



Universidad Católica
San Pablo

FACULTAD DE INGENIERÍA Y COMPUTACIÓN
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA Y
ELECTRÓNICA

Escuela Profesional de Ingeniería Electrónica y de
Telecomunicaciones

Tesis

**Diseño e implementación de un método para el
reconocimiento de patrones biométricos de las venas de
la muñeca mediante luz infrarroja**

Autor: Bach. Jasmine Fiorella Aquisé Cardenas

Asesor: Dr. Efrain Jose Zenteno Bolaños

Documento presentado a la Escuela Profesional de Ingeniería Electrónica y de Telecomunicaciones como parte de los requisitos para obtener el título profesional de Ingeniero Electrónico y de Telecomunicaciones

Arequipa, octubre de 2022

Trabajo de Titulación Final_v.1

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	es.scribd.com Fuente de Internet	1%
2	pure.tue.nl Fuente de Internet	<1%
3	hdl.handle.net Fuente de Internet	<1%
4	Submitted to Hong Kong University of Science and Technology Trabajo del estudiante	<1%
5	Álvaro Andrés Amaya Vesga, Raúl Armando Gómez Tarazona, Yeisson Ricardo Mendoza Castellanos, Astrid Carolina Carvajal Grimaldos et al. "Experimentos en el aula para la demostración de los fenómenos de fluorescencia, fosforescencia y quimioluminiscencia", Educación Química, 2022 Publicación	<1%
6	dblp.uni-trier.de Fuente de Internet	<1%

Figura 1: Índice de Puntuación de Similitud.

Índice general

Abstract	1
Resumen	3
1. Introducción	5
1.1. Motivación y contexto	5
1.2. Planteamiento del problema	6
1.3. Objetivos	6
1.3.1. Objetivo general	6
1.3.2. Objetivos específicos	6
1.4. Metodología	6
1.4.1. Línea(s) de investigación	6
1.4.2. Tipo de investigación	7
1.4.3. Métodos para experimentos y pruebas	7
1.4.4. Formas de comprobación	8
1.5. Consideraciones Complementarias	8
1.5.1. Recursos y Materiales	8
1.5.2. Cronograma de Trabajo	9
2. Marco Teórico	11
2.1. Biometría	11
2.1.1. Sistemas comerciales biométricos	11
2.2. Radiación infrarrojo (IR)	11
2.2.1. Propiedades de la luz	12
2.2.2. Ventanas del IR	12
2.2.3. Parámetros de seguridad del IR	12
2.2.4. Aplicaciones del IR	12
2.3. Sistemas de Reconocimiento	12
2.3.1. Vulnerabilidad de los sistemas de biométricos	13
2.4. Procesamiento digital de imágenes	14
2.4.1. Requerimientos	14
2.4.2. Métodos	14
2.4.3. Aplicaciones	22
2.5. Clasificación de imágenes	22
2.5.1. k -Vecino más cercano o k -Nearest Neighbor (KNN)	22
2.5.2. Comparación de plantillas - <i>Template Matching</i>	23
3. Antecedentes	27
3.1. Adquisición de muestras	27
3.2. Pre-procesamiento	29
3.3. Extracción de características	29
3.4. Clasificación	30

4. Propuesta de Solución	31
4.1. Diseño y construcción del sistema	31
4.1.1. Hardware	31
4.1.2. Ensamble final del sistema	33
4.2. Estructura externa del sistema	34
4.2.1. Primera fase	34
4.2.2. Segunda fase	35
4.3. Creación de la base de datos	35
4.3.1. Primera versión base de datos	35
4.3.2. Segunda versión base de datos	36
4.3.3. Tercera versión base de datos	36
4.4. Pre-procesamiento	37
4.4.1. Máscara	38
4.4.2. Filtro paso altas	38
4.4.3. Filtro de mediana	39
4.4.4. Enmascaramiento	39
4.4.5. Erosión	40
4.4.6. Esqueletización	40
4.4.7. Plantilla	41
4.5. Decisión - Reconocimiento	41
5. Resultados y Comparaciones	45
5.1. Comparación de plantillas	45
6. Conclusiones y trabajos futuros	51
6.1. Conclusiones	51
6.2. Trabajos Futuros	52

Índice de figuras

1.	Índice de Puntuación de Similitud.	I
1.1.	Diagrama de flujo que sintetiza las etapas a seguir en la presente tesis.	7
2.1.	Sistemas de reconocimiento versus la dificultad de clonación de patrones biométricos versus la tecnología empleada en ellos. (Imagen adaptada de [MJ08]).	13
2.2.	Diagrama de flujo para filtrar una imagen en el dominio frecuencial mediante la transformada de Fourier.	15
2.3.	Representación gráfica de un filtro Gaussiano paso alta: (a) Izquierda, mapa de calor y (b) Derecha, sección transversal del filtro paso alta.	15
2.4.	(a) Ruido sal y pimienta, (b) y (c) Uso del filtro de mediana con kernel de dimensión 3 y 5 respectivamente.	16
2.5.	(a) Imagen original, (b) y (c) Uso del Filtro Sobel sobre los ejes “X” y “Y” respectivamente.	16
2.6.	(a) Imagen de interés e (b) Histograma generado en base a los valores de los píxeles de la imagen de interés.	17
2.7.	(a) Imagen original, (b) y (c) Resultados de la operación de segmentación con umbrales de 100 y 150 respectivamente.	18
2.8.	(a) Imagen original, (b) y (c) Resultados de la operación de segmentación con un umbral de 100 y mediante el método Otsu respectivamente.	19
2.9.	(a) Imagen original, (b) y (c) Uso del operador de erosión con kernel de dimensión 3 y 5 respectivamente.	19
2.10.	(a) Imagen original, (b) y (c) Uso del operador de dilatación con kernel de dimensión 3 y 5 respectivamente.	20
2.11.	(a) Imagen original, (b) Detección de esquinas, (c) Extracción de puntos invariantes y (d) Detección de círculos.	20
2.12.	Arquitectura AlexNet introducida por [KSH12] <i>et al.</i>	21
2.13.	K-Vecinos más cercanos aplicado a un problema de dos clases.	22
2.14.	Proceso de la comparación de plantillas o <i>template matching</i> sobre una sección de dimensión 3x3 dada una imagen de interés y una plantilla correspondiente.	24
2.15.	(a) Imagen original, (b) Plantilla o <i>template</i> , (c) Mapa de calor generado luego de haber aplicado una operación de convolución entre la imagen original y la plantilla, y (d) Resultado de la comparación de plantilla.	25
3.1.	Adquisición de muestras sin contacto: (a) Equipo de adquisición y (b) captura de la muestra. Imagen extraída de [KDN ⁺ 22].	28
3.2.	Adquisición de muestras sin contacto: (a)(c) Procedimiento de captura y (b)(d) resultado de la captura. Imagen extraída de [LGBHA22].	28

4.1.	Diagrama de bloques correspondiente a la propuesta de solución para el sistema de reconocimiento de patrones biométricos.	31
4.2.	Diagrama de componentes del hardware del sistema biométrico. . . .	32
4.3.	(a) Sistema de recolección de datos en estado apagado y (b) en estado encendido.	34
4.4.	Primer diseño de la estructura externa del sistema de reconocimiento de patrones biométricos: (a) Vista interior y (b) Vista exterior. . . .	34
4.5.	Segundo diseño de la estructura externa del sistema de reconocimiento de patrones biométricos.	35
4.6.	Muestra de 160 x 128 píxeles extraída de la segunda versión de la base de datos.	36
4.7.	Muestra de 160 x 128 píxeles más la región de interés extraída de la tercera versión de la base de datos.	36
4.8.	Gráfico de barras de la distribución de la base de datos final.	37
4.9.	Diagrama de bloques para la etapa de pre-procesamiento.	37
4.10.	(a) Imagen original y (b) máscara.	38
4.11.	(a) Imagen original e (b) imagen filtrada con un filtro paso altas. . . .	38
4.12.	(a) Imagen original e (b) imagen filtrada con un filtro de mediana. . . .	39
4.13.	(a) Imagen original y (b) objeto de interés obtenido.	39
4.14.	(a) Imagen original e (b) imagen resultante luego de enmascarar. . . .	40
4.15.	(a) Imagen original e (b) imagen resultante luego de erosionar.	40
4.16.	(a) Imagen original y (b) esqueleto resultante.	41
4.17.	(a) Imagen original y (b) Plantilla.	41
4.18.	Técnicas empleadas para el reconocimiento de usuarios.	42
4.19.	Extracción de características utilizando una red neuronal convolucional. . . .	42
4.20.	Matriz similitud de coseno.	43
5.1.	Matriz de confusión para el segundo experimento utilizando una única plantilla.	46
5.2.	Matriz de confusión para el segundo experimento utilizando 5 plantillas. . . .	46
5.3.	Matriz de confusión para el tercer experimento utilizando única plantilla y con las muestras giradas.	47
5.4.	Matriz de confusión para el segundo experimento utilizando la técnica de similitud de coseno.	48
5.5.	Venas dorsales de la mano (izquierda) y sus respectivos esqueletos (derecha).	49

Índice de cuadros

1.1. Recursos y materiales para el desarrollo del sistema.	8
1.2. Cronograma de trabajo acorde al diagrama de flujo del diseño del sistema.	9
2.1. Configuración de la arquitectura AlexNet [KSH12].	21
3.1. Recopilación de diferentes bases de datos en biometría vascular.	29
4.1. Características electro-ópticas y parámetros de voltaje en tensión directa del Led IR333-A de 940nm. y Led 850nm.	32
4.2. Distribución de la base de datos final.	37
5.1. Resultados obtenidos en los experimentos realizados con la técnica de comparación de plantillas.	45
5.2. Resultados obtenidos en los experimentos realizados con la técnica de comparación de plantillas (plantillas giradas).	47
5.3. Resultados obtenidos en los experimentos realizados con la técnica de similitud de coseno.	48
5.4. Resultados obtenidos en los experimentos realizados con la técnica de similitud de coseno.	49

Abstract

There are different biometric systems for user recognition, but at a technological and commercial level, systems based on vascular patterns only make up 3% of commercial technology. These systems are characterized by having a high computational cost, being expensive and bulky.

In this sense and in order to produce a system with low production cost, portability, this thesis proposes the development of a method for recognizing biometric patterns of the veins of the wrist. Such a method is integrated by the coupling of several phases such as hardware design, system construction, database creation, image processing software implementation, system testing and final system evaluation. The techniques addressed are divided into two groups: (1) The techniques corresponding to the pre-processing of the acquired images and (2) the techniques for the classification of users. Among the techniques for pre-processing, use is made of a filter stack and morphological operations. While among the techniques for user classification, the template matching and feature extraction is reviewed by means of a convolutional neural network, these features being classified considering the cosine similarity distance.

Portability is one of the greatest qualities of this proposed system, the results obtained are proof that it is possible to easily and correctly identify a person according to the biometric patterns of their wrist veins with an embedded system, giving us a range of possibilities for future applications such as security systems, strongboxes or locks for restricted areas.

Keywords: wrist-vein authentication, biometrics, wrist-vein, feature extraction, pattern recognition, classification, machine learning, identity validation, wrist-vein extraction.

Resumen

Existen diferentes sistemas biométricos para el reconocimiento de usuarios pero a nivel tecnológico y comercial los sistemas basados en los patrones vasculares solo conforman el 3% de la tecnología comercial. Dichos sistemas se caracterizan por tener un alto coste computacional, ser caros y voluminosos.

En tal sentido y con la finalidad de producir un sistema con bajo coste de producción, portabilidad, esta tesis propone el desarrollo de un método de reconocimiento de patrones biométricos de las venas de la muñeca. Tal método está integrado por el acoplamiento de varias fases tales como la diseño del hardware, construcción del sistema, la creación de la base de datos, implementación del software para el procesamiento de imágenes, pruebas del sistema y evaluación final del sistema. Las técnicas abordadas son divididas en dos grupos: (1) Las técnicas correspondientes al pre-procesamiento de las imágenes adquiridas y (2) las técnicas para la clasificación de usuarios. Entre las técnicas para el pre-procesamiento se hace uso de una pila de filtros y operaciones morfológicas. Mientras que entre las técnicas para clasificación de usuarios se revisa la comparación de plantillas y extracción de características por medio de una red neuronal convolucional, siendo estas características clasificadas considerando la distancia similitud de coseno.

La portabilidad es una de las mas grandes cualidades que posee este sistema propuesto, los resultados obtenidos son prueba de que es posible identificar de manera sencilla y correcta a una persona acorde a los patrones biométricos de las venas de sus muñeca con un sistema embebido, dando así un abanico de posibilidades a las futuras aplicaciones tales como sistemas de seguridad, cajas fuertes o cerraduras de áreas restringidas.

Palabras clave: Identificación de venas de la muñeca, biometría, vena de la muñeca, extracción de características, reconocimiento de patrones, aprendizaje automático, procesamiento digital de imágenes

Capítulo 1

Introducción

En estos últimos años, el desarrollo en el campo biométrico se ha revitalizado paralelamente con el avance tecnológico en dispositivos móviles, claro ejemplo de esto fue el uso de la huella dactilar como medio de identificación, a ello y aprovechando la cámara frontal de estos siguió el reconocimiento de características faciales aún cuando el usuario portaba accesorios como lentes o mascarillas. Sumado a ello, en el mercado de soluciones biométricas se encuentra una amplia gama de métodos menos convencionales que utilizan los patrones vasculares [AMR⁺21], el iris de los ojos [CRM⁺21], la voz [ZXDX18, KDN⁺20] o incluso el lóbulo de las orejas [KRN22] como único método de identificación (llave o contraseña) para un usuario.

Cada una de estas soluciones pueden ser clasificadas según su nivel de robustez (cuán difícil representa para un intruso replicar la identidad de un usuario). En consecuencia, los sistemas basados en patrones biométricos se sitúan en la cúspide siendo los más robustos, mientras que los basados en huella dactilar son los más fáciles de replicar. Sin embargo, un factor inversamente proporcional a su robustez es el grado de complejidad de tales sistemas, siendo que dicha complejidad se traduce en un incremento en su coste de producción.

Por lo que sujeto a la continua evolución tecnológica es necesaria la demanda de nuevos sistemas biométricos que otorguen una alta fiabilidad de seguridad en identificación y autenticación de usuarios. Impulsados por ello, la presente tesis tiene como objetivo la implementación de un sistema capaz de reconocer a una persona a partir de sus patrones biométricos vasculares de la muñeca. Por tanto se abordan temas como: La biometría, procesamiento de imágenes, radiación infrarroja, sistemas de reconocimiento, métodos de comparación y validación de estos mismos. Así mismo, esta propuesta desarrolla el hardware basado en radiación infrarroja y el software implementado en Python, soportados en la plataforma de la Raspberry Pi, dando así un sistema portátil, embebido y open source lo que quiere decir que no necesitamos licencias.

1.1. Motivación y contexto

La motivación es brindar un método capaz de reconocer los patrones biométricos de las venas de la muñeca, para generar una futura aplicación en el ámbito de control de acceso en áreas restringidas. Por ende se busca dar una solución viable, cuyas propiedades sean: La portabilidad, la seguridad, y al ser en Python garantizamos que sea de código abierto, incluso para un uso comercial.

En el ámbito de la biometría el contexto actual es que las áreas que están más desarrolladas a nivel comercial son los sistemas basados en la huella digital, el iris y el rostro pero en el mismo grado de desarrollo, existe un alto grado de vulnerabilidad en estos sistemas de seguridad. Esto debido a que la dificultad de clonación de la

huella digital, el iris y el rostro es baja. Por otro lado, la dificultad de clonación de las venas es alta, ya que para obtener imágenes del sistema vascular se requiere tecnología poco convencional. A pesar de esa ventaja a nivel comercial el principal problema es que son escasas las empresas que desarrollan sistemas basados en la biometría vascular [XS08, GMSR20].

Al ser escasas las alternativas comerciales en el mercado, nuestra principal motivación es crear un sistema que sea tanto hardware como software es decir un sistema embebido y así poder dar una solución integral a esta problemática.

1.2. Planteamiento del problema

Por lo expuesto en la Sección 1.1, se concluye que el problema en la biometría es que existe un alto grado de vulnerabilidad en los sistemas convencionales y existe una carencia de sistemas comerciales basados en la biometría de las venas.

Es decir el problema principal es la facilidad con la que se puede replicar una huella digital, un rostro e incluso el iris, esto seguido al hecho de que en el mercado tecnológico no se ven otras opciones comerciales. Ello da como resultado que las personas se limiten a lo que las empresas venden, sin conocer que existen mejores métodos de reconocimiento de personas [XS08].

1.3. Objetivos

1.3.1. Objetivo general

Diseñar, implementar y validar un sistema para el reconocimiento de patrones biométricos de las venas de la muñeca mediante luz infrarroja.

1.3.2. Objetivos específicos

1. Diseñar, implementar y validar el Hardware del sistema de reconocimiento.
2. Crear una base de datos, compuesta por venas de la muñeca de diferentes usuarios.
3. Diseñar, implementar y validar el Software para el reconocimiento de usuarios.
4. Integrar y evaluar el funcionamiento del sistema de reconocimiento biométrico.

1.4. Metodología

1.4.1. Línea(s) de investigación

Las líneas sectoriales de la Escuela Profesional (EP) de Ingeniería Electrónica y de Telecomunicaciones (IET) son las siguientes, y se debe consignar aquí aquella en la que más encaje el proyecto de tesis:

1. Procesamiento de señales y datos.

Se trata de un trabajo multidisciplinar.

El presente trabajo se encuentra alineado de manera transversal en la línea matricial UCSP de:

1. Tecnología para el desarrollo.

1.4.2. Tipo de investigación

Este proyecto de tesis tiene un fin de desarrollo tecnológico en el área señales y datos para el reconocimiento de usuarios por medio de imágenes de venas de las muñecas en las manos.

1.4.3. Métodos para experimentos y pruebas

Para lograr diseñar e implementar un método de reconocimiento de patrones biométricos de venas con radiación infrarroja es necesario dividir el trabajo por etapas las cuales se detallan en la siguiente Figura 1.1.

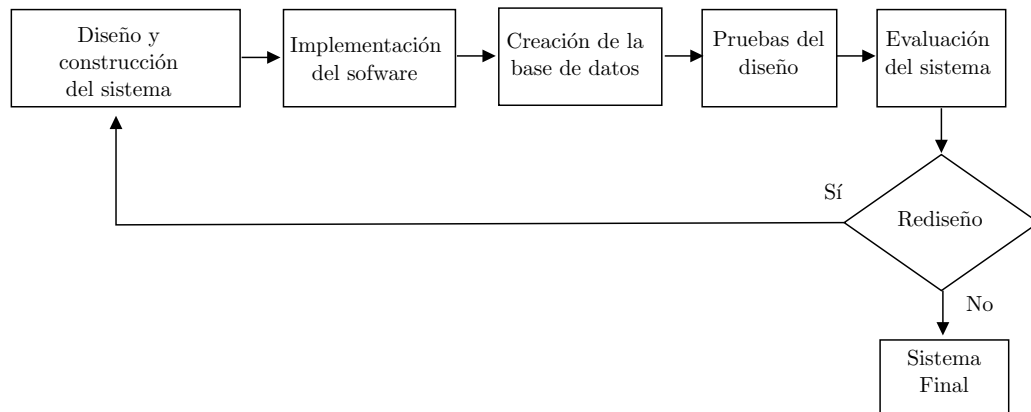


Figura 1.1: Diagrama de flujo que sintetiza las etapas a seguir en la presente tesis.

Del diagrama de flujo se entiende lo siguiente:

1. La primera etapa, es el diseño del sistema, es la formulación de los requerimientos que este posee, es decir las necesidades físicas y lógicas que este requiera.
2. La segunda etapa, es la implementación del sistema en hardware y software, previamente diseñado.
3. La tercera etapa, se crea la base de datos utilizando el hardware y software implementado y la participación de un grupo personas dispuestas a contribuir con el trabajo.
4. La cuarta etapa, se procede a optimizar los resultados del sistema.
5. La quinta etapa, se evalúan los resultados obtenidos en la optimización.
6. La sexta etapa, es una etapa fundamental pues en esta se ve si es posible o es necesario mejorar el sistema, siendo una etapa de decisión, será necesario regresar a la cuarta etapa de optimización si es necesaria la mejora, caso contrario se procede a la siguiente etapa.
7. La séptima etapa, es la culminación del diseño e implementación de nuestro método de reconocimiento de patrones biométricos de venas con radiación infrarroja.

1.4.4. Formas de comprobación

La forma de comprobar la eficacia del sistema propuesto el cual comprende las etapas antes descritas es mediante la tasa de exactitud obtenida en la clasificación de usuarios utilizando como característica los patrones en las venas de las muñecas. Por otro lado, la aplicación más clara que se le puede brindar a este método propuesto, está en el ámbito de la seguridad es decir la identificación de personas y control de acceso en áreas restringidas [SB04]. Dando cabida a que las empresas tengan un nuevo método portátil por el cuál optar. Debido a que en la actualidad existen métodos para vulnerar los sistemas de seguridad que antes se creían seguros (incluso la huella digital puede ser clonada de forma muy sencilla con tan sólo colocar un dedo sobre una superficie cualquiera la huella puede ser replicada [COTQM⁺15]). Es decir, a medida que la tecnología avanza con ella mejoran los métodos delictivos y ante ello la innovación de los sistemas de seguridad es sumamente necesaria.

1.5. Consideraciones Complementarias

1.5.1. Recursos y Materiales

Para el desarrollo de esta tesis fueron necesarios los siguientes elementos listados en el Cuadro 1.1.

Tipo	Recursos	Descripción	Costo S
Hardware	RaspberryPi 3	Computador reducido de bajo coste.	120
Hardware	Micro SD 16GB clase 10	Donde portar el software "Raspian" el cual es open source.	40
Hardware	Pantalla, teclado y ratón	Como entradas y/o salidas del sistema.	20
Hardware	Cables	VGA, HDMI interfaces de conexión.	20
Hardware	Leds IR Infra Rojos Emisores	Permitirá incrementar la claridad de las imágenes captadas. En formato array.	24
Hardware	Fuentes de alimentación constante 5v	Para alimentar los Leds IR con un voltaje constante.	10
Hardware	Módulo de Cámara IR de la Raspberry Pi	Permitirá captar imágenes en la frecuencia de IR, cuenta con dos leds IR como parte del diseño.	50
Hardware	Caja de cartón negro	Como estructura de portabilidad y obtención de datos. (Primera fase de diseño de cartón).	50
Hardware	Caja de MDF	Como estructura de portabilidad y obtención de datos. (Segunda fase de diseño de MDF).	15
Hardware	Otros	Pegamentos, conectores eléctricos cutter, pistolas de soldar, etc.	10
Fuentes	Libros, Scopus, bases de datos de revistas indexadas i.e. IEEE, etc.	El material usado se encuentra en la biblioteca u obtenida de la base de datos de la IEEE, u otros servidores.	0

Cuadro 1.1: Recursos y materiales para el desarrollo del sistema.

1.5.2. Cronograma de Trabajo

El siguiente Cuadro detalla el cronograma de trabajo 1.2.

Primera Etapa	Semana 3 de Abril del 2022	Diseñar sistema.
Segunda Etapa	Semanas 4 a 5 de Abril del 2022	Implementar sistema.
Tercera Etapa	Mes de Mayo del 2022	Crear la base de datos.
Cuarta Etapa	Mes de Junio del 2022	Optimizar sistema.
Quinta Etapa	Mes de Julio del 2022	Evaluar sistema.
Sexta Etapa	Mes de Agosto del 2022	Mejora - Rediseño.
Séptima Etapa	Mes de Septiembre del 2022	Sistema final.

Cuadro 1.2: Cronograma de trabajo acorde al diagrama de flujo del diseño del sistema.

Organización del Presente Documento

En el Capítulo 2 se presenta el sustento teórico de esta tesis mientras que el Capítulo 3 explora las investigaciones relacionadas a nuestro sistema de forma cronológica. En el Capítulo 4 se desarrolla la propuesta del diseño de un método capaz de reconocer los patrones biométricos de las venas. Por otro lado, el Capítulo 5 expone los resultados obtenidos bajo nuestra propuesta. Finalmente, el Capítulo 6 presenta las conclusiones así como ideas para posibles trabajos futuros.

Capítulo 2

Marco Teórico

2.1. Biometría

Como se menciona en el Capítulo 1, la biometría es el estudio que indica que se puede reconocer a una persona por medio de sus características físicas irrepetibles, tales como: El iris, la huella digital, el ADN, las venas del sistema vascular, la geometría del rostro, entre otros [RRO09]. Por tanto, mediante el procesamiento de la información biométrica se pueden desarrollar sistemas de autenticación que brinden seguridad a empresas, instituciones o en soluciones diversas [SB04].

2.1.1. Sistemas comerciales biométricos

Según el estudio: “Mercado tecnológico biométrico” del *International Biometric Group*, las tecnologías más utilizadas en el ámbito de sistemas de seguridad por patrones biométricos son: reconocimiento dactilar de personas equivalen al 35 %, en la huella digital es de 25.3 %, voz 14 %, reconocimiento del rostro 12.9 % , iris son un 5.1 % , geometría de la mano 4.7 %, mientras que los sistemas desarrollados a base del reconocimiento de venas apenas llegan al 3 % [XS08], es decir el reconocimiento biométrico de venas está poco explotado comercialmente.

2.2. Radiación infrarrojo (IR)

El espectro electromagnético está dividido en ionizante y no ionizante, de acuerdo a sus diferentes longitudes de onda. Las ondas ionizantes son aquellas que están por encima del espectro visible, es decir las ondas ultravioleta o los rayos gamma cuyas frecuencias son tan altas que son capaces de destruir a nivel atómico. Dicho de otra forma ionizan un átomo, lo cargan de forma negativa y provocan su inestabilidad. Esto en seres vivos genera un daño a nivel celular, pues los átomos que componen las células son destruidos [Ser18]. A las ondas ionizantes se les considera como parte de las principales causas del origen del cáncer, ya que cuando un grupo de células muere, ese daño se extiende y se genera dicho mal.

Por otra parte, las ondas no ionizantes están compuestas por las ondas de radio, las infrarrojas y la luz visible. Estas son llamadas también “no dañinas”, dado que estas no perjudican a los seres vivos ya que sus frecuencias son muy bajas como para causar daño. Para el desarrollo de esta tesis se verá a profundidad el espectro infrarrojo, el cuál es capaz de realizar la visualización y canalización de venas que determina la oxigenación de la sangre [Cha98], tratar la celulitis [AT05], para la calvicie y terapia muscular [Mor11], tratamiento para el cáncer [Wan11]. Por lo que, entre tantas aplicaciones que se le pueden otorgar, y movidos por nuestro fin de

proponer un nuevo método para el reconocimiento de patrones vasculares, usaremos esta banda de frecuencias.

Y ¿Por qué la radiación infrarroja posee tantos usos?, básicamente porque: Permite analizar tejido sin dañarlo [Cha98], su efecto calorífico posee propiedades regenerativas [AT05], ayuda a la vascularización y posee propiedades analgésicas por su efecto calorífico [Wan11], es relajante tonificante muscular y estimulador de la vascularización [Mor11].

2.2.1. Propiedades de la luz

- La luz se propaga en línea recta: extendida en forma de haz, se propaga en línea recta.
- La luz se refleja: retorna en dirección opuesta a la que va después de incidir en una superficie.
- La luz se refracta: después de incidir en un medio, esta es absorbida en cierta proporción provocando reflexión.
- Ley de absorción selectiva de la luz: de acuerdo a la longitud de onda a la que los átomos de un material vibran, la luz puede ser absorbida en un 100 % o no, por ejemplo: Una luz roja en un medio rojo es absorbida por completo viéndose negra.

2.2.2. Ventanas del IR

Las frecuencias que componen los rangos de la radiación infrarroja son:

- IR A cuyo rango es de 780 - 1400nm.
- IR B cuyo rango es de 1400 - 3000nm.
- IR C cuyo rango es de 3000 - 10000nm.

2.2.3. Parámetros de seguridad del IR

La densidad de energía que ha sido encontrada como el parámetro de seguridad ante la exposición de la radiación infrarroja es de $1317.3 \pm 44.84 \text{ Ws/cm}^2$, (durante 1800 segundos). Este valor se entiende como la intensidad máxima ha ser aplicada en una personas, por un periodo de media hora como máximo, esto antes de generar molestias significativas por el efecto térmico [LLCC06].

2.2.4. Aplicaciones del IR

Existen distintas aplicaciones tales como la terapia para el cáncer, pupilometría no invasiva, neuroimágenes no invasiva, determinación de la oxigenación de la sangre, método para tratar la insuficiencia varicosa, terapia contra toxinas, regeneración a nivel retina, termografía para la evaluación no destructiva, terapia muscular y tratamiento para la celulitis.

2.3. Sistemas de Reconocimiento

Los sistemas de reconocimiento poseen un principio simple el cual es primero generar la obtención de datos o información, proceden al almacenamiento, para luego de un proceso de clasificación poder obtener el reconocimiento. Sea cual sea el

método de clasificación es posible afirmar que no se garantiza el 100% de precisión o confiabilidad [SS94].

Existen sistemas tales como: El reconocimiento de huellas digitales, simetría del iris, simetría del sistema vascular, tarjetas, *tags* o *tokens*.

2.3.1. Vulnerabilidad de los sistemas de biométricos

De la misma manera en que se han desarrollado sistemas de seguridad basado en la biometría, se han desarrollado métodos y/o formas de vulnerarlos es decir el grado de factibilidad de falsificar los datos biométricos [Ish10]. Como se detalla en la siguiente Figura 2.1.

GRADO DE DIFICULTAD PARA LA FALSIFICACIÓN					
			TECNOLOGÍA NO ESPECIAL	TECNOLOGÍA CONVENCIONAL	TECNOLOGÍA ESPECIAL
DIFICULTAD DE REPLICACIÓN					VENAS DEL DEDO
	ROSTRO	IRIS	VENAS		
	Huella Digital				
	DIFICULTAD DE ADQUISICIÓN DE LA DATA BIOMÉTRICA				

Figura 2.1: Sistemas de reconocimiento versus la dificultad de clonación de patrones biométricos versus la tecnología empleada en ellos. (Imagen adaptada de [MJ08]).

Como se puede apreciar en la Figura 2.1, la huella digital está en un grado de fácil replicación, ya que las huellas digitales las dejamos de manera inevitable al tacto de cualquier superficie. En el caso de rostro con una cámara normal y una impresora se puede replicar de igual manera. En el caso del reconocimiento de iris, a pesar de ser un método seguro, no es muy utilizado, por lo incomodo que resulta la cercanía de aparatos a una zona tan delicada.

Por otra parte, el sistema vascular posee patrones únicos que son extraídos mediante una cámara sensible a la radiación infrarroja, la cual aparte de ser un método no invasivo proporciona una imagen clara de las venas gracias a la propiedad de absorción selectiva de la radiación. Para la replicación del sistema vascular se requiere un alto grado de cercanía a la persona y una tecnología no convencional, es decir es más complicada su replicación haciéndolo menos vulnerable.

Por último, se observa que los sistemas biométricos de las venas de los dedos son sumamente complejos y seguros. También son incluso más robustos en hardware y software y en mayor grado escasos en el mercado tecnológico comercial. Presentan un alto grado de dificultad de replicación y alta dificultad en la tecnología de adquisición de datos, eso los hace mas complejos y tal como el estudio de [VVCZLCML20] donde utilizan Spectral Clustering no cuentan con la tecnología para la adquisición de sus datos, usando una base de datos externa para sus propósitos. Cabe resaltar que la

biometría solo aporta formas de contribuir a la seguridad, pero eso no la aleja de los problemas de inseguridad que todo sistema biométrico posee [XS08].

2.4. Procesamiento digital de imágenes

Existen varios tipos de tecnologías para adquisición de imágenes. Estas pueden provenir de sensores electromagnéticos (SAR - radar), sensores magnéticos (resonancia), lentes ópticos (microscopios y telescopios), infrarrojos, entre otros. Estas tecnologías se asocian usualmente con alguna aplicación particular donde el tipo de procesamiento requerido es distinto a fin de lograr los resultados deseados.

Las imágenes son representadas en forma $f(x, y)$ donde “x” será vista como el espacio donde está su coordenada, “y” es la intensidad RGB o escala de grises, siendo el par discretos y finitos, por lo tanto es posible trabajar computacionalmente con ellos. A estas dos componentes (x, y) se les llama píxel, las cuales en conjuntos conforman las imágenes [Jä05].

2.4.1. Requerimientos

El procesamiento de imágenes tiene una etapa previa de adquisición, para esta es necesario realizar primero la obtención de la imagen, luego realizar el bloque de procesamiento para posteriormente obtener un valor numérico o una imagen resultante. Por lo que se tiene que tomar en cuenta los siguientes componentes:

- Para la captura de imágenes es necesario un transductor, pues esta cambia la radiación captada en datos digitales.
- Para el procesamiento es necesario un software capaz de realizar procesos matemáticos a la imagen, esto puede ser dado en cualquier micro-procesador o computador.

2.4.2. Métodos

El procesamiento de imágenes se realiza mediante el filtrado, la erosión, eliminación de ruidos, segmentación y extracción de características.

2.4.2.1. Filtros digitales

En el procesamiento de imágenes los filtros digitales son principalmente usados para la eliminación de altas frecuencias, por ejemplo, para suavización de la imagen o de bajas frecuencias como el realce o detección de bordes. Cabe señalar que una imagen puede ser filtrada tanto en el dominio frecuencial como espacial.

El filtrado en el dominio frecuencial sigue el flujo ilustrado en la Figura 2.2, como es posible observar la función de filtrado corresponde a un filtro paso altas, cuyo resultado es el realce de los bordes.

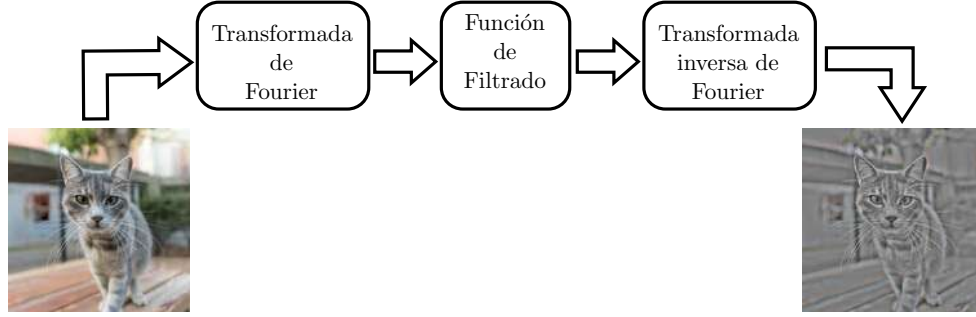


Figura 2.2: Diagrama de flujo para filtrar una imagen en el dominio frecuencial mediante la transformada de Fourier.

Siguiendo el diagrama de bloques antes mencionado, la transformada de Fourier o *Discrete Fourier Transform - DFT* viene expresada por la Ecuación 2.1

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi(\frac{ux}{M} + \frac{vy}{N})} \quad (2.1)$$

Siendo N el ancho y M el alto de la imagen, mientras que “ u ” y “ v ” la posición del píxel resultante de la *DFT*. Luego se aplica un función de filtrado es decir función paso bajas o paso altas. Por ejemplo, la siguiente Ecuación 2.2 expresa la función de transferencia de un filtro Gaussiano paso alta.

$$H(u, v) = 1 - e^{-D^2(u,v)/2D_0^2} \quad (2.2)$$

Siendo D la distancia del píxel (u, v) hacia el centro de la imagen, mientras que D_0 es la distancia de corte. La Figure 2.3 ilustra una función Gaussiana paso alta, como es posible observarse en el mapa de calor las distancias más cercanas al centro son filtradas en su mayoría.




Figura 2.3: Representación gráfica de un filtro Gaussiano paso alta: (a) Izquierda, mapa de calor y (b) Derecha, sección transversal del filtro paso alta.

Finalmente, la transformada inversa de Fourier o *Inverse Discrete Fourier Transform - IDFT* (Ecuación 2.3) es aplicada al resultado de $H(u, v)F(u, v)$ para convertir la imagen filtrada del dominio frecuencial al dominio espacial.

$$f(x, y) = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{-j2\pi(\frac{ux}{M} + \frac{vy}{N})} \quad (2.3)$$

Por otra parte, el filtrado en el dominio espacial se caracteriza por ejecutar operaciones de suma de productos entre una imagen y un *kernel* establecido [Jä05]. El *kernel* es una matriz cuya dimensión define las operaciones entre píxeles vecinos y cuyos coeficientes determinan la naturaleza del filtro. La siguiente Ecuación 2.4 representa la multiplicación de ambas matrices, un kernel asociado y una vecindad o porción de píxeles de la imagen.

$$g(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t) \quad (2.4)$$

Donde a y b corresponden al ancho y alto del kernel respectivamente.

La siguiente Figura 2.4 ilustra el suavizado mediante un filtro de mediana para la eliminación de ruido sal y pimienta. Como es posible observarse, mientras más grande sea el kernel el ruido es menor dado que se toman más píxeles vecinos para el promediado pero ello puede resultar en pérdida de información por lo que se busca un balance adecuado entre la dimensión del kernel y la preservación de píxeles.

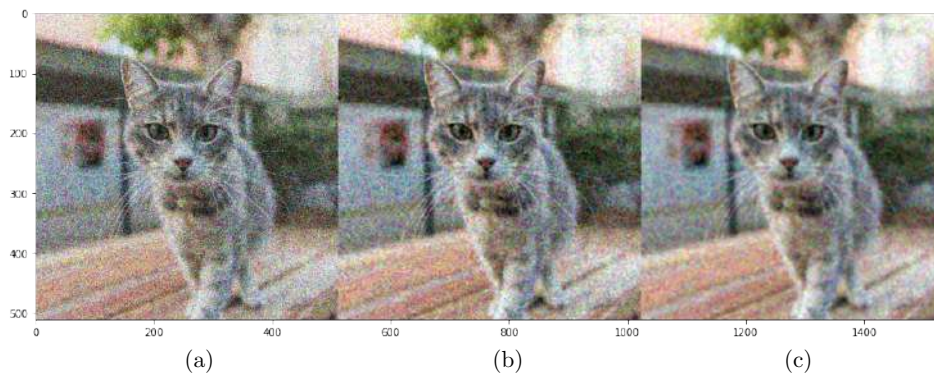


Figura 2.4: (a) Ruido sal y pimienta, (b) y (c) Uso del filtro de mediana con kernel de dimensión 3 y 5 respectivamente.

De igual forma, los filtros espaciales para detección de bordes son comúnmente usados, la Figura 2.5 representa la aplicación del filtro Sobel sobre una imagen, se puede observar los diferentes bordes encontrados en los diferentes ejes tanto vertical como horizontal respectivamente.




Figura 2.5: (a) Imagen original, (b) y (c) Uso del Filtro Sobel sobre los ejes “X” y “Y” respectivamente.

2.4.2.2. Segmentación

La segmentación de imágenes es definido como el proceso de dividir o particionar una imagen en múltiples regiones o categorías las cuales pertenecen a diferentes objetos como resultado de ello se produce una imagen binaria [Jä05, Tan16]. Teniendo que, si un píxel tiene el valor de “1” es parte del objeto y “0” en otro caso. Una segmentación es calificada como buena [GH95]:

- Los píxeles que pertenecen a un mismo objeto o categoría tiene similares valores en la escala de grises y forman una región conectada.
- Los píxeles vecinos los cuales pertenecen a diferentes categorías deben tener valores diferentes.

La segmentación por umbral o *thresholding* es un tipo de segmentación ampliamente aplicado por su simplicidad de implementación, rapidez y eficiencia computacional [GW08]. Este método consiste en seleccionar un umbral o “threshold” por lo que dado un valor de píxel en el punto (x, y) , si este es mayor a un umbral T se considera parte del objeto de interés de otra manera este es parte del fondo. Dicho en otras palabras, una imagen segmentada $g(x, y)$ está definida mediante la siguiente Ecuación 2.5:

$$g(x, y) = \begin{cases} 1 & f(x, y) > T \\ 0 & f(x, y) \leq T \end{cases} \quad (2.5)$$

Una metodología para seleccionar el umbral propicio es encontrar la distribución de intensidad de los píxeles mediante un histograma y buscar la partición adecuada que mejor separa el fondo de la imagen del objeto de interés. La Figura 2.6 ilustra el histograma de una imagen dada, como se puede observar los píxeles correspondientes al fondo están agrupados a la izquierda mientras que los píxeles de interés permanecen a la derecha, un valor adecuado de umbral podría ser el valor de 100.

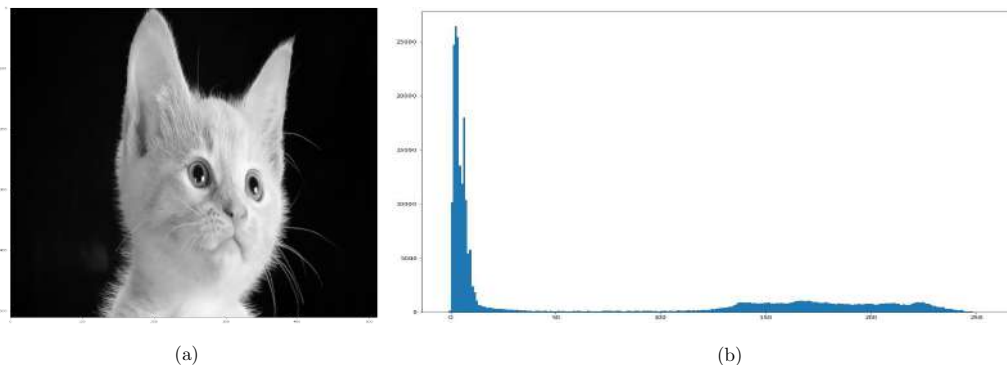


Figura 2.6: (a) Imagen de interés e (b) Histograma generado en base a los valores de los píxeles de la imagen de interés.

La Figura 2.7 ejemplifica el resultado de aplicar diferentes umbrales de segmentación, tomando en consideración el histograma de la Figura 2.6, un umbral con valor comprendido entre 50 y 100 es adecuado y ello puede verse reflejado mientras que un umbral más alto resta información en el objeto de interés.




Figura 2.7: (a) Imagen original, (b) y (c) Resultados de la operación de segmentación con umbrales de 100 y 150 respectivamente.

Otra de las técnicas populares basan su operatividad en el uso de un umbral dinámico como es el caso del método de segmentación Otsu [Ots79]. Tal método obtiene el umbral óptimo maximizando la varianza entre las clases (suponiendo que la imagen es binaria, objeto de interés y fondo) mediante una búsqueda voraz. En consecuencia, el proceso para encontrar la máxima varianza mediante el método Otsu queda establecida como sigue:

1. Normalizar el histograma y representarlo como una distribución de probabilidad.

$$p_i = \frac{n_i}{N}, \quad \sum_{i=1}^L p_i = 1 \quad (2.6)$$

Siendo n_i el total de píxeles con valor de intensidad i y N el total de píxeles en la imagen.

2. Por lo tanto, la probabilidad de ocurrencia de las clases C_1 (suponiendo que la clase C_1 comprende los valores de intensidad de $[1..k]$), y C_2 (comprende los valores de intensidad de $[k + 1..L]$) están dadas por:

$$w_1 = Pr(C_1) = \sum_{i=1}^k p_i \quad (2.7)$$

$$w_2 = Pr(C_2) = \sum_{i=k+1}^L p_i$$

3. Y las medias acumuladas de ambas clases como:

$$\mu_1 = \sum_{i=1}^k i \frac{p_i}{w_1} \quad (2.8)$$

$$\mu_2 = \sum_{i=k+1}^L i \frac{p_i}{w_2}$$

4. Por lo que la intensidad media acumulada de toda la imagen es:

$$\mu_T = w_1 \mu_1 + w_2 \mu_2 \quad (2.9)$$

5. Por último, la varianza para un valor de intensidad t está determinada por:

$$\sigma_B^2 = w_1 (\mu_1 - \mu_T)^2 + w_2 (\mu_2 - \mu_T)^2 \quad (2.10)$$

La Figura 2.8 representa los resultados obtenidos mediante un umbral estático obtenido con el análisis de histograma y por el método Otsu, que como se abordó en el párrafo anterior encuentra un umbral mediante la maximización de la varianza.

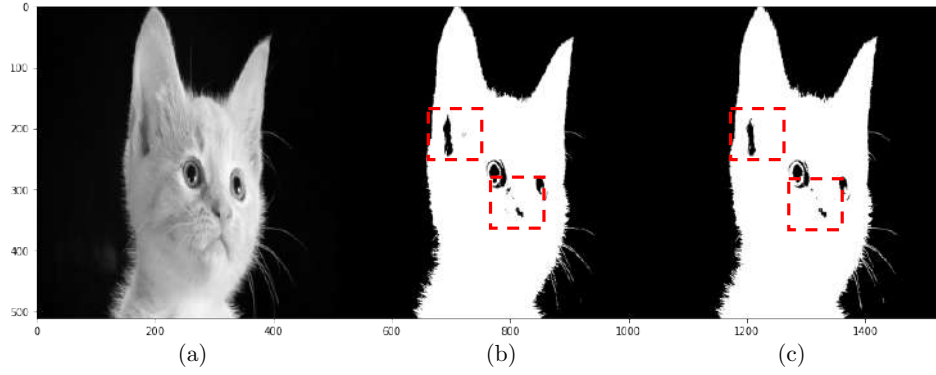


Figura 2.8: (a) Imagen original, (b) y (c) Resultados de la operación de segmentación con un umbral de 100 y mediante el método Otsu respectivamente.

2.4.2.3. Operaciones morfológicas

Particularmente cuando una imagen es binarizada mediante un proceso de umbral (asignar valor de “0” ó “1” al píxel dependiendo del umbral o *threshold*) presenta regiones distorsionadas por efectos de ruido o textura. Por ello y con el fin de remover estas imperfecciones se hace uso de operaciones morfológicas considerando la estructura y forma de la imagen [Soi13].

Entre las operaciones morfológicas más comunes destacan la erosión, dilatación, apertura y cierre. Matemáticamente una operación de erosión es representada como sigue (Ecuación 2.11):

$$A \ominus B = \{z | (B)_z \subseteq A\} \quad (2.11)$$

Siendo A la imagen y B el kernel, la erosión de A dado B es el conjunto de todos los puntos z tal que B está contenido en A .

Por lo que la erosión puede ser usada para encoger, afinar y remover objetos en imágenes binarias. La Figura 2.9 ilustra la operación de erosión en una imagen binaria con kernel de diferentes dimensiones, donde un kernel de dimensión mayor es más agresivo al momento de remover detalles de la imagen como los ojos y orejas del gato o los bigotes de este.




Figura 2.9: (a) Imagen original, (b) y (c) Uso del operador de erosión con kernel de dimensión 3 y 5 respectivamente.

En contra parte, la operación de dilatación es usada para expandir o dilatar detalles de la imagen. Tal operación es definida mediante la siguiente Ecuación 2.12:

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\} \quad (2.12)$$

Siendo A la imagen y B el kernel, la dilatación A dado B es el conjunto de todos los desplazamientos de z tal que la reflexión de \hat{B} y A tienen al menos un elemento en común.

La Figura 2.10 representa visualmente el proceso de dilatación, como es posible observarse ciertos detalles como los bigotes, ojos u orejas han sido ensanchados. En conclusión ambas operaciones erosión y dilatación son útiles para filtrar ruido o recomponer detalles respectivamente producto de una segmentación.




Figura 2.10: (a) Imagen original, (b) y (c) Uso del operador de dilatación con kernel de dimensión 3 y 5 respectivamente.

Tanto operaciones de erosión como dilatación pueden ser utilizadas en conjunto una después de la otra, siendo denominada operación de apertura si primero se erosiona y luego se dilata. La operación de apertura es útil para suavizar contornos o eliminar protuberancias. Por el contrario, la operación de cierre primero dilata y luego erosiona, siendo conveniente para eliminar pequeños hoyos o rellenar espacios en contornos.

2.4.2.4. Extracción de características

La extracción de características es el proceso de transformar los datos desde su estado original hacia un conjunto de vectores numéricos los cuales sean capaces de describir y preservar la información de su procedencia. Este proceso de extracción de características puede ser ejecutado de dos modos: Manualmente y automáticamente. Entre los procedimientos bajo supervisión humana (extracción de características manual) más utilizados destacan la extracción de bordes (primer y segundo orden) [yCjZS08], extracción de curvaturas [NA12], textura y color [CD19]. La Figura 2.11 ejemplifica diferentes métodos para la extracción de características entre ellos:

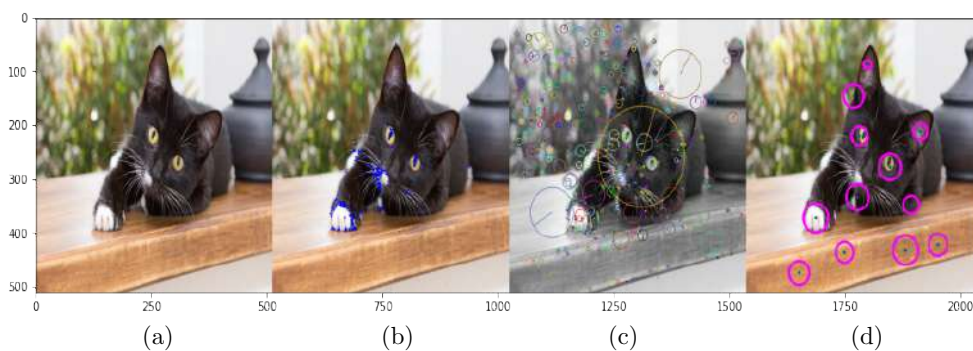


Figura 2.11: (a) Imagen original, (b) Detección de esquinas, (c) Extracción de puntos invariantes y (d) Detección de círculos.

Detección de esquinas mediante el método Harris [WZ18], extracción de puntos invariantes o *Scale-Invariant Feature Transform* [Low04] y la transformada Hough para la extracción de círculos [YPIK90].

Por otro lado, un método que ha ganado bastante atención para la extracción de características de forma no supervisada es el uso de modelos neuronales profundos pre-entrenados [HZD⁺21] en ciento, miles o incluso millones de imágenes como es el caso de *ImageNet* [DDS⁺09] que contiene aproximadamente 3.2 millones de información visual. Por ejemplo, la siguiente Figura 2.12 muestra la red neuronal profunda propuesta por [KSH12] *et al*, la cual fue entrenada en *ImageNet*.




Figura 2.12: Arquitectura AlexNet introducida por [KSH12] *et al*.

La Tabla 2.1 detalla la configuración de la red neuronal profunda AlexNet ilustrada en la Figura 2.12. Como es posible verse, presenta diferentes capas convolucionales con diferentes dimensiones de kernel (3, 5 ó 11) y número de filtros (96, 256, 384). Así mismo, luego de cada capa de convolución le sigue una capa de agrupamiento cuya función es reducir de dimensión la salida generada por la convolución manteniendo la información más relevante, ello se consigue buscando el píxel vecino con mayor valor dentro del kernel. A ello le sigue una función de activación ReLU, cuya principal ventaja es aliviar en gran medida la saturación de la neurona durante el entrenamiento además que se caracteriza por su rápido cómputo [Aga18]. Finalmente, para la clasificación utilizan dos bloques de perceptrones multicapa [PBPPM09] cada uno de ellos con 4096 neuronas.

Configuración de red convolucional
Entrada 224 x 224 x 3
Conv11-96
Capa normalización de grupo + ReLU
Conv5-256
Capa normalización de grupo + ReLU
Conv3-384
Capa normalización de grupo + ReLU
Conv3-384
Capa normalización de grupo + ReLU
Conv3-256
Capa normalización de grupo + ReLU
MLP - 4096 neuronas + ReLU
MLP - 4096 neuronas

Cuadro 2.1: Configuración de la arquitectura AlexNet [KSH12].

2.4.3. Aplicaciones

El procesamiento de imágenes es utilizado en diferentes áreas de estudio, para citar algunos ejemplos: Para la mejora de imágenes satelitales (en el ámbito de la astronomía) [AAC⁺20, ASP20], análisis de imágenes médicas (en el ámbito de la medicina) [MLM⁺01] o en la mejora de mapas [MDK85].

2.5. Clasificación de imágenes

La clasificación de imágenes es el proceso mediante el cual dado un grupo de imágenes se pretende identificar a que clase pertenece cada una de ellas. Esta tarea no representa un gran problema para un humano pero enseñar a las computadoras a “ver”, ha impulsado una de las áreas de investigación con mayor auge la visión artificial [LRR21]. Tal es así que hoy en día se ha alcanzado resultados impresionantes en algunas tareas de clasificación llegando casi al 100% de exactitud, como es el caso en la clasificación de las hojas de las plantas [WHAF21] o en la clasificación de diversas enfermedades que afectan a la piel [CZW⁺22]. A continuación revisaremos algunos métodos para la clasificación de imágenes considerando un conjunto de vectores de características “x” y sus respectivas etiquetas “y”:

2.5.1. k-Vecino más cercano o *k-Nearest Neighbor* (KNN)

K-Vecino más cercano es uno de los métodos más simples y efectivos cuando las características de cada clase son bien representativas y generalizables, además es considerado un método no paramétrico dado que no hace ninguna presunción entorno a los datos. El funcionamiento de KNN se basa en almacenar todos los vectores de características y clasificar un nuevo vector basándose en su similitud (distancia más cercana hacia un vecino). La Figura 2.13 ilustra un escenario de clasificación binaria, donde cada elemento triángulo y cuadrado representa un vector de características N -dimensional, suponiendo que se quiere clasificar el nuevo vector representado por una estrella, KNN opera de la siguiente manera:




Figura 2.13: K-Vecinos más cercanos aplicado a un problema de dos clases.

1. Calcular la distancia del vector de características (el cuál se quiere clasificar, estrella) hacia los demás vectores de características almacenados (estrellas y cuadrados). Es necesario precisar que la función de distancia tiene que ser establecida, esta puede ser la distancia Euclídea la cual puede ser expresada con la Ecuación 2.13 donde p y q son los vectores de características y n es la

componente enésima dimensión.

$$d(p, q) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2} \quad (2.13)$$

O la distancia función de coseno, descrita con la Ecuación 2.14 que es el resultado del producto punto de los vectores normalizados. Este tipo de distancia basa su funcionamiento en la dirección de los vectores es decir vectores paralelos el ángulo entre ellos es 1 por lo que su distancia es 0, mientras que si son ortogonales el ángulo entre ellos es 0 teniendo como distancia 1 y si estos van en direcciones contrarias el ángulo entre ellos es -1 y su distancia es 2.

$$\cos(p, q) = 1 - \frac{\sum_{i=1}^n p_i q_i}{\sqrt{\sum_{i=1}^n p_i^2} \sqrt{\sum_{i=1}^n q_i^2}} \quad (2.14)$$

2. Establecer el valor de k-vecinos.
3. Realizar una votación tomando como referencia los k-vecinos más cercanos hacia el vector de clase desconocida (estrella).
4. Asignar el vector de clase desconocida (estrella) a la clase con mayor número de votos.

Tomando como referencia la Figura 2.13 y considerando los pasos antes expuestos, si tenemos un valor de $k = 3$ el elemento estrella pertenecería a la clase 2 mientras que si se fija un valor de $k = 5$ este sería clasificado como triángulo. Por lo que establecer un número adecuado de k es vital ello se puede conseguir considerando el conjunto de validación de la base de datos y encontrando el error.

2.5.2. Comparación de plantillas - *Template Matching*

La comparación de plantillas es una técnica de visión artificial de alto nivel que permite identificar regiones de la imagen que tienen una alta correlación con una imagen de referencia o plantilla dada [HAGF16]. Dicha plantilla es desplazada sobre la totalidad de la imagen para calcular la convolución entre esta y una ventana de la misma dimensión (ver Figura 2.14).

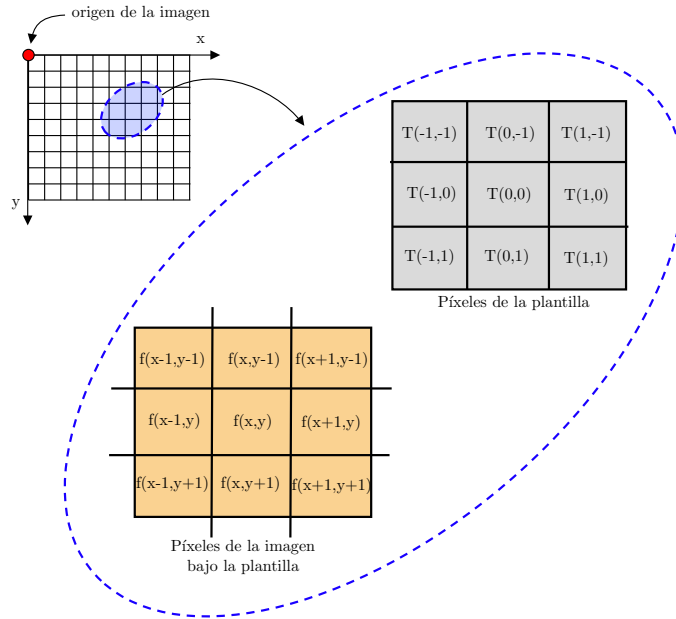


Figura 2.14: Proceso de la comparación de plantillas o *template matching* sobre una sección de dimensión 3x3 dada una imagen de interés y una plantilla correspondiente.

Por consiguiente y teniendo como referencia la Figura 2.14, la salida luego de haber calculado la convolución está representada mediante la siguiente Ecuación 2.15:

$$g(i, j) = \sum_{m=1}^M \sum_{n=1}^N t(m, n) \cdot f(i - m, j - n) \quad (2.15)$$

Donde f representa la imagen, t la plantilla, M y N son las dimensiones de la plantilla.

La Figura 2.15 ilustra el resultado luego de haber aplicado el método de comparación de plantillas, como es posible observarse en el mapa de calor el área de color amarillo representa el más alto grado de similitud luego de haber computado la convolución entre la plantilla y la ventana que cubre este en la imagen fuente.

En este punto es necesario plantearnos la siguiente interrogante: ¿Es posible utilizar la comparación de plantillas para la clasificación de imágenes?. Depende del contexto, para citar un ejemplo: Para la identificación de usuarios mediante algunas de sus características biométricas es ideal, [NML20] *et al.* utilizaron el iris para la clasificación de usuarios vía comparación de plantillas, dado que estas características biométricas son las mismas para un usuario, mientras que si por ejemplo queremos clasificar gatos y perros este método no serviría dado el infinito universo que poseen estas clases.

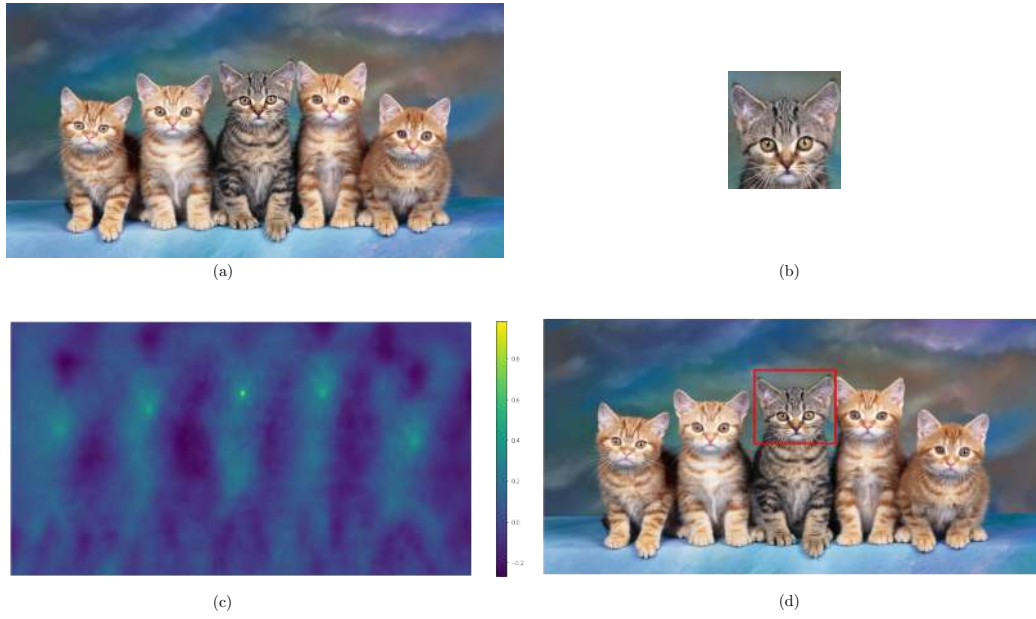


Figura 2.15: (a) Imagen original, (b) Plantilla o *template*, (c) Mapa de calor generado luego de haber aplicado una operación de convolución entre la imagen original y la plantilla, y (d) Resultado de la comparación de plantilla.

Capítulo 3

Antecedentes

Existen diversos métodos de reconocimiento de patrones biométricos, pero a nivel tecnológico-comercial los sistemas basados en características vasculares solo conforman el 3% de la tecnología comercial. No obstante, dentro de las diferentes alternativas que hacen uso de los patrones vasculares (muñeca, palma y dedo), los basados en las venas de la muñeca han ganado bastante popularidad y presentan ventajas tales como una mejor visualización y distinción de los patrones únicos que forman las venas [GMSR20], por ello nuestro principal interés en este tipo de sistemas.

Por lo tanto, en este Capítulo 3 se estudia los métodos y técnicas de diferentes trabajos publicados en torno al reconocimiento de usuarios mediante los patrones biométricos de las venas. Para este fin, se abordan trabajos que describen 4 etapas fundamentales: Adquisición de muestras, pre-procesamiento de las muestras adquiridas, técnicas de extracción de características y por último el reconocimiento de los usuarios (clasificación de las muestras).

3.1. Adquisición de muestras

La adquisición de muestras constituye la primera etapa en un sistema de reconocimiento biométrico. Para el caso de los sistemas biométricos basados en venas es común el uso de cámaras infrarrojas (longitud de onda en un rango de 780 a 10000 *nm.*) debido que la hemoglobina contenida en la sangre posee una gran capacidad de absorción de dicha luz provocando ello que las venas resalten más en comparación de los tejidos que las rodean.

Sin embargo, es posible utilizar la cámara tradicional RGB de un celular inteligente [LGBHA22] aunque este método está sujeto a diferentes restricciones y dependencia tomando en consideración la iluminación del ambiente. Cabe precisar que la tasa de éxito de reconocimiento de usuarios en estos sistemas está fuertemente correlacionada con la calidad de muestras adquiridas [RB16].

Por otro lado, la adquisición de muestras puede ser clasificada en dos variantes: (1) Adquisición con contacto: Requiere que el usuario apoye el área de interés sobre una superficie previamente diseñada [WL06]. Por lo general, este tipo de trabajos presenta una mejor tasa de exactitud comparados con su contraparte que son los sistemas de adquisición sin contacto, ello debido a que estos requieren un ambiente controlado y una área de interés fija mitigando así alteración en la iluminación y posibles desplazamiento o rotaciones del área de interés.

La Figura 3.1 muestra un sistema de adquisición por contacto. Como es posible observarse este requiere que el usuario pose su dedo en una área pre-definida e intuitiva para el usuario, es decir la forma natural en que apoyaría su dedo para la captura de la imagen.




Figura 3.1: Adquisición de muestras sin contacto: (a) Equipo de adquisición y (b) captura de la muestra. Imagen extraída de [KDN⁺22].

(2) Adquisición sin contacto: No se necesita de algún soporte para que el usuario apoye el área de interés [GMSR21]. Siendo esta última más demandante en el pre-procesamiento y clasificación de las imágenes capturadas, ya que presenta mucha variabilidad (aleatoriedad en la posición y distancia de la muestra hacia la cámara e iluminación).

La Figura 3.2 ilustra la adquisición de las venas tanto de la muñeca como el dorso de la mano sin contacto en una superficie. Como se puede ver, requiere que el *flash* este encendido para que las venas puedan ser resaltadas.

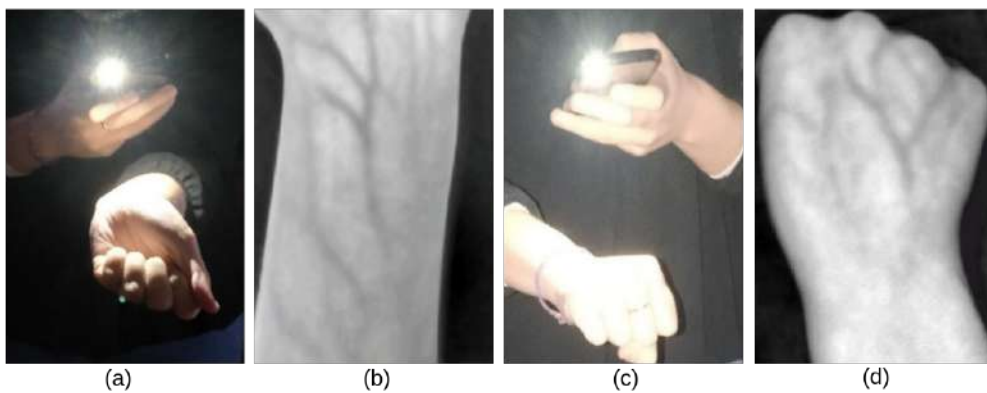


Figura 3.2: Adquisición de muestras sin contacto: (a)(c) Procedimiento de captura y (b)(d) resultado de la captura. Imagen extraída de [LGBHA22].

El Cuadro 3.1 recopila y describe las principales bases de datos, el número de usuarios, el total de imágenes adquiridas. Así como el sistema utilizado para la captura de muestras y si este requiere que el usuario tenga o no contacto con el sistema. Además, se tiene una etiqueta según el tipo de venas que utilizan ya sean palma (P), muñeca (M), dorso de la mano (DS) o dedo (D).

Autor	Usuarios	Imágenes	Hardware	Tipo	Venas
[WL06]	150	2700	Hitachi KP-F2A	Contacto	P,M
[KZ12]	156	6264	RGB Webcam	Conacto	D
[TV13]	60	1440	Pentax H1214-M	Contacto	D
[HLP17]	20	1200	Logitech C600	Contacto	D
[KPU19]	42	840	UI-ML3240-NIR	Sin contacto	P, D
[WBNAV20]	113	339	LW-13 S-1394	Contacto	DS
[JZ20]	100	600	Canon 750D	Contacto	D
[GMSR20]	100	1200	Logitech C525	Sin contacto	M
[LGBHA22]	10	50	Xiaomi Redmi Note 8	Sin contacto	DS

Cuadro 3.1: Recopilación de diferentes bases de datos en biometría vascular.

3.2. Pre-procesamiento

El principal propósito del pre-procesamiento es mejorar, normalizar y definir los patrones formados por las venas [GMSR20] e incluso corregir desplazamientos, rotaciones y cambios de dimensiones (escalamiento) en la muestra [KPU19]. En tal sentido es necesario encontrar una área de interés o denominada ROI - *region of interest*, mediante la cual se extrae la información relevante del área de las venas y se descarta el fondo, como consecuencia la carga computacional se ve reducida.

La extracción de la ROI se puede hacer manualmente estableciendo una dimensión fija en la cual recortar la muestra [Hsi18, TBB20], o mediante un proceso de enmascaramiento (encontrar una máscara binaria para luego hacer una operación lógica *and* sobre la imagen). Por ejemplo en [YYZY15, VVCZLC20] hacen uso de un método de clusterización de superpíxeles para etiquetar los píxeles pertenecientes al fondo y al área de las venas, mientras que [RDGP20] fijaron un umbral de decisión para binarizar la imagen y conseguir la máscara, cabe señalar que ese umbral es computado mediante el método Otsu [Ots79], dado que el umbral es encontrado automáticamente y no es fijado manualmente. Sin embargo, en la literatura hay métodos que prescinden de encontrar una ROI y realizar un pre-procesamiento como en el caso de [GMSR21] que utilizan redes neuronales convolucionales para extraer características de las muestras como tal.

Una vez se haya encontrado la ROI, es común la aplicación de una serie de filtros para limpiar o reducir el posible ruido existente ocasionado por el sensor de adquisición, por ejemplo el uso de filtros de mediana [HGL⁺19], y el uso de técnicas para corregir los niveles de iluminación y contraste, como la aplicación de un histograma de equalización [TBB20, AAA⁺20, VVCZLC20] con el propósito de mejorar la calidad de la muestra. También se explora el uso de otros espacios de color (HSI) con la finalidad de descartar la componente de intensidad [AAK14].

3.3. Extracción de características

Luego de la etapa de pre-procesamiento, se extraen características que consigan representar o describir a través de un vector o matriz numérica la muestra. Para ello, en la literatura es posible distinguir dos tipos de métodos: (1) Los métodos que utilizan técnicas tradicionales, como el uso de descriptores para extraer patrones locales de textura [OPM02, AHP04], detección de bordes y cambios en la textura usando el filtro Gabor [AAK14] y (2) Métodos de aprendizaje profundo, como las redes neuronales convolucionales capaces de extraer características automáticamente. Sin un conocimiento exacto de que características aprende la red neuronal (caja

negra) se ha demostrado que en las primeras capas se aprenden características de forma, luego color, textura y las capas más profundas características cada vez más abstractas [TZK⁺19, GMSR20].

Aunque el aprendizaje profundo ha cobrado bastante popularidad, presenta una desventaja en bases de datos cuyas clases contengan pocas muestras de entrenamiento (tendencia a sobre-entrenar) como es el caso de los sistemas biométricos. En consecuencia, los métodos clásicos aún continúan siendo explorados, por ejemplo [AAA⁺20] proponen un método heurístico de enjambre de partículas para seleccionar un conjunto de características obteniendo resultados comparables a las redes neuronales convolucionales. Además, existen trabajos que combinan ambos métodos, como [LLZ⁺22] que hizo un banco de características extraídas por una Resnet [HZRS16] y el algoritmo de histograma de gradientes orientadas.

3.4. Clasificación

Como última etapa, se tiene el reconocimiento del usuario a través de sus patrones vasculares. Se distinguen dos tipos de enfoque: (1) Clasificación mediante una función de distancia, en este enfoque se hace una comparación de las características computadas en el momento versus características previamente pre-computadas almacenadas en un banco. Para medir la discrepancia entre ambas muestras se suele usar la distancia Mahalanobis [AAK14] o distancia Hamming [MA19]. (2) Clasificación mediante un algoritmo de aprendizaje máquina, dadas las características extraídas se procede a entrenar un algoritmo de aprendizaje automático. Por ejemplo, [VVCZLC20] utilizaron un perceptrón multicapa para clasificar las características previamente extraídas utilizando agrupamiento espectral, por otro lado [AAA⁺20] entrena diferentes algoritmos como k-vecinos más cercanos, máquina vector de soporte y un árbol de decisión, cabe recalcar que su algoritmo propuesto de selección de características obtiene resultados competitivos con las redes neuronales convolucionales. Además existen métodos híbridos como [AKAT22] que extraen características mediante una red neuronal pero clasifican utilizando k-vecinos más cercanos, ello con la finalidad de combatir el sobre-entrenamiento producido por la escasez de muestras.

Capítulo 4

Propuesta de Solución

En el presente Capítulo 4, se describe todas las etapas que se ha realizado para el diseño e implementación del sistema. En cada etapa existen sub-procesos los cuales son detallados a cabalidad para alcanzar la comprensión de la propuesta.

El sistema debe contar con la capacidad de recolectar datos, realizar un procesamiento de la información y finalmente tomar una decisión, es decir generar el reconocimiento. Todo lo expresado está acorde a como se ve gráficamente en la siguiente Figura 4.1:




Figura 4.1: Diagrama de bloques correspondiente a la propuesta de solución para el sistema de reconocimiento de patrones biométricos.

Estos procesos son descritos a detalles en las siguientes secciones:

- El proceso de “Diseño del sistema” en la Secciones 4.1 y 4.2.
- El proceso de “Recolección de datos” en la Sección 4.3.
- El proceso de “Procesamiento de datos” en la Sección 4.4.
- El proceso de “Decisión - Reconocimiento” en la Sección 4.5.

4.1. Diseño y construcción del sistema

Con el fin de ejecutar la recolección de imágenes infrarrojas, se requiere de un prototipo que nos facilite esta tarea. El proceso de “recolección de datos” es parte de la subsección a continuación.

4.1.1. Hardware

El hardware comprende un sistema con las capacidades de generar una señal infrarroja y captar imágenes producidas en esa frecuencia como se puede apreciar en la siguiente Figura 4.2:

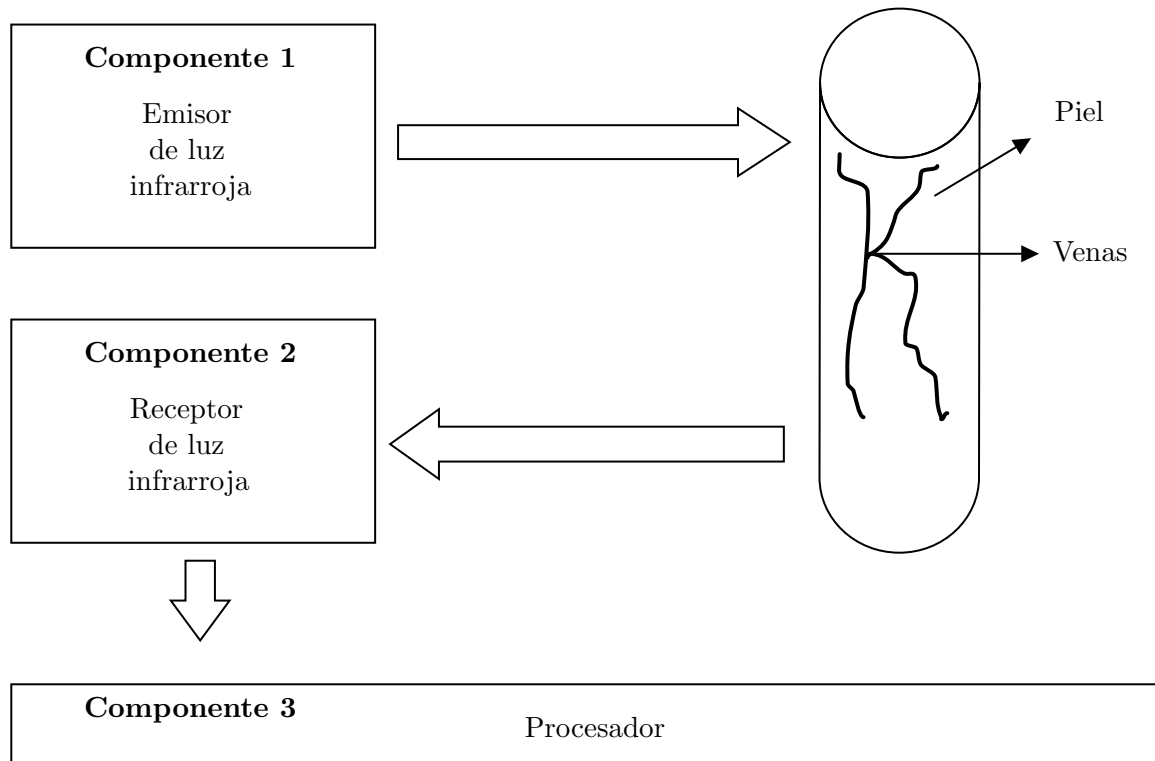


Figura 4.2: Diagrama de componentes del hardware del sistema biométrico.

Componente 1 - Fuente emisora de radiación infrarroja

Se utiliza la banda de frecuencia más baja de la radiación infrarroja, es decir, la IRA de 780 a 1400nm. [MJP⁺12]. La radiación infrarroja es empleada para la visualización del sistema vascular, ello gracias a la propiedad de absorción selectiva de la radiación debido a que las venas poseen una pigmentación características dada por la hemoglobina, una proteína compuesta por hierro, que al entrar en contacto con el oxígeno que transporta la sangre se torna de color rojo.

Como ya se mencionó anteriormente esta propiedad indica que: Si se emite una longitud de onda a un material el cual oscila a esa misma frecuencia entonces esta será absorbida y sólo se verá en color negro.

La radiación infrarroja incide y gracias a que su grado de penetración bajo la piel es de (5 a 10mm.) [CE08] llega a la vena y es absorbida por esta, dejando una imagen en color oscuro de las venas en contraste con la parte de radiación que incidió sobre la piel.

Los componentes que trabajan en dicho rango de frecuencias son los led IR333-A de 940nm. y 850nm., estos son sumamente comerciales y brindan la información necesaria para el cálculo de parámetros de seguridad que anteriormente se ha comentado. Para implementar la fuente emisora de radiación IR se disponen de 24 leds IR333-A de 940nm. con conexión paralela a la fuente de alimentación y se cuenta con dos leds 850nm. de características más importantes extraídas de la hoja de especificaciones técnicas, las cuáles son mostradas en el Cuadro 4.1.

Tipo	Condición	Voltaje en modo electro-óptico
Leds IR333-A de 940 nm.	$I = 1A$	$V = 4v$
Leds 850 nm.	$I = 1A$	$V = 1.8v$

Cuadro 4.1: Características electro-ópticas y parámetros de voltaje en tensión directa del Led IR333-A de 940nm. y Led 850nm.

De acuerdo al Cuadro 4.1 se aprecia que para los leds IR333-A de 940nm. a 1A en corriente, se tiene un voltaje de salida de 4v en modo electro-óptico.

Por otra parte, para los IR Diodo de 850nm. tenemos que la intensidad de voltaje electro-óptico emitido es de 1.8v y con corriente de 1A.

Por lo tanto:

- Dado que potencia es igual al producto de voltaje y corriente se entiende que en el caso del IR333-A 940nm. se cuentan con 4W y en el caso del Diodo de 850nm. se cuenta con 1.8W.
- Si se cuenta con 24 leds IR333-A de 940nm. da como resultado 96W de potencia y en el caso del diodo de 850nm. se tienen 2 entonces es igual a 3.6W de potencia.

Como tal, el flujo radiante dado por los leds y sus características electro-ópticas en un caso ideal, la potencia máxima lumínica emitida es $4W * 24 + 1,8W * 2$, lo que resulta en 99.6W el cual es medido en unidad de tiempo, es decir, en cada segundo se emiten 99.6Ws. Lo cual cumple los parámetros de seguridad ya que la dosis saludable es de $1317,3 \pm 44,84Ws/cm^2$ por cada 30 minutos como máximo [LLCC06]. Es decir, en porcentajes este sistema es menor al 7.56 % de la máxima potencia eléctrica infrarroja transmitida admisible, dando como resultado un sistema seguro para el cuerpo humano. Por ende no existe inconveniente en usarlo para tomar una captura de las venas, ya que esta acción no demora más de unos segundos. En resumen, dado que el sistema propuesto tiene una emisión lumínica máxima que es únicamente una porción pequeña (7.56 %) de lo que considera el estándar como seguro. Por consiguiente, se concluye que el sistema propuesto no representa una amenaza para la salud.

Componente 2 - Fuente receptora de radiación infrarroja

La cámara infrarroja, esta es soportada por todas las versiones de la Raspberry Pi. Otorga una visión nocturna, además posee un transductor OV5647 de 5 megapíxeles. Su sensor da mejor resolución y permite trabajar hasta con 1080 píxeles.

Componente 3 - Procesador

La Raspberry Pi 3 tiene un procesador de 1,2 GHz de 64 bits con cuatro núcleos ARMv8. Esta plataforma cuenta con una interfaz para la cámara infrarroja que utilizaremos y su propia interfaz para la cámara. También posee núcleo de gráficos VideoCore IV 3D capaz de trabajar imágenes en tiempo real, lo cual nos permite realizar el procesamiento de las imágenes en el mismo equipo, sin necesidad de un computador externo para el procesamiento de las imágenes captadas por la cámara sensible a infrarrojos. Además posee su propio sistema operativo de tipo *open source*, esto sumado a todo lo anteriormente dicho garantiza la portabilidad del sistema.

4.1.2. Ensamble final del sistema

El bloque de diseño está comprendido por la Raspberry Pi como base para el procesamiento y obtención de datos, los leds emisores de radiación IR y la cámara IR para la obtención de las imágenes. El hardware como tal se aprecia en la siguiente Figura 4.3.




Figura 4.3: (a) Sistema de recolección de datos en estado apagado y (b) en estado encendido.

4.2. Estructura externa del sistema

El sistema paso por dos fases de diseño en la estructura externa, esto a lo largo de su implementación.

4.2.1. Primera fase

El primer diseño expuesto en la Figura 4.4 dado por una caja de cartón era preliminar, dificultaba la toma de datos, dado que la mano se introducía dentro de la caja. Es por ello que ante la necesidad y la posibilidad de mejorar la estructura de este se paso por una etapa de rediseño.



Figura 4.4: Primer diseño de la estructura externa del sistema de reconocimiento de patrones biométricos: (a) Vista interior y (b) Vista exterior.

4.2.2. Segunda fase

El segundo diseño visto en la Figura 4.5 muestra la mejora implementada. La cual nos facilita la de determinación de la región de interés desde el hardware. Con ello, se consigue mejorar el pre-procesamiento implementado en el software. Esto además reduce el tamaño, por ende es más portable. Es decir, esta reducción de su estructura externa equivale aproximadamente al 50 % haciéndolo sumamente portátil y como se mencionó esto añade una restricción para la toma de datos, es decir nos aporta una región de interés de 4*4 cm² ayudando al procesamiento de las imágenes captadas.



Figura 4.5: Segundo diseño de la estructura externa del sistema de reconocimiento de patrones biométricos.

Cabe resaltar que para este rediseño ya no es necesario introducir la mano en la caja, sino que la muñeca se posa sobre la región de interés.

4.3. Creación de la base de datos

Se realizaron pruebas experimentales tanto del hardware y software implementado. Con ello obtuvimos la colección de muestras de distintos participantes para generar la base de datos del sistema. La creación de una base de datos propia fue necesaria para la autonomía de nuestro sistema, este proceso es extenso pero necesario. Cabe señalar, que a lo largo del diseño del sistema con cada mejora introducida fue necesaria la creación de una nueva base de datos que contenga dicha mejora. De esta manera se realizaron tres bases de datos.

4.3.1. Primera versión base de datos

Se realizó la captura de imágenes haciendo uso del 100 % de la capacidad de la cámara es decir usando los 1080 píxeles, pero durante el desarrollo del sistema se descubrió que no es necesario trabajar con imágenes tan grandes. Ello daba como

resultado un procesamiento lento por el alto coste computacional al trabajar con imágenes de tal dimensión.

4.3.2. Segunda versión base de datos

Por consiguiente, se decidió cambiar la configuración de la cámara a una resolución de 160 píxeles de ancho por 128 píxeles de alto, ello nos permitió acelerar el procesamiento. Sin embargo, la región de interés al igual que la primera base de datos era ambigua producto de que el usuario tenía total libertad (ángulo libre) en posar la muñeca de la mano. La siguiente Figura 4.6 representa una muestra extraída de esta base de datos.



Figura 4.6: Muestra de 160 x 128 píxeles extraída de la segunda versión de la base de datos.

4.3.3. Tercera versión base de datos

La tercera base de datos añade la mejora del hardware realizada en la etapa de re-diseño y conserva el tamaño de 160 x 128 píxeles de resolución configurados en la cámara. Tal y como se aprecia en la Figura 4.7 la mejora es notoria, la región de interés es dada desde el hardware mejorando a su vez el procesamiento del software (reduce el coste computacional y permite segmentar mejor). Cabe recordar que el área a trabajar es equivalente a 4 x 4 cm.

Es preciso señalar que el principal requerimiento de adquisición para la base de datos es que el fondo de la imagen sea color negro, caso contrario este provocaría ruido afectando en el reconocimiento de la persona.



Figura 4.7: Muestra de 160 x 128 píxeles más la región de interés extraída de la tercera versión de la base de datos.

Finalmente, la Figura 4.8 muestra la distribución de la tercera base de datos. Presenta un total de 275 muestras pertenecientes a 10 personas diferentes. Como es posible observarse nuestra base de datos final no está balanceada (igual número de

muestras por cada clase) pero nuestro método propuesto es independiente de esta característica como se explicará más adelante.




Figura 4.8: Gráfico de barras de la distribución de la base de datos final.

En complemento al gráfico de barras (Figura 4.8), el Cuadro 4.2 cuantifica numéricamente las muestras.

Persona	Número de muestras
Persona 1	11
Persona 2	29
Persona 3	12
Persona 4	26
Persona 5	26
Persona 6	36
Persona 7	26
Persona 8	39

Cuadro 4.2: Distribución de la base de datos final.

4.4. Pre-procesamiento

La etapa de pre-procesamiento es desarrollada como muestra el diagrama de bloques (Figura 4.9). Cabe precisar que dicho diagrama de bloques contiene los algoritmos revisados en el Capítulo 2.




Figura 4.9: Diagrama de bloques para la etapa de pre-procesamiento.

4.4.1. Máscara

Con la finalidad de encontrar nuestra región de interés es necesario generar una máscara que nos permita separar el área de la muñeca de los bordes de la caja de cartón. Para ello se hace uso de la técnica de segmentación fijando un valor empírico de umbral equivalente a 120, por lo que cualquier valor por debajo de este es considerado fondo y en otro caso parte de la región de interés. Es posible fijar ese valor dado el ambiente controlado (caja de cartón, sin ningún tipo de variación en la iluminación) que presenta nuestro sistema. La Figura 4.10 ilustra la máscara encontrada luego de aplicar el método de segmentación descrito.




Figura 4.10: (a) Imagen original y (b) máscara.

4.4.2. Filtro paso altas

Dado que los bordes de una imagen corresponden a frecuencias altas y siendo esto lo que nos interesa ya que se necesita resaltar el área de las venas, ya que estas han tomado apariencia de bordes por efecto de la radiación infrarroja. Se procede con la implementación de un filtro Gaussiano a nuestra imagen. La Figura 4.11 muestra el efecto de filtrar la imagen aplicando un filtro paso altas, como es posible observarse los bordes han sido resaltados lo que es ideal para nuestro propósito.




Figura 4.11: (a) Imagen original e (b) imagen filtrada con un filtro paso altas.

4.4.3. Filtro de mediana

Luego de haber aplicado el filtro paso altas para reducir y/o eliminar ruido en algunas muestras, ya que existen muestras que contienen ruido con características similares al ruido de sal y pimienta, se procede aplicar un filtro de mediana. La Figura 4.12 muestra el resultado de haber aplicado un filtro de mediana.




Figura 4.12: (a) Imagen original e (b) imagen filtrada con un filtro de mediana.

En este punto, se observó que los píxeles correspondientes a las venas han adquirido valores negativos por efecto del filtro paso altas utilizado en el dominio frecuencial. Por ello y utilizando un simple umbral fijado en valor de 0 se consigue obtener nuestro objeto de interés que representan las venas. La Figura 4.13 ilustra el objeto de interés obtenido aplicando el umbral fijado.




Figura 4.13: (a) Imagen original y (b) objeto de interés obtenido.

4.4.4. Enmascaramiento

Como se expuso en el punto anterior, el área correspondiente a la caja puede ser removida utilizando la máscara encontrada. Para ello se utiliza la operación aritmética “and” que es equivalente a multiplicar la imagen con las máscara. La Figura 4.14 es el resultado del enmascaramiento con la finalidad de encontrar finalmente el objeto de interés (las venas).




Figura 4.14: (a) Imagen original e (b) imagen resultante luego de enmascarar.

4.4.5. Erosión

Como es posible observar en la Figura 4.14 quedan pequeños puntos blancos que no pertenecen al objeto de interés. Para ello y como lo revisado en el Capítulo 2 se utiliza la operación morfológica de erosión con el fin de minimizarlos o removerlos ya que ello es considerado ruido y no aporta en nada a la generalización del usuario. La Figura 4.15 ilustra el resultado de esta etapa, como se aprecia esos pequeños puntos blancos han sido removidos con éxito.




Figura 4.15: (a) Imagen original e (b) imagen resultante luego de erosionar.

4.4.6. Esqueletización

Puesto que nuestro objeto de interés presenta redundancia (grosor de los píxeles) en representar la venas, este puede ser reducido a su mínima expresión utilizando una técnica denominada esqueletización. Esto nos permite obtener una matriz dispersa que computacionalmente ahorra espacio. La siguiente Figura 4.16 ilustra el esqueleto computado, como se puede ver la redundancia ha sido removida:




Figura 4.16: (a) Imagen original y (b) esqueleto resultante.

4.4.7. Plantilla

Finalmente para encontrar la plantilla (imagen con dimensión menor a la imagen fuente) tomamos como referencia el centroide de la máscara para encontrar el ancho y alto de la región con información, ello con el fin de cortar apropiadamente el esqueleto obtenido en el punto anterior. La Figura 4.17 representa la plantilla encontrada luego de haber realizado los pasos anteriores.




Figura 4.17: (a) Imagen original y (b) Plantilla.

4.5. Decisión - Reconocimiento

Como último paso y para garantizar el funcionamiento de nuestro sistema, se emplean dos técnicas para validar nuestros resultados. El primer método de reconocimiento es mediante la comparación de plantillas, sí bien este método es eficiente cuando los datos son adquiridos siempre bajo las mismas condiciones, lo cual solo dejaba la pregunta abierta ¿qué pasa sí se toman las muestras con un grado de inclinación? En respuesta a esta cuestión el segundo método fue la solución y la salida ante la debilidad del primer método dejando un sistema mas robusto gracias a la Función de similitud de cosenos.

Cabe resaltar en este momento que este trabajo no pretende comparar dichas técnicas, sino valerse de ambas para la creación de este sistema de reconocimiento biométrico.

La Figura 4.18, muestra ambas técnicas las cuales fueron abordadas en el Capítulo 2. En cuanto a la comparación de plantillas en el Capítulo 5 se describe como fueron seleccionadas las plantillas y como se realizó tal decisión.




Figura 4.18: Técnicas empleadas para el reconocimiento de usuarios.

Por otro lado, para emplear la función similitud de coseno hemos decidido usar como descriptor de características la red convolucional *EfficientNetB0* [TL19], pre-entrenada en la base de datos *ImageNet*. Tal red neuronal no es re-entrenada en nuestra base de datos, aún así los resultados expuestos en el siguiente Capítulo demuestran que si las imágenes no sufren de rotaciones la exactitud tiene un valor aceptable mientras que si son afectadas por rotación, se necesitaría de una etapa de *fine-tunning*.

Tal red neuronal se ilustra en la Figura 4.19, como es posible observar la red convolucional está marcada en líneas punteadas de color rojo y de color morado el vector numérico saliente dada la entrada que es una imagen de la esqueletización de las venas del dorso de la mano. Tal vector tiene una dimensión de 62720 valores característicos.

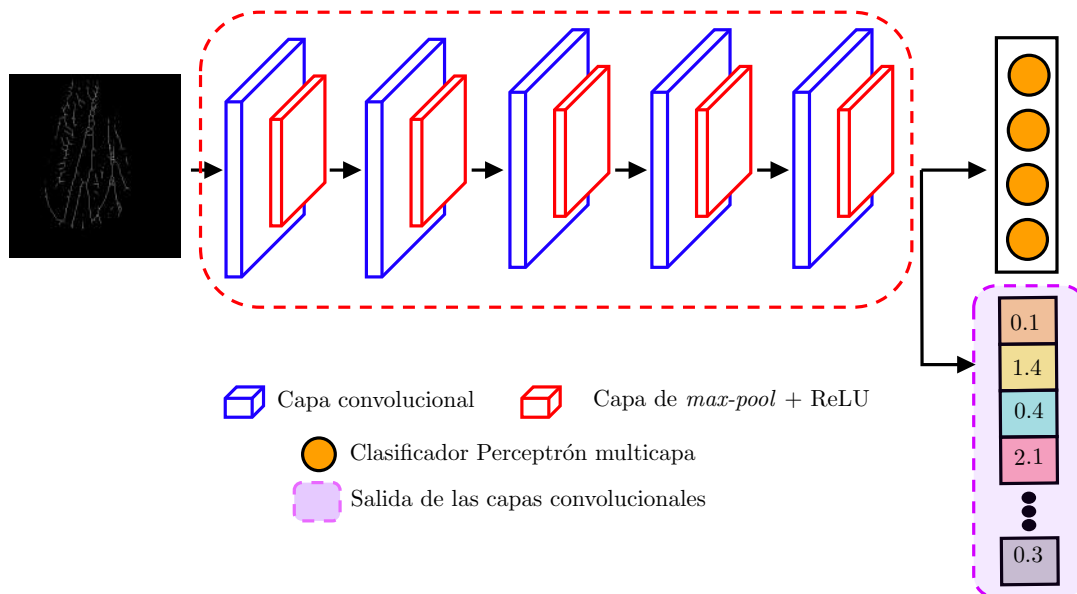


Figura 4.19: Extracción de características utilizando una red neuronal convolucional.

Por ejemplo, dadas 100 muestras se genera una matriz de dimensión 100 x 62720. En tal matriz aplicamos la función de similitud de coseno, dando como resultado una matriz cuya diagonal principal contiene 1 (dado que la similitud de coseno entre la misma muestra es 1) y la primera fila representa la similitud de coseno de la primera muestra versus las demás muestras y así sucesivamente. La Figura 4.20 ilustra un ejemplo de los valores obtenidos de aplicar la similitud de coseno entre todas las muestras. Como se puede observar para la primera muestra, la tercera

muestra pertenecería a su misma clase dado que el valor más alto es 0.63 mientras que para la segunda muestra la quinta muestra pertenecería a su misma clase ya que tiene un valor de 0.96.

Es decir con ello, podemos hallar un vector resultante de predicciones tomando el índice del mayor valor en la fila y compararlo con el valor esperado para obtener una exactitud.

1	0.51	0.63	0.13	0.01	...	N
0.51	1	0.22	0.66	0.96		
0.63	0.22	1	0.16	0.06		
0.13	0.66	0.16	1	0.02		
0.01	0.96	0.06	0.02	1		
⋮					⋮	
N						1

Figura 4.20: Matriz similitud de coseno.

Capítulo 5

Resultados y Comparaciones

A continuación se exponen los resultados obtenidos producto de la presente investigación, utilizando las técnicas de comparación de plantillas y similitud de coseno entre los vectores característicos obtenidos mediante una red neuronal.

5.1. Comparación de plantillas

Considerando que las todas las imágenes de nuestra base de datos ya han pasado por la fase de pre-procesamiento y producto de ello se tiene 275 esqueletos y 275 plantillas. Procedemos a evaluar esta técnica de la siguiente manera:

Se realiza un total de ocho experimentos, donde en los primero cuatro experimentos se almacena una sola plantilla y en los últimos cuatro experimentos se almacena cinco plantillas de cada usuario aleatoriamente y se realiza la comparación de un nuevo esqueleto contra las plantillas almacenadas.

El Cuadro 5.1 muestra los resultados obtenidos en los diferentes experimentos realizados bajo la técnica de comparación de plantillas. Como es posible notar, la exactitud y el puntaje F1 es mayor cuando se incrementa el número de plantillas almacenadas, lo cuál es obvio dado que se tiene mayor “muestras de entrenamiento” almacenadas. Aún así el método es bastante robusto con una sola plantilla. La exactitud final de nuestro sistema cuando se tiene una sola plantilla es igual a $0,992 \pm 0,003$ mientras que cuando se tiene cinco plantillas es igual a $0,999 \pm 0,001$.

Experimento	Número de plantillas	Exactitud	Puntaje F1
1	1	0.996	0.9938
2	1	0.988	0.980
3	1	0.992	0.985
4	1	0.988	0.979
5	5	1	1
6	5	0.995	0.991
7	5	1	1
8	5	1	1

Cuadro 5.1: Resultados obtenidos en los experimentos realizados con la técnica de comparación de plantillas.

La Figura 5.1 muestra la matriz de confusión para el segundo experimento utilizando el caso más crítico que consta de una sola plantilla. Como es posible verse, hay una muestra de la persona 1 que es confundida con la persona 10 y de la misma forma la persona 3 tiene 2 muestras que las confunde como la persona 10.




Figura 5.1: Matriz de confusión para el segundo experimento utilizando una única plantilla.

Por otro lado, la Figura 5.2 muestra una matriz de confusión para el sexto experimento utilizando 5 plantillas. Con el incremento de plantillas se consigue que la persona 1, sea correctamente clasificada mientras que una muestra de la persona 3 aun sigue siendo confundida con la persona 10.




Figura 5.2: Matriz de confusión para el segundo experimento utilizando 5 plantillas.

En este punto, nos cabe plantear una pregunta: ¿Qué sucede cuando el usuario por azar del destino no posa la muñeca en paralelo con la región de interés hecha en

la estructura sino la posa con 15 ó 30 grados de desviación? Para darle respuesta a esta inquietud se ha girado aleatoriamente algunas muestras con un ángulo aleatorio comprendido entre -45 y 45 grados y se ha procedido a experimentar con la misma dinámica de los experimentos mostrados en el Cuadro 5.1.

El siguiente Cuadro 5.2 agrupa los resultados obtenidos luego de haber girado las plantillas bajo el criterio explicado antes. Como se puede observar tanto la exactitud como el puntaje F1 a disminuido aunque la tendencia es la misma a mayor número de plantillas mejor exactitud. Sin embargo, la técnica de comparación de plantillas no muestra robustez ante este caso particular en que el usuario posa la muñeca con cierta desviación aunque cabe señalar que es un caso hipotético ya que naturalmente es poco probable que se dé porque eso lo hemos solucionado vía hardware creando justamente esa área de interés. La exactitud final obtenida para los experimentos que usa una sola plantilla es de $0,311 \pm 0,065$ mientras que para los experimentos que hacen uso de cinco plantillas es de $0,554 \pm 0,041$.

Experimento	Número de plantillas	Exactitud	Puntaje F1
1	1	0.415	0.457
2	1	0.298	0.315
3	1	0.294	0.294
4	1	0.238	0.192
5	5	0.618	0.632
6	5	0.564	0.579
7	5	0.493	0.535
8	5	0.542	0.576

Cuadro 5.2: Resultados obtenidos en los experimentos realizados con la técnica de comparación de plantillas (plantillas giradas).




Figura 5.3: Matriz de confusión para el tercer experimento utilizando única plantilla y con las muestras giradas.

La Figura 5.3 expone la matriz de confusión para el tercer experimento utilizando una sola plantilla como vemos la persona 9 tiene el mayor número de verdaderos positivos mientras que la persona 5 es confundida en su totalidad.

Como parte de estos experimentos y considerando la robustez de las redes convolucionales ante rotaciones o desplazamientos en las imágenes, se procede a extraer los vectores característicos como se describió en el Capítulo 4.

La forma de evaluación es como sigue: Se realizan dos experimentos, el primer experimento con las imágenes sin rotar y el segundo con las imágenes giradas siguiendo la misma metodología antes expuesta. La forma para clasificar un vector de características es utilizando la similitud de Coseno expuesta en el Capítulo 2 entre este y las demás vectores correspondientes a las imágenes de la base de datos, es decir uno contra todos.

El Cuadro 5.3 recoge los resultados obtenidos para ambos experimentos, como es posible notar tanto la exactitud como el puntaje F1 son 1 ó cercanos a 1 lo que comprueba la robustez antes rotaciones en comparación con la técnica de la comparación de plantillas.

Experimento	Exactitud	Puntaje F1
1 (Imágenes sin rotación)	1	1
2 (Imágenes con rotación)	0.993	0.99

Cuadro 5.3: Resultados obtenidos en los experimentos realizados con la técnica de similitud de coseno.

Las siguiente Figura 5.4 representa la matriz de confusión utilizando la similitud de coseno. Como se puede ver, a pesar de que las muestras estén giradas el sistema es robusto, confundiendo sola dos muestras de la persona 1 con la persona 10 y una muestra de la persona 3 con la persona 9.




Figura 5.4: Matriz de confusión para el segundo experimento utilizando la técnica de similitud de coseno.

Finalmente, para validar nuestra propuesta y resultados, utilizamos la base de datos introducida en [WBNAV20], la cual consta imágenes de las venas del dorso de la mano. Si bien las imágenes fueron hechas en un ambiente controlado, no se utilizó o se remarcó una área de interés para el usuario, por lo que las imágenes poseen variabilidad en rotación y traslación y los resultados se obtuvieron sin la necesidad de realizar un re-entrenamiento ya que el vector de características no varía.

La Figura 5.5 ilustra 3 muestras de la base de datos y sus respectivos esqueletos.




Figura 5.5: Venas dorsales de la mano (izquierda) y sus respectivos esqueletos (de-
recha).

Utilizando el mismo flujo de pre-procesamiento y extracción de características se pone a prueba nuestros dos métodos propuestos, comparación de plantillas y similitud de coseno en los experimentos antes descritos. Los resultados son expuestos en el Cuadro 5.4 como se puede apreciar, cuando las imágenes no tiene rotación (rotación sintética, generada por nosotros) la exactitud es de aproximadamente 96 % mientras que cuando son giradas la exactitud decae a 89 %.

Experimento	Exactitud
1 (Imágenes sin rotación)	0.962
2 (Imágenes con rotación)	0.89

Cuadro 5.4: Resultados obtenidos en los experimentos realizados con la técnica de similitud de coseno.

Capítulo 6

Conclusiones y trabajos futuros

En el presente trabajo de tesis se diseñó e implementó un sistema tanto hardware como software para la identificación de usuarios mediante los patrones vasculares presentes en las muñecas de las manos. La visualización de los patrones vasculares mediante infrarrojos fue posible gracias a la propiedad de absorción selectiva de la luz y al diseño de nuestro sistema, el cual es apto para captar esas frecuencias. Así mismo se implementó diversas técnicas de procesamiento digital de imágenes para el tratamiento de los datos adquiridos y se hizo uso de dos métodos para el reconocimiento, comparación de plantillas y similitud de coseno en características extraídas por una red neuronal pre-entrenada.

6.1. Conclusiones

1. Ante las dificultades encontradas se logró exitosamente el propósito de esta tesis, el cual era diseñar, implementar y validar un dispositivo embebido y portátil capaz de brindar un aporte a la problemática planteada, la cual es la escasez de dispositivos comerciales con la capacidad de reconocer a los usuarios ingresados mediante el reconocimiento biométrico vascular.
2. Para el método de comparación de plantillas los resultados son mejores mientras la muestra se comparé contra mas plantillas, sí bien su vulnerabilidad es la rotación esto se soluciona ya sea por hardware, delimitando el espacio donde el usuario coloque la mano o por software mediante el método de función de similitud de coseno.
3. Para el método de comparación de plantillas las diferentes fases por las cuales pasó el diseño del hardware ayudaron enormemente a disminuir la labor en el pre-procesamiento de las imágenes, en otras palabras se consiguió un ambiente controlado donde la región de interés sea lo principal y el ruido consiga ser removido en su mayoría.
4. Considerando el punto anterior, ello ayudó que el método de comparación de plantillas, un método que cuya exactitud tiende a disminuir cuando la imagen origen es desplazada o girada consiga una exactitud casi perfecta incluso cuando solo se tiene una única plantilla de referencia.
5. El método de comparación de plantillas se beneficia enormemente cuando se tiene más plantillas de referencia, sin embargo el número de plantillas es directamente proporcional al coste computacional.
6. La extracción de características mediante redes neuronales convolucionales son más robustas a efectos de rotación y desplazamiento y ello quedó evidenciado

en nuestros experimentos, siendo esta su principal ventaja y dando razón a que se utilizó este método para complementar el sistema del dispositivo propuesto.

7. Los experimentos realizados con la base de datos externa, validan los resultados del sistema propuesto, aun cuando se probó con muestras de bases de datos externas los resultados siguen siendo positivos para los fines de este proyecto.
8. Una ventaja importante de la comparación de plantillas en contraste con las redes neuronales convolucionales es el bajo coste computacional que se necesita. Considerando que ambos métodos son capaces de correr bajo el procesador de la Raspberry Pi 3.
9. Los sistemas basados en venas poseen un grado más elevado de seguridad ya que para la replicación de las venas se necesita tecnología poco convencional y ciertas condiciones para la adquisición de datos.
10. Por último, recalcar que la contribución es el dispositivo como una solución integral a la escases de este tipo de equipos en el mercado.

6.2. Trabajos Futuros

1. Generar una comparación de los resultados con otros métodos que utilizan los patrones vasculares como la palma de la mano, dedo, entre otros.
2. Se debe agregar que esta propuesta puede ser mejorada de dos maneras, incluyendo más muestras por usuario o aplicando técnicas de *fine-tuning* en la red neuronal convolucional, con miras a obtener mejores resultados.
3. Ampliar la base de datos con más usuarios y verificar como responde nuestro sistema ante el aumento de datos.
4. Con los hechos suscitados recientemente a raíz de una pandemia global, en un escenario donde el uso de la mascarilla es obligatorio teniendo como consecuencia un reconocimiento facial fallido plantemos como futuro explorar la aplicación de los sistemas biométricos basados en patrones vasculares a dispositivos móviles como alternativa.
5. Cabe resaltar que como todo en la tecnología, la mejora es constante y si bien en esta tesis se llega a un punto del “sistema final”, la mejora puede ser constante a medida que se desarrollen nuevos productos en el futuro, tal y como sucede con los celulares, televisores, etc.

Bibliografía

- [AAA⁺20] Mohammed Hamzah Abed, Ali H. Alsaeedi, Ali Saeed Dayem Al-foudi, Abayomi Moradeyo Otebolaku, and Yasmeen Sajid Razooqi. Palm vein identification based on hybrid features selection model. *CoRR*, abs/2007.16195, 2020.
- [AAC⁺20] Anju Asokan, J. Anitha, Monica Ciobanu, Andrei Gabor, Antoanela Naaaji, and D. Jude Hemanth. Image processing techniques for analysis of satellite images for historical maps classification—an overview. *Applied Sciences*, 10(12), 2020.
- [AAK14] M. Usman Akram, Hassan Moatasam Awan, and Abdullah Amaan Khan. Dorsal hand veins based person identification. In *2014 4th International Conference on Image Processing Theory, Tools and Applications (IPTA)*, pages 1–6, 2014.
- [Aga18] Abien Fred Agarap. Deep learning using rectified linear units (relu). *CoRR*, abs/1803.08375, 2018.
- [AHP04] Timo Ahonen, Abdenour Hadid, and Matti Pietikäinen. Face recognition with local binary patterns. volume 3021, pages 469–481, 05 2004.
- [AKAT22] Ruaa S.S. Al-Khafaji and Mohammed S.H. Al-Tamimi. Vein biometric recognition methods and systems: A review. *Advances in Science and Technology Research Journal*, 16(1):36–46, 2022.
- [AMR⁺21] Rama Vasantha Adiraju, Kranthi Kumar Masanipalli, Tamalam-pudi Deepak Reddy, Rohini Pedapalli, Sindhu Chundru, and Asissa Kumar Panigrahy. An extensive survey on finger and palm vein recognition system. *Materials Today: Proceedings*, 45:1804–1808, 2021. International Conference on Advances in Materials Research - 2019.
- [ASP20] R. Ablin, C.Helen Sulochana, and G. Prabin. An investigation in satellite images based on image enhancement techniques. *European Journal of Remote Sensing*, 53(sup2):86–94, 2020.
- [AT05] Tina Alster and Elizabeth L. Tanzi. Cellulite treatment using a novel combination radiofrequency, infrared light, and mechanical tissue manipulation device. *Journal of Cosmetic and Laser Therapy*, 7(2):81–85, 2005.
- [CD19] Jyotismita Chaki and Nilanjan Dey. *Texture Feature Extraction Techniques for Image Recognition*. 09 2019.

- [CE08] Martin Cordero and Jorge Enrique. Radiación infrarroja. *El Centro Nacional de Información de Ciencias Médicas de la Habana*, 2008.
- [Cha98] Britton Chance. Near infrared images using continuous, phase modulated, and pulsed light with quantitation of blood and blood oxygenation. *Annals of the New York Academy of Sciences*, 838(1):29–45, 1998.
- [COTQM⁺15] Castro-Ortega, Toxqui-Quitl, Cristobal Marcos, J. V., Padilla-Vivanco, and Perez. Analysis of the hand vein pattern for people recognition. *SPIE Optical Engineering+ Applications. International Society for Optics and Photonics*, 2015.
- [CRM⁺21] Vincenzo Conti, Leonardo Rundo, Carmelo Militello, Valerio Mario Salerno, Salvatore Vitabile, and Sabato Marco Siniscalchi. A multimodal retina-iris biometric system using the levenshtein distance for spatial feature comparison. *IET Biometrics*, 10(1):44–64, 2021.
- [CZW⁺22] Gan Cai, Yu Zhu, Yue Wu, Xiaoben Jiang, Jiongyao Ye, and Dawei Yang. A multimodal transformer to fuse images and metadata for skin disease classification. *The Visual Computer*, May 2022.
- [DDS⁺09] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255, 2009.
- [GH95] C. A. Glasbey and G. W. Horgan. *Image Analysis for the Biological Sciences*. John Wiley and Sons, Inc., USA, 1995.
- [GMSR20] Raul Garcia-Martin and Raul Sanchez-Reillo. Wrist vascular biometric recognition using a portable contactless system. *Sensors*, 20(5), 2020.
- [GMSR21] Raul Garcia-Martin and Raul Sanchez-Reillo. Deep learning for vein biometric recognition on a smartphone. *IEEE Access*, 9:98812–98832, 2021.
- [GW08] Rafael C. Gonzalez and Richard E. Woods. *Digital image processing*. Prentice Hall, Upper Saddle River, N.J., 2008.
- [HAGF16] Nazanin Sadat Hashemi, Roya Babaie Aghdam, Atieh Sadat Bayat Ghiasi, and Parastoo Fatemi. Template matching advances and applications in image analysis. *CoRR*, abs/1610.07231, 2016.
- [HGL⁺19] Abderrahmane Herbadji, Noubel Guermat, Ziet Lahcene, Cheniti Mohamed, and Djamel Herbadji. Personal authentication based on wrist and palm vein images. *International Journal of Biometrics*, 11:309–327, 07 2019.
- [HLP17] Hyung Gil Hong, Min Beom Lee, and Kang Ryoung Park. Convolutional neural network-based finger-vein recognition using nir image sensors. *Sensors*, 17(6), 2017.

- [Hsi18] Chih-Hsien Hsia. New verification strategy for finger-vein recognition system. *IEEE Sensors Journal*, 18(2):790–797, 2018.
- [HZD⁺21] Xu Han, Zhengyan Zhang, Ning Ding, Yuxian Gu, Xiao Liu, Yuqi Huo, Jiezhong Qiu, Yuan Yao, Ao Zhang, Liang Zhang, Wentao Han, Minlie Huang, Qin Jin, Yanyan Lan, Yang Liu, Zhiyuan Liu, Zhiwu Lu, Xipeng Qiu, Ruihua Song, Jie Tang, Ji-Rong Wen, Jinhui Yuan, Wayne Xin Zhao, and Jun Zhu. Pre-trained models: Past, present and future. *AI Open*, 2:225–250, 2021.
- [HZRS16] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep Residual Learning for Image Recognition. In *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 16*, pages 770–778. IEEE, June 2016.
- [Ish10] Sarkar Ishani. Palm vein authentication system: a review. *International Journal of Control Automation*, 2010.
- [JZ20] Shereen Jumaa and Khamis Zidan. High accuracy recognition biometrics based on finger vein screening sensor. *Iraqi Journal of Information and Communications Technology*, 3:35–46, 07 2020.
- [Jä05] Bernd Jähne. *Digital Image Processing 6th Edition*. Springer, Berlin [u.a.], 2005.
- [KDN⁺20] Christof Kauba, Martin Drahansky, Marie Novakova, Andreas Uhl, and Stepan Rydlo. Identification and authentication of user voice using dnn features and i-vector. *Cogent Engineering*, 7(1):1751557, 2020.
- [KDN⁺22] Christof Kauba, Martin Drahansky, Marie Novakova, Andreas Uhl, and Stepan Rydlo. Three-dimensional finger vein recognition: A novel mirror-based imaging device. *Journal of Imaging*, 8(5), 2022.
- [KPU19] Christof Kauba, Bernhard Prommegger, and Andreas Uhl. Combined fully contactless finger and hand vein capturing device with a corresponding dataset. *Sensors*, 19(22), 2019.
- [KRN22] Aman Kamboj, Rajneesh Rani, and Aditya Nigam. A comprehensive survey and deep learning-based approach for human recognition using ear biometric. *The Visual Computer*, 38(7):2383–2416, Jul 2022.
- [KSH12] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In F. Pereira, C.J. Burges, L. Bottou, and K.Q. Weinberger, editors, *Advances in Neural Information Processing Systems*, volume 25. Curran Associates, Inc., 2012.
- [KZ12] Ajay Kumar and Yingbo Zhou. Human identification using finger images. *IEEE Transactions on Image Processing*, 21(4):2228–2244, 2012.
- [LGBHA22] Paula López-González, Iluminada Baturone, Mercedes Hinojosa, and Rosario Arjona. Evaluation of a vein biometric recognition system on an ordinary smartphone. *Applied Sciences*, 12(7), 2022.

- [LLCC06] Hyoun Seung Lee, Dong Hun Lee, Soyun Cho, and Jin Ho Chung. Minimal heating dose: a novel biological unit to measure infrared irradiation. *Photodermatol. Photoimmunol. Photomed.*, 22(3):148–152, jun 2006.
- [LLZ⁺22] Jindi Li, Kefeng Li, Guangyuan Zhang, Jiaqi Wang, Keming Li, and Yumin Yang. Recognition of dorsal hand vein in small-scale sample database based on fusion of resnet and hog feature. *Electronics*, 11(17), 2022.
- [Low04] David G. Lowe. Distinctive image features from scale-invariant keypoints. *Int. J. Comput. Vision*, 60(2):91–110, nov 2004.
- [LRR21] Òscar Lorente, Ian Riera, and Aditya Rana. Image classification with classic and deep learning techniques. *CoRR*, abs/2105.04895, 2021.
- [MA19] Felix Marattukalam and Waleed H. Abdulla. On palm vein as a contactless identification technology. In *2019 Australian and New Zealand Control Conference (ANZCC)*, pages 270–275, 2019.
- [MDK85] Ronald G. McLeod, Julie Daily, and Kenneth Kiss. Image Processing and Geographic Information. In Andrew G. Tescher, editor, *Applications of Digital Image Processing VIII*, volume 0575, pages 271 – 278. International Society for Optics and Photonics, SPIE, 1985.
- [MJ08] David Mulyono and Horng Shi Jinn. A study of finger vein biometric for personal identification. In *2008 International Symposium on Biometrics and Security Technologies*, pages 1–8, 2008.
- [MJP⁺12] Mats-Olof Mattsson, Thomas Jung, Ana Proykova, Francine Behar-Cohen, Frank de Gruijl, James Ferguson, Johnni Hansen, H. Moseley, and Georges Zissis. *Health Effects of Artificial Light*. 03 2012.
- [MLM⁺01] M.J. McAuliffe, F.M. Lalonde, D. McGarry, W. Gandler, K. Csaky, and B.L. Trus. Medical image processing, analysis and visualization in clinical research. In *Proceedings 14th IEEE Symposium on Computer-Based Medical Systems. CBMS 2001*, pages 381–386, 2001.
- [Mor11] Miguel Morales. Termografía infrarroja y el estudio de riesgos de lesiones musculoesqueléticas. *Revista Ingeniería Industrial*, 10(1), 2011.
- [NA12] Mark Nixon and Alberto S. Aguado. *Feature Extraction and Image Processing for Computer Vision, Third Edition*. Academic Press, Inc., USA, 3rd edition, 2012.
- [NML20] Vladimir Novik, Ivan Matveev, and Igor Litvinchev. Enhancing iris template matching with the optimal path method. *Wireless Networks*, 26(7):4861–4868, Oct 2020.
- [OPM02] T. Ojala, M. Pietikainen, and T. Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary

- patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7):971–987, 2002.
- [Ots79] Nobuyuki Otsu. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1):62–66, 1979.
- [PBPPM09] Marius Constantin Popescu, Valentina E. Balas, Liliana Perescu Popescu, and Nikos Mastorakis. Multilayer perceptron and neural networks. *WSEAS Trans. Cir. and Sys.*, 8(7):579–588, jul 2009.
- [RB16] R. Raghavendra and Christoph Busch. A low cost wrist vein sensor for biometric authentication. In *2016 IEEE International Conference on Imaging Systems and Techniques (IST)*, pages 201–205, 2016.
- [RDGP20] Swati Rastogi, Siddhartha P Dutttagupta, Anirban Guha, and Surya Prakash. Nir palm vein pattern recognition. In *2020 IEEE International Conference for Innovation in Technology (INOCON)*, pages 1–5, 2020.
- [RRO09] Marin Ruiz, Juan Rodriguez, and Juan Olivares. Una mirada a la biometria. *Avances en Sistemas e Informática*, pages 29–38, 2009.
- [SB04] Sukhai and Nataliya B. Access control and biometrics. *Proceedings of the 1st annual conference on Information security curriculum development*, pages 124–127, 2004.
- [Ser18] R.A. Serway. *Física para ciencias e ingeniería: Volumen 1*. CENGAGE Learning, 2018.
- [Soi13] P. Soille. *Morphological Image Analysis: Principles and Applications*. Springer Berlin Heidelberg, 2013.
- [SS94] R. S. Sandhu and P. Samarati. Access control: Principle and practice. *Comm. Mag.*, 32(9):40–48, sep 1994.
- [Tan16] Ying Tan. Chapter 11 - applications. In Ying Tan, editor, *Gpu-Based Parallel Implementation of Swarm Intelligence Algorithms*, pages 167–177. Morgan Kaufmann, 2016.
- [TBB20] Onsen Toygar, Felix O. Babalola, and Yiltan Bifirim. Fyo: A novel multimodal vein database with palmar, dorsal and wrist biometrics. *IEEE Access*, 8:82461–82470, 2020.
- [TL19] Mingxing Tan and Quoc Le. EfficientNet: Rethinking model scaling for convolutional neural networks. In Kamalika Chaudhuri and Ruslan Salakhutdinov, editors, *Proceedings of the 36th International Conference on Machine Learning*, volume 97 of *Proceedings of Machine Learning Research*, pages 6105–6114. PMLR, 09–15 Jun 2019.
- [TV13] B. T. Ton and R. N. J. Veldhuis. A high quality finger vascular pattern dataset collected using a custom designed capturing device. In *2013 International Conference on Biometrics (ICB)*, pages 1–5, 2013.

- [TZK⁺19] Su Tang, Shan Zhou, Wenxiong Kang, Qiuxia Wu, and Feiqi Deng. Finger vein verification using a siamese cnn. *IET Biometrics*, 8(5):306–315, 2019.
- [VVCZLC20] Zenin J. Vásquez-Villar, Juan J. Choquehuanca-Zevallos, and Jimmy Ludeña-Choez. Finger vein segmentation from infrared images using spectral clustering: An approach for user identification. In *2020 IEEE 10th International Conference on System Engineering and Technology (ICSET)*, pages 245–249, 2020.
- [VVCZLCML20] Zenin J. Vásquez-Villar, Juan J. Choquehuanca-Zevallos, Jimmy Ludeña-Choez, and Efraín Mayhua-López. Finger vein segmentation from infrared images using spectral clustering: An approach for user identification. In *2020 IEEE 10th International Conference on System Engineering and Technology (ICSET)*, pages 245–249, 2020.
- [Wan11] Chao Wang. Near-infrared light induced in vivo photodynamic therapy of cancer based on upconversion nanoparticles. *Biomaterials*, 32(26):6145–6154, 2011.
- [WBNAV20] Felipe Wilches Bernal, Bernardo Nuñez Alvares, and Pedro Vizcaya. A database of dorsal hand vein images, 2020.
- [WHAF21] Shivali Amit Wagle, R Harikrishnan, Sawal Hamid Md Ali, and Mohammad Faseehuddin. Classification of plant leaves using new compact convolutional neural network models. *Plants*, 11(1):24, dec 2021.
- [WL06] Lingyu Wang and Graham Leedham. Near- and far- infrared imaging for vein pattern biometrics. In *2006 IEEE International Conference on Video and Signal Based Surveillance*, pages 52–52, 2006.
- [WZ18] Junqing Wang and Weichuan Zhang. A survey of corner detection methods. In *Proceedings of the 2018 2nd International Conference on Electrical Engineering and Automation (ICEEA 2018)*, pages 214–219. Atlantis Press, 2018.
- [XS08] Li Xueyan and Guo Shuxu. The fourth biometric - vein recognition. In Peng-Yeng Yin, editor, *Pattern Recognition*, chapter 23. IntechOpen, Rijeka, 2008.
- [yCjZS08] Feng ying Cui, Li jun Zou, and Bei Song. Edge feature extraction based on digital image processing techniques. In *2008 IEEE International Conference on Automation and Logistics*, pages 2320–2324, 2008.
- [YPIK90] HK Yuen, J Princen, J Illingworth, and J Kittler. Comparative study of hough transform methods for circle finding. *Image and Vision Computing*, 8(1):71–77, 1990.
- [YYZY15] Lu Yang, Gongping Yang, Lizhen Zhou, and Yilong Yin. Superpixel based finger vein roi extraction with sensor interoperability. In *2015 International Conference on Biometrics (ICB)*, pages 444–451, 2015.

- [ZXDX18] Xinman Zhang, Qi Xiong, Yixuan Dai, and Xuebin Xu. Voice biometric identity authentication system based on android smart phone. In *2018 IEEE 4th International Conference on Computer and Communications (ICCC)*, pages 1440–1444, 2018.