagrama de bloques simplificado de la unión de estos dos módulos.




Figura 36. Diagrama de bloques simplificado.

5.2.1 Carga de datos

En primer lugar, es necesario cargar las imágenes generadas en el bloque anterior. Para ello, se leen todos los archivos del directorio local donde se encuentran, habiendo una carpeta asignada para cada paciente. Seguidamente, se redimensionan las imágenes a 224x224 píxeles para poder trabajar con ellas y, en función de la configuración de la simulación que se vaya a realizar, se mantendrán en RGB o se convertirán a escala de grises.

Los datos se almacenan en una lista de espectrogramas y se les asigna una etiqueta a cada uno, utilizando para ello el nombre de la carpeta del paciente donde se encuentran.

5.2.2 Preprocesado

Antes de poder trabajar con los datos hay que normalizarlos, dividiendo los valores de amplitud de los píxeles por 255 para obtener valores entre 0 y 1. Se añade una dimensión para que sean compatibles con la entrada de la red: (224, 224, 1) en el caso de la escala de grises, y (224, 224, 3) en el caso de las imágenes a color. Para terminar, las etiquetas de texto se convierten en índices numéricos, que luego se transforman en una **codificación one-hot**. La codificación *one-hot* es una técnica de representación utilizada en aprendizaje automático y procesamiento de datos para convertir datos categóricos en un formato que pueda ser proporcionado a algoritmos de aprendizaje automático [61]. Este formato es especialmente útil para representar variables categóricas no ordinales, es decir, aquellas que no tienen un orden intrínseco. Esta codificación convierte cada categoría en un vector binario. Si se tienen N categorías, la codificación *one-hot* representará cada categoría como un vector de longitud N, donde el elemento correspondiente a la categoría específica será 1 y los demás elementos serán 0. Así, por ejemplo, si tenemos 52 sujetos (categorías), tendremos un vector binario de longitud 52 en el que la etiqueta del sujeto 18 se representará mediante 17 ceros, 1 uno y otros 34 ceros.

A partir de este momento, los datos ya están preparados para ser utilizados por el clasificador que, en este caso, se trata de una red neuronal.

En el código implementado para este bloque del sistema biométrico, se ha creado una función que realiza las tareas de preprocesado.

```
# Preprocesar datos
def preprocess_data(spectrograms, labels):
    # Normalizar las imágenes
    spectrograms = spectrograms / 255.0
    # Añadir una dimensión al array de espectrogramas (imágenes) para que sea
    compatible con la entrada de la red (N, 224, 224, 1)
    spectrograms = np.expand_dims(spectrograms, axis=-1)

    # Convertir etiquetas a números
    label_to_index = {label: index for index, label in enumerate(np.unique(labels))}
    labels = np.array([label_to_index[label] for label in labels])
    labels = to_categorical(labels, num_classes=len(label_to_index)) # Convertir
    etiquetas a one-hot encoding

    return spectrograms, labels, label_to_index
```

5.2.3 Arquitectura de red

La arquitectura del modelo elaborado es una versión simplificada de la red neuronal convolucional (CNN) VGGNet, utilizada comúnmente para tareas de clasificación de imágenes [5]. Las características principales del modelo son las siguientes:

- **Capa de entrada:** como se ha mencionado anteriormente, las dimensiones de entrada son (224, 224, 1) para imágenes en escala de grises y (224, 224, 3) para imágenes a color (RGB).
- **Capas convolucionales y de *Max-Pooling*:** estas capas se utilizan conjuntamente para extraer características espaciales de las imágenes. Cada capa convolucional aplica filtros de convolución de tamaño 3x3 y una función de activación ReLU, mientras que las capas de *Max-Pooling* reducen la dimensionalidad espacial de las características. Se utilizan un total de cinco agrupaciones de estas capas, aumentando el tamaño del mapa de características con cada una; siendo estos 64, 128, 256 y 512 (los dos últimos).

```
conv1 = Conv2D(filters=64, kernel_size=(3,3), padding="same", activation="relu")(_input)
pool1 = MaxPooling2D((2, 2))(conv1)

conv2 = Conv2D(filters=128, kernel_size=(3,3), padding="same", activation="relu")(pool1)
pool2 = MaxPooling2D((2, 2))(conv2)

conv3 = Conv2D(filters=256, kernel_size=(3,3), padding="same", activation="relu")(pool2)
pool3 = MaxPooling2D((2, 2))(conv3)

conv4 = Conv2D(filters=512, kernel_size=(3,3), padding="same", activation="relu")(pool3)
pool4 = MaxPooling2D((2, 2))(conv4)

conv5 = Conv2D(filters=512, kernel_size=(3,3), padding="same", activation="relu")(pool4)
pool5 = MaxPooling2D((2, 2))(conv5)
```

La función de activación ReLU (*Rectified Linear Unit*) es una función de activación no lineal que es computacionalmente simple y eficiente, ya que solo requiere una comparación y una operación básica. Matemáticamente se define de la siguiente manera:

$$ReLU(x) = \max(0, x) \quad (14)$$

Esto significa que la función devuelve 0 si la entrada es negativa, y devuelve la entrada misma si esta es positiva.

Esta función, introduce la no linealidad requerida en el modelo, permitiendo que la red aprenda representaciones complejas de los datos

- **Capas Densas (*Fully Connected*):** las capas densas son capas en las que cada neurona está conectada a todas las neuronas de la capa anterior, responsables de aprender las combinaciones de características no lineales en los datos. Cada neurona recibe una entrada que es una combinación lineal de las salidas de todas las neuronas de la capa anterior, multiplicadas por un conjunto de pesos y con un sesgo añadido. Tras calcular la combinación lineal, se aplica una función de activación no lineal (ReLU en nuestro caso)

DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS

para introducir no linealidad. El funcionamiento de una neurona en una capa densa se puede describir matemáticamente como:

$$y = f\left(\sum_{i=1}^n \omega_i x_i + b\right) \quad (15)$$

Donde x_i son las entradas (salidas de cada neurona de la capa anterior), ω_i son sus pesos, b es el sesgo y $f(\cdot)$ es la función de activación no lineal (ReLU).

- **Dropout:** ayuda a prevenir el sobreajuste (*overfitting*) durante el entrenamiento. Durante cada paso del entrenamiento, se desactiva un porcentaje de neuronas establecido, conocido como tasa de Dropout; típicamente, estos valores se encuentran entre 0.2 y 0.5 (20% y 50%). De esta forma, las neuronas restantes (neuronas activas) deben aprender a funcionar de manera más robusta y eficaz, ya que no pueden depender únicamente de una neurona específica. El valor elegido para la tasa de Dropout puede tener gran influencia en los resultados obtenidos, por ello será un parámetro a optimizar en el momento de realizar simulaciones.

```
dense1 = Dense(4096, activation="relu")(flat)
dense1 = Dropout(0.3)(dense1)
dense2 = Dense(4096, activation="relu")(dense1)
dense2 = Dropout(0.3)(dense2)
```

- **Capa de salida:** se trata de una capa densa que utiliza una función de activación *softmax*, la cual produce una distribución de probabilidad sobre las clases; siendo cada clase un individuo distinto del sistema biométrico. El número de neuronas en esta capa será igual al número de clases. La función de activación *softmax* se puede expresar matemáticamente con la siguiente ecuación:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (16)$$

Donde z_i es la i -ésima componente del vector de entrada $z = [z_1, z_2, \dots, z_k]$ y K es el número total de clases.

```
output = Dense(num_classes, activation="softmax")(dense2)
```

- **Compilación del modelo:** el modelo se compila con la función de pérdida *categorical_crossentropy*, que es adecuada para la clasificación multiclase, donde cada ejemplo pertenece a una sola clase entre varias posibles. Esta función mide la distancia entre la distribución de las etiquetas verdaderas y las predicciones del modelo, penalizando en mayor medida las predicciones más alejadas de las etiquetas verdaderas con el fin de que tengan mayor semejanza a las etiquetas correctas. La función de pérdida puede expresarse matemáticamente de la siguiente forma:

$$L(y, \hat{y}) = -\sum_{i=1}^K y_i \log(\hat{y}_i) \quad (17)$$

Donde K es el número de clases, y_i es el valor verdadero de la clase i (1 si la clase es correcta, 0 en caso contrario) e \hat{y}_i es la probabilidad predicha para la clase i . La suma de todas las probabilidades predichas debe ser igual a 1.

DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS

Para encontrar los parámetros de la red, se hace uso de un optimizador que ajusta los pesos del modelo y así minimizar la función de pérdida durante el entrenamiento. El optimizador elegido es Adam⁴¹ (*Adaptive Moment Estimation*), uno de los más eficaces en el entrenamiento de redes neuronales.

Finalmente, para evaluar el rendimiento del modelo, se utiliza la métrica *accuracy* (precisión), que mide la fracción de predicciones correctas (véase la sección 2.6).

```
model.compile(optimizer=Adam(learning_rate=1e-4), loss='categorical_crossentropy',  
metrics=['accuracy'])
```

En la *Figura 37* puede observarse el esquema la arquitectura de la red descrita:




Figura 37. Arquitectura de la CNN para imágenes a color.

5.2.4 Entrenamiento y evaluación

Para poder hacer uso del modelo creado es preciso dividir los datos, diferenciando entre datos de entrenamiento y datos de validación. Para este proyecto, se ha hecho una división del 75% para entrenamiento y 25% para validación, asegurando que esta proporción se cumple para cada carpeta de datos. De esta forma, el modelo se entrena utilizando los datos de entrenamiento y es evaluado posteriormente utilizando los datos de validación, comprobando su capacidad de generalización a datos no vistos durante el entrenamiento.

⁴¹ <https://blog.marketmuse.com/glossary/adaptive-moment-estimation-adam-definition/>

5.3 Resultados

En esta sección se mostrarán los resultados del sistema biométrico desarrollado y sus correspondientes interpretaciones. Para evaluar el rendimiento de los distintos sistemas probados se utilizará una de las medidas de rendimiento mencionadas en el Capítulo 2, la precisión o *accuracy* (ACC), ya que un valor elevado significa un gran rendimiento del sistema.

En primer lugar, se recuerda que los resultados se han obtenido mediante el procesado de las señales correspondientes a la primera derivación, es decir, al primer canal de los 15 utilizados en las grabaciones. Asimismo, se va a mostrar el éxito del sistema desarrollado teniendo en cuenta sólo los sujetos sanos, también denominados sujetos de control.

Por otro lado, hay una serie de parámetros, detallados en la *Tabla 9*, que se irán modificando con el fin de observar los diferentes resultados obtenidos, y así elegir la configuración óptima.

Parámetros variables			
Representaciones t - f	Espectrograma	Espectrograma logarítmico	Espectrograma de Mel
Formato imágenes	Escala de grises		RGB
Dropout	0%	20%	30%
Nº de capas	C ₁ (64) - C ₂ (128) C ₃ (256) - C ₄ (512) C ₅ (512) - 3xDense		C ₁ (64) - C ₂ (128) C ₃ (256) - C ₄ (512) C ₅ (512) - 2xDense

Tabla 9. Parámetros variables en las simulaciones.

Finalmente, se establece un máximo de 100 iteraciones (épocas) por simulación, aunque es una cantidad que puede provocar sobreentrenamiento (también conocido como *overfitting*). Este problema ocurre cuando el modelo aprende demasiado bien los detalles y el ruido de los datos de entrenamiento, resultando en un rendimiento excelente en el conjunto de entrenamiento frente a un rendimiento pobre en el conjunto de validación o prueba. Si los resultados muestran que la precisión del modelo en los datos de entrenamiento continúa mejorando mientras que la precisión de los datos de validación deja de mejorar o incluso empeora, es un fuerte indicador de sobreentrenamiento.

Para prevenir el *overfitting*, se hace uso de *callbacks*, en este caso, de la función *EarlyStopping*, que detiene el entrenamiento cuando la precisión de validación deja de mejorar después de un cierto número de épocas. Esto ayuda a evitar que el modelo siga aprendiendo los detalles específicos del conjunto de entrenamiento. También es de gran ayuda el uso de Dropout, ya que obliga a la red a aprender patrones más robustos y generalizables.

5.3.1 Simulaciones con espectrogramas

Se realizan 12 simulaciones distintas con todas las configuraciones posibles de la *Tabla 9*, tomando el espectrograma como entrada de la red. Los resultados obtenidos se recogen en la *Tabla 10*.

Color	Red	Dropout	Épocas	Train acc	Val acc
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	30%	38	0,9986	0,7167
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	20%	44	1	0,7250
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	0%	52	1	0,7583
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	30%	26	0,9792	0,5875
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	20%	37	0,9986	0,6625
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	0%	39	1	0,6417
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	30%	41	0,9986	0,6500
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	20%	28	0,9778	0,6500
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	0%	50	1	0,7083
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	30%	32	0,9889	0,5708
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	20%	30	0,9889	0,6000
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	0%	34	0,9972	0,6333

Tabla 10. Resultados obtenidos con las distintas configuraciones de simulación usando espectrogramas.

Como se ha mencionado anteriormente, para determinar el rendimiento del modelo hay que evaluar la precisión, en este caso, la precisión de validación (Val acc). Revisando la anterior tabla, se observa que el mejor resultado es proporcionado por la tercera combinación de parámetros (escala de grises, 3 capas densas y sin dropout), mientras que el peor resultado lo ofrece la décima combinación (RGB, 2 capas densas y dropout del 30%); ambos resaltados en verde y rojo respectivamente. En cualquier caso, la mayor precisión obtenida apenas supera el 75%.

DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS

Las *Figuras 38* y *39* muestran la evolución de la precisión y pérdida (*loss*) de entrenamiento frente a la evolución y pérdida de validación para las configuraciones que aportan el mejor y el peor resultado.




Figura 38. Evolución de la precisión y pérdida de la configuración óptima usando espectrogramas.




Figura 39. Evolución de la precisión y pérdida para la peor configuración usando espectrogramas.

Como puede apreciarse en ambas figuras, hay un “overfitting” considerable, evidenciado por la gran diferencia entre la precisión/pérdida en el conjunto de entrenamiento y de validación.

Observaciones generales:

- ♦ **Dropout:** un Dropout más alto (30%) lleva a una menor precisión en validación, como se observa en la peor de las configuraciones.
- ♦ **Número de capas:** las redes más profundas (con más capas convolucionales y densas) tienden a tener una mayor capacidad de representación y, por lo tanto, mejores resultados en validación, como se observa con la mejor configuración. Es por esto que, al quitar una capa densa, los resultados empeoran considerablemente.
- ♦ **Tipo de imagen (GRAY vs RGB):** las imágenes en escala de grises tienden a funcionar mejor en este conjunto de datos, como es el caso de la configuración resaltada en verde. Una configuración con imágenes RGB también alcanza una precisión de validación por encima del 70%, pero los tres mejores resultados se obtienen con imágenes en escala de grises.

5.3.2 Simulaciones con espectrogramas logarítmicos

En este caso, se reduce el número de simulaciones a la mitad, variando la tasa de Dropout entre 0% y 20%, y eliminando una capa densa. Los resultados obtenidos se resumen en la *Tabla 11*.

Color	Red	Dropout	Épocas	Train acc	Val acc
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	20%	35	0,9917	0,6917
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	20%	48	1	0,7250
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	20%	29	0,9792	0,6417
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	20%	29	1	0,6667
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	0%	40	1	0,7000
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	0%	27	0,9986	0,7792

Tabla 11. Resultados obtenidos con las distintas configuraciones de simulación usando espectrogramas logarítmicos.

DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS

El mejor resultado, resaltado en verde, lo proporciona la última configuración, constituida por la red completa en RGB y un 0% de Dropout. Mientras que la peor configuración, resaltada en rojo, es en escala de grises, quitando una capa densa y con un Dropout del 20%.

Las *Figuras 40* y *41* muestran la evolución de la precisión y pérdida de entrenamiento frente a la evolución de la precisión y pérdida de validación para las configuraciones que aportan el mejor y el peor resultado.




Figura 40. Evolución de la precisión y pérdida de la configuración óptima usando espectrogramas logarítmicos.




Figura 41. Evolución de la precisión y pérdida para la peor configuración usando espectrogramas logarítmicos.

Observaciones generales:

En general, parece que los modelos sin Dropout tienden a tener una mejor precisión de validación en comparación con los que usan un 20% de Dropout. Esto sugiere que el Dropout no está proporcionando un beneficio significativo para estos casos. No obstante, se mantiene el problema de *overfitting* anterior, habiendo una diferencia significativa entre las precisiones de entrenamiento y las de validación.

Por otra parte, los modelos entrenados con imágenes en RGB tienen a generar una mejor precisión de validación en comparación con los entrenados con imágenes en escala de grises.

5.3.3 Simulaciones con espectrogramas de Mel

Para este último grupo de simulaciones, se repiten las configuraciones del grupo anterior. La *Tabla 12* muestra los resultados obtenidos.

Color	Red	Dropout	Épocas	Train acc	Val acc
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	20%	36	0,9958	0,9625
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	20%	36	1	0,9750
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	20%	38	1	0,9542
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 2xDense	20%	35	1	0,9500
GRAY	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	0%	34	1	0,9292
RGB	C ₁ (64) – C ₂ (128) C ₃ (256) – C ₄ (512) C ₅ (512) – 3xDense	0%	30	1	0,9583

Tabla 12. Resultados obtenidos con las distintas configuraciones de simulación usando espectrogramas de Mel.

Como puede observarse, los resultados son mucho mejores en este caso, con todas las configuraciones obteniendo una precisión superior al 95% en el conjunto de validación. El mejor resultado, resaltado en verde, lo proporciona la segunda configuración, constituida por la red completa en RGB y un 20% de Dropout. Mientras que la peor configuración, resaltada en rojo, es en escala de grises, con la red completa y un Dropout del 0%.

Las *Figuras 42* y *43* muestran la evolución de la precisión y pérdida de entrenamiento frente a la evolución de la precisión y pérdida de validación para las configuraciones que aportan el mejor y el peor resultado.

DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS





Figura 42. Evolución de la precisión y pérdida de la configuración óptima usando espectrogramas de Mel.




Figura 43. Evolución de la precisión y pérdida para la peor configuración usando espectrogramas de Mel.

Observaciones generales:

En este caso, parece que el uso de Dropout tiende a mejorar ligeramente la precisión de validación en comparación con no usar Dropout. Además, existe una diferencia importante respecto a las anteriores simulaciones, siendo esta la aparente desaparición del *overfitting*, ya que los resultados en la precisión de validación apenas distan de la precisión de entrenamiento.

De nuevo, los modelos entrenados con imágenes en RGB tienden a tener mejor precisión de validación en comparación con los entrenados con imágenes en escala de grises, sugiriendo que la información de color es beneficiosa.

5.4 Discusión

El sistema desarrollado consta de dos grandes bloques. En el primero de ellos se descargan las señales de control de la base de datos PTBDB para crear una base de datos local; seguidamente, se tratan estas señales para obtener tres representaciones tiempo-frecuencia diferentes: espectrograma, espectrograma logarítmico y espectrograma de Mel. En el segundo gran bloque, las imágenes obtenidas en el bloque anterior se utilizan como parámetros de entrada para el clasificador a desarrollar, asignando a cada una de ellas una etiqueta que las relacione con el sujeto al que pertenecen. En este caso, el clasificador es una red neuronal convolucional inspirada en la CNN VGGNet, cuya arquitectura puede verse en la *Figura 36*. Por último, es preciso comprobar el funcionamiento del modelo creado, por lo que el repositorio local es dividido entre datos de entrenamiento y datos de validación o prueba, con una proporción de 75% y 25% respectivamente.

Una vez se tiene el sistema biométrico completo se realizan una serie de simulaciones con variaciones en los siguientes parámetros: representaciones $t - f$, formato de las imágenes de entrada, tasa de Dropout y número de capas que forman la red neuronal. Para poder evaluar el rendimiento de las distintas configuraciones probadas se utilizará la precisión (*accuracy*), ya que un valor elevado significa un gran rendimiento del sistema. Tras estas simulaciones, se concluye que los mejores resultados se obtienen haciendo uso del espectrograma del Mel, ya que presenta una precisión de validación superior al 95% en la mayoría de las configuraciones. Además, desaparece el problema de *overfitting* presente en las simulaciones que hacen uso del espectrograma y espectrograma logarítmico.

DESCRIPCIÓN DEL SISTEMA BIOMÉTRICO Y RESULTADOS

CAPÍTULO 6: CONCLUSIÓN Y LÍNEAS FUTURAS

En este proyecto se ha analizado el comportamiento de una red neuronal convolucional frente a la variación de una serie de parámetros que la conforman.

Las **conclusiones** obtenidas en el desarrollo de este proyecto son las siguientes:

- ◆ El espectrograma de Mel proporciona la mejor precisión de validación en comparación con el espectrograma estándar y el espectrograma logarítmico, ya que en estos últimos se produce el fenómeno de *overfitting* a la hora de entrenar el modelo.
- ◆ Generalmente, las entradas RGB tienden a proporcionar mejores resultados en comparación con las entradas en escala de grises. Esto indica que la información de color añade un valor significativo para la clasificación.
- ◆ Una tasa de Dropout del 20% parece ofrecer un buen equilibrio en los resultados, especialmente en el caso de los espectrogramas de Mel. Esto sugiere que una cierta cantidad de regularización es beneficiosa para evitar el sobreajuste sin sacrificar precisión de validación.
- ◆ Las configuraciones con más capas densas tienen a mejorar el rendimiento del sistema, especialmente en el caso de los espectrogramas de Mel y las entradas RGB, sugiriendo que una mayor capacidad de la red para aprender características complejas es beneficiosa para la clasificación.

En resumen, la configuración ideal para obtener los mejores resultados de clasificación sería el uso de espectrogramas de Mel usando imágenes RGB como entrada de la red, con una tasa de Dropout del 20% y 3 capas densas al final. Esta combinación parece capturar las características más relevantes y proporcionar la mejor precisión de validación.

En cuanto a las **líneas futuras** que presenta este trabajo, son las siguientes:

- ◆ El clasificador creado se ha probado sólo con los sujetos sanos de la base de datos utilizada (PTB). Sería interesante ver los resultados obtenidos utilizando la base de datos completa, es decir, la señales tanto de pacientes sanos como de pacientes con patologías.
- ◆ En el presente trabajo se ha utilizado una versión simplificada de la CNN VGGNet, por lo que se podría estudiar la posibilidad de desarrollar una red neuronal más compleja.
- ◆ En relación con el punto anterior, sería de gran utilidad estudiar la causa del *overfitting* presente en las simulaciones con espectrogramas y espectrogramas logarítmicos, así como el desarrollo de un modelo modificado que acabe con este problema.
- ◆ El ECG puede servir como complemento para otros sistemas biométricos, es decir, se puede estudiar la posibilidad de realizar un sistema multibiométrico.

CONCLUSIÓN Y LÍNEAS FUTURAS

Como se puede observar, se han abierto nuevas líneas de investigación para que futuros estudiantes puedan poner en práctica los conocimientos adquiridos y contribuir a una mejora en la investigación de la biometría basada en el ECG.

CAPÍTULO 7: PRESUPUESTO

Este capítulo está dedicado a la estimación de los costes necesarios para el sistema propuesto, los cuales se han dividido en diferentes categorías dependiendo de su procedencia.

7.1 Costes físicos

En la *Tabla 13* se enumeran las herramientas necesarias para el desarrollo del proyecto, ya sean *hardware* o *software*.

Concepto	Cantidad	Coste
Ordenador personal MSI GS73VR 6FR (Stealth Pro 4K) Intel Core i7-6700HQ 2 TB HDD + 512 GB SSD	1	2.382,76 €
Ordenador personal HP EliteBook x360 1030 G2 Táctil Intel Core i5-7200U 256 GB SSD	1	499,00 €
Tablet personal Samsung Galaxy Tab S6 Lite (2022)	1	319,00 €
Microsoft 365	1	69,00 €
Base de datos PTB (Physionet)	1	0 €
Entorno de desarrollo SPYDER IDE	1	0 €
Encuadernación de tomos	1	160 €

Tabla 13. Costes físicos.

7.2 Costes indirectos

En la *Tabla 14* se muestran los recursos relacionados con la alimentación del ordenador y el acceso a Internet tanto para la descarga de contenido como para la búsqueda de documentación. Son recursos clave, sin los cuales el proyecto no podría desarrollarse.

Concepto	Coste por mes	Meses	Coste
Electricidad	30 €/mes	6	180 €
Acceso a Internet	20 €/mes	6	120 €

Tabla 14. Costes indirectos.

7.3 Costes humanos

Basado en experiencias personales, el salario medio de un recién Graduado en Ingeniería de Telecomunicaciones es de 26.000,00 € brutos anuales. Suponiendo 14 pagas al año, al mes se recibirían 1.857,14 € brutos. Por tanto, el coste total de la persona trabajando en el proyecto durante 6 meses a tiempo completo sería de **13.000 €**.

7.4 Coste total

Uniando los costes de las tres categorías mencionadas se obtiene el presupuesto total del proyecto, detallado en la *Tabla 15*.

Categoría	Concepto	Coste
Costes físicos	Ordenador personal MSI	2.382,76 €
	Ordenador personal HP	499,00 €
	Tablet personal Samsung	319,00 €
	Microsoft 365	69,00 €
	Base de datos PTB (Physionet)	0 €
	Entorno de desarrollo SPYDER IDE	0 €
	Encuadernación de tomos	160 €
	Total	3.429,76 €
Costes indirectos	Electricidad	180 €
	Acceso a internet	120 €
	Total	300 €
Costes humanos	Personal	13.000 €
	Total	13.000 €
COSTE TOTAL		16.729,76 €

Tabla 15. Coste total del proyecto.

CAPÍTULO 8: IMPACTO DEL PROYECTO

El desarrollo del tema tratado en este proyecto conlleva una serie de implicaciones, las cuales se describen a continuación:

- ❖ **Implicaciones de Salud y Seguridad:** la biometría basada en ECG puede mejorar significativamente la seguridad y privacidad de la identificación de las personas. Como ya se ha comentado en anteriores capítulos, al utilizar características biométricas intrínsecas y difíciles de falsificar, como la actividad eléctrica del corazón, se reduce el riesgo de suplantación de identidad. Esto es especialmente relevante en áreas sensibles como la banca, el acceso a datos personales y los sistemas de seguridad. También puede ofrecer beneficios para la salud, ya que al estar monitorizando la actividad cardíaca, es posible detectar anomalías y potenciales problemas cardíacos en tiempo real; pudiendo salvar vidas al proporcionar alertas tempranas y permitir intervenciones médicas rápidas.
- ❖ **Implicaciones Ambientales:** la tecnología de reconocimiento biométrico basada en ECG tiene un impacto ambiental mínimo comparada con otros métodos tradicionales que requieren de tarjetas físicas o dispositivos adicionales. La reducción del uso de plásticos y otros materiales para tarjetas de identificación contribuye a la sostenibilidad ambiental.
- ❖ **Implicaciones Económicas:** implementar sistemas biométricos basados en ECG puede tener costes iniciales elevados, debido a la investigación y el desarrollo que supondría, así como la infraestructura necesaria. No obstante, a largo plazo puede resultar económicamente beneficioso, al reducir costes asociados a fraudes y la gestión de contraseñas o tarjetas físicas. Asimismo, el desarrollo y la implementación de esta tecnología pueden crear nuevas oportunidades de empleo en el sector tecnológico.
- ❖ **Implicaciones Tecnológicas:** el avance en tecnologías de procesamiento de señales y redes neuronales convolucionales es clave para el éxito de este tipo de biometría. La investigación y el desarrollo en esta área impulsan la innovación y pueden llevar a aplicaciones más avanzadas en otros campos, como la telemedicina y la salud móvil.

Además, este trabajo puede contribuir con varios Objetivos de Desarrollo Sostenibles (ODS), entre los que se encuentran:

- ❖ **Salud y bienestar (ODS 3):** al facilitar la detección temprana de problemas cardíacos y mejorar la seguridad en la identificación, se promueve el bienestar y la salud de las personas.
- ❖ **Industria, innovación e infraestructura (ODS 9):** ya que se fomenta la innovación en tecnologías biométricas y una mejora de las infraestructuras de seguridad.
- ❖ **Producción y consumo responsables (ODS 12):** reduciendo la necesidad de tarjetas físicas y otros materiales, se contribuye a una producción más sostenible y responsable.

IMPACTO DEL PROYECTO

REFERENCIAS BIBLIOGRÁFICAS

- [1] Thales Group, "Biometría para la identificación y autenticación", [en línea]. Disponible en: <https://www.thalesgroup.com/es/countries/americas/latin-america/dis/gobierno/inspiracion/biometria#:~:text=La%20biometr%C3%ADa%20es%20la%20ciencia,%22medici%C3%B3n%20del%20cuerpo%20humano%22>. [Último acceso: 28 de febrero de 2023].
- [2] D. Luengo, D. Osés y T. Trigano, "Digital signal processing of ECG and PCG signals", Cap. 28 de *Teaching and Subjects on Bio-Medical Engineering*, Acco, 2021.
- [3] Kaspersky, "What is Biometrics? How is it used in security?", [en línea]. Disponible en: <https://www.kaspersky.com/resource-center/definitions/biometrics>. [Último acceso: 28 de febrero de 2023].
- [4] BIOSYS, "¿Qué es la biometría?", [en línea]. Disponible en: <https://www.biosys.es/que-es-la-biometria/>. [Último acceso: 28 de febrero de 2023].
- [5] Y.-H. Byeon y K.-C. Kwak, "Pre-Configured deep convolutional neural networks with various time-frequency representations for biometrics from ECG signals", *Applied Sciences*, vol. 9, no. 22, p. 4810, 2019.
- [6] C. Janiesch, P. Azchech y K. Heinrich, "Machine learning and deep learning", *Electronic Markets*, vol. 31, no. 3, pp. 685-695, 2021.
- [7] L. Zhang, et al., "From machine learning to deep learning: progress in machine intelligence for rational drug discovery", *Drug Discovery Today*, vol. 22, no. 11, pp. 1680-1685, 2017.
- [8] C. Tolosa Borja y Á. Giz Bueno, "Sistemas biométricos", Disponible en: https://www.dsi.uclm.es/personal/miguelfgraciani/mikicurri/docencia/bioinformatica/web_bio/Documentacion/Trabajos/Biometria/Trabajo%20Biometria.pdf, 2006.
- [9] D. Meltzer y V. Alarcón-Aquino, "Recent advances in biometrics and its standardization: a survey", Informe Técnico, 2017.
- [10] S. Mayhew, "History of Biometrics", *Biometric Update*, [en línea]. Disponible en: <https://www.biometricupdate.com/201802/history-of-biometrics-2>. [Último acceso: 19 de abril de 2023].
- [11] J. Barnes, "El libro de referencias de las huellas dactilares", Departamento de Justicia de los Estados Unidos. Oficina de Programas de Justicia, 2014.
- [12] F. Serratos, "La biometría para la identificación de las personas", Universitat Oberta de Catalunya, 2008.
- [13] S. Raviv, "The Secret History of Facial Recognition", *WIRED*, [en línea]. Disponible en: <https://www.wired.com/story/secret-history-facial-recognition/>. [Último acceso: 22 de abril de 2023].

REFERENCIAS BIBLIOGRÁFICAS

- [14] K. R. Moses et al., "Automated fingerprint identification system (AFIS)", *The fingerprint sourcebook*, vol. 1, p. 6-1, 2011.
- [15] R. Sánchez Reillo, "El Iris Ocular como parámetro para la Identificación Biométrica", *Revista SIC – Revista de Ciberseguridad, Seguridad de la Información y Privacidad*, [en línea]. Disponible en: https://revistasic.com/revista41/agorarevista_41.htm. [Último acceso: 3 de junio de 2023].
- [16] Aware Inc., "Aware, Inc – Biometrics Software Solutions", [en línea]. Disponible en: <https://www.aware.com/automated-biometric-identification-system/#demo>. [Último acceso: 3 de junio de 2023].
- [17] A. K. Jain, A. A. Ross y K. Nandakumar, "Introduction to Biometrics", Springer, 2011.
- [18] K. Nandakumar, *Multibiometric systems: Fusion strategies and template security*, Michigan State University. Department of Computer Science and Engineering, 2008.
- [19] Wikipedia, "Confusion matrix", [en línea]. Disponible en: https://en.wikipedia.org/wiki/Confusion_matrix. [Último acceso: 19 de julio de 2023].
- [20] L. Sörnmo y P. Laguna, *Bioelectrical signal processing in cardiac and neurological applications*, Academic Press, 2005.
- [21] J. D. Bronzino, *The biomedical engineering handbook*, CRC Press Taylor & Francis Group, 2006.
- [22] Health Jade, "Mean arterial pressure definition, calculator and formula", [en línea]. Disponible en: <https://healthjade.net/mean-arterial-pressure/>. [Último acceso: 4 de febrero de 2024].
- [23] A. Gharehbaghi, M. Lindén y A. Babic, "An artificial intelligent-based model for detecting systolic pathological patterns of phonocardiogram based on time-growing neural network", *Applied Soft Computing*, 2019.
- [24] S. Krey, "Applications – Stefan Krey", [en línea]. Disponible en: <http://kreynet.de/squids/applications/>. [Último acceso: 5 de febrero de 2024].
- [25] J. R. Pinto, J. S. Cardoso y A. Lourenço, "Evolution, current challenges, and future possibilities in ECG biometrics", *IEEE Access*, vol. 6, pp. 34746-34776, 2018.
- [26] F. R. J. Lopez, O. J. Otero y G. E. R. Ramírez, "Diseño e implementación del sistema para el control de movimientos de una plataforma móvil a partir de ElectroOculografía", *Vestigium Ire*, 2008.
- [27] N. Ozkan, A. Işık y U. Fidan, "Design and acquisition of EOG based interactive communications for ALS patients", *International Journal of Applied Mathematics Electronics and Computers*, 2017.
- [28] "Application of a Heat- and Steam-Generating Sheet Increases Peripheral Blood Flow and Induces Parasympathetic Predominance", ResearchGate, [en línea]. Disponible en: <https://www.researchgate.net/figure/Sites-of->

- [electrode-placement-for-the-electrogastrography-An-indifferent-electrode-was fig4 51138513](#). [Último acceso: 18 de febrero de 2024].
- [29] "Lessons Learned: Gastric Motility Assessment During Driving Simulation", MDPI Sensors, [en línea]. Disponible en: <https://www.mdpi.com/1424-8220/19/14/3175>. [Último acceso: 18 de febrero de 2024].
- [30] "Electromiografía: Principio De Funcionamiento y Aplicaciones En La Medicina", Electropreguntas, [en línea]. Disponible en: <https://electropreguntas.com/electromiografia-principio-de-funcionamiento-y-aplicaciones-en-la-medicina/>. [Último acceso: 18 de febrero de 2024].
- [31] S. E. Mulrone y A. K. Myers, *Netter. Fundamentos de fisiología*, Elsevier Health Sciences Spain, 2016.
- [32] "Electrocardiografía básica", *Guiones para la práctica clínica*. UCM – Facultad de Medicina.
- [33] A. C. Vinzio Maggio, et al., "Quantification of ventricular repolarization dispersion using digital processing of the surface ECG", *Advances in Electrocardiograms-Methods and Analysis*, pp. 181-206, 2012.
- [34] A. K. Jain, P. Flynn y A. A. Ross, Eds., *Handbook of Biometrics*, Springer US, 2008.
- [35] P. Bontrager, et al., "DeepMasterPrints: Generating MasterPrints for Dictionary Attacks via Latent Variable Evolution", en *2018 IEEE 9th International Conference on Biometrics Theory, Applications and Systems (BTAS)*, pp. 1-9, 2018.
- [36] Z. Wei, et al., "Counterfeit iris detection based on texture analysis", en *19th IEEE International Conference on Pattern Recognition*, pp. 1-4, 2008.
- [37] S. Singh y S. V. A. V. Prasad, "Techniques and challenges of face recognition: A critical review", *Procedia Computer Science*, vol. 143, pp. 536-543, 2018.
- [38] Threatpost, "Black Hat 2018: Voice Authentication is Broken, Researchers Say", [en línea]. Disponible en: <https://threatpost.com/black-hat-2018-voice-authentication-is-broken-researchers-say/134926/>. [Último acceso: 23 de abril de 2024].
- [39] K. Yamamoto, R. Hiromatsu y T. Ohtsuki, "ECG signal reconstruction via Doppler sensor by hybrid deep learning model with CNN and LSTM", *IEEE Access*, vol. 8, pp. 130551-130560, 2020.
- [40] L. M. Casas Quiroz, "Aplicación para la detección de arritmias basado en los Algoritmos de Pan Tompkins, Elgendi y Boonperm", Tesis para optar el Título Profesional de Ingeniero de Sistemas, Universidad de Lima, 2021.
- [41] "Algoritmo de Pan Tompkins (QRS)", Google Docs, [en línea]. Disponible en: https://docs.google.com/document/d/1Wxa7u0gtGcF_A-ayon7RUWa0mI0yvgcFW05APOE9vD8/preview?hgd=1. [Último acceso: 10 de mayo de 2024].
- [42] J. Pan y W. J. Tompkins, "A real-time QRS detection algorithm", *IEEE Transactions on Biomedical Engineering*, no. 3, pp. 230-236, 1985.

REFERENCIAS BIBLIOGRÁFICAS

- [43] T. Choudhary y M. S. Manikandan, "A novel unified framework for noise-robust ECG-based biometric authentication", en *2nd IEEE International Conference on Signal Processing and Integrated Networks (SPIN)*, , pp. 186-191, 2015.
- [44] S. Saechia, J. Koseeyaporn y P. Wardkein, "Human identification system based ECG signal", en *TENCON 2005-2005 IEEE Region 10 Conference*, pp. 1-4, 2005.
- [45] N. Belgacem, et al., "ECG based human authentication using wavelets and random forests", *Int. J. Cryptogr. Inf. Secur.*, vol. 2, no. 2, pp. 1-11, 2012.
- [46] K. N. Plataniotis, D. Hatzinakos y J. K. M. Lee, "ECG biometric recognition without fiducial detection", en *IEEE Biometrics Symposium: Special Session on Research at the Biometric Consortium Conference*, pp. 1-6, 2006.
- [47] W. Louis, M. Komeili y D. Hatzinakos, "Continuous authentication using one-dimensional multi-resolution local binary patterns (1DMRLBP) in ECG biometrics", *IEEE Transactions on Information Forensics and Security*, vol. 11, no. 12, pp. 2818-2832, 2016.
- [48] G. Garcia Molina, et al., "Morphological synthesis of ECG signals for person authentication", en *15th European Signal Processing Conference*, pp. 738-742, 2007.
- [49] L. Biel, et al., "ECG analysis: a new approach in human identification", *IEEE Transactions on Instrumentation and Measurement*, vol. 50, no. 3, pp. 808-812, 2001.
- [50] S. A. Israel, et al., "ECG to identify individuals", *Pattern Recognition*, vol. 38, no. 1, pp. 133-142, 2005.
- [51] F. Agrafioti y D. Hatzinakos, "ECG based recognition using second order statistics", en *6th IEEE Annual Communication Networks and Services Research Conference (CNSR 2008)*, pp. 82-87, 2008.
- [52] M. Hejazi, et al., "ECG biometric authentication based on non-fiducial approach using kernel methods", *Digital Signal Processing*, vol. 52, pp. 72-86, 2016.
- [53] I. Steinwart y A. Christmann, *Support Vector Machines*, Springer Science & Business Media, 2008.
- [54] C. M. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [55] I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning*, MIT Press, 2016.
- [56] V. R. Zuluaga, "Actividad Eléctrica", *GoConqr*, [en línea]. Disponible en: <https://www.goconqr.com/mapamental/9701010/actividad-electrica>. [Último acceso: 26 de junio de 2024].
- [57] J. E. Hall, *Guyton & Hall. Tratado de fisiología médica*, Elsevier Health Sciences, 2021.
- [58] S. Mok, S. Park y M. Whang, "Examining the Impact of Digital Human Gaze Expressions on Engagement Induction", *Biomimetics*, vol. 8, no. 8, p. 610, 2023.

- [59] J. Ding, et al., "Reduction in the motion artifacts in noncontact ECG measurements using a novel designed electrode structure", *Sensors*, vol. 23, no 2, p. 956, 2023.
- [60] H. Meng, et al., "Speech emotion recognition from 3D log-mel spectrograms with deep learning network", *IEEE access*, vol. 7, pp. 125868-125881, 2019.
- [61] Z. Lu, Y. Liu y Q. Li, "A Research on the Academic System in Universities Basen on the One-Hot Encoding PAC Fuzzy Comprehensive Evaluation Algorithm", *International Conference on Innovative Computing*, Singapore: Springer Nature Singapore, pp. 224-235, 2024.