

Universidad de Oriente
Facultad de Ingeniería Eléctrica
Departamento de Telecomunicaciones y Electrónica



TRABAJO DE DIPLOMA

**Diseño e implementación de un algoritmo
para la estimación de orientaciones y
frecuencias locales en imágenes de huellas
latentes.**

Autor: Jorge Luis Pérez Reyes.

Tutor: Ing. Rodobaldo Cupull Gómez .

Santiago de Cuba

Junio, 2015

Universidad de Oriente
Facultad de Ingeniería Eléctrica
Departamento de Telecomunicaciones y Electrónica



TRABAJO DE DIPLOMA

**Diseño e implementación de un algoritmo
para la estimación de orientaciones y
frecuencias locales en imágenes de huellas
latentes.**

Autor: Jorge Luis Pérez Reyes.

jorge.perez@tle.fie.uo.edu.cu

Tutor: Ing. Rodobaldo Cupull Gómez.

Profesor Instructor, Departamento de Telecomunicaciones, Facultad de Ingeniería
Eléctrica.

rcupull@fie.uo.edu.cu

Santiago de Cuba

Junio, 2015



COMPROMISO DEL AUTOR

Hago constar que el presente trabajo de diploma es de mi autoría exclusivamente, no constituyendo copia de ningún trabajo realizado anteriormente y las fuentes usadas para la realización del trabajo se encuentran referidas en la bibliografía. Doy mi consentimiento a que el mismo sea utilizado por la Institución, para los fines que estime conveniente, tanto de forma parcial como total y que además no podrá ser presentado en eventos, ni publicados sin autorización del Tutor o Institución.

Firma del Autor

PENSAMIENTO

Investigar es ver lo que todo el mundo ha visto, y pensar lo que nadie más ha pensado.

Albert Szent Gyorgi

(1893-1986) médico húngaro

Todas las cosas son fáciles de entender cuando se descubren. El punto es descubrirlas.
Eso requiere investigación.

Galileo Galilei

DEDICATORIA

Este trabajo de diploma lo dedico a las personas más importantes de mi vida, a las que han dado todo por mí. Si todos somos dichosos por tener madres, yo he tenido la suerte de contar con 4: Carmen Rosa Reyes, Zenaida Almaguer, Martha García y Rada Reyes. Además también he contado con la guía y apoyo de 3 padres: Jorge Luis Pérez, Rolando Reyes y Maximino Pérez, los cuales han sido una mezcla interesante en mi carácter. Este trabajo está dedicado además para Lianelys Rosa Segura, que más que mi novia en estos últimos años se ha perfilado como mi mujer para el resto de la vida.

AGRADECIMIENTOS

A mis padres Carmen Rosa Reyes Almaguer y Jorge Luis Pérez García por apoyarme siempre en mis decisiones aunque no estuviesen de acuerdo en algunas.

A mi tutor Rodobaldo Cupull Gómez por su ayuda incondicional, por su dedicación y tiempo.

A mis abuelos: Zenaida Almaguer, Martha García, Rolando Reyes, Maximino Pérez, a los cuales no tengo palabras para agradecerles.

A mis tíos Rada Reyes y Javier por todo su cariño y apoyo.

A mi novia y a mis suegros Martha Rodríguez y Leonardo Segura por todo su apoyo.

A mi prima Lianys Reyes por todo su cariño.

A mis compañeros de estudio y de universidad por tantos buenos momentos, en especial a Ángel Rosado, Raysel Mendoza, Enmanuel Fajardo.

A todo el claustro de profesores por contribuir a mi formación profesional.

Y a todos aquellos que de una forma u otra han contribuido en mi formación como ingeniero en Telecomunicaciones y Electrónica.

RESUMEN

El principal objetivo de este trabajo fue el diseño e implementación de un algoritmo para estimar las direcciones y frecuencias locales en imágenes de huellas latentes, con el propósito de aumentar la fiabilidad en el proceso de mejoramiento de este tipo de huellas en los sistemas de reconocimiento biométrico. Para cumplir con lo anterior se empleó la Transformada de Fourier de Tiempo Reducido para realizar un análisis local en la imagen que permitiera la estimación de dichos parámetros directamente del espectro de Fourier. Además, se utilizó un algoritmo de crecimiento de regiones con condiciones de continuidad adaptativas, que posibilita estimar con precisión las orientaciones y frecuencias locales al mismo tiempo que se segmenta la imagen. El empleo de un filtro contextual Log-Gabor como etapa final del mejoramiento, en conjunto con el algoritmo de detección de minucias implementado en GAPIS, posibilitaron la validación de los resultados. Se emplearon dos bases de datos de huellas latentes certificadas entre las que se encuentra la NIST27, muy utilizada internacionalmente para la validación de algoritmo de reconocimiento epitelial. Los resultados obtenidos en este trabajo evidenciaron que el algoritmo propuesto posee un mejor desempeño en la estimación de la orientación y frecuencia, y en la segmentación que los algoritmos implementados anteriormente en GAPIS, obteniéndose en promedio un 48.06% de minucias detectadas correctamente.

Palabras clave: huellas latentes, GAPIS, Transformada de Fourier de Tiempo Reducido, crecimiento de regiones, filtro Log-Gabor, minucias.

ABSTRACT

The main objective of this work was the design and implementation of an algorithm for estimating local frequencies directions and images for latent prints, in order to increase reliability in the process of improving this type of latent prints in the biometrics . To achieve the above Short Time Fourier Transform was employed for a local analysis in the image to allow the estimation of these parameters directly from the Fourier spectrum. In addition, a region growing algorithm was used with continuity adaptive conditions, enabling to accurately estimate local frequencies and orientations while the image is segmented. Using a contextual Log-Gabor filter as the final stage of improvement, together with the minutiae detection algorithm implemented in GAPIS, they enabled the validation of the results. Two databases Latent certified among which is the NIST27, widely used internationally for validating epithelial recognition algorithm is used. The results obtained in this work showed that the proposed algorithm has better performance in estimating the orientation and frequency, and the segmentation algorithms than implemented earlier in GAPIS, yielding an average of 48.06% of minutiae detected correctly.

Keywords: latent prints, GAPIS, Short Time Fourier Transform, region growing, Log-Gabor filter, minutiae.

ÍNDICE

INTRODUCCIÓN	1
CAPITULO 1 . PROCESAMIENTO DE IMÁGENES DE HUELLAS EPITELIALES	4
1.1 Morfología de la huella epitelial	4
1.1.1 Minucias y su representación	5
1.1.2 Orientación local de la cresta	6
1.1.3 Frecuencia local de la cresta.....	7
1.1.4 Regiones singulares y no singulares en huellas epiteliales	9
1.1.5 Calidad de imágenes de huellas epiteliales.....	9
1.1.6 Modelo ideal de una región local de huella epitelial.....	11
1.2 Short Time Fourier Transform (STFT)	15
1.3 Segmentación en huellas epiteliales	16
1.3.1 Segmentación orientada a regiones.....	17
1.4 Filtro de Gabor logarítmico.....	18
1.4.1 Componente radial del filtro Log-Gabor.....	19
1.4.2 Componente angular del filtro Log-Gabor	20
1.5 Algoritmo de mejoramiento implementado en GAPIS.....	23
CAPITULO 2 . ALGORITMO DE MEJORAMIENTO PROPUESTO	25
2.1 Cálculo de la STFT	26
2.2 Algoritmo propuesto para la estimación de la orientación y la frecuencia local...	27
2.3 Filtrado del espectro y reconstrucción de la imagen mejorada	32
CAPITULO 3 . RESULTADOS Y VALIDACIÓN.....	33
3.1 Resultados de la estimación de la orientación y frecuencia local en imágenes ruidosas.....	34
3.1.1 Influencia del ruido gaussiano en la estimación de los parámetros locales .	35

3.1.2	Influencia del ruido salt & pepper en la estimación de los parámetros locales	38
3.1.3	Estimación de la orientación en imágenes reales de huellas epiteliales	41
3.2	Resultados de la influencia de los algoritmos de mejoramiento en los algoritmos de detección de minucias	44
CONCLUSIONES Y RECOMENDACIONES		50
REFERENCIAS BIBLIOGRÁFICAS		51
Anexos		53

INTRODUCCIÓN

Las huellas epiteliales han sido la forma de identificación biométrica más antigua y utilizada debido a su invariabilidad a lo largo de toda la vida de una persona, así como su carácter distintivo aun para gemelos idénticos [1].

Los estudios científicos de este rasgo biométrico se iniciaron a finales del siglo XVI, pero los fundamentos de las técnicas modernas de identificación, fueron establecidos en los estudios de F. Galton y E. Henry hacia finales del siglo XIX. Para la identificación mediante las huellas epiteliales el principal patrón empleado son las minucias, término que se refiere a determinadas estructuras formadas por las crestas y valles [2]. Se pueden observar las principales minucias en la figura siguiente.

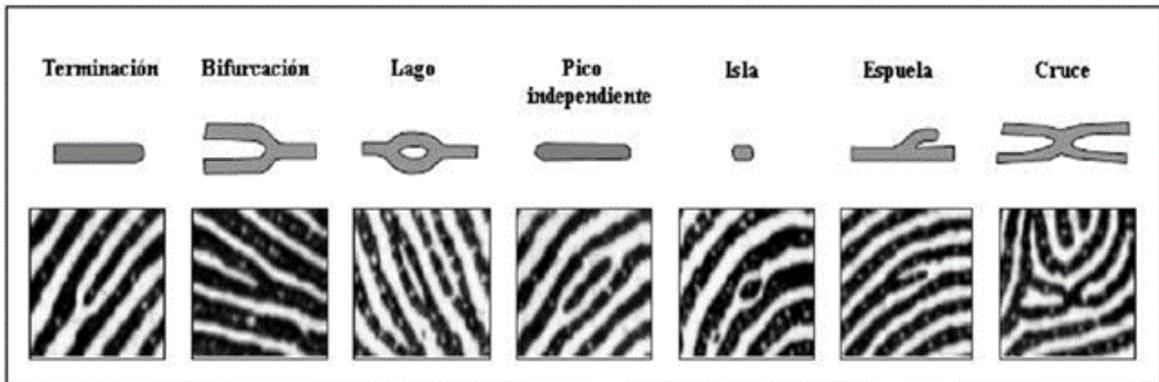


Figura. 1 Principales minucias en huellas epiteliales. (Fuente: [2])

La coincidencia angular y espacial de un pequeño número de minucias (de 12 a 15 minucias) es suficiente para afirmar que dos impresiones de huellas epiteliales corresponden a la misma huella. En la extracción de minucias influye notablemente la calidad de la imagen de entrada, debido a las características de la piel y fundamentalmente al modo de adquisición, un porcentaje alto de imágenes de huellas epiteliales son de pobre calidad [2].

Para garantizar que los algoritmos de extracción de minucias sean robustos, independientemente de la calidad de la imagen de entrada, es necesario la implementación de un algoritmo de mejoramiento que resalte las estructuras de crestas

en las regiones de buena calidad y recuperables y marque las regiones no recuperables (con demasiado ruido) para un posterior procesamiento. La robustez del algoritmo de mejoramiento se cuantifica por la capacidad de resaltar las verdaderas minucias, así como no generar minucias falsas [3].

Los filtros contextuales Log-Gabor han sido muy efectivos en el mejoramiento de la calidad de las imágenes de huellas epiteliales, dos importantes parámetros de estos filtros son la orientación y la frecuencia [4]. Si estos parámetros son estimados correctamente, el filtro puede conectar el flujo de crestas interrumpido por zonas de pliegues y además, aumentar el contraste entre las crestas y los valles. Por el contrario, si al menos uno de estos parámetros se estima de forma incorrecta, las verdaderas estructuras de crestas en la huella epitelial pueden perderse, y falsas estructuras de crestas crearse con el filtrado. Por tanto, la estimación de la orientación y frecuencia local es de vital importancia para la extracción de minucias en las huellas epiteliales [5].

En las últimas décadas se han obtenido importantes avances en diversas áreas del procesamiento de imágenes de huella epiteliales como: mejoramiento, clasificación y el desarrollo de sistemas comerciales automáticos de identificación (AFIS). Sin embargo el trabajo con imágenes de huellas latentes y palmares se ha visto rezagado debido a la presencia de ruidos intensos como pliegues, manchas, escrituras, etc. que dificultan la estimación confiable de la orientación y la frecuencia del flujo de crestas local y por tanto el mejoramiento de la calidad de la imagen [6]. Por otra parte la mayor limitación que poseen los algoritmos de estimación de la orientación y frecuencia local no es precisamente la presencia de fuertes ruidos, sino que no incorporan los conocimientos estadísticos obtenidos en los estudios de las huellas epiteliales, los cuales en el área del mejoramiento han recibido poca atención [7].

Antecedentes del problema

En el Departamento de Telecomunicaciones de la Universidad de Oriente se ha creado el Grupo de Aplicaciones de Procesamiento de Imágenes y Señales (GAPIS), el cual se dedica al estudio e implementación de algoritmos en varias esferas del procesamiento de señales, incluyendo el tratamiento de rasgos biométricos.

En la actualidad GAPIS cuenta con la implementación de varios algoritmos para el mejoramiento de la calidad de imágenes de huellas epiteliales. Uno de ellos, basado en la publicación de Jianjian Feng y Anil K. Jain "Latent Palmprint Matching", 2009, fue

desarrollado en un trabajo de diploma de tesis de pregrado en el 2014, y obtuvo aceptables resultados en la estimación de orientaciones y frecuencias locales en imágenes de huellas latentes de baja y mediana calidad.

Un análisis crítico del algoritmo propuesto en dicha tesis concluyó que el mismo no estima las orientaciones y frecuencias locales acertadamente cuando la presencia de regiones de bajo contraste en la imagen, es notable. Además la correcta segmentación de las imágenes también se ve afectada en imágenes de huella latente de baja calidad.

Problema a resolver

El algoritmo de estimación de orientaciones y frecuencias para imágenes latentes, implementado GAPIS, no es eficiente en imágenes donde la presencia de fondos complejos y bajo contraste resulta predominante, lo cual dificulta el mejoramiento de este tipo de huellas mediante filtros de Log-Gabor, y por ende la detección de minucias válidas en los patrones de dichas huellas.

Objeto de estudio

Técnicas de estimación de frecuencias y direcciones locales en imágenes de huellas latentes.

Objetivos

Diseñar e implementar un algoritmo de procesamiento de imágenes que permita estimar los valores de frecuencias y direcciones locales de una imagen de huella latente.

Hipótesis.

Si se diseña e implementa un algoritmo que permita estimar eficientemente los valores de frecuencias y orientaciones locales en imágenes de huellas latentes que posean fondos complejos y bajo contraste, se podrán mejorar dichas imágenes mediante filtros de Log-Gabor y se facilitará la detección de minucias válidas en los patrones de dichas huellas.

CAPITULO 1 . PROCESAMIENTO DE IMÁGENES DE HUELLAS EPITELIALES

En este capítulo se aborda sobre la morfología de las huellas epiteliales, enfatizando en la representación de las minucias, en la orientación y frecuencia local del flujo de crestas, así como las principales estadísticas relacionadas con dichos parámetros. Se introduce la representación de una región local de huella mediante una senoide bidimensional, y la estimación de sus parámetros en el dominio de Fourier, lo cual constituye una técnica robusta para la estimación de la orientación y frecuencia en regiones locales contaminadas por fuertes ruidos, pertenecientes principalmente a imágenes de huellas palmares y latentes. Se fundamenta la utilización de la transformada de Fourier de tiempo reducido, la cual permite realizar un análisis por regiones locales de la imagen, útil tanto para la estimación de la orientación y frecuencia local de dichas regiones como para el mejoramiento y reconstrucción de la imagen directamente del espectro, por lo que se exponen además las principales características del filtro contextual Log-Gabor ampliamente utilizado para la realización de dicho mejoramiento. Por último se realiza un breve análisis del algoritmo implementado en GAPIS para para el mejoramiento de imágenes de huellas latentes y palmares.

1.1 Morfología de la huella epitelial

Una huella epitelial es la reproducción de la apariencia exterior de la epidermis, su característica estructural más evidente es un patrón de crestas y valles intercalados que son representados en una imagen por líneas oscuras y claras respectivamente. La mayoría de las lesiones como quemaduras superficiales, rasguños, o cortes no afectan la estructura de crestas subyacente, pues esta se regenera en la nueva piel que crece [2].

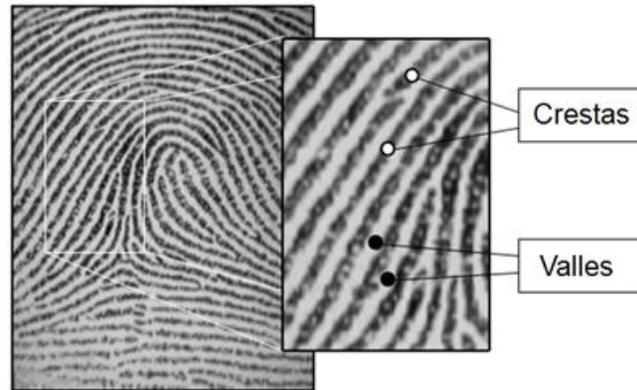


Figura. 1.1 Crestas y valles en huellas epiteliales. (Fuente: [2])

En la figura anterior se muestra una imagen de huella epitelial donde aparecen reflejados las crestas y valles del flujo epidérmico.

1.1.1 Minucias y su representación

Uno de los principales métodos para poder realizar el reconocimiento de una huella epitelial es a través de la identificación de las minucias. El Instituto Nacional de Estándares Americano (ANSI/NIST-ITL 1,2007), propone solo la extracción de las terminaciones, bifurcaciones y cruces para aumentar la fiabilidad de los sistemas automáticos de extracción de minucias [2]. En la siguiente figura se muestran las minucias que propone dicho estándar.

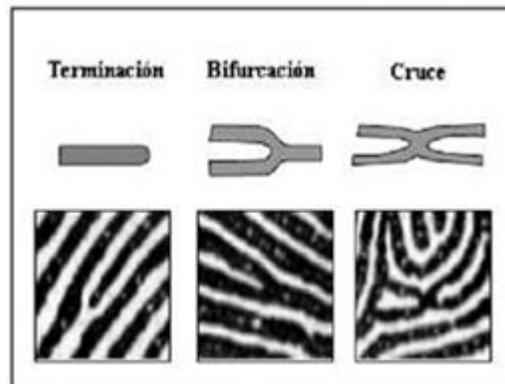


Figura. 1.2 Minucias recomendadas por el estándar ANSI/NIST-ITL 1,2007. (Fuente: [2])

Las minucias se representan en la imagen por su ubicación espacial (x,y), y su ubicación angular referenciada al eje coordenado tomado como referencia horizontal [2].

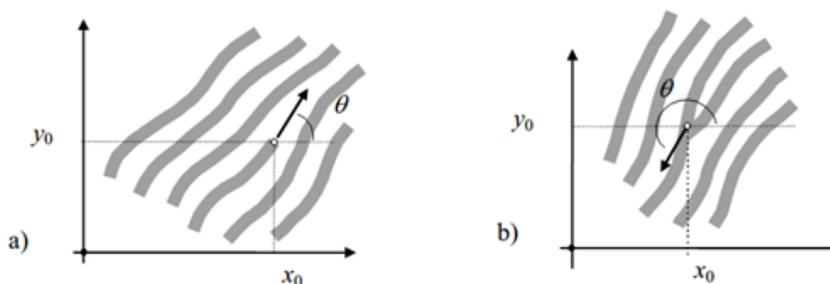


Figura. 1.3 Representación de minucias: a) terminación b) bifurcación. (Fuente: [2])

En la figura anterior se muestra la representación de la minucia terminación y la minucia bifurcación. A la ubicación angular de la minucia se le conoce como dirección, la cual varía en el rango $0 \leq \theta < 2\pi$ [2].

1.1.2 Orientación local de la cresta

La orientación local de la cresta en el pixel(x, y) es el ángulo que la cresta forma, en una pequeña vecindad centrada en dicho pixel, con el eje coordenado tomado como referencia horizontal. Debido a que las estructuras de crestas no son direccionales, la orientación local de la cresta varía en el rango $0 \leq \theta_e < \pi$ [2].

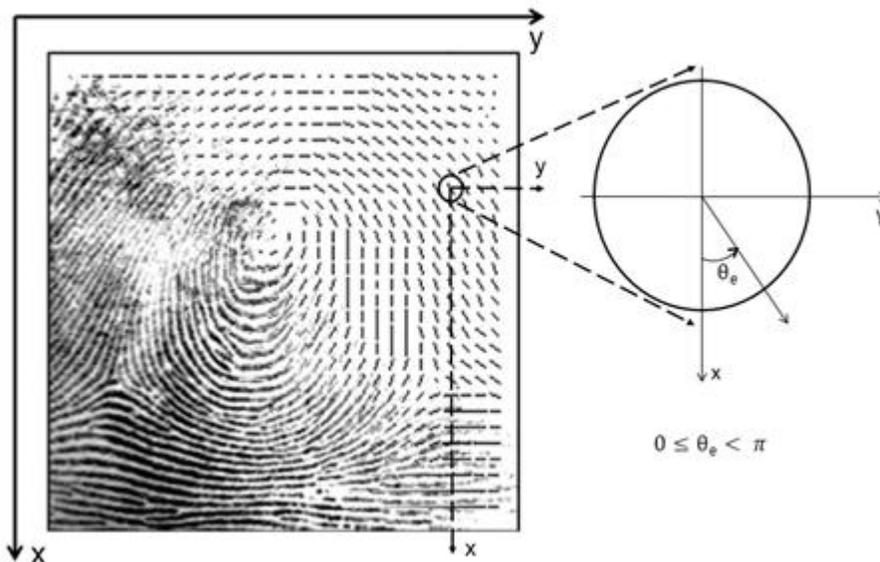


Figura. 1.4 Representación de la orientación local de la cresta. (Fuente: [2])

En la figura anterior se observa la representación de la orientación local de crestas y la referencia horizontal utilizada en este trabajo de diploma.

1.1.3 Frecuencia local de la cresta

La frecuencia local de crestas, es el inverso del periodo local de crestas, donde el periodo local de crestas en imágenes de huellas epiteliales, es la distancia en pixeles en dirección ortogonal a la orientación local de la cresta entre el centro de dos crestas consecutivas [2], representación que se muestra en la siguiente figura.

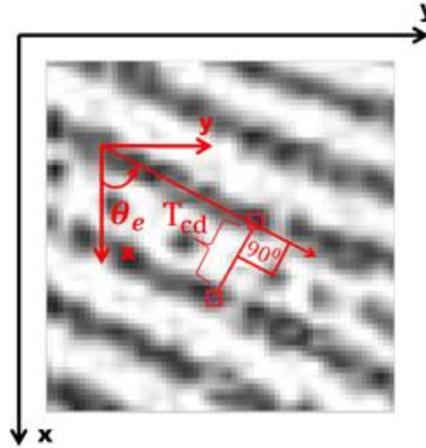


Figura. 1.5 Representación del periodo local de crestas

El periodo local de crestas varía de una huella epitelial a otra e incluso ente diferentes regiones locales de la misma huella epitelial. Se ha determinado que el periodo espacial promedio de repetición de crestas en huellas epiteliales es de 500μm [8].

El periodo de las crestas en las imágenes de huellas epiteliales depende de la resolución en dpi con que fue tomada la imagen, mediante la regla de tres, se puede obtener la relación aproximada entre el periodo de crestas en las huellas epiteliales ampliamente estudiado y el periodo de crestas en las imágenes de huellas epiteliales.

$$\frac{25000}{\text{dpi}} = \frac{T_c}{T_{cd}} \quad (1.1)$$

$$T_{cd} = \frac{T_c * \text{dpi}}{25000} \quad (1.2)$$

donde:

- T_{cd} : periodo de cresta en la imagen digital de la huella epitelial [pixeles]
- T_c : periodo de cresta en la huella epitelial [μm]
- dpi: resolución de la imagen [pixeles/pulgada]

25000: constante introducida para transformar pulgadas en μm .

Para imágenes de 500 dpi y periodo promedio de crestas de $500\mu\text{m}$ se obtiene:

$$T_{cd} = \frac{500 * 500}{25000}$$

$$T_{cd} = 10 \text{ [pixeles]}$$

O sea, el periodo promedio local de crestas en imágenes de huellas epiteliales de 500 dpi es aproximadamente 10 pixeles.

Resultados similares se han obtenido en experimentos realizados en imágenes de huellas de las bases de datos del National Institute of Standards (NIST) y 2002 Fingerprint Verification Competition (FVC2002), donde las imágenes fueron escaneadas a 500 dpi.

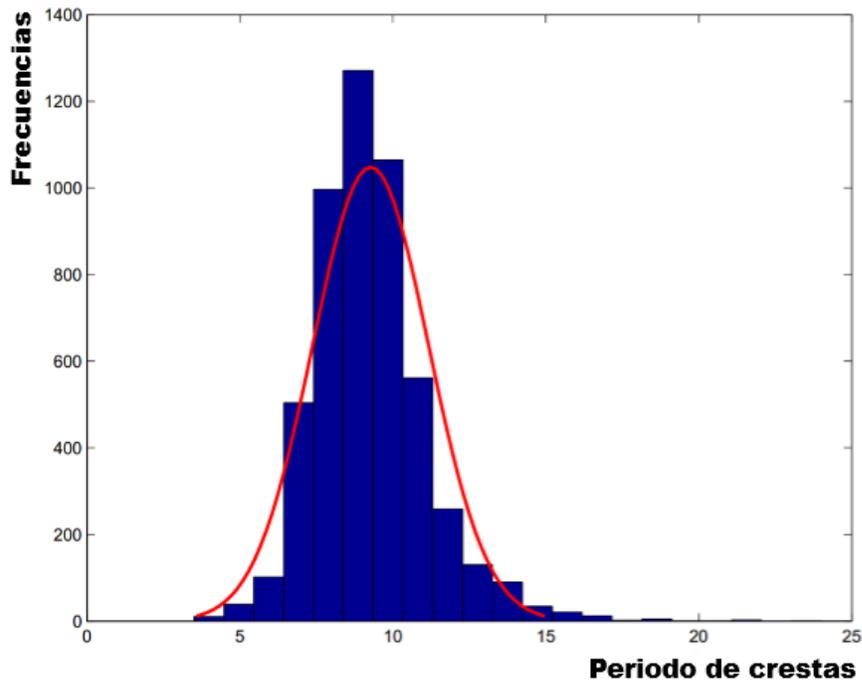


Figura. 1.6 Histograma del periodo local de crestas de los experimentos con función gaussiana superpuesta. (Fuente: [1])

En la figura anterior se muestra el histograma de los resultados obtenidos en dichos experimentos, se puede observar que el periodo de crestas varía entre $5 \leq T_{cd} \leq 15$ pixeles, donde el periodo promedio es de 9.2732 pixeles con una desviación estándar de 1.8985. [1].

1.1.4 Regiones singulares y no singulares en huellas epiteliales

En las huellas epiteliales existen regiones que poseen ciertas formas distintivas, caracterizadas por variaciones bruscas en la orientación y frecuencia de las crestas, estas regiones son llamadas singularidades o regiones singulares, y poseen una densidad de minucias de $0.49 \text{ minucias/mm}^2$. Las singularidades se agrupan en tres categorías diferentes: *loop* (\cap), *delta* (Δ), y *whorl* (O), al centro de la singularidad se le llama *core* [2]. Empíricamente se ha determinado que entre bloques adyacentes de 16×16 pixeles que conforman una singularidad se cumple $0 \leq \Delta\theta_e < \pi/6$, $0 \leq \Delta T_{cd} \leq 3$ pixeles[5].

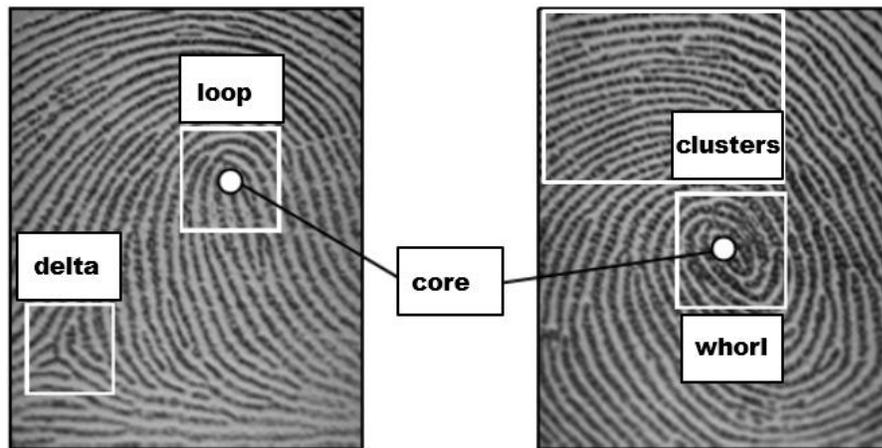


Figura. 1.7 Regiones singulares y no singulares en huellas epiteliales. (Fuente: [2])

Las regiones no singulares son las de mayores dimensiones en una huella epitelial, poseen una densidad de minucias de $0.18 \text{ minucias/mm}^2$ [2] y un flujo de crestas con variaciones tenues en la orientación y frecuencia [5].

Empíricamente se ha determinado que entre bloques adyacentes de 16×16 pixeles que conforman una región no singular de más de 20 bloques, a las que llamaremos clusters, se cumple $0 \leq \Delta\theta_e < \pi/12$ [7], $0 \leq \Delta T_{cd} \leq 3$ pixeles. En la Figura.1.7 se representan las regiones singulares y no singulares anteriormente comentadas.

1.1.5 Calidad de imágenes de huellas epiteliales

La calidad de las imágenes de huellas epiteliales depende de las condiciones de la epidermis (arrugas, callos, desgaste, etc.), pero de forma predominante del método utilizado para su digitalización, existen tres formas básicas de digitalizar una huella [2].

- Método de captura en vivo: La persona de forma consciente y voluntaria permite el escaneado de su huella epitelial mediante sensores especializados, por lo que la calidad de la imagen de huella será alta.
- Método de entintado: La persona de forma consciente y voluntaria permite el entintado de su huella epitelial y su representación sobre una superficie plana específica, la cual se digitaliza en una imagen, por lo que la calidad de la imagen de huella será alta.
- Método latente: La persona de forma inconsciente realiza impresiones epiteliales sobre ciertos materiales, no visibles a simple vista, pero revelables con técnicas químicas y digitalizadas en una imagen.

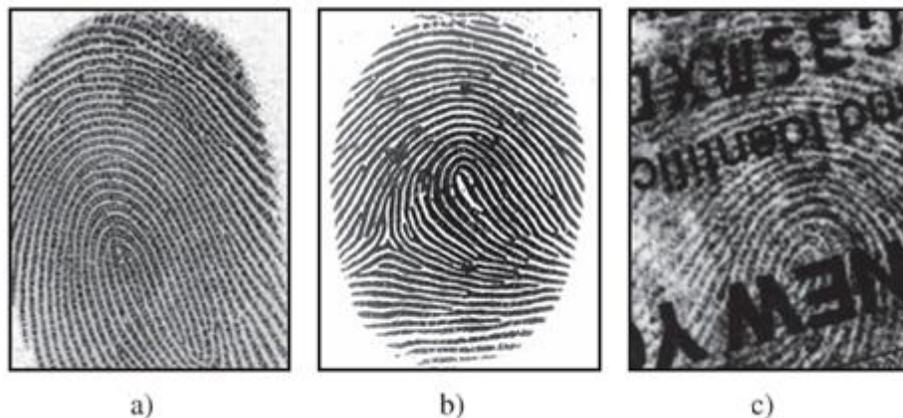


Figura. 1.8 Huella epitelial obtenida usando tres tipos de métodos a) captura en vivo; b) entintado; c) latente. (Fuente: [7])

En la figura anterior se muestran 3 imágenes digitalizadas por los métodos anteriormente comentados, nótese que comparado con la calidad de las imágenes de huellas epiteliales realizadas intencionalmente, las imágenes de huellas latentes son de muy mala calidad, debido a que presentan tenues estructuras de crestas, con poco contraste y patrones solapados, como otras huellas, escrituras, etc. [7].

Independientemente del método de digitalización de la huella epitelial, las regiones locales de huellas presentan diferentes definiciones en cuanto a las estructuras de crestas, dichas regiones locales pueden dividirse en tres categorías fundamentales [2].

- Regiones de buena calidad: conformada por estructuras de crestas bien definidas
- Regiones recuperables: Las estructuras de crestas están corruptas por un pequeño conjunto de manchas, pliegues, ruido en general, pero aun es visible las

estructuras de crestas y las regiones vecinas aportan suficiente información sobre las mismas.

- Regiones no recuperables o fondo: las estructuras de crestas están altamente corruptas por ruido y no son visibles, además las regiones vecinas no aportan suficiente información sobre las mismas.



Figura. 1.9 Regiones locales con diferentes calidades a) región de buena calidad; b) región recuperable; c) región no recuperable o de fondo. (Fuente: [2])

En la figura anterior se muestran 3 regiones locales de diferente calidad. Regiones de buena calidad, recuperables y no recuperables pueden ser identificadas de acuerdo a muchos criterios, en general, el contraste, la consistencia en la orientación, frecuencia, predominio de un pico en el espectro de Fourier y otros parámetros locales que en conjunto conforman el sistema de clasificación. [2].

1.1.6 Modelo ideal de una región local de huella epitelial

Con excepción de las regiones locales recuperables y no recuperables, toda región local de huella epitelial se puede aproximar mediante una senoide bidimensional como se muestra en la Figura.1.10, la cual se le conoce como onda modelo y cuya ecuación se define por [5]:

$$f(x, y) = a \cdot \sin[2\pi f(\sin(\theta_e)x - \cos(\theta_e)y) + \phi] \quad (1.3)$$

donde:

$f(x, y)$: seno bidimensional expresado en coordenadas cartesianas

a: amplitud

f: frecuencia

θ_e : orientación del flujo de crestas

ϕ : fase

Por tanto, la estimación de la orientación y frecuencia de la región local de la huella se transforma en la estimación de los parámetros de la onda modelo [5].

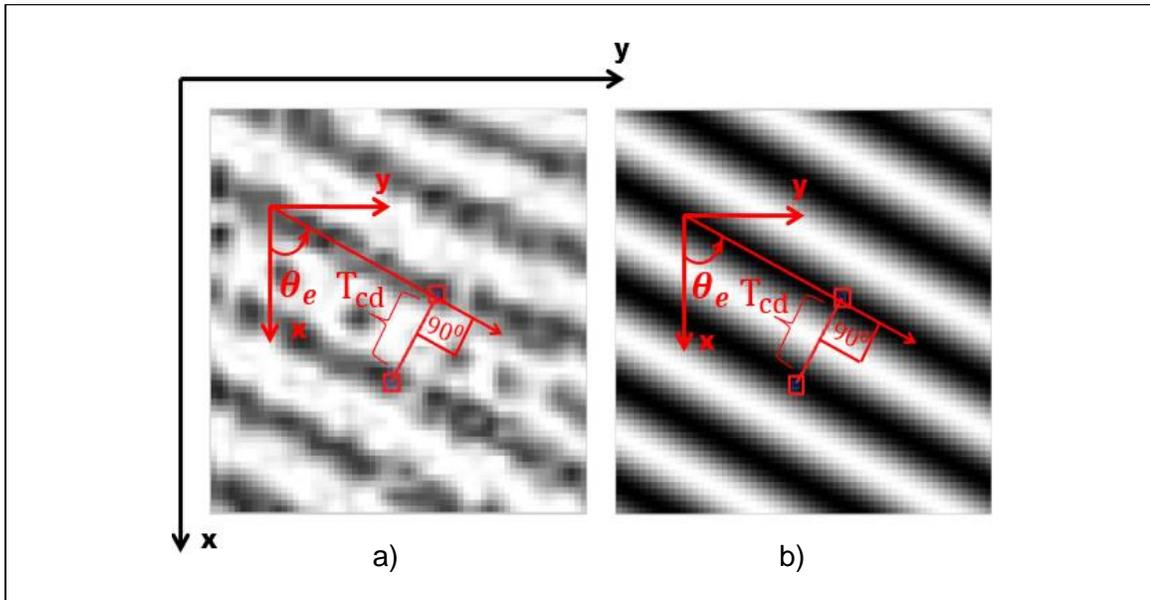


Figura. 1.10 Modelo ideal de una región local de huella epitelial; a) región local de huella; b) onda modelo de la región local

El espectro de amplitud de Fourier de un seno bidimensional exhibe un pico, término utilizado para referirse al pixel que posea la mayor amplitud dentro de la 8 vecindad que define. Los parámetros del seno bidimensional quedarán definidos por la ubicación del pico en el espectro de Fourier mediante las siguientes ecuaciones [5].

$$a = |F(u, v)| \quad (1.4)$$

$$f = \frac{\sqrt{(u - u_0)^2 + (v - v_0)^2}}{L} = \frac{r}{L} \quad (1.5)$$

$$\phi = \arctan\left(\frac{\text{Im}(F(u, v))}{\text{Re}(F(u, v))}\right) \quad (1.6)$$

$$\theta_f = \arctan\left(\frac{v - v_0}{u - u_0}\right) \quad (1.7)$$

$$\theta_e = \begin{cases} \theta_f - \frac{\pi}{2} & , \quad \theta_f \geq \frac{\pi}{2} \\ \theta_f + \frac{\pi}{2} & , \quad \theta_f < \frac{\pi}{2} \end{cases} \quad (1.8)$$

donde:

$F(u, v)$: espectro de Fourier centrado del seno bidimensional

(u, v) : coordenadas cartesianas del pico en el espectro

(u_0, v_0) : coordenadas cartesianas del centro del espectro

r : distancia euclidiana del pico en el espectro de amplitud al centro del espectro

L : tamaño de la sección local analizada o dimensión del espectro

a : amplitud del pico en el espectro

f : frecuencia del seno

ϕ : fase del seno

θ_e : orientación del flujo de crestas del seno

θ_f : orientación en el dominio de la frecuencia del flujo de crestas del seno

En la siguiente figura se observa el pico en el espectro de amplitud centrado que define a la senoide.

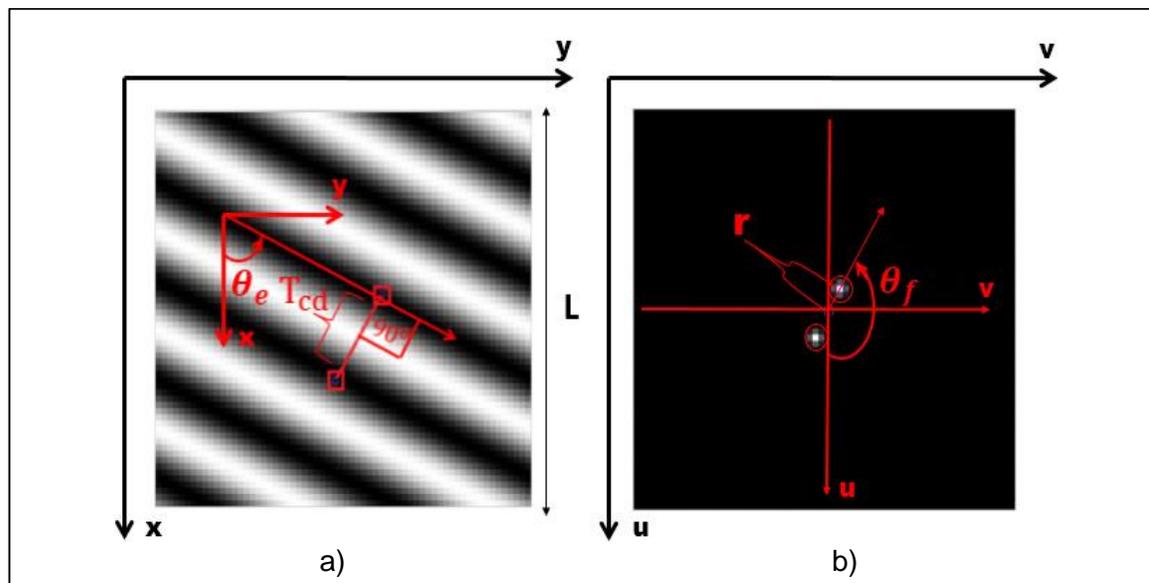


Figura.1.11 Estimación de la orientación y frecuencia del seno bidimensional;
a) seno bidimensional; b) espectro de amplitud centrado del seno

Es importante notar que la orientación en el dominio de la frecuencia es perpendicular a la orientación en el dominio espacial del flujo de crestas, y la propiedad de simetría del espectro centrado.

En el espectro de amplitud de las regiones locales de buena calidad de huellas epiteliales se observa un pico predominante una vez suprimida la componente de DC, como se muestra en la Figura.1.12 b), dicho pico cumple con la siguiente relación empírica [5]:

$$umbral_{local} = 0.67 < \frac{A_1}{A_1 + A_2} \quad (1.9)$$

donde:

A_1 : amplitud del pico mayor en el espectro de amplitud

A_2 : amplitud del segundo mayor pico en el espectro de amplitud

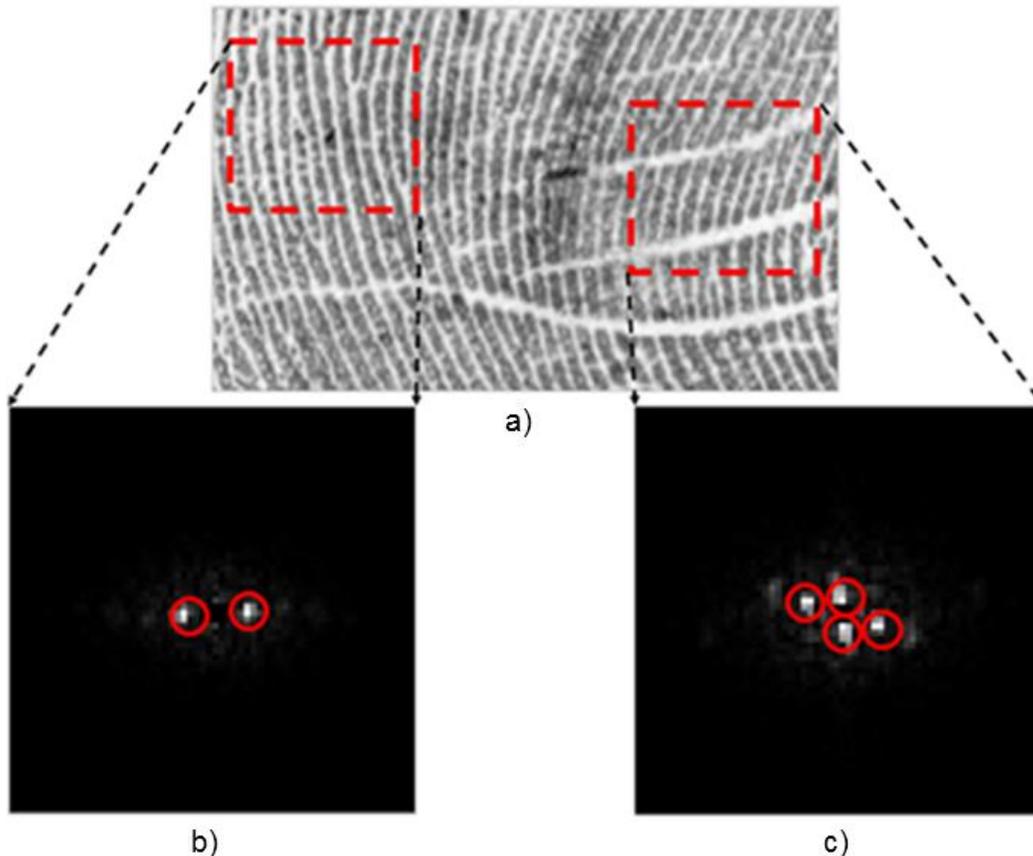


Figura.1.12 Espectros de regiones locales de huellas epiteliales; a) imagen de huella; b) espectro de amplitud de una región local de buena calidad; c) espectro de amplitud de una región local recuperable

En el espectro de amplitud de las regiones locales recuperables y no recuperables de huellas epiteliales se observan varios picos, con amplitudes semejantes, el pico de mayor amplitud puede ser de crestas o introducido por el ruido, como se muestra en la Figura.1.12 c), por lo que no se podrá solo con la información de amplitud escoger una onda que realmente represente a la zona de crestas [5].

1.2 Short Time Fourier Transform (STFT)

Debido a la necesidad de analizar espectralmente la huella epitelial por regiones locales, tanto para la estimación de la orientación y la frecuencia local en el espectro como para el mejoramiento y reconstrucción de la imagen mediante un filtrado contextual, se emplea la STFT. La misma constituye una importante herramienta en el análisis de señales no estacionarias, puesto que permite proporcionar una visión simultánea en el tiempo y el comportamiento de frecuencia de las señales, concepto que se puede extender al análisis de señales en dos dimensiones como las huellas epiteliales [4].

Su definición matemática para el caso de una señal bidimensional discreta, puede ser enunciada por la ecuación siguiente [6] .

$$\text{STFT}(u, v, x_0, y_0) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} h(x - x_0, y - y_0) f(x, y) e^{-j2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)} \quad (1.10)$$

donde:

$f(x,y)$: imagen original

(M, N) : dimensiones de $f(x,y)$

$h(x - x_0, y - y_0)$: ventana centrada en (x_0, y_0)

$x_0 = a, 2a, 3a, \dots, 1 < x_0 < M$

$y_0 = b, 2b, 3b, \dots, 1 < y_0 < N$

a : separación entre las ventanas en el eje x

b : separación entre las ventanas en el eje y

Para la implementación de la STFT es necesario dividir la imagen original en bloques no solapados. Centrado en cada bloque se escoge una región local, de las dimensiones de la

ventana utilizada, para ser transformada mediante la DFT la multiplicación de dicha región local con la ventana escogida [5].

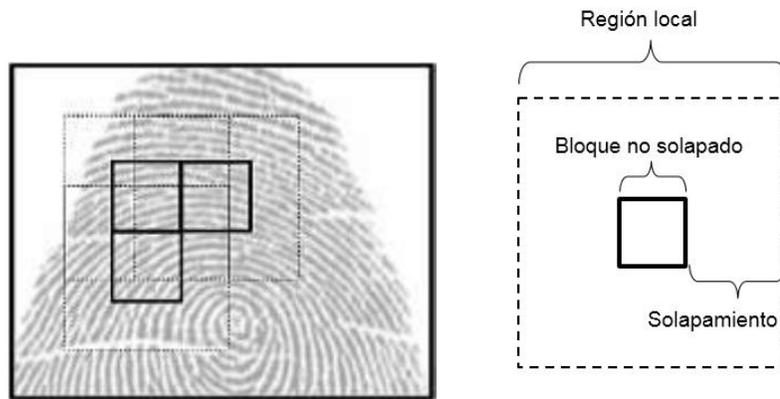


Figura.1.13 Implementación de la STFT

El resultado de la STFT depende de la elección de la ventana [8], por tanto, esta debe garantizar que la región local pueda ser recuperada del dominio frecuencial, enfatizar el espectro aportado por cada bloque no solapado, aumentar la resolución espectral, aumentar la robustez frente al ruido, eliminar el efecto de bloque producido por dividir la imagen en bloques no solapados, etc. [4] [5]. Para cumplir los anteriores requisitos, la dimensión de la ventana debe ser mayor que la dimensión de un bloque no solapado [4].

1.3 Segmentación en huellas epiteliales

La segmentación en huellas epiteliales se refiere a la separación de las regiones locales de buena calidad y recuperables que en su conjunto conforman el primer plano o plano de crestas de las regiones no recuperables que en su conjunto conforman el segundo plano o plano de fondo [2].

En la literatura se pueden encontrar varias técnicas aplicadas a imágenes de huella con este objetivo, algunas de las cuales se comentan brevemente a continuación:

- Segmentación propuesta por Maio y Maltoni (1997) :discriminan el plano de crestas del plano de fondo mediante el promedio de la magnitud del gradiente en cada bloque; debido a que la zona de la huella epitelial presenta muchos bordes por la alternación de crestas y valles, el gradiente es elevado en esta área y pequeño en el fondo [3].

- Segmentación propuesta por Pais Barreto Marques y Gay Thome (2005), y Chikkerur, Cartwright y Govindaraju (2007): discriminan el plano de crestas del plano de fondo mediante la medición de la energía local en el espectro de Fourier debido en que las crestas y los valles representan un plano de onda sinusoidal con frecuencia y orientación bien definida, lo que significa que tendrán gran energía comparado con el plano de fondo que por ser una superficie con menos variación, contiene poca energía en el dominio de la frecuencia [6]
- Segmentación propuesta por Ratha, Chen, y Jain (1995): discriminan el plano de crestas del plano de fondo de acuerdo a la varianza del nivel de gris en la dirección ortogonal de la orientación de las crestas de cada bloque no solapado de 16 x 16 píxeles de la imagen debido a que el área del plano de crestas presenta valores altos de varianza, al contrario del plano de fondo que presenta valores menores [3].

1.3.1 Segmentación orientada a regiones

La segmentación orientada a regiones en huellas epiteliales contaminadas por fuertes ruidos y fondos complejos como las imágenes de huellas latentes y palmares, posee mejor desempeño que las técnicas comentadas anteriormente debido a que tanto la magnitud del gradiente, la energía local en el espectro de Fourier como la varianza del nivel de gris no proporcionan fiabilidad en zonas de pliegues, escrituras, y otras estructuras que no representan crestas. Lo cual trae como consecuencia una errónea segmentación.

Existen dos enfoques diferentes para realizar dicha segmentación. El primero es mediante un proceso de crecimiento que permite la agrupación regiones locales en regiones mayores, y el segundo consiste en un procedimiento de división y fusión en el cual se fragmenta inicialmente la imagen en un conjunto de regiones disjuntas que luego se unen o separan. Ambos enfoques se desarrollan ateniendo a reglas de similitud o condiciones de continuidad y conectividad de las regiones locales con las regiones vecinas.

En las imágenes de huellas epiteliales se suele tomar como regla para el crecimiento de regiones los parámetros locales del flujo de crestas. La selección del tamaño de las regiones locales depende de varios factores pero como regla general deben ser lo suficientemente grandes como para formular un criterio certero de la frecuencia y

orientación de la región local y lo suficientemente pequeño como para que dichas características solo tengan un valor posible [6].

Para la segmentación de huellas epiteliales mediante el algoritmo de crecimiento de región se elige una o varias regiones locales adyacentes que cumplan determinadas condiciones de continuidad y conectividad conocidas como semillas, para a partir de dichas semillas ir añadiendo regiones locales adyacentes a la semilla en crecimiento correspondiente que cumplan con los criterios de continuidad y conectividad establecidos mientras al menos exista una región local que cumpla con las mismas.

1.4 Filtro de Gabor logarítmico

Los filtros de Gabor son una elección tradicional para obtener la mejor localización simultánea del dominio espacial y frecuencial, sin embargo, tienen una gran limitación pues no se pueden formular funciones de Gabor de un ancho de banda arbitrario y mantener simultáneamente una componente de directa razonablemente pequeña. Una alternativa es la función Log-Gabor propuesta en [4].

Comparado con el filtro de Gabor, el filtro Log-Gabor se pueden construir con ancho de banda arbitrario y por definición no posee componente de DC, lo que contribuye a mejorar el contraste entre las crestas y los valles de las huellas epiteliales, además, la función de transferencia de este filtro tiene una cola extendida en el extremo de alta frecuencia, lo que contribuye a preservar las verdaderas estructuras en la huella epitelial. Debido a la singularidad de la función en el origen, no se ha sintetizado una expresión analítica en el dominio espacial. Por lo tanto, los filtros de Log-Gabor se construyen en el dominio de la frecuencia [4].

En coordenadas polares (r, θ) , el filtro se puede dividir en dos componentes, una radial y la otra angular. El filtro Log-Gabor se obtiene de la multiplicación de ambas componentes como se define en la siguiente ecuación:

$$G(r, \theta) = G_r(r) \cdot G_\theta(\theta) \quad (1.11)$$

donde

$G_r(r)$: componente radial del filtro Log-Gabor

$G_\theta(\theta)$: componente angular del filtro Log-Gabor

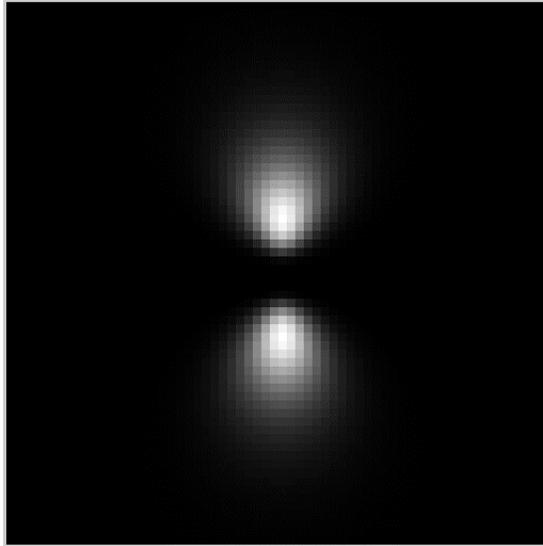


Figura. 1.14 Filtro Log-Gabor

En la figura anterior se muestra un filtro Log-Gabor, donde se puede notar la cola extendida hacia las altas frecuencias y la ausencia de la componente de DC.

1.4.1 Componente radial del filtro Log-Gabor

La componente radial del filtro Log-Gabor se expresa como:

$$G_r(r) = e^{-\frac{\left[\log\left(\frac{r}{r_0}\right)\right]^2}{2\sigma_r^2}} \quad (1.12)$$

donde:

r : radio

r_0 : frecuencia central del filtro

σ_r : desviación estándar de la componente radial del filtro

El valor de la desviación estándar de la componente radial del filtro determina el ancho de banda radial, empíricamente, un valor de 0.3 produce un ancho de banda de aproximadamente un octavo y un valor de 0.6 produce un ancho de banda de dos octavos, se observa que a medida que se incrementa el valor de σ_r , se preservan las verdaderas estructuras de la huella, pero a su vez disminuye el rechazo al ruido. Para balancear las ventajas y desventajas de utilizar valores grandes de σ_r , este es fijado empíricamente en 0.5 [4] como se muestra en la siguiente figura.

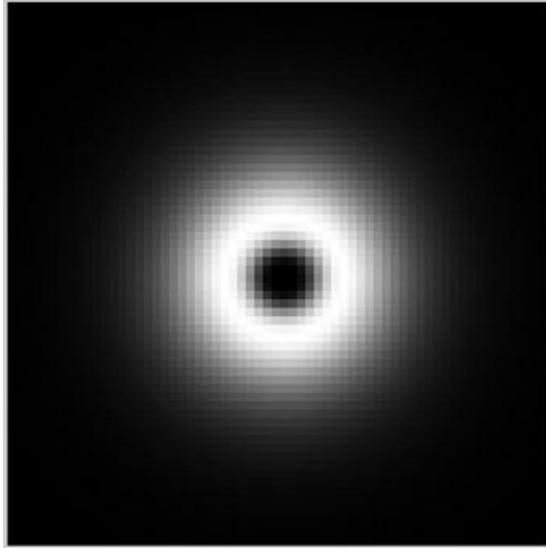


Figura. 1.15 Componente radial del filtro Log-Gabor con $r_0 = 7$ y $\sigma_r = 0.5$

En la figura anterior se muestra la componente radial del filtro Log-Gabor con dimensiones 64x64, es importante recordar la relación de la orientación local y la frecuencia local en el dominio espacial y frecuencial establecidas anteriormente en las ecuaciones 1.5, 1.7 y 1.8.

1.4.2 Componente angular del filtro Log-Gabor

La componente angular del filtro Log-Gabor se expresa como:

$$G_{\theta}(\theta) = e^{-\frac{(\theta - \theta_0)^2}{2\sigma_{\theta}^2}} \quad (1.13)$$

donde:

θ : ángulo de orientación

θ_0 : ángulo de orientación del filtro

σ_{θ} : desviación estándar de la componente angular del filtro

El valor de la desviación estándar de la componente angular del filtro determina el ancho de banda angular. El valor de dicho parámetro es directamente proporcional a la curvatura de la cresta de la región local referenciada a las orientaciones de las crestas de las regiones locales vecinas, en la práctica, una gran curvatura requiere un ancho de banda angular grande para conservar las verdaderas estructuras de la huella epitelial, basados en datos empíricos, para gran curvatura con $\sigma_{\theta} = \pi/5$ y para pequeña curvatura con $\sigma_{\theta} = \pi/9$, se logran resultados satisfactorios [4].

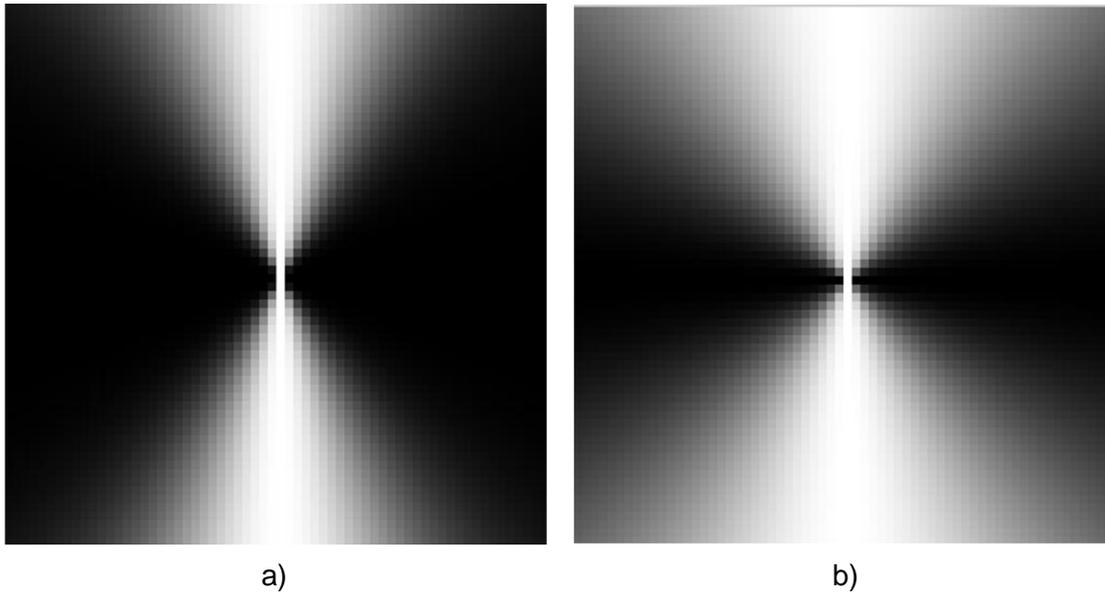


Figura. 1.16 Componente angular del filtro Log-Gabor; a) con $\theta_0=0$ y $\sigma_\theta = \pi/9$; b) con $\theta_0=0$ y $\sigma_\theta = \pi/5$

En la figura anterior se muestran las componentes angulares del filtro Log-Gabor utilizadas en dependencia de si la región de crestas es de pequeña o de gran curvatura. Con el propósito de un ajuste adaptativo en cuanto al ancho de banda de la componente angular del filtro de Log-Gabor se define el parámetro curvatura, el cual representa la dispersión de la orientación de la región local respecto a las orientaciones de las regiones vecinas [4], su ecuación se define como:

$$C(i, j) = \frac{1}{N^2} \sum_{u=i-N/2}^{i+N/2} \sum_{v=j-N/2}^{j+N/2} (\phi_x(i, j, u, v) + \phi_y(i, j, u, v)) \quad (1.14)$$

$$\phi_x(i, j, u, v) = | \cos(2\theta(i, j)) - \cos(2\theta(u, v)) | \quad (1.15)$$

$$\phi_y(i, j, u, v) = | \sin(2\theta(i, j)) - \sin(2\theta(u, v)) | \quad (1.16)$$

donde:

$C(i,j)$: Curvatura de la región local.

N^2 : Cantidad de regiones en la vecindad.

$\phi_x(i,j,u,v)$: Dispersión del coseno doble entre la curvatura de la región local y la curvatura de una región vecina.

$\phi_y(i,j,u,v)$: Dispersión del seno doble entre la curvatura de la región local y la curvatura de una región vecina.

$\theta(i,j)$: especifica la orientación de la región local

$\theta(u,v)$: especifica la orientación de una región vecina

El valor de la curvatura aumenta de forma adaptativa cuando se acerca a un punto singular y disminuye cuando se aleja de él [4] como se muestra en la siguiente figura.

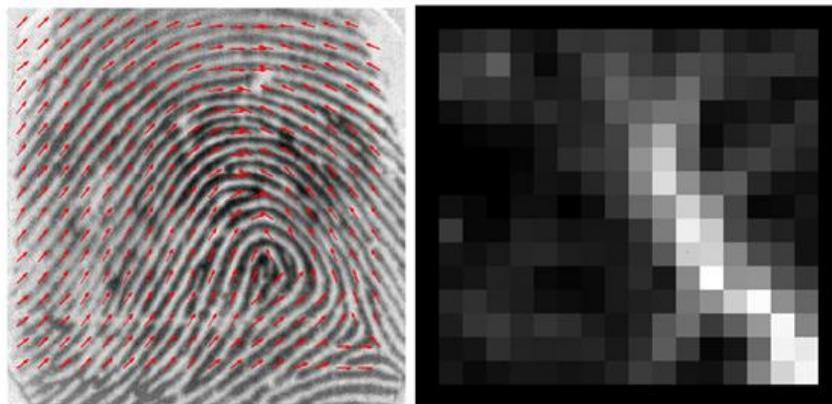


Figura. 1.17 Imagen de la curvatura en escala de grises

El ajuste adaptativo del ancho de banda de la componente angular del filtro de Log- Gabor mediante el cálculo de la curvatura puede evitar la dificultad y falta de fiabilidad en la extracción de puntos singulares, lo que se traduce en una disminución de las probabilidades de detección de minucias falsas [4].

Sobre la base del cálculo de la curvatura, se especifica un umbral empírico de valor $U=0.75$ para determinar si la curvatura de cresta es grande o pequeña. Si la curvatura es menor que el umbral, se considera que la región local es de pequeña curvatura, de lo contrario, se considera que la región local es de gran curvatura. Empíricamente se observan buenos resultados para una 8 vecindad de la región en análisis, por tanto $N^2=9$ [4].

1.5 Algoritmo de mejoramiento implementado en GAPIS

El algoritmo de mejoramiento de la calidad de imágenes latentes desarrollado en GAPIS, fue desarrollado en un trabajo de diploma de tesis de pregrado en el 2014 basado en la publicación de Jianjian Feng y Anil K. Jain “Latent Palmprint Matching”, 2009. En la siguiente figura de muestra el esquema en bloques de dicho algoritmo.

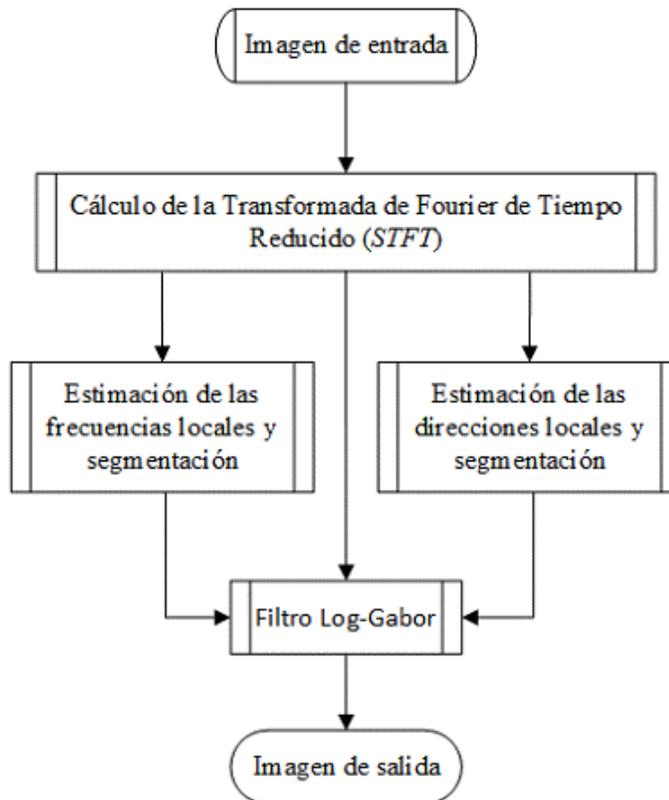


Figura.1.18 Algoritmo de mejoramiento de la calidad de imagen implementado en GAPIS.

Inicialmente se aplica la STFT, lo que permite fragmentar la imagen de huella en bloques pequeños y realizar un análisis local de la misma. Con el empleo de dos bancos de filtros, uno selectivo en frecuencia y el otro en dirección, se caracteriza espectralmente cada uno de estos bloques. Posteriormente se estima la dirección y la frecuencia del segmento de huella contenido en cada bloque empleando un algoritmo de crecimiento de regiones, que utiliza como semillas iniciales aquellos bloques cuyos espectros de potencia posean los valores más altos en una sola dirección o banda de frecuencia. Esta información es utilizada para la creación de los filtros Log-Gabor que finalmente realizan el mejoramiento de la imagen [6]

Dicho algoritmo no estima las orientaciones y frecuencias locales acertadamente cuando la presencia de regiones de bajo contraste en la imagen, es notable. Además la correcta segmentación de las imágenes también se ve afectada en imágenes de huella latente de baja calidad.

El desempeño de este algoritmo se limita debido a que el crecimiento de regiones no implementa los conocimientos estadísticos de los principales parámetros de la huella epitelial, por lo que se formularon condiciones de continuidad fijos e ineficientes, además solo considera la información aportada por un vecino adyacente perteneciente a la región en crecimiento. En el siguiente capítulo se propondrá un algoritmo que presenta un mejor desempeño en la estimación de las orientaciones y frecuencias locales que el existente en GAPIS.

CAPITULO 2 . ALGORITMO DE MEJORAMIENTO PROPUESTO

El algoritmo de mejoramiento posee como etapa final un filtrado contextual basado en el filtro Log-Gabor. Para la correcta configuración de dicho filtro se requiere la estimación acertada de las orientaciones y frecuencias locales de la imagen de huella, lo cual se realiza mediante el algoritmo de estimación propuesto basado en un proceso de crecimiento de regiones. El esquema en bloques de todos los procedimientos se muestra a continuación, y se explican en los siguientes epígrafes.

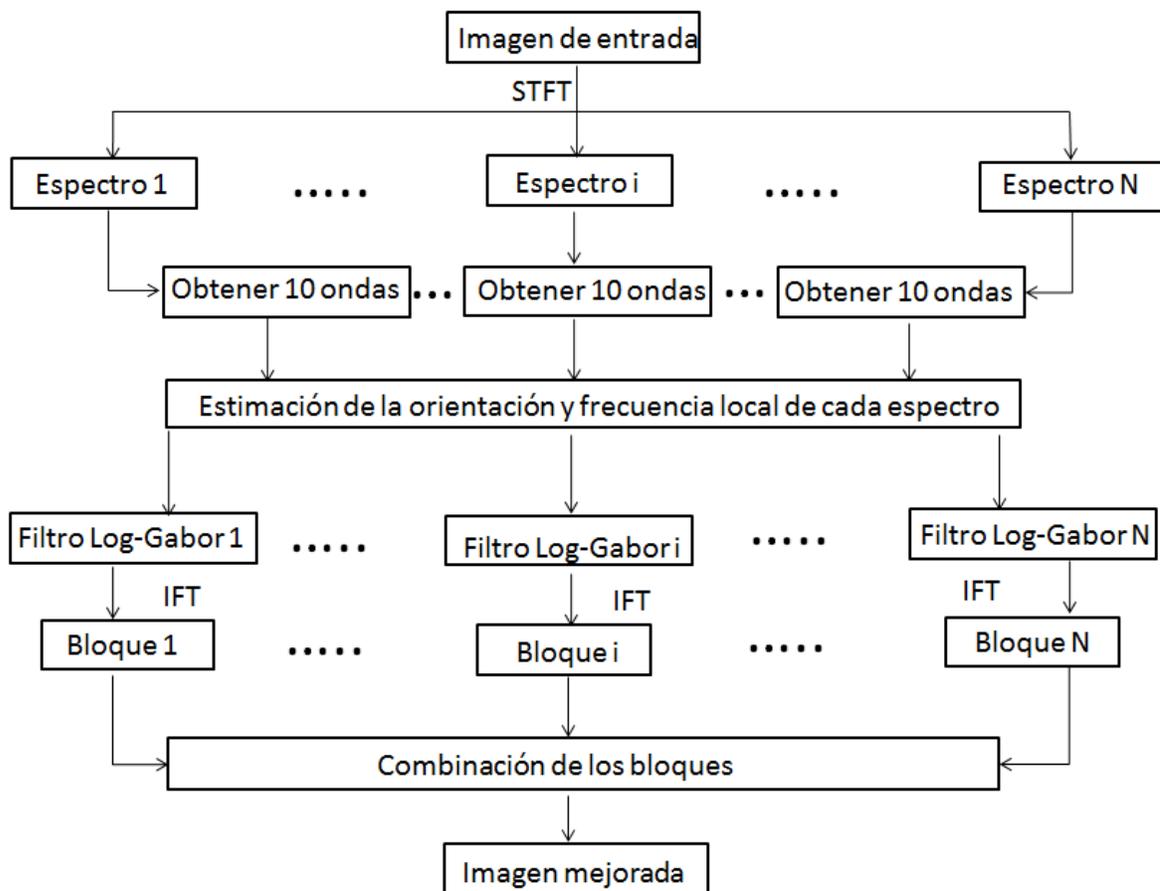


Figura. 2.1 Algoritmo de mejoramiento de la calidad de imagen propuesto

2.1 Cálculo de la STFT

En las huellas epiteliales, la dimensión de los bloques no solapados se escoge de forma tal que contenga un periodo cresta, esto garantiza que las zonas de la huella que contengan minucias, puedan ser modeladas por un conjunto de sinusoides sin que se pierdan las verdaderas estructuras de crestas.

Como el periodo local de crestas en imágenes de huellas epiteliales de 500 dpi de resolución varía entre 5 y 15 pixeles, para aumentar la eficiencia computacional, se establecen bloques no solapados cuadrados de 16 pixeles de lado

Para garantizar que la región local pueda ser recuperada del dominio frecuencial manteniendo un compromiso entre el rendimiento y complejidad, como los bloques no solapados son bloques cuadrados de 16 pixeles de lado, se establece una ventana cuadrada de 64 pixeles de lado. Estas dimensiones contribuyen a eliminar el efecto de bloque producido por dividir la imagen en bloques no solapados.

Una función ventana que cumple con todos los requisitos para la estimación de la orientación y frecuencia en el espectro de Fourier, así como para el mejoramiento y reconstrucción de imágenes ruidosas directamente del espectro es la función Gaussiana con $\sigma=16$ para enfatizar el espectro aportado por cada bloque no solapado [5] mostrada en la Figura. 2.2, cuya ecuación se define por [9]:

$$h(x,y) = e^{-\frac{D^2(x,y)}{2\sigma^2}} \quad (2.1)$$

donde:

$D(x,y)$: distancia al centro de rectángulo

σ : desviación estándar

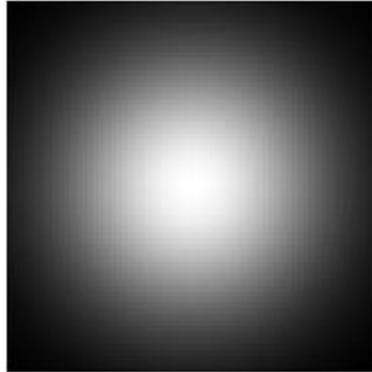


Figura. 2.2 Función Gaussiana con $\sigma=16$

Luego de obtener los espectros de las regiones locales definidas por la STFT, se seleccionan los 10 picos u ondas de mayor amplitud en cada espectro con el periodo de crestas en el rango de 5 a 15 pixeles, llamadas ondas candidatas, lo que minimiza la posibilidad de que una onda candidata sea de ruido y al mismo tiempo garantiza que la onda modelo se encuentre entre las candidatas.

2.2 Algoritmo propuesto para la estimación de la orientación y la frecuencia local

El algoritmo propuesto para la estimación de la orientación y la frecuencia local determina, de las 10 ondas candidatas preseleccionada en la etapa anterior, la que mejor modela el flujo de crestas de cada bloque de buena calidad o recuperable, o sea, la onda modelo del bloque, mientras que marca los bloques no recuperables o de fondo para una posterior segmentación. Para ello se fundamenta en que generalmente la onda candidata de mayor amplitud es la onda modelo del bloque y que fuera de las singularidades las orientaciones del flujo de crestas y frecuencias locales poseen variaciones tenues.

El algoritmo de estimación consiste primeramente en la determinación de las ondas modelos de las regiones locales con las estructuras de crestas mejor definidas dentro de la imagen que no pertenezcan a singularidades, y puedan formar al menos clusters de 20 ondas modelos, a los que llamaremos núcleos de semillas , para luego extraer las ondas modelos de las regiones locales recuperables que no pertenezcan a singularidades con el mínimo de error posible, lo que posibilitará determinar las ondas modelos de las regiones locales de buena calidad y recuperables que conforman las singularidades con alta fidelidad en la estimación.

Para cumplir con tales propósitos se utilizará un algoritmo de crecimiento de regiones que pueda adaptarse a las etapas anteriormente comentadas. Los parámetros escogidos para la definición de las condiciones de continuidad son: la frecuencia local, la orientación local y la amplitud de la onda, los cuales definen umbrales de continuidad entre dos regiones locales adyacentes de la siguiente manera:

- Continuidad en frecuencia:

$$U_f \geq \left| \frac{1}{f_1} - \frac{1}{f_2} \right| \quad (2.2)$$

donde:

U_f : umbral adaptativo de continuidad en frecuencia

f_1 : frecuencia de la región local

f_2 : frecuencia de la región local vecina

- Continuidad en orientación:

$$U_\theta \geq \text{Angle}(\theta_1 - \theta_2) \quad (2.3)$$

donde:

U_θ : umbral adaptativo de continuidad en orientación

θ_1 : orientación de la región local

θ_2 : orientación de la región local vecina

$\text{Angle}(\theta_1, \theta_2)$: diferencia de orientación en el rango $0 < \Delta\theta < \pi/2$

- Continuidad en amplitud:

$$U_A \geq R_A \quad (2.4)$$

donde:

U_A : umbral adaptativo de continuidad en amplitud definido por:

$$U_A = \frac{A_{\max}}{A_{\max} + A_{\min}} \quad (2.4)$$

R_A : relación de amplitudes definido por:

$$R_A = \frac{A_{\max}}{A_{\max} + A_1} \quad (2.4)$$

A_{max} : mayor amplitud detectada en el núcleo de semilla

A_{min} : menor amplitud detectada en el núcleo de semilla

A_1 : amplitud de la onda candidata de la región local

El primer paso para el crecimiento es la determinación de los núcleos de semillas, los que se forman a partir de la agrupación de al menos 20 ondas fuertes adyacentes. Una onda fuerte se define como la mayor onda en amplitud entre las 10 candidatas de cada bloque que sea continua en orientación y frecuencia con los umbrales $U_f = 3$ y $U_\theta = \pi/12$, con al menos 6 de las 8 ondas de mayor amplitud de los bloques vecinos. Para que una onda fuerte pertenezca a un núcleo de semillas, debe ser continua con al menos una onda fuerte perteneciente a dicho núcleo.

El primer crecimiento, realizado a los núcleos de semillas hasta obtener las semillas correspondientes, garantiza la obtención de las ondas modelos de las regiones locales de buena calidad y recuperables que no pertenezcan a singularidades, se prioriza el crecimiento de los núcleos de semillas por orden descendente en cuanto a la cantidad de ondas fuertes que contienen, el algoritmo de crecimiento que garantiza la obtención de las semillas presenta los siguientes umbrales de continuidad:

- $U_f = 3$
- $U_\theta = \pi/12$
- $U_A \geq R_A$

Para garantizar la influencia de la vecindad sobre la determinación de la onda modelo de la región local en cuestión se exige que:

- al menos 4 de las 8 posibles ondas modelos en la vecindad pertenezcan a la semilla en formación.
- dicha onda sea la de mayor amplitud entre las 10 candidatas del bloque y sea continua con todas las ondas modelos presentes en su vecindad.

El segundo crecimiento, realizado a las semillas, garantiza la unión entre las mismas y la estimación de las ondas modelos que conforman las singularidades, se prioriza el crecimiento de la misma forma que el anterior y para ello el crecimiento está caracterizado por.

- $U_f = 3$
- $U_\theta = \frac{\pi}{6}$
- $U_A \geq R_A$

Para garantizar la influencia de la vecindad sobre la determinación de la onda modelo de la región local en cuestión se exige que:

- al menos se hayan determinado 4 ondas modelos en su vecindad y al menos una de ellas pertenezca a la semilla en crecimiento
- que dicha onda sea la de mayor amplitud entre las 10 candidatas del bloque y sea continua con todas las ondas modelos presentes en su vecindad.

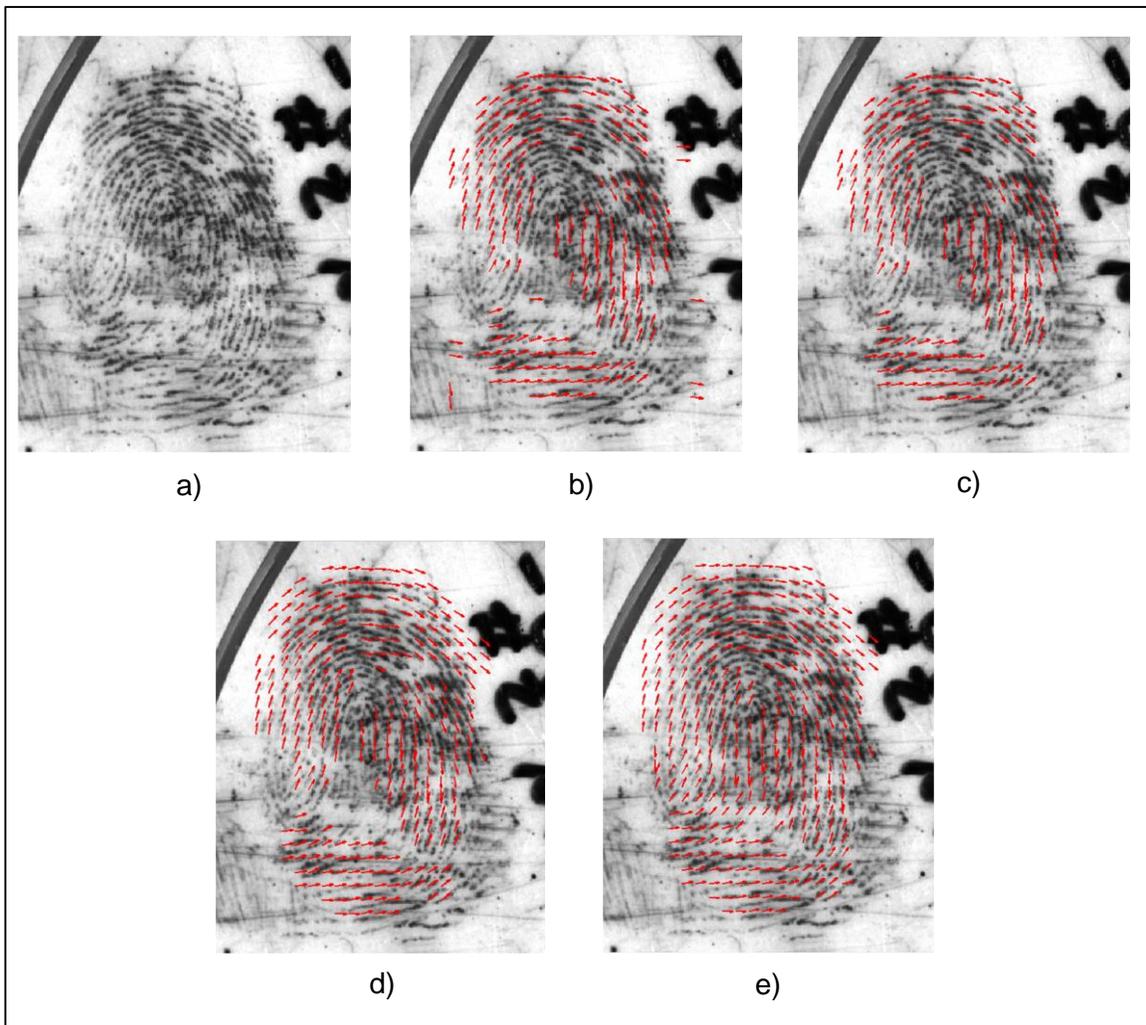


Figura. 2.3 Etapas del algoritmo propuesto; a) Imagen original; b) Ondas fuertes; c) Núcleos de semillas; d) Semillas; e) primer plano

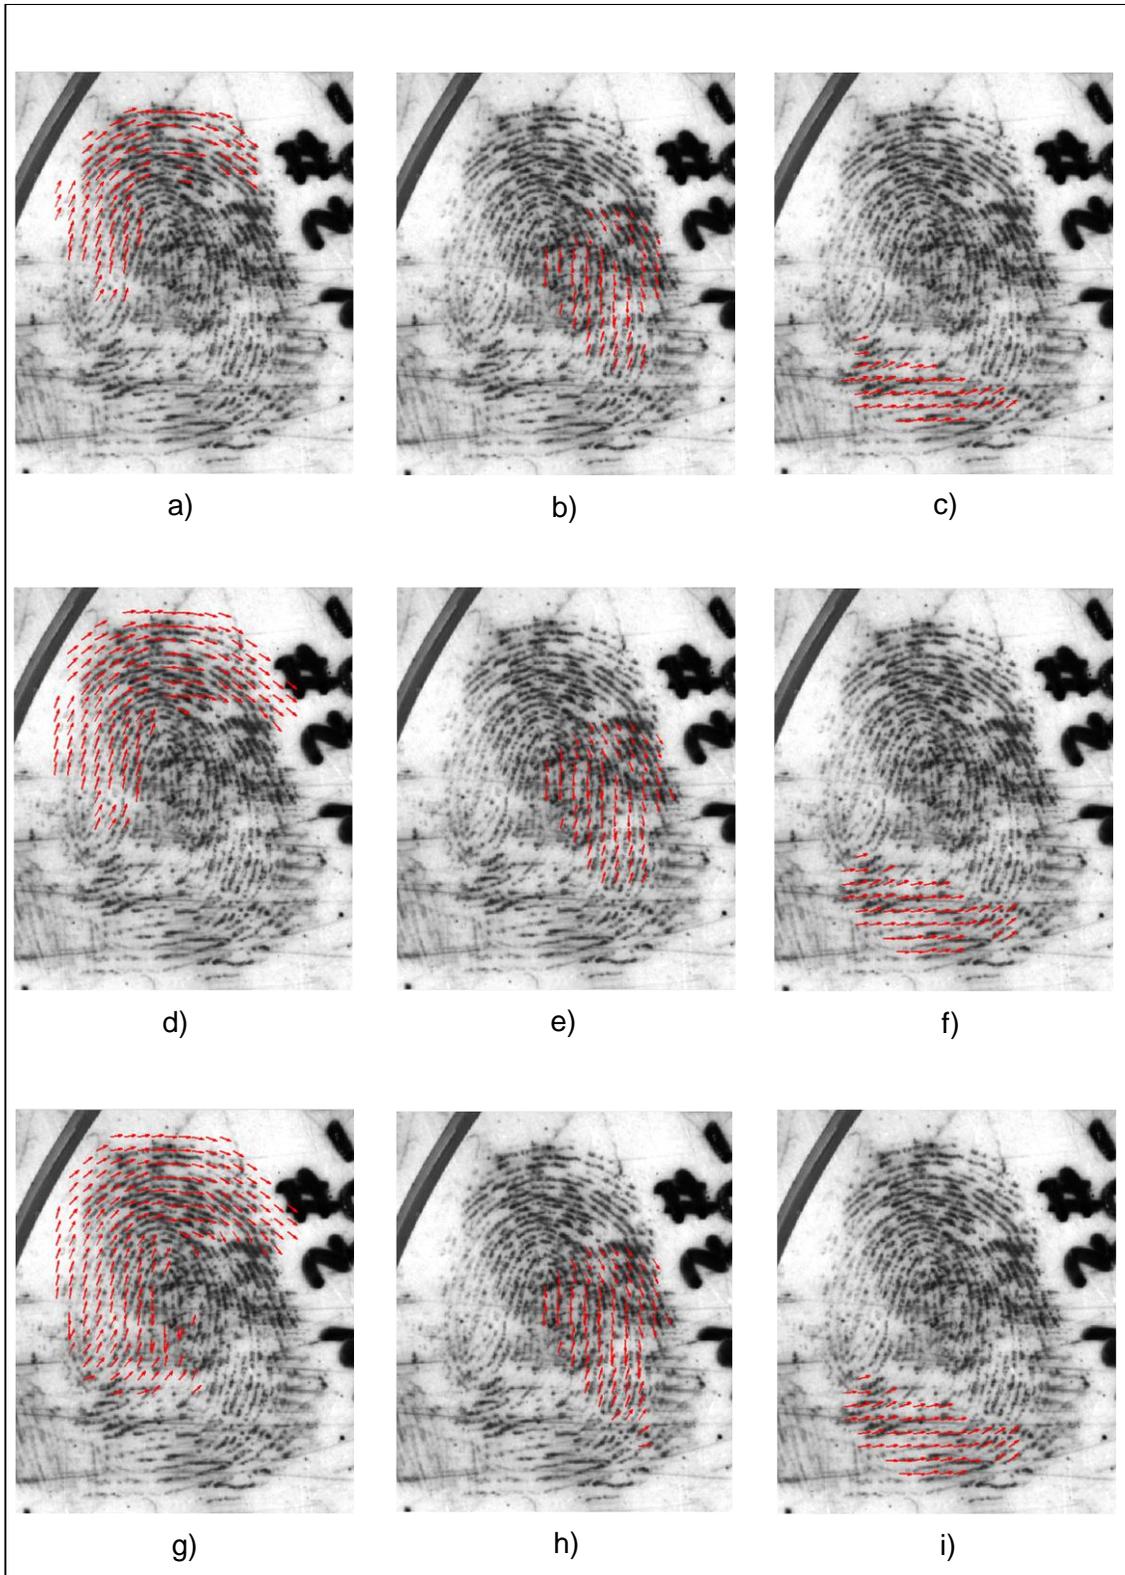


Figura. 2.4 Crecimientos realizados; a) , b) y c) núcleos de semillas; d),e) y f) semillas obtenidas debido al crecimiento de los núcleos de semillas; g), h) e i) regiones obtenidas debido al crecimiento de semillas.

En la Figura. 2.3 se observan las distintas etapas del algoritmo propuesto mientras que en la Figura. 2.4 se muestran los detalles de crecimientos de dichas etapas.

2.3 Filtrado del espectro y reconstrucción de la imagen mejorada

Una vez obtenida la onda modelo de cada región local, se puede configurar el filtro contextual de Log-Gabor para resaltar las verdaderas estructuras de crestas. Se filtrará el espectro correspondiente mientras no se cumpla el umbral local establecido en la ecuación 1.9, lo que garantiza obtener las verdaderas estructuras de crestas, así como el rechazo a las falsas estructuras creadas por fuertes ruidos.

La combinación de las regiones locales mejoradas debe garantizar la reconstrucción de las verdaderas minucias, por tanto se combinarán los bloques de 48x48 pixeles que tiene como centro a los bloques no solapados de cada región local. Solo los niveles de grises de dichos bloques no serán alterados por la máscara de segmentación.

CAPITULO 3 . RESULTADOS Y VALIDACIÓN

En este capítulo se muestran los resultados obtenidos en las diferentes pruebas realizadas con imágenes sintéticas e imágenes de huellas latentes para comprobar la fiabilidad y robustez frente al ruido de los algoritmos propuestos.

Dos bases de datos de imágenes latentes con las minucias marcadas por especialistas se han utilizado en este trabajo de diploma las cuales han sido proporcionadas por el Centro Nacional de Tecnologías de Avanzada (CENATAV), institución rectora en Cuba en el reconocimiento de rasgos biométricos. Una base de datos es de palmares latentes, y la otra es la NIST BD 27.

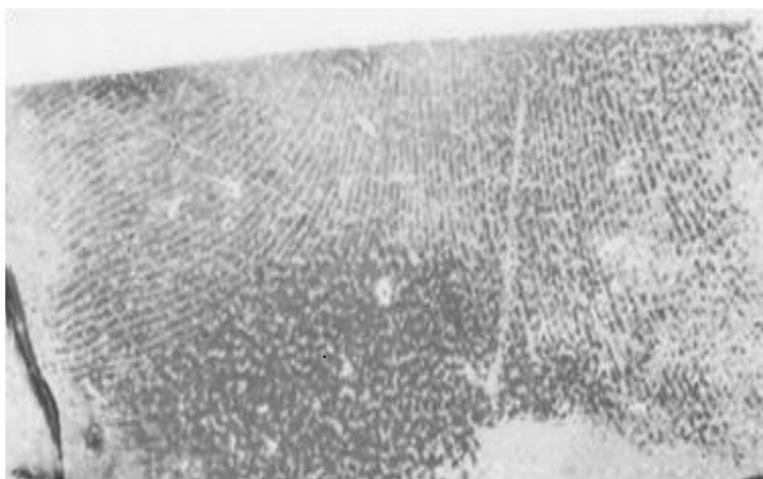


Figura. 3.1 Imagen A119999900000200811312000.tif perteneciente a la base de datos palmar latente.

La base de datos NIST BD 27 define 3 categorías en cuanto a la calidad de huellas latentes: buena (g), mala (b) y muy mala (u) [10] las que se ilustran en la siguiente figura.

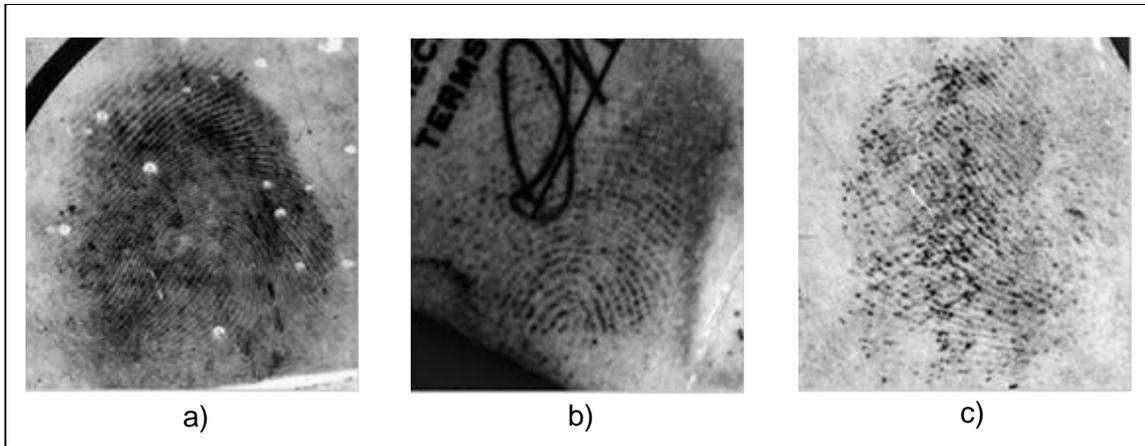


Figura. 3.2 Imágenes pertenecientes a la base de datos NIST BD 27: a) imagen g068l6u.tif latente de buena calidad; b) imagen b101l9u.tif latente de mala calidad; c) imagen u288l6u.tif latente de muy mala calidad.

Todos los algoritmos y métodos descritos en este trabajo de diploma han sido implementados en el asistente matemático MATLAB R2014a sobre el sistema operativo Windows 7 profesional a 32 bit. Los experimentos han sido realizados en una PC core i5 -3.10Ghz con 4 GB de RAM.

En las siguientes sesiones de este capítulo se ilustrarán los resultados obtenidos en los algoritmos propuestos de estimación de los parámetros locales de huellas así como en el mejoramiento de la imagen de huella, además, para obtener un punto de referencia, los resultados de los algoritmos propuestos serán comparados con los resultados de los algoritmos desarrollados en GAPIS para imágenes latentes.

3.1 Resultados de la estimación de la orientación y frecuencia local en imágenes ruidosas

Para comprobar la robustez de los algoritmos en la estimación de las orientaciones y frecuencias locales frente a ruidos fuertes, se aplican los mismos sobre imágenes sintéticas generadas por la función *circsine* [1], la cual consiste en generar una serie de patrones circulares en dependencia de los parámetros que se le asignen. El ruido será incluido mediante la función *imnoise* del MATLAB. Esta técnica es ampliamente utilizada debido a que permite una comprobación precisa de la influencia del ruido en los algoritmos de estimación [1].

La cuantificación de la influencia del ruido en la estimación de la orientación y frecuencia local se obtiene mediante la desviación típica entre las orientaciones y frecuencias

estimadas sobre la imagen sintética pura, las cuales se consideran verdaderas y las orientaciones y frecuencias estimadas sobre la imagen sintética contaminada con ruido.

La ecuación de la desviación típica se define como [11]:

$$S = \sqrt{\frac{\sum_{i=1}^N (X_{ie} - X_i)^2}{N - 1}} \quad (3.1)$$

donde:

S: desviación típica

N: cantidad de muestras a comparar, representa a las regiones homólogas en ubicación espacial que se le estimó la onda modelo

X_{ie}: representa el valor del parámetro estimado en la imagen ruidosa

X_i : representa el valor del parámetro en la imagen pura

Como la desviación típica no brinda información del crecimiento total, se incluirá la imagen correspondiente a las estimaciones realizadas con la mayor varianza del ruido para una valoración visual. Es importante destacar que las comparaciones se realizaron en los rangos de varianza de ruido en que es apreciable la diferencia en el desempeño de los algoritmos. Dicho rango está limitado superiormente por el máximo valor de varianza con el cual el algoritmo de GAPIS es capaz de crear semillas para el crecimiento. El algoritmo propuesto puede establecer semillas en imágenes con niveles superiores que los del rango establecido.

En contraste con las pruebas en imágenes sintéticas, cuando se realizan pruebas sobre imágenes de huellas reales, solo se puede cualificar la estimación de la orientación y se realizará por inspección visual humana bajo un criterio que permita valorar cuanto la estimación realizada se asemeja a la orientación del flujo de crestas [1].

3.1.1 Influencia del ruido gaussiano en la estimación de los parámetros locales

El ruido gaussiano o ruido normal añadido a las imágenes sintéticas modela el ruido presente en imágenes reales de bajo contraste entre crestas y valles. La siguiente figura permite una estimación visual del desempeño de los algoritmos de estimación en una imagen contaminada con ruido gaussiano con varianza de ruido de 1.1, mientras que la

Figura. 3.4 muestra la desviación típica de cada algoritmo para una varianza de ruido en el rango de 8.5 a 1.1 con saltos de 0.025.

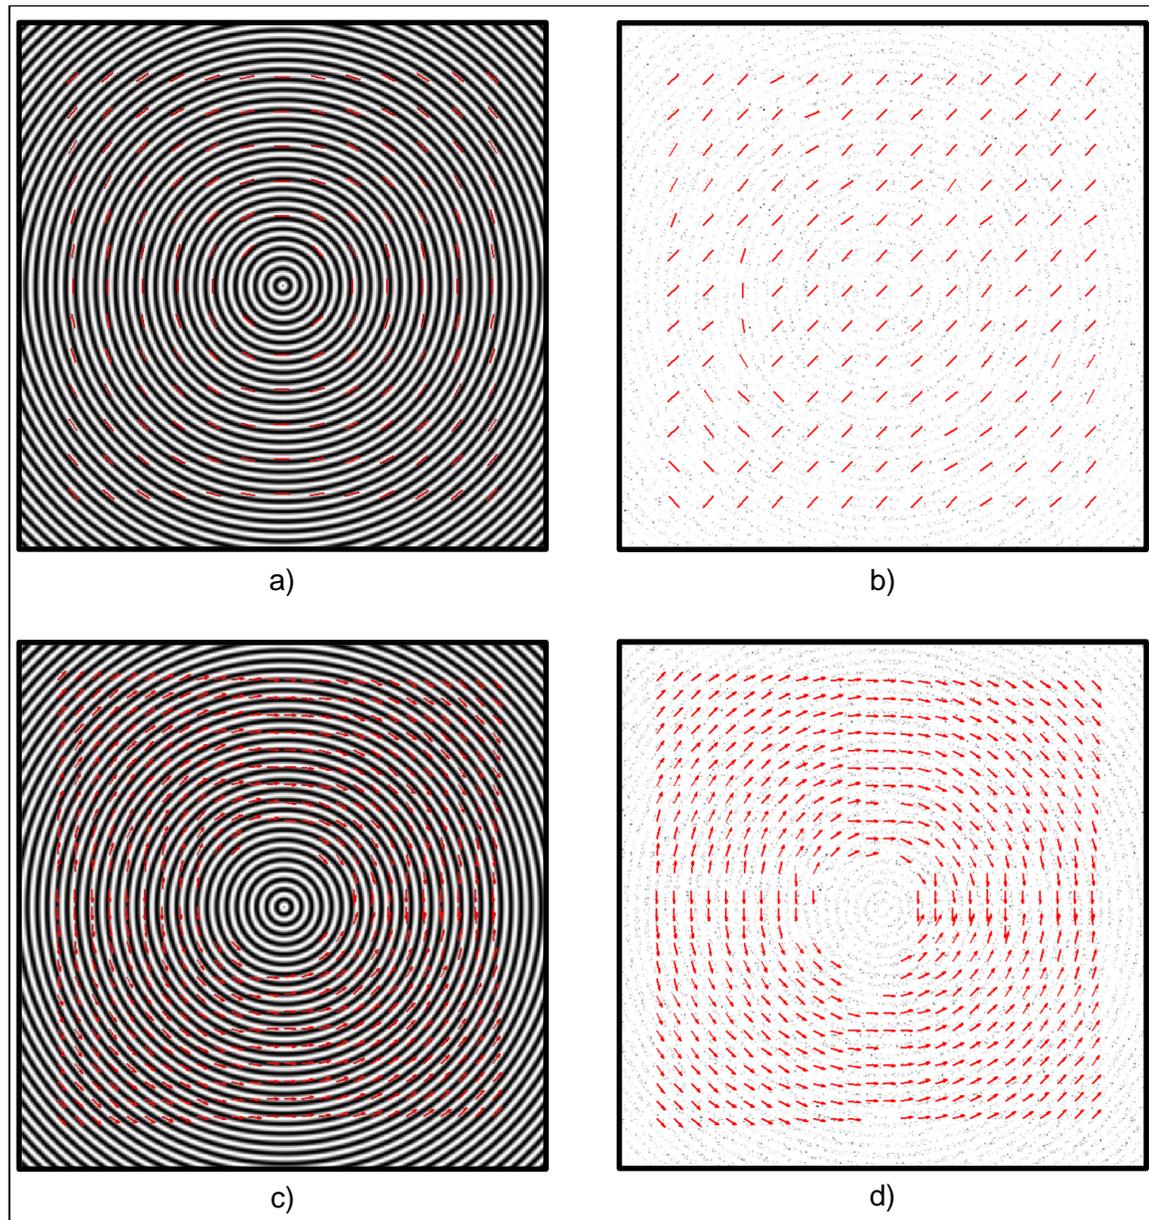


Figura. 3.3 Imágenes sintéticas con dimensiones 480x480 píxeles y frecuencia 0.109375 ciclos/píxel; a) y c) orientaciones estimadas por los algoritmos del GAPIS y propuesto respectivamente en la imagen pura; b) y d) orientaciones estimadas por el algoritmo del GAPIS y propuesto respectivamente en la imagen contaminada con ruido gaussiano con varianza del ruido de 1.1.

En la Figura. 3.3 b) se puede observar, además de la estimación errónea de la orientación mediante el algoritmo del GAPIS, un erróneo crecimiento hacia el centro del patrón

sintético, no estimado en la imagen pura, lo que provocará una segmentación posterior errónea, mientras que el algoritmo propuesto presenta un mejor desempeño.

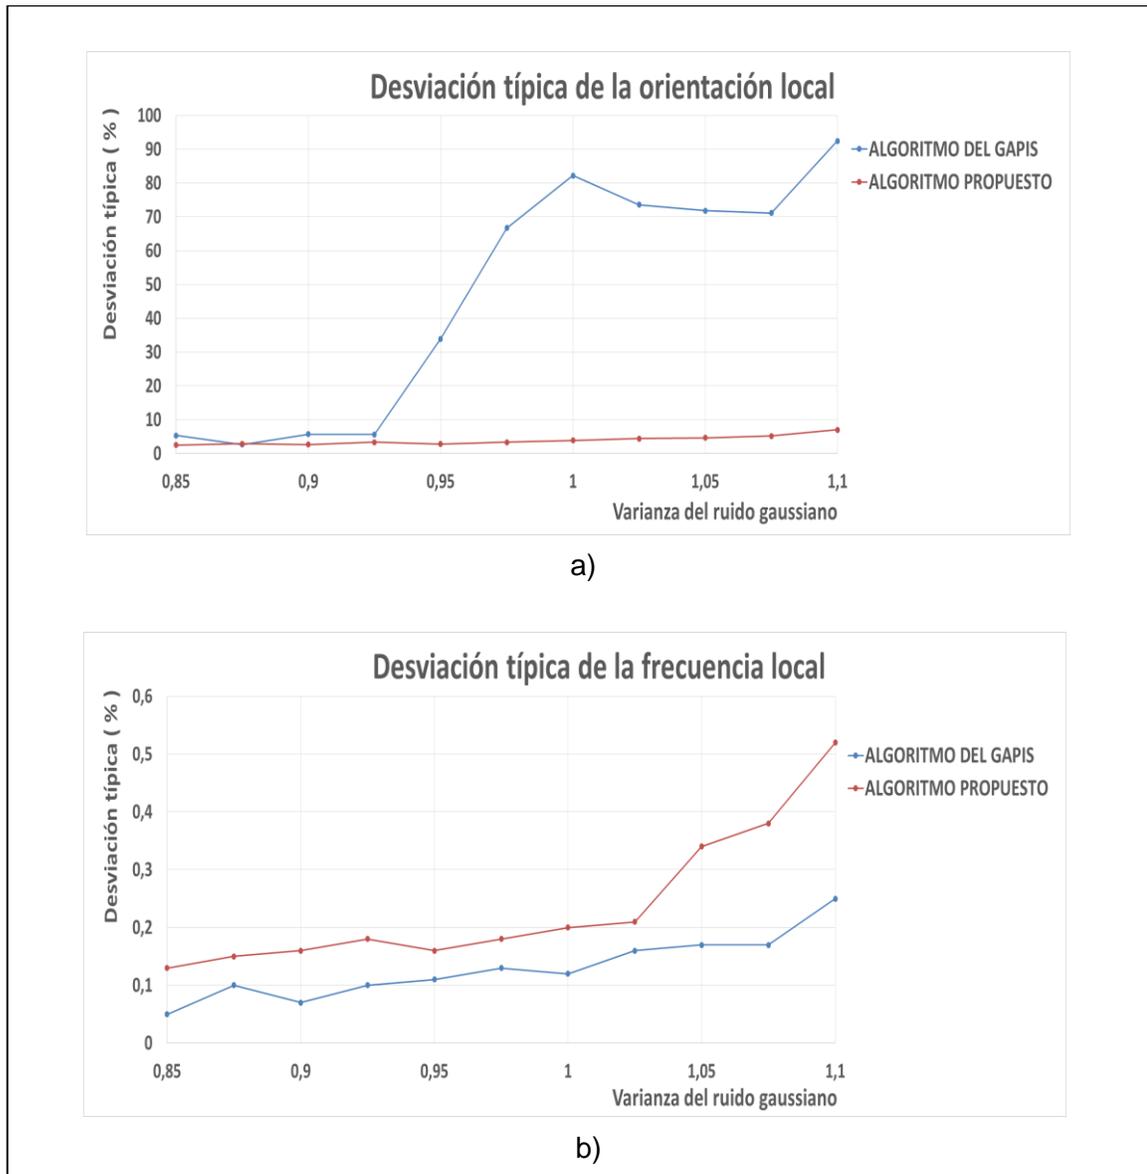


Figura. 3.4 desviación típica en la estimación de los parámetros para una varianza del ruido gaussiano de 0.8 a 1.1 en saltos de 0.025; a) desviación típica en la orientación local; b) desviación típica en la frecuencia local.

En la Figura. 3.4 a) se observa que el algoritmo propuesto es más robusto frente al ruido gaussiano en la estimación de la orientación que el desarrollado en GAPIS en todo el rango de la varianza del ruido, presentando apenas un 7% de desviación típica frente a un 92 % de desviación típica del GAPIS para una varianza del ruido de 1.1.

En la Figura. 3.4 b) se observa que el algoritmo propuesto posee una desviación típica de 0.52% en la estimación de las frecuencias locales, levemente mayor que el algoritmo del GAPIS de 0.25% para una varianza del ruido de 1.1. Sin embargo, como la estimación de la frecuencia no es tan importante como la estimación de la orientación y la diferencia de la desviación típica entre ambos algoritmo no excede el 0.25% se asume como irrelevante este resultado en la comparación del desempeño de los algoritmos.

3.1.2 Influencia del ruido salt & pepper en la estimación de los parámetros locales

El ruido salt & pepper o ruido impulsivo añadido a las imágenes sintéticas modela al ruido presente en imágenes latentes levantadas con técnicas químicas donde se pueden observar pixeles claros (salt) y oscuros(pepper). La siguiente figura permite una estimación visual del desempeño de los algoritmos de estimación en una imagen contaminada con este ruido, con varianza de ruido de 0.80, mientras que la Figura. 3.6 muestra la desviación típica de cada algoritmo para una varianza de ruido en el rango de 5.5 a 0.8 con saltos de 0.025.

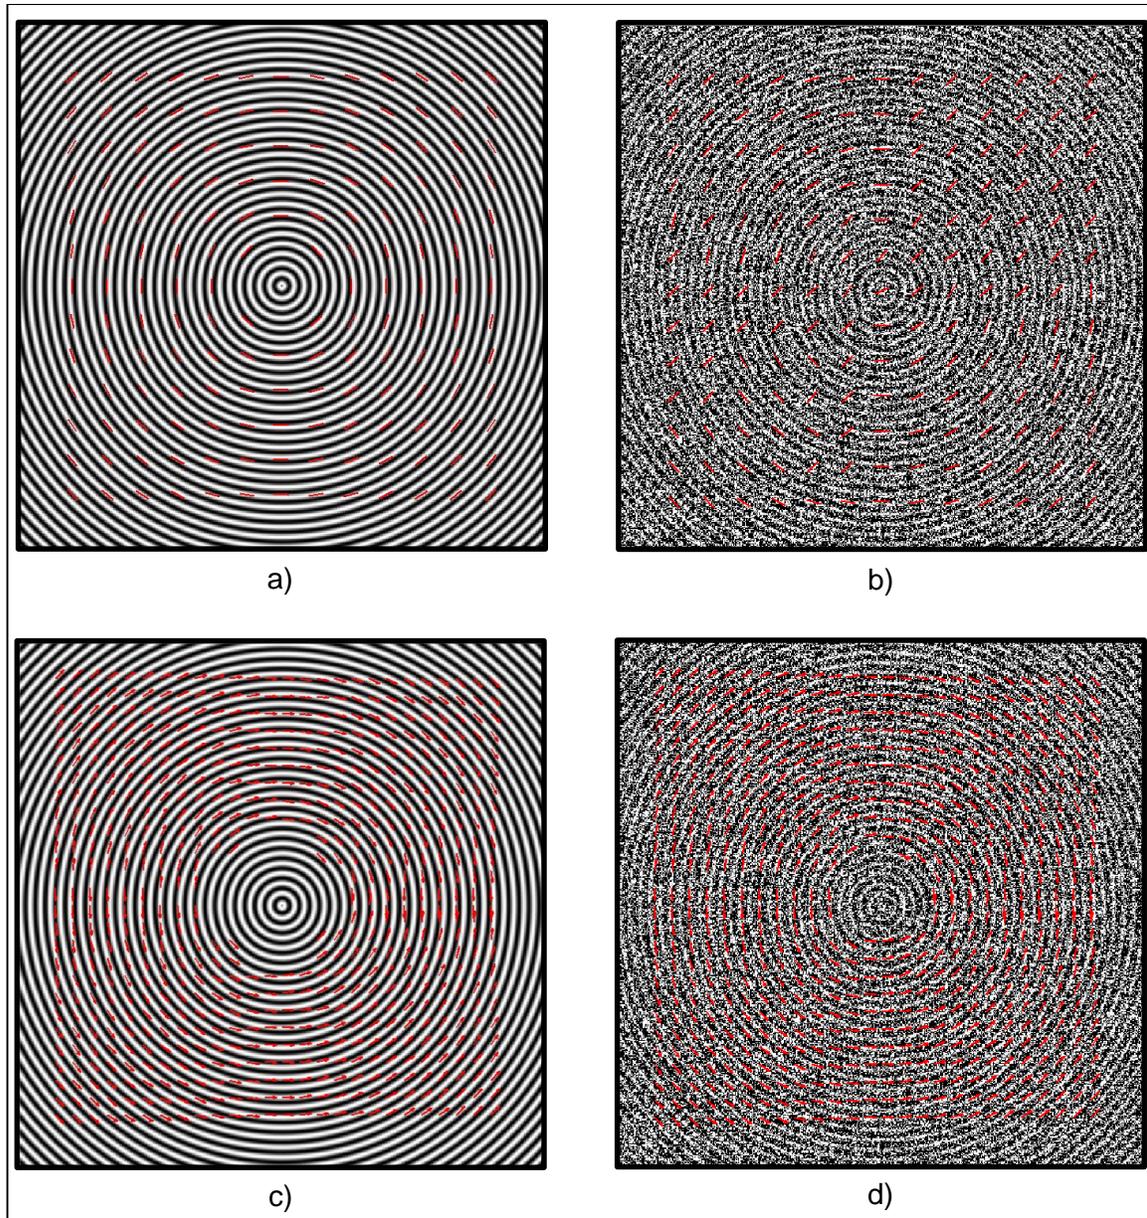


Figura. 3.5 Imágenes sintéticas con dimensiones 480x480 píxeles y frecuencia 0.109375 ciclos/píxel; a) y c) orientaciones estimadas por los algoritmos del GAPIS y propuesto respectivamente en la imagen pura; b) y d) orientaciones estimadas por el algoritmo del GAPIS y propuesto respectivamente en la imagen contaminada con ruido salt & pepper con varianza del ruido de 0.8.

En la Figura. 3.5 b) se puede observar, además de la estimación errónea de la orientación mediante el algoritmo del GAPIS, un erróneo crecimiento hacia el centro del patrón sintético, no estimado en la imagen pura, lo que provocará una segmentación posterior errónea, mientras que el algoritmo propuesto presenta un mejor desempeño.

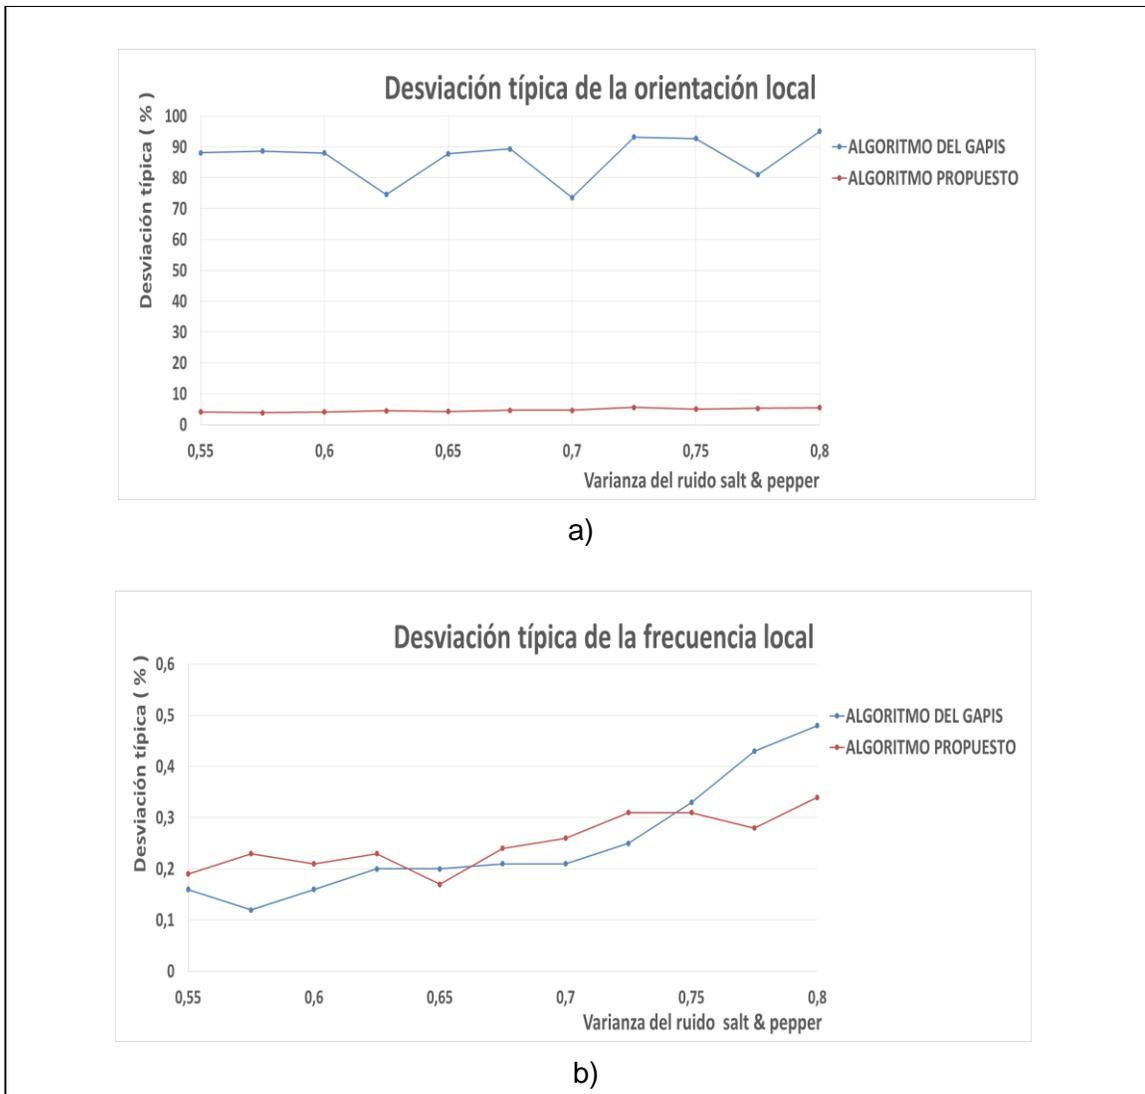


Figura. 3.6 desviación típica en la estimación de los parámetros para una varianza del ruido salt & pepper de 0.55 a 0.8 en saltos de 0.025; a) desviación típica en la orientación local; b) desviación típica en la frecuencia local.

En la Figura. 3.6 a) se observa que el algoritmo propuesto es más robusto frente al ruido salt & pepper en la estimación de la orientación que el desarrollado en GAPIS en todo el rango de la varianza del ruido, presentando apenas un 5.5 % de desviación típica frente a un 95 % de desviación típica del GAPIS para una varianza del ruido de 0.8.

En la Figura. 3.6 b) se observa que el algoritmo propuesto posee una desviación típica de 0.34% en la estimación de las frecuencias locales, levemente menor que el algoritmo del GAPIS de 0.48% para una varianza del ruido de 0.8. De todos modos, como la diferencia

de la desviación típica entre ambos algoritmos no excede el 0.14% se asume como irrelevante este resultado en la comparación del desempeño de los algoritmos.

3.1.3 Estimación de la orientación en imágenes reales de huellas epiteliales

Además de las pruebas en imágenes sintéticas se realizaron varias pruebas sobre imágenes reales de huellas latentes. Dichas pruebas permitieron corroborar la robustez del algoritmo propuesto en cuanto a la estimación de la orientación del flujo de crestas y a la segmentación mediante una valoración visual. Una muestra de dichas pruebas aparece a continuación.

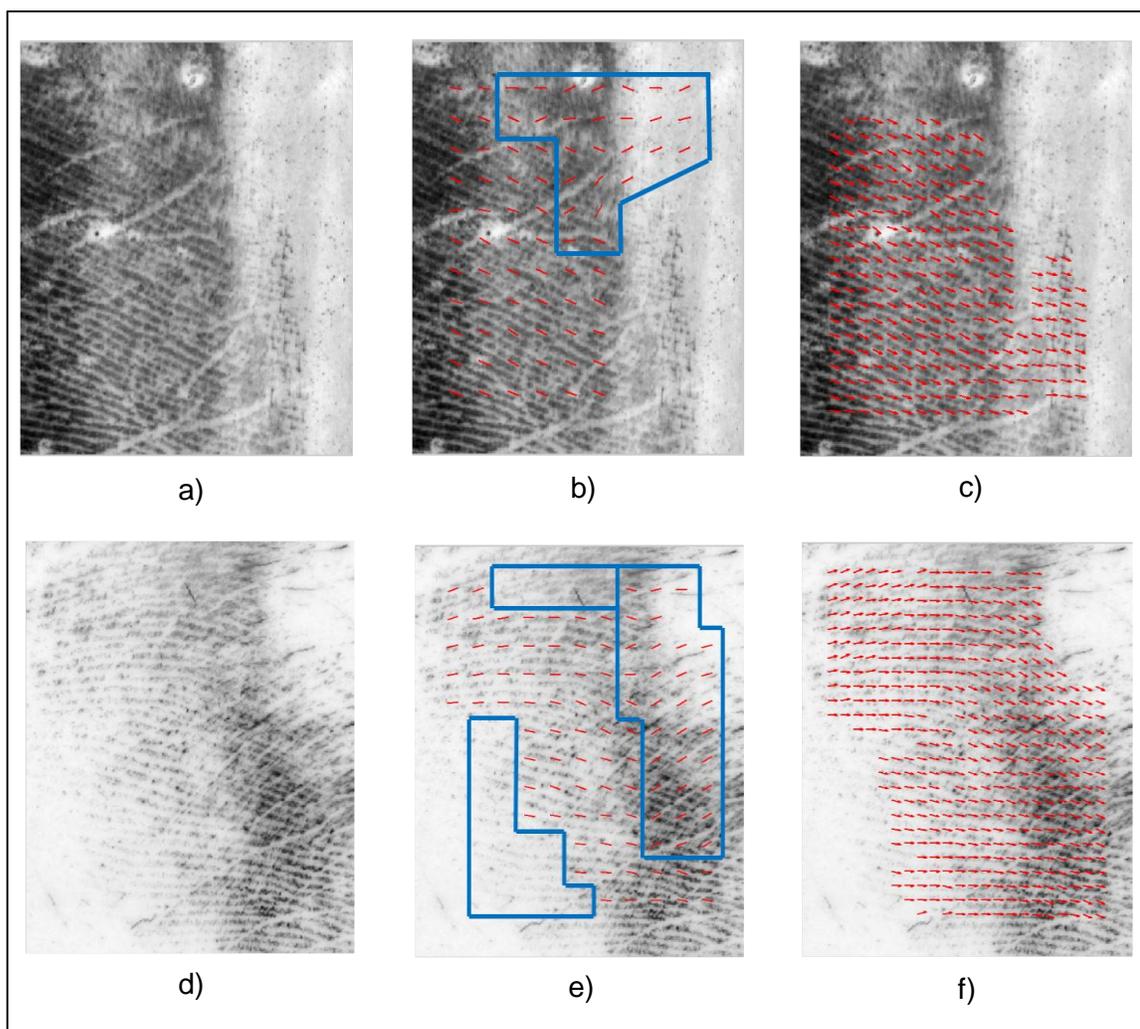


Figura. 3.7 Imágenes de la base de datos palmars latentes; a) y d) imágenes originales; b) y e) estimaciones de la orientación realizada por el algoritmo del GAPIS; c) y f) estimaciones de la orientación realizada por el algoritmo propuesto.

En la figura anterior se encuentran señaladas algunas de las deficiencias del algoritmo del GAPIS, las cuales han sido superadas en el algoritmo propuesto. En la Figura. 3.7 b) se observa una errónea estimación de la orientación del flujo de crestas como un erróneo crecimiento hacia zonas de fondo no presente en la Figura. 3.7 c) correspondiente al algoritmo propuesto. Mientras que en la Figura. 3.7 e) se muestran además de los crecimientos erróneos, zonas recuperables donde el algoritmo del GAPIS no estimó sus parámetros locales, dificultad superada en la Figura. 3.7 f) perteneciente al algoritmo propuesto.

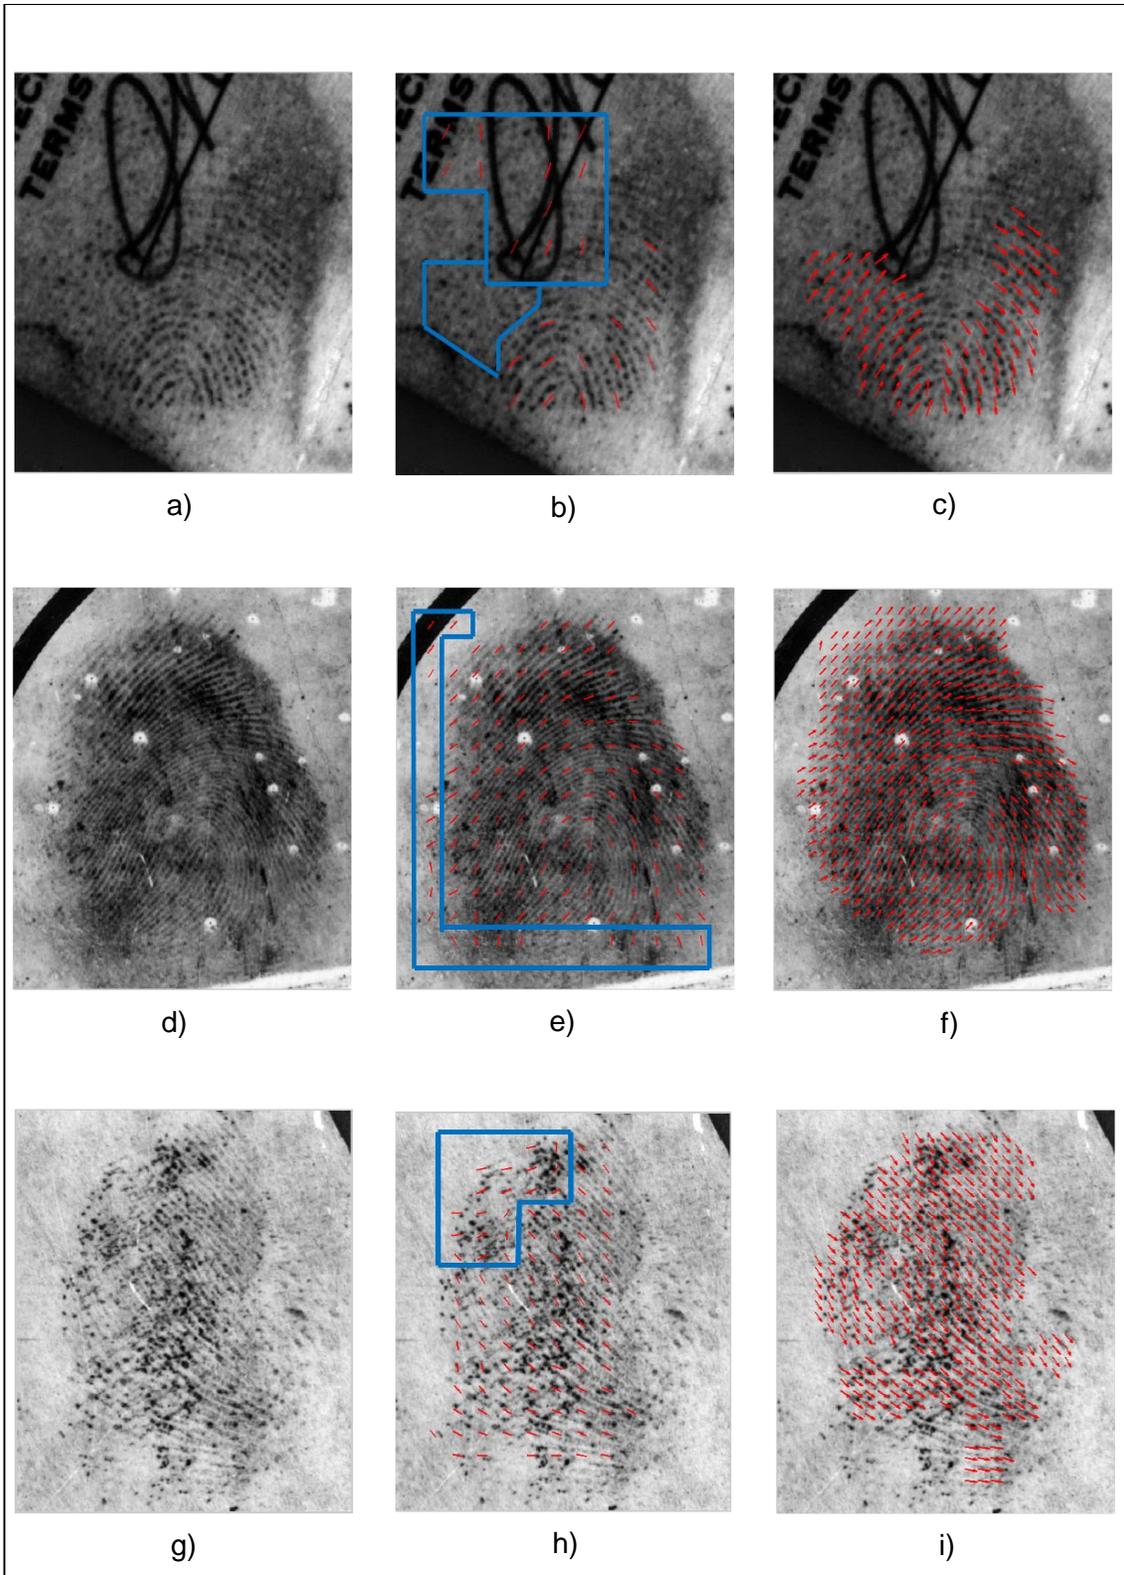


Figura. 3.8 Imágenes de la base de datos NIST BD 27; a), d) y g) imágenes originales; b), e) y h) estimaciones de la orientación realizada por el algoritmo del GAPIS; c), f) e i) estimaciones de la orientación realizada por el algoritmo propuesto.

La figura anterior muestra una selección de las 3 categorías de imágenes de huellas latentes presentes en la base de datos NIST BD 27 a las cuales se le ha realizado las pruebas, la Figura. 3.8 a) corresponde a las imágenes latentes de buena calidad, la Figura. 3.8 d) corresponde a las latentes de mala calidad y la Figura. 3.8 g) corresponde a las latentes de muy mala calidad.

En la figura anterior se encuentran señaladas algunas de las deficiencias del algoritmo de estimación del GAPIS, las cuales han sido superadas en el algoritmo propuesto, en la Figura. 3.8 b), e) y h) se observa una errónea estimación de la orientación del flujo de crestas como un erróneo crecimiento hacia zonas de fondo no presente en la Figura. 3.8 c), f) e i) respectivamente correspondientes al algoritmo propuesto.

3.2 Resultados de la influencia de los algoritmos de mejoramiento en los algoritmos de detección de minucias

Para la cuantificación y comparación de la robustez de los algoritmos de mejoramiento de la calidad de imágenes en huellas latentes se utilizó el algoritmo de detección de minucias desarrollado en el GAPIS.

Se comparará la influencia de los algoritmos de mejoramiento, en relación a la cantidad de minucias extraídas por dicho algoritmo que coincidan con las existentes en la imagen. Las siguientes figuras recogen las estadísticas de las minucias recuperadas debido a la influencia de los algoritmos de mejoramiento, las tablas que recogen los resultados pueden consultarse en los anexos.

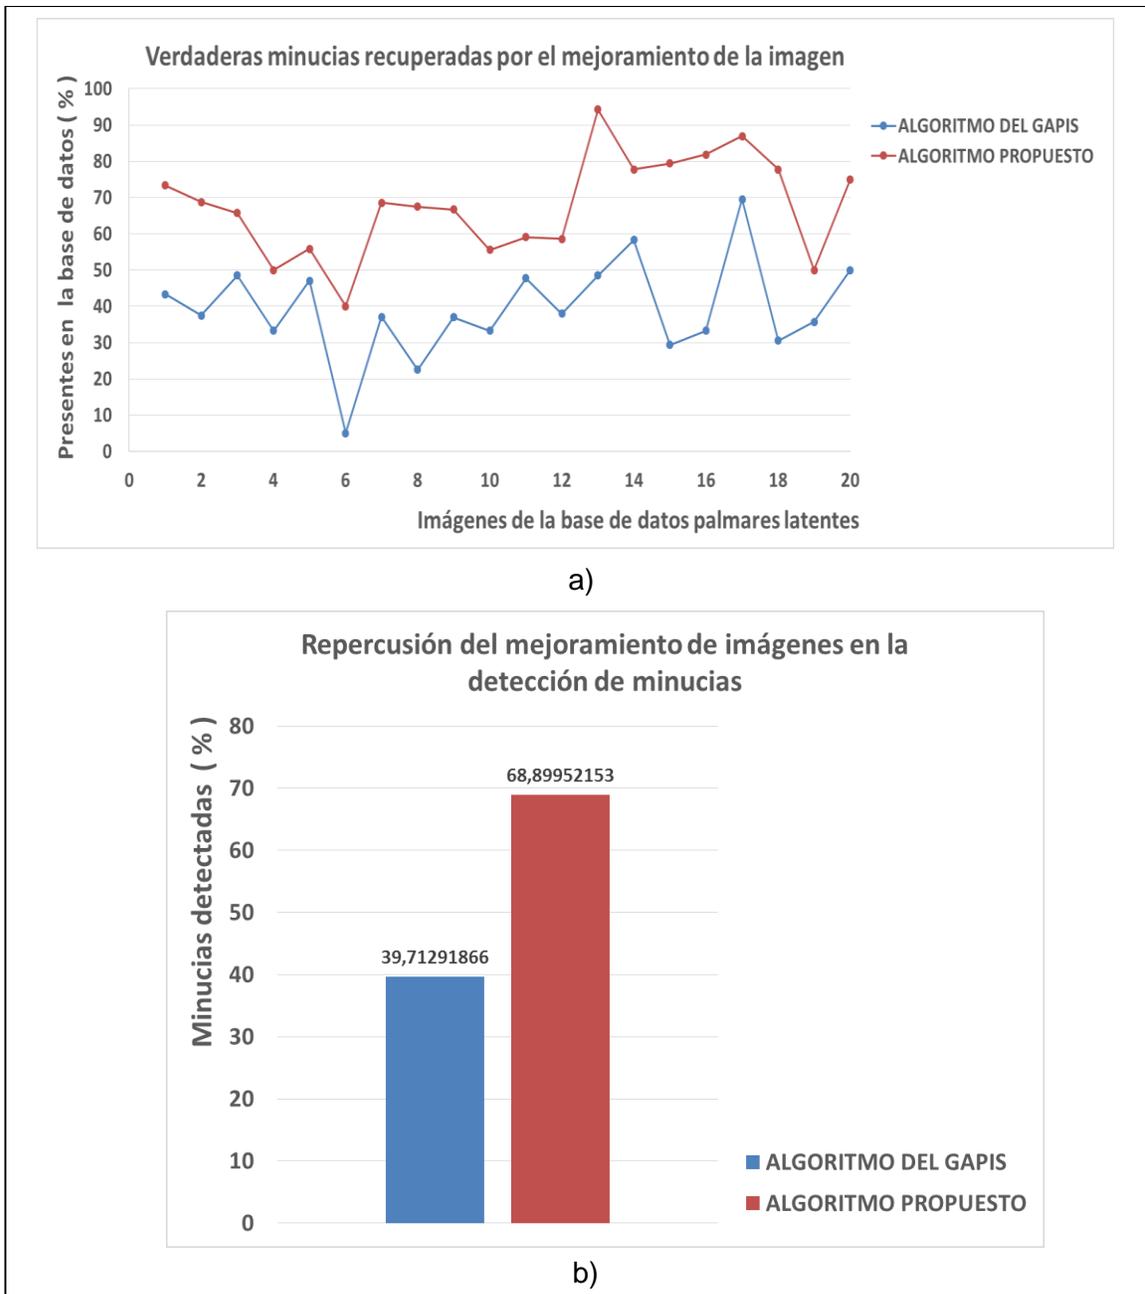


Figura. 3.9 Repercusión del mejoramiento de la calidad de imágenes en la detección de minucias; a) Estadísticas de las minucias detectadas en cada imagen de la base de datos palmar latente; b) Estadísticas de las minucias detectadas en la base de datos palmar latente.

En la Figura. 3.9 a) se comprueba que al algoritmo de mejoramiento propuesto permite un porcentaje mayor de extracción de las minucias existentes en todas las imágenes seleccionadas de la base de datos palmar latente, mientras que la Figura. 3.9 b) resalta que algoritmo propuesto permite la extracción de aproximadamente un 68.9 % de las minucias de dicha base de datos, y el del GAPIS aproximadamente de un 39.7 % .

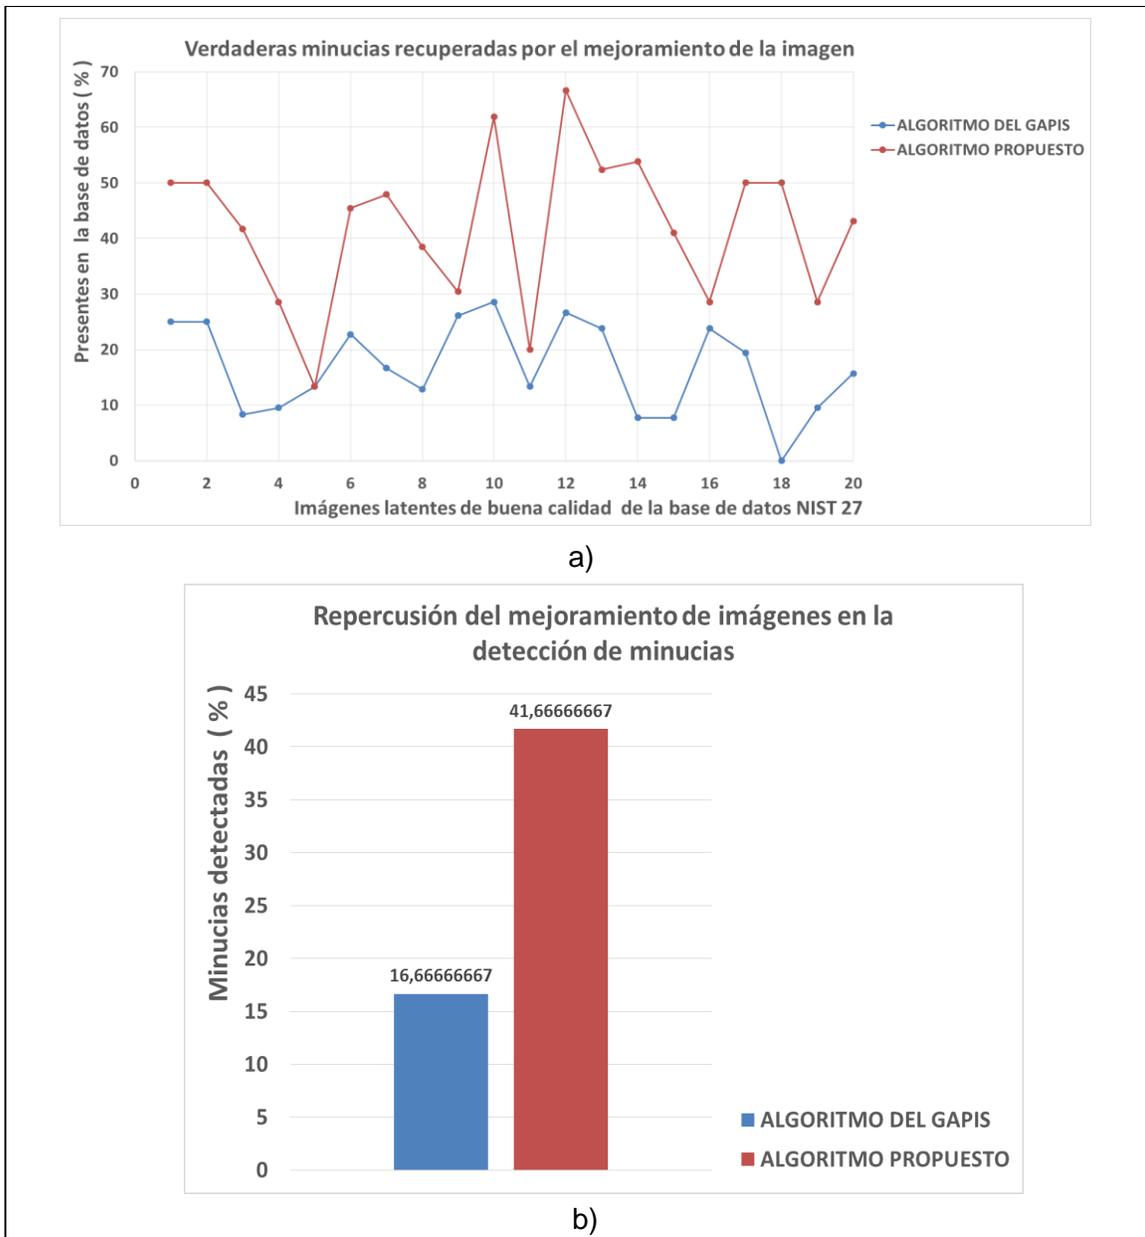


Figura. 3.10 Repercusión del mejoramiento de la calidad de imágenes en la detección de minucias; a) Estadísticas de las minucias detectadas en cada imagen latente de buena calidad de la base de datos NIST BD 27; b) Estadísticas de las minucias detectadas en las imágenes latentes de buena calidad de la base de datos NIST BD 27.

En la Figura. 3.10 a) se comprueba que al algoritmo de mejoramiento propuesto permite una por ciento mayor de extracción de las minucias existentes en las imágenes latentes de buena calidad de la base de datos NIST BD 27, mientras que la Figura. 3.10 b) resalta que algoritmo propuesto permite la extracción de aproximadamente un 41.7 % de las minucias de la base de datos, y el del GAPIS aproximadamente de un 16.7 %

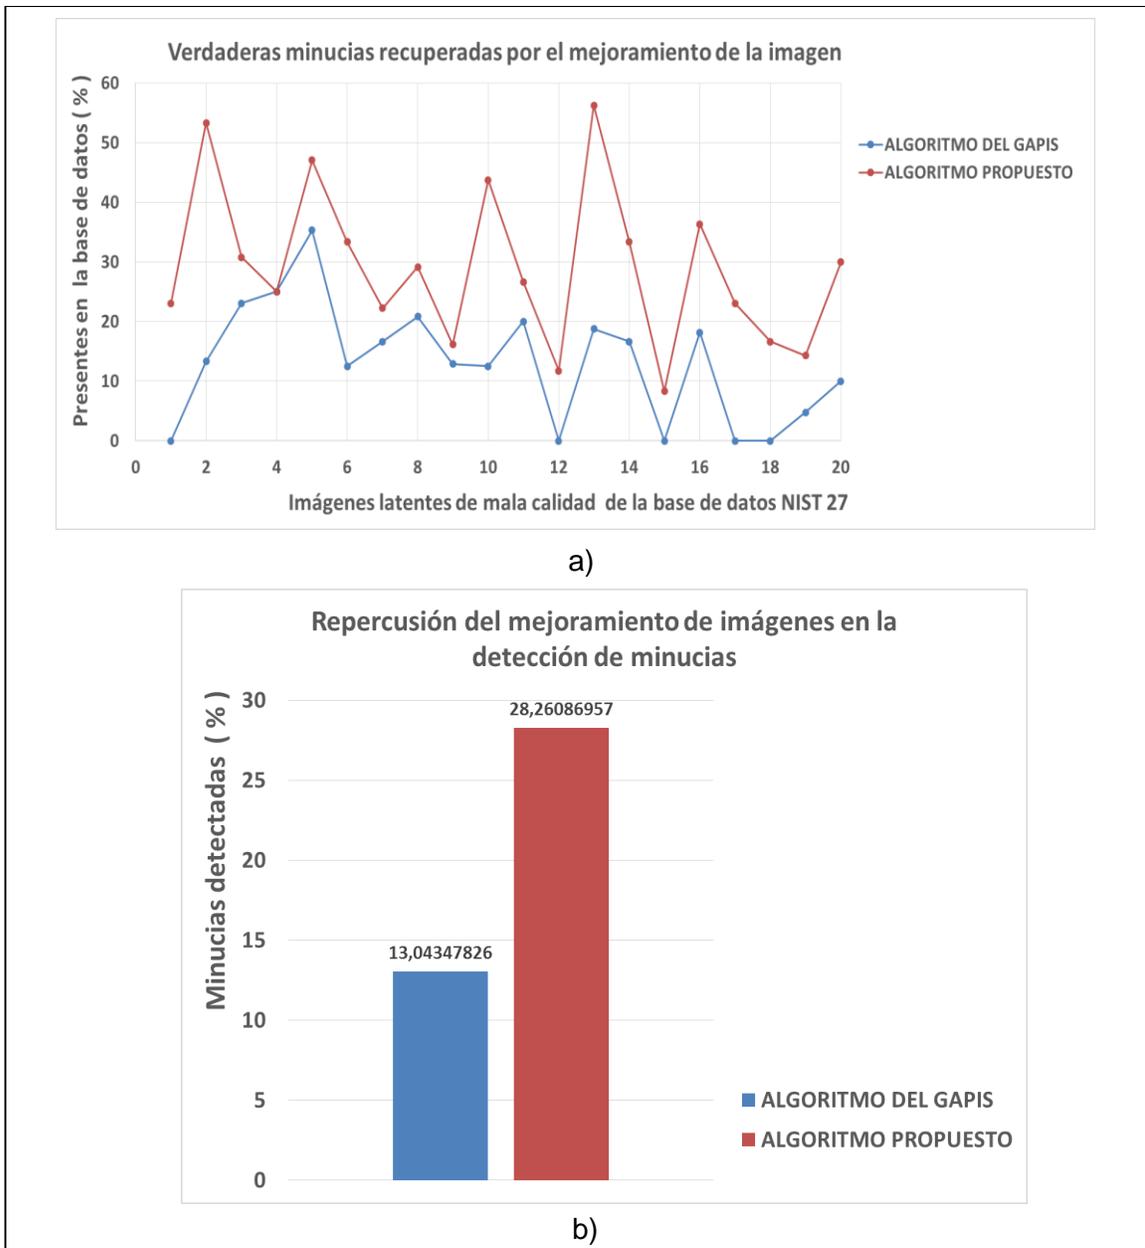


Figura. 3.11 Repercusión del mejoramiento de la calidad de imágenes en la detección de minucias; a) Estadísticas de las minucias detectadas en cada imagen latente de mala calidad de la base de datos NIST BD 27; b) Estadísticas de las minucias detectadas en las imágenes latentes de mala calidad de la base de datos NIST BD 27.

En la Figura. 3.11 a) se comprueba que al algoritmo de mejoramiento propuesto permite una por ciento mayor de extracción de las minucias existentes en las imágenes latentes de mala calidad de la base de datos NIST BD 27, mientras que la Figura. 3.11 b) resalta que algoritmo propuesto permite la extracción de aproximadamente un 28.3 % de las minucias de la base de datos, y el del GAPIS aproximadamente de un 13.0 %.

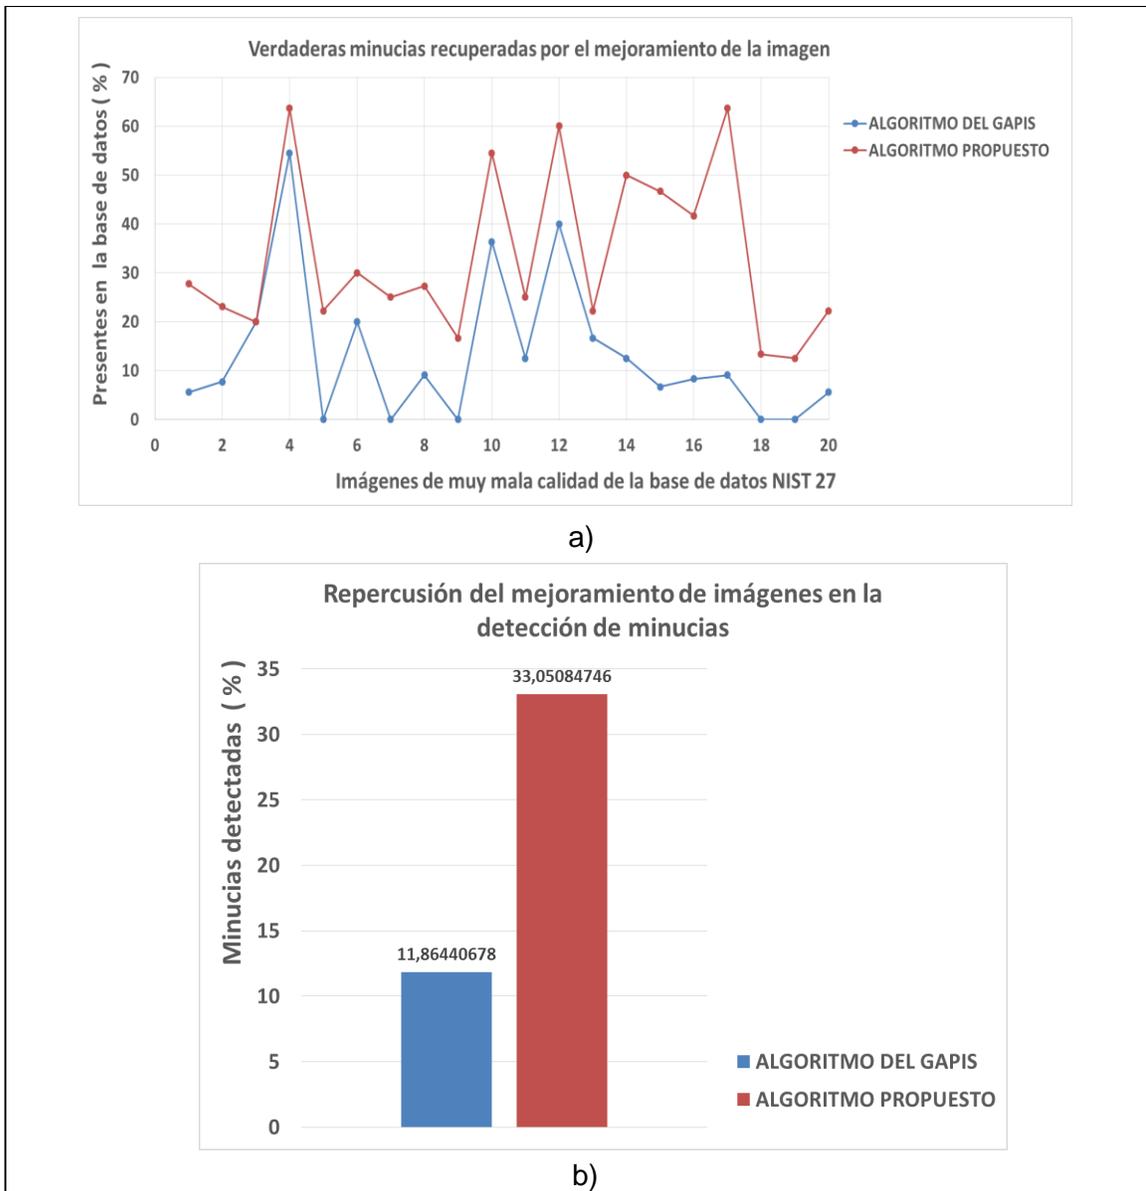


Figura. 3.12 Repercusión del mejoramiento de la calidad de imágenes en la detección de minucias; a) Estadísticas de las minucias detectadas en cada imagen latente de muy mala calidad de la base de datos NIST BD 27; b) Estadísticas de las minucias detectadas en las imágenes latentes de muy mala calidad de la base de datos NIST BD 27.

En la Figura. 3.12 a) se comprueba que al algoritmo de mejoramiento propuesto permite una por ciento mayor de extracción de las minucias existentes en las imágenes latentes de muy mala calidad de la base de datos NIST 27, mientras que la Figura. 3.12 b) resalta que algoritmo propuesto permite la extracción de aproximadamente un 33.0 % de las minucias de la base de datos, y el del GAPIS aproximadamente de un 11.9 %

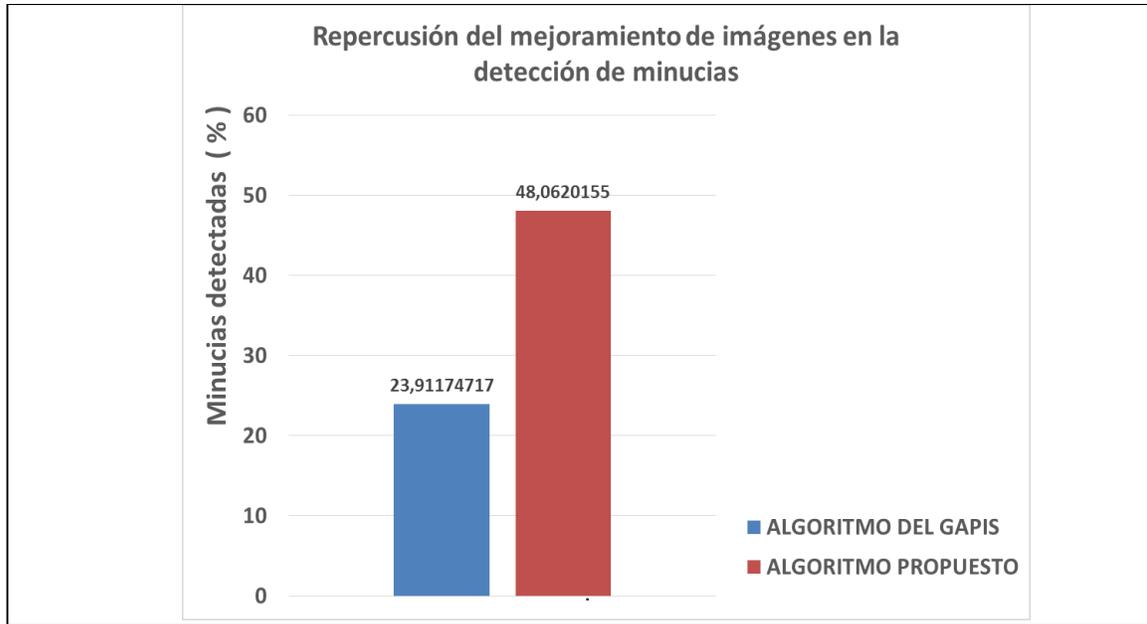


Figura. 3.13 Estadísticas de las minucias detectadas en las imágenes latentes de las bases de datos palmar latente y NIST BD 27.

En la anterior figura se resalta que algoritmo propuesto permite la extracción de aproximadamente un 48.1 % de las minucias de las bases de datos utilizadas, y el del GAPIS aproximadamente de un 23.9 %.

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

Los aportes fundamentales de este trabajo, como conclusión del proceso investigativo llevado a cabo, se pueden resumir en los siguientes puntos:

- Se verificó que la inclusión de conocimientos estadísticos de las huellas epiteliales mejora el desempeño de los algoritmos de mejoramiento.
- Se demostró que el empleo de umbrales adaptativos en las condiciones de continuidad del algoritmo de crecimiento de región, junto a una condición de conectividad que garantice la influencia de la vecindad en la estimación de la onda modelo, permite una estimación fiable de la orientación y frecuencia local así como una segmentación robusta.
- Se comprobó cualitativamente y cuantitativamente, mediante la utilización de imágenes sintéticas alteradas con ruido gaussiano aditivo y salt & pepper, que el algoritmo de estimación propuesto es más robusto y confiable que el implementado en GAPIS.
- Se evidenció cuantitativamente que el porcentaje de minucias verdaderas encontradas debido al algoritmo propuesto de mejoramiento supera al algoritmo de GAPIS.
- Se comprobó que el algoritmo propuesto estima de forma más acertada las orientaciones y frecuencias locales en imágenes de huellas latentes de elevada complejidad, en comparación con el algoritmo implementado anteriormente en GAPIS.

Recomendaciones

- Incluir el porcentaje de minucias falsas detectadas por ambos algoritmos como criterio de evaluación.
- Realizar un proceso de evaluación del algoritmo que incluya un banco de imágenes de huellas latentes pertenecientes a los sistemas de reconocimientos biométricos del país.

REFERENCIAS BIBLIOGRÁFICAS

- [1] . R. Thai, "Fingerprint Image Enhancement and Minutiae Extraction," 2003.
- [2] D. Davide, D. Maio, A. K. Jain y S. Prabhakar, Edits., Handbook of Fingerprint Recognition, Segunda ed., London: Springer, 2009.
- [3] . A. Y. Villalón Duany, «Mejoramiento de la calidad de imágenes de huella dactilar mediante el filtrado direccional en el dominio de la frecuencia,» Santiago de Cuba, 2013.
- [4] W. Wang, J. Li, F. Huang y H. Feng, «Design and implementation of Log-Gabor filter in fingerprint image enhancement,» *Pattern Recognition Letters*, vol. 29, pp. 301-308, 2008.
- [5] A. K. Jain y J. Feng, «Latent Palmprint Matching,» *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 31, nº 6, June 2009.
- [6] . Y. R. Guerrero López, «Diseño e implementación de un algoritmo para la estimación de frecuencias y direcciones locales en imágenes de huellas latentes,» Santiago de Cuba, 2014.
- [7] K. Cao, E. Liu y A. K. Jain, «Segmentation and Enhancement of Latent Fingerprints: A Coarse to Fine Ridge Structure Dictionary,» 2014.
- [8] D. Simón Zorita, «Reconocimiento automático mediante patrones biométricos de huella dactilar,» Madrid, 2003.
- [9] S. S. Chikkerur, A. N. Cartwright y V. Govindaraju, *Fingerprint image enhancement using STFT analysis*, New York, 2004.
- [10] R. C. Gonzalez y R. E. Woods, Digital Image Processing, Tercera ed., M. J Horton, Ed., New Jersey: Prentice Hall, 2008.

- [11] M. D. Garris y M. McCabe, *NIST Special Database 27, Fingerprint Minutiae from Latent and Matching Tenprint Images*.
- [12] W. J. Dixon y F. J. Massey, *Introducción al análisis estadístico*, Habana: Pueblo y Educación, 1974.
- [13] A. K. Jain y J. Feng, «Latent palmprint matching,» *IEEE Transactions on Pattern Analysis and machine intelligence* , vol. 31, nº 6, pp. 1032-1047, June 2009.

Anexos

Anexo I. Influencia de los algoritmos de mejoramiento en la extracción de minucias en la base de datos palmar latente

Imágenes de los experimentos		minucias marcadas	Algoritmo del GAPIS		Algoritmo propuesto	
			Minucias coincidentes	%	Minucias coincidentes	%
Base de datos proporcionada por el CENATAV						
1	A119999900000200805325600.tif	60	26	43,33333	44	73,33333
2	A119999900000200807305200.tif	32	12	37,5	22	68,75
3	A119999900000200809304001.tif	35	17	48,57143	23	65,71429
4	A119999900000200811312000.tif	30	10	33,33333	15	50
5	A119999900000200811312001.tif	34	16	47,05882	19	55,88235
6	A119999900000200812306800.tif	20	1	5	8	40
7	A119999900000200812306801.tif	35	13	37,14286	24	68,57143
8	A119999900000200812306802.tif	40	9	22,5	27	67,5
9	A119999900000200812318200.tif	27	10	37,03704	18	66,66667
10	A119999900000200812318201.tif	18	6	33,33333	10	55,55556
11	A11999999990200801309300.tif	44	21	47,72727	26	59,09091
12	A11999999990200801309301.tif	29	11	37,93103	17	58,62069
13	A11999999990200805301300.tif	35	17	48,57143	33	94,28571
14	A11999999990200805301301.tif	36	21	58,33333	28	77,77778
15	A11999999990200805301302.tif	34	10	29,41176	27	79,41176
16	A11999999990200805301303.tif	33	11	33,33333	27	81,81818
17	A11999999990200805301304.tif	23	16	69,56522	20	86,95652
18	A11999999990200805301305.tif	36	11	30,55556	28	77,77778
19	A11999999990200811500200.tif	14	5	35,71429	7	50
20	A11999999990200809306400.tif	12	6	50	9	75
total		627	249	39,71292	432	68,89952

Anexo II. Influencia de los algoritmos de mejoramiento en la extracción de minucias en las imágenes de buena calidad de la base de datos NIST BD 27

Imágenes de los experimentos		minucias marcadas	Algoritmo del GAPIS		Algoritmo propuesto	
			Minucias coincidentes	%	Minucias coincidentes	%
Base de datos NIST 27						
Latentes de buena calidad						
1	g001l2u.tif	16	4	25	8	50
2	g002l3u.tif	16	4	25	8	50
3	g003l8u.tif	12	1	8,333333	5	41,66667
4	g004l8u.tif	42	4	9,52381	12	28,57143
5	g005l8u.tif	15	2	13,33333	2	13,33333
6	g006l6u.tif	22	5	22,72727	10	45,45455
7	g007l1u.tif	48	8	16,66667	23	47,91667
8	g008l6u.tif	39	5	12,82051	15	38,46154
9	g009l8u.tif	23	6	26,08696	7	30,43478
10	g011l7u.tif	21	6	28,57143	13	61,90476
11	g012l8u.tif	15	2	13,33333	3	20
12	g013l4u.tif	15	4	26,66667	10	66,66667
13	g014l7u.tif	21	5	23,80952	11	52,38095
14	g016l8u.tif	13	1	7,692308	7	53,84615
15	g017l9u.tif	39	3	7,692308	16	41,02564
16	g018l6u.tif	21	5	23,80952	6	28,57143
17	g019l1u.tif	36	7	19,44444	18	50
18	g020l6u.tif	6	0	0	3	50
19	g021l7u.tif	21	2	9,52381	6	28,57143
20	g023l6u.tif	51	8	15,68627	22	43,13725
total		492	82	16,66667	205	41,66667

Anexo III. Influencia de los algoritmos de mejoramiento en la extracción de minucias en las imágenes de mala calidad de la base de datos NIST BD 27

Imágenes de los experimentos		minucias marcadas	Algoritmo del GAPIS		Algoritmo propuesto	
			Minucias coincidentes	%	Minucias coincidentes	%
Base de datos NIST 27						
Latentes de mala calidad						
1	b101l9u.tif	13	0	0	3	23,07692
2	b102l0u.tif	15	2	13,33333	8	53,33333
3	b104l8u.tif	13	3	23,07692	4	30,76923
4	b191l3u.tif	12	3	25	3	25
5	b106l8u.tif	17	6	35,29412	8	47,05882
6	b107l9u.tif	24	3	12,5	8	33,33333
7	b108l6u.tif	18	3	16,66667	4	22,22222
8	b109l4u.tif	24	5	20,83333	7	29,16667
9	b110l6u.tif	31	4	12,90323	5	16,12903
10	b111l7u.tif	16	2	12,5	7	43,75
11	b112l2u.tif	15	3	20	4	26,66667
12	b114l3u.tif	17	0	0	2	11,76471
13	b115l8u.tif	16	3	18,75	9	56,25
14	b116l6u.tif	6	1	16,66667	2	33,33333
15	b117l0u.tif	12	0	0	1	8,333333
16	b118l8u.tif	11	2	18,18182	4	36,36364
17	b119l0u.tif	13	0	0	3	23,07692
18	b120l9u.tif	18	0	0	3	16,66667
19	b121l7u.tif	21	1	4,761905	3	14,28571
20	b122l4u.tif	10	1	10	3	30
total		322	42	13,04348	91	28,26087

Anexo IV. Influencia de los algoritmos de mejoramiento en la extracción de minucias en las imágenes de muy mala calidad de la base de datos NIST BD 27

Imágenes de los experimentos		minucias marcadas	Algoritmo del GAPIS		Algoritmo propuesto	
			Minucias coincidentes	%	Minucias coincidentes	%
Base de datos NIST 27						
Latentes de muy mala calidad						
1	u201l6u.tif	18	1	5,555556	5	27,77778
2	u202l8u.tif	13	1	7,692308	3	23,07692
3	u206l3u.tif	5	1	20	1	20
4	u209l7u.tif	11	6	54,54545	7	63,63636
5	u212l2u.tif	9	0	0	2	22,22222
6	u214l5u.tif	10	2	20	3	30
7	u216l4u.tif	12	0	0	3	25
8	u217l6u.tif	11	1	9,090909	3	27,27273
9	u218l1u.tif	6	0	0	1	16,66667
10	u220l5u.tif	11	4	36,36364	6	54,54545
11	u221l9u.tif	8	1	12,5	2	25
12	u222l3u.tif	5	2	40	3	60
13	u223l6u.tif	18	3	16,66667	4	22,22222
14	u224l6u.tif	8	1	12,5	4	50
15	u226l3u.tif	15	1	6,666667	7	46,66667
16	u229l2u.tif	24	2	8,333333	10	41,66667
17	u230l6u.tif	11	1	9,090909	7	63,63636
18	u231l2u.tif	15	0	0	2	13,33333
19	u233l6u.tif	8	0	0	1	12,5
20	u300l2u.tif	18	1	5,555556	4	22,22222
total		236	28	11,86441	78	33,05085