

---

**DETERMINACIÓN DE LA INCIDENCIA DEL  
CÁLCULO DE LA ROI EN UN SISTEMA DE  
IDENTIFICACIÓN BIOMÉTRICA DE PALMA DE LA  
MANO MEDIANTE LBP.**

---

**MARIBEL ARROYAVE GIRALDO**



**INSTITUTO TECNOLÓGICO METROPOLITANO  
MAESTRÍA EN AUTOMATIZACIÓN Y CONTROL INDUSTRIAL  
MEDELLIN, COLOMBIA  
2012**

---

**DETERMINACIÓN DE LA INCIDENCIA DEL  
CÁLCULO DE LA ROI EN UN SISTEMA DE  
IDENTIFICACIÓN BIOMÉTRICA DE PALMA DE  
LA MANO MEDIANTE LBP.**

---

Maribel Arroyave Giraldo

Tesis para optar al título de

Magíster en Automatización y Control Industrial

Director

Prof., Alejandro Restrepo, Ph.D - ITM



**INSTITUTO TECNOLÓGICO METROPOLITANO  
MAESTRÍA EN AUTOMATIZACIÓN Y CONTROL INDUSTRIAL  
MEDELLIN, COLOMBIA  
2012**

---

**DETERMINE THE IMPACT OF THE ROI  
CALCULATION ON PALMPRINT BIOMETRIC  
SYSTEM BY TEXTURE ANALYSIS**

---

Maribel Arroyave Giraldo

A thesis submitted to the postgraduate program “Industrial Control and Automation” in partial fulfillment of the requirements for the Master Degree

Thesis Supervisor

Prof., Alejandro Restrepo, Ph.D - ITM



**INSTITUTO TECNOLÓGICO METROPOLITANO  
MAESTRÍA EN AUTOMATIZACIÓN Y CONTROL INDUSTRIAL  
MEDELLIN, COLOMBIA  
2012**

---

## DEDICATORIA

---

A mis padres y mis hermanitos por su apoyo incondicional, su gran comprensión doy gracias por tenerlos a ustedes..... mi familia perfecta.

Además dedico este trabajo a mi padre académico, mi profe, mi tutor, mi asesor, mi orientador porque gracias a ti alcance hoy a llegar a aquí, a tener una maestría, una especialización, a ser docente, porque mis mayores enseñanzas las recibí de ti mi gran maestro, porque como profesional, como académico y como persona resalta tu excelencia. Gracias mil gracias mi modelo de referencia Luis Eduardo García Jaimes.

En especial mi trabajo se lo dedico a mi novio que fue mi gran apoyo para culminar este trabajo porque cuando pensaba que, las cosas no podían ser, que el cansancio me vencería, llegas tú, me levantas y me animas a continuar, prácticamente me obligas a concluir mi tesis, gracias por sacrificar tus fines de semana mientras yo estudiaba, gracias por permanecer a mi lado. Mi vida te adoro y simplemente quería explicarte la razón por la cual no puedo separarme de ti.....Porque en el dominio de  $Z$  no permites que mis polos salgan de la circunferencia unitaria, porque en el dominio de Laplace mantienes mis polos en el semiplano izquierdo, porque en el dominio del tiempo me dejas un error de estado estable igual a cero y porque del dominio de mi corazón no saldrás nunca. Te amo mi controlador PI. Iván Gonzalo Rojas Rodas.

---

## AGRADECIMIENTOS

---

Agradezco a Jesús Francisco Vargas y Alejandro Restrepo por su orientación, sugerencias y colaboración durante este trabajo. Alejandro gracias por soportarme y no permitirme abandonar.

Del mismo modo al centro de investigación del ITM institución universitaria por la financiación del proyecto con código PM10202 inscrito en el grupo MIRP.

También doy gracias a todas aquellas personas que de una u otra manera me apoyaron en este proceso: Diana Lucia Mazo, Jorge Jaramillo, Cristian Guarnizo, Julián Mauricio Granados, Luis Eduardo García y Edilson Delgado Trejos.

---

# ÍNDICE GENERAL

---

<b>ÍNDICE GENERAL</b> .....	<b>1</b>
<b>ÍNDICE DE FIGURAS</b> .....	<b>3</b>
<b>ÍNDICE DE TABLAS</b> .....	<b>6</b>
<b>RESUMEN</b> .....	<b>7</b>
<b>ABSTRACT</b> .....	<b>9</b>
<b>1. INTRODUCCIÓN</b> .....	<b>11</b>
<b>2. MARCO TEÓRICO Y ESTADO DEL ARTE</b> .....	<b>16</b>
2.1. Introducción .....	16
2.2. Tratamiento de Imágenes .....	17
2.3. Métricas de comparación de imágenes .....	18
2.4. Umbralización .....	20
2.5. Detección de borde .....	25
2.6. Localización de puntos .....	26
2.7. Ubicación de la ROI.....	28
2.8. Caracterización.....	30
2.9. Clasificación .....	33
<b>3. METODOLOGÍA PROPUESTA</b> .....	<b>38</b>
3.1 Introducción .....	38
3.2. Bases de datos .....	38
3.3. Metodología propuesta .....	39
3.4. Diseño del software .....	40
3.5. Preprocesamiento .....	43
3.6. Patrones binarios locales (LBP) .....	48
3.7. Clasificación .....	52
3.8. Evaluación de desempeño .....	54
<b>4. EXPERIMENTOS Y RESULTADOS</b> .....	<b>56</b>
4.1 Introducción .....	56

4.2. Selección del método de umbralización .....	56
4.3. Comparación de imágenes.....	61
4.4. Variación en el brillo .....	64
4.5. Variación en el contraste .....	68
4.6. Variación en el desplazamiento de la ROI.....	70
4.7. Análisis de sintonización.....	73
4.8. Evaluación de los LBP's .....	74
4.9. Análisis de la técnica de sobremuestreo .....	80
4.10. Análisis de los métodos de la ROI .....	82
4.11. Clasificador lineal .....	87
4.12. Discusiones .....	<b>¡Error! Marcador no definido.</b>
<b>CONCLUSIONES .....</b>	<b>¡ERROR! MARCADOR NO DEFINIDO.</b>
<b>REFERENCIAS.....</b>	<b>104</b>
<b>ANEXOS .....</b>	<b>109</b>

---

## ÍNDICE DE FIGURAS

---

<i>Figura 1. Muestras de diferentes ROI para dos individuos. a) Imagen del individuo 1, ROI 1. b) Imagen del individuo 1, ROI 2. c) Imagen del individuo 1, ROI 3. d) Imagen del individuo 2, ROI 1. e) Imagen del individuo 2, ROI 2. f) Imagen del individuo 2, ROI 3. ....</i>	<i>14</i>
<i>Figura 2. 1. Mapa conceptual de sistemas biométricos.....</i>	<i>16</i>
<i>Figura 2. 2. Etapas del sistema biométrico de palma de la mano .....</i>	<i>18</i>
<i>Figura 2. 3. Ubicación de mínimos y máximos (Han, Cheng, Lin, &amp; Fan, 2003). a) Perfil de curvatura de la forma de la mano. b) Perfil transformado en subbanda de alta frecuencia .....</i>	<i>27</i>
<i>Figura 2. 4. Ubicación de mínimos y máximos (Lin, C. Chuang, &amp; Fan, 2005). a) Diagrama de distribución de distancias del borde de la palma. Construido con la distancia euclídea entre el punto medio de la muñeca y los pixeles del borde de la palma.....</i>	<i>27</i>
<i>Figura 2. 5. Ubicación de mínimos y máximos (Chen, Moon, Wong, &amp; Su, 2010) a) Base de datos Poly U. b) Base de datos CANSIA. ....</i>	<i>28</i>
<i>Figura 2. 6. Ubicación de mínimos y máximos (Kong &amp; Zhang, 2002). a) Detección de puntos. b) Ubicación de la ROI.....</i>	<i>28</i>
<i>Figura 2. 7. Ubicación de la ROI. ....</i>	<i>29</i>
<i>Figura 2. 8. LBP Patrones binarios locales.....</i>	<i>31</i>
<i>Figura 2. 9. Imagen de la ROI Dividida por bloques.....</i>	<i>32</i>
<i>Figura 3. 1. Imágenes de las bases de datos. a) CASIA. b) PolyU .....</i>	<i>39</i>
<i>Figura 3. 2. Estructura del sistema de identificación .....</i>	<i>40</i>
<i>Figura 3. 3 Software del sistema biométrico.....</i>	<i>41</i>
<i>Figura 3. 4. Diagrama de flujo del programa principal.....</i>	<i>41</i>
<i>Figura 3. 5 Diagrama de flujo de las funciones de las bases de datos.....</i>	<i>42</i>
<i>Figura 3. 6. Pasos para ubicar la ROI .....</i>	<i>43</i>
<i>Figura 3. 7. Pasos del preprocesamiento.....</i>	<i>45</i>
<i>Figura 3. 8. Puntos valles.....</i>	<i>45</i>

<i>Figura 3. 9. Rotación.....</i>	<i>46</i>
<i>Figura 3. 10 Configuraciones de los LBP's.....</i>	<i>49</i>
<i>Figura 3. 11 División de la imagen por bloques.....</i>	<i>50</i>
<i>Figura 3. 12 Conjuntos de vecinos y Radios.....</i>	<i>50</i>
<i>Figura 3. 13. Esquema de la clasificación.....</i>	<i>52</i>
<i>Figura 3. 14 Curvas de desempeño. a) Curva CMC. b) Curva ROC.....</i>	<i>55</i>
Figura 4. 1 Desempeño de los métodos umbral para CASIA.....	57
Figura 4. 2. Segmentación PolyU. a) Imagen binaria Otsu. b) Imagen original con el borde Otsu. c) Imagen binaria Huang. d) Imagen con el borde Huang..	58
Figura 4. 3 Desempeño de los métodos umbral para PolyU.....	58
Figura 4. 4 Imágenes ROI a) Método 1. b) Método 2.....	59
Figura 4. 5 Mapa conceptual de la metodología diferenciación método umbral y método ROI.....	60
Figura 4. 6. Región de interés. a) Isodata método ROI 3 CASIA. b) Isodata método ROI 4. CASIA c) Otsu método ROI 3 CASIA. d) Otsu método ROI 4 CASIA. a*) Huang método ROI 3 PolyU. b*) Huang método ROI 4 PolyU. c*) Otsu método ROI 3 PolyU. d*) Otsu método ROI 4 PolyU.....	61
Figura 4. 7. a) Umbral Huang el método ROI3 y ROI4. b) Umbral Otsu el método ROI3 y ROI4. c) Método ROI3 con umbral Huang y Otsu. d) Método ROI4 con umbral Huang y Otsu. e) Método ROI3 con umbral Otsu y ROI4 con Huang. f) Método ROI4 con umbral Otsu y ROI3 con Huang.....	62
Figura 4. 8 a) Imagen original. b) Imagen de la ROI. c) Histograma.....	65
Figura 4. 9 a) Imagen con disminución de brillo de 36 (no clasifica). b) Imagen con disminución de brillo de 35 (si clasifica). c) Imagen de la ROI (Figura a). d) Imagen de la ROI (Figura b). e) Histograma (Figura a).f) Histograma (Figura b). .....	66
Figura 4. 10. a) Imagen con incremento de brillo de 27 (no clasifica). b) Imagen con incremento de brillo de 26 (si clasifica). c) Imagen de la ROI (Figura a). d) Imagen de la ROI (Figura b). e) Histograma (Figura a).f) Histograma (Figura b). .....	68

Figura 4. 11 a) Imagen con disminución de contraste de (20 -210) (no clasifica). b) Imagen con disminución de contraste de (19 -200) (si clasifica). c) Imagen de la ROI (Figura a). d) Imagen de la ROI (Figura b). .....	69
Figura 4. 12 a) Imagen con incremento de contraste de 77 a 179 (no clasifica). b) Imagen con incremento de contraste de 102 a 179 (si clasifica). c) Imagen de la ROI (Figura a). d) Imagen de la ROI (Figura b). .....	70
Figura 4. 13. Desplazamiento de la ROI. a) desplazamiento en x de - 30. b) desplazamiento en x de +17. c) desplazamiento en y de -8. d) desplazamiento en y de +19. ....	71
Figura 4. 14 Desplazamientos diagonales de la ROI. a) Desplazamiento en x de +13 y en y de +13. b) Desplazamiento en x de +5 y en y de -5. c) Desplazamiento en x de -14 y en y de -14. d) Desplazamiento en x de -16 y en y de +16. ....	72
Figura 4. 15. LBP's de la ROI con desplazamientos en diagonal.....	72
Figura 4. 16. Sintonización del clasificador .....	73
Figura 4. 17. Curva CMC para la base de datos PolyU. a) Método 3, b) método 4 .....	75
Figura 4. 18. Curvas CMC para la base de datos CASIA a). Método 1, b) Método 2, c). Método 3, d) Método 4, e). Método 5. ....	78
Figura 4. 19. LBP's CASIA Método 5 .....	79
Figura 4. 20 CMC PolyU con y sin SMOTE. a) Método 3, b) método 4.....	81
Figura 4. 21 CMC CASIA con y sin SMOTE. a) Método 1, b) método 2, c) método 3, d) método 4, e) método 5. ....	81
Figura 4. 22 Mejores Curvas LBP's.....	83
Figura 4. 23. Curvas CMC con LBP 0 8 64 PolyU a) método 1. b) método 2... ..	84
Figura 4. 24 Curvas CMC con LBP 0 8 64. ....	85
Figura 4. 25 Clasificadores.....	88
Figura 4. 26 Mínimo y Máximo LBP PolyU. a) Método 3, b) Método 4.....	92
Figura 4. 27 Mínimo y Máximo LBP CASIA. a) Método 3, b) Método 4,.....	92
Figura 4. 28 CMC Métodos de la ROI .....	94
Figura 4. 29. Factores que afectan la ROI y la Clasificación.....	98

---

## ÍNDICE DE TABLAS

---

Tabla 3. 1 Métodos ROI. ....	48
Tabla 3. 2 Configuración de los LBP's .....	51
Tabla 4. 1 Resultados promedios de las medidas de comparación de ROI's para la base de datos CASIA. ....	63
Tabla 4. 2 Resultados promedios de las medidas de comparación de ROI's para la base de datos PolyU. ....	64
Tabla 4. 3 Área bajo la Curva CMC de sintonización .....	74
Tabla 4. 4 Área bajo la curva para la base de datos PolyU.....	75
Tabla 4. 5 Área bajo la curva para la base de datos CASIA.....	77
Tabla 4. 6 Porcentaje de acierto área bajo la curva CMC .....	82
Tabla 4. 7 Diferencias entre áreas CMC .....	85
Tabla 4. 8 Matriz de confusión. ....	86
Tabla 4. 9 Área CMC de los clasificadores .....	88
Tabla 4. 10 Clasificador lineal variando M.....	89
Tabla 4. 11 Clasificador lineal variando S .....	89
Tabla 4. 12 Clasificador lineal variando R .....	90
Tabla 4. 13 LBP Clasificador lineal PolyU .....	91
Tabla 4. 14 LBP Clasificador lineal CASIA .....	93
Tabla 4. 15 Diferencias entre los métodos ROI.....	95

---

## RESUMEN

---

Una de las mayores dificultades en el reconocimiento de patrones y en particular en sistemas biométricos basados en la palma de la mano, es obtener en el preprocesamiento un adecuado cálculo de la región de interés (ROI) ya que esta influye directamente en los resultados finales del sistema de identificación, teniendo en cuenta que estos sistemas son implementados en procesos delicados, donde el rendimiento se encuentra afectado directamente tanto por la selección de la técnica de clasificación, como por el tratamiento inicial de la base de datos y en definitiva lo que se pretende alcanzar es una tasa de error nula ya sea ante una verificación o una identificación de personas.

El proyecto presenta una metodología para la validación de la incidencia de la ROI en la identificación biométrica de personas mediante un sistema de reconocimiento de la palma de la mano, donde la extracción de características se realiza mediante la implementación de técnicas de procesamiento digital de imágenes orientadas al análisis de texturas en niveles de gris, en particular, Patrones binarios Locales. La validación de la robustez del sistema se realiza empleando técnicas convencionales de clasificación, previo estudio de la relevancia y efectividad de las características estimadas.

Para la implementación del software de identificación biométrica se diseñó un entorno gráfico en Matlab. Utilizando dos bases de datos públicas PolyU y CASIA, las cuales cuentan con 329 y 306 clases respectivamente, el número de individuos por clase oscila entre 10 y 20 y para contrarrestar los efectos de utilizar tan pocos individuos por clase con relación al número de clases, se consideró utilizar una técnica de balance de muestras (SMOTE) que demostró mejorar las respuestas del clasificador, para utilizar la técnica de sobremuestreo y las máquinas de soporte vectorial se empleó una función en el software R.

El software diseñado permite determinar la incidencia en la obtención de la ROI en un sistema biométrico de palma de la mano, con el fin de identificar los

niveles de error en la extracción de la información relevante de la imagen y verificar las variaciones del sistema de identificación, causadas por el cambio en los métodos para la obtención de dicha ROI.

Después de la realización de pruebas con métricas de similitud, se comprueba que las imágenes generadas con diferentes métodos de la ROI presentan variaciones.

Al evaluar el área bajo las curvas CMC, la mayor diferencia fue de un 3% entre el método 2 (Lin, C. Chuang, & Fan, 2005) y el método 5 (Shang & Li, 2009) de la base de datos de CASIA con tiempos de ejecución de 1113s y 1024s respectivamente. La menor diferencia presentada fue de 0.9% entre el métodos 3 y el método 4 de la base de datos de PolyU con tiempos de ejecución de 5103s y 6330s respectivamente.

También, se evaluaron 24 combinaciones de patrones binarios locales, para determinar las variaciones presentadas en las curvas CMC. Para la base de datos de Polyu en el método 3 se presentaron variaciones en el área bajo la curva desde 70.2231% hasta 85.2758%, además las variaciones en los tiempos de ejecución se encuentran entre 2403s y 6634s y para el método 4 se presentan variaciones en el área bajo la curva de 65.295% a 84.4542%. Según lo anterior las diferencias presentadas son del 15% para el método 3 y del 17% para el método 4, lo cual demuestra que los parámetros para el cálculo de los LBP's varían considerablemente los resultados de la clasificación.

El método de la ROI que presento mejor desempeño al utilizar el clasificador de máquinas de soporte vectorial fue el método 2 para la base de datos de CASIA con 91.6% de área bajo la curva CMC y el método 3 para la base de datos de PolyU con 85.3% de área bajo la curva CMC.

---

## ABSTRACT

---

One of the biggest problems in pattern recognition and in particular based on the preprocessing stage in palm biometrics system is to obtain a proper estimate of the region of interest (ROI), because this directly affects the final results of the system identification, given that these systems are deployed in sensitive processes, where performance is directly affected by the classification technique and the initial treatment of the database. Finally what is intended to be achieved is a zero error rate either for verification or identification of persons.

The project presents a methodology for validating the impact of ROI on biometric identification of persons through a palmprint recognition system, where feature extraction is done through the implementation of digital image processing techniques aimed to texture analysis of gray levels, in particular, local binary patterns. The validation of system robustness is performed using conventional classification techniques, after examining the relevance and effectiveness of features.

For the implementation of biometric identification software was designed a graphic interface in Matlab. using two public databases PolyU and CASIA, which have respectively 329 and 306 classes, the number of individuals per class ranges from 10 to 20 and to counteract the effects of using few individuals per class with the number of classes, it is considered to use a sample balance technique (smote) that showed improved responses of the classifier, the oversampling technique and support vector machines function was realized in R software.

The designed Software allows to calculate the impact on ROI regarding a biometric palmprint system, in order to identify the levels of error in extracting relevant information from the image and check the system for identifying variations caused by changes from palmprint extraction methods.

After testing the similarity metrics, we found that the images generated with different ROI methods have variations.

In assessing the area under the curves CMC, the largest difference was 3% in method 2 (Lin, C. Chuang, & Fan, 2005) and method 5 (Shang & Li, 2009) of the database CASIA with execution times of 1113s and 1024s respectively. The smallest difference was 0.9% lodged between Methods 3 and 4 the method of PolyU database with runtimes 5103s and 6330s, respectively.

Also, 24 local binary patterns combinations were evaluated, determining variations in the presented CMC curves. For polyU database in Method 3 showed variations in the area under the curve from 70.2231% to 85.2758%, and variations in the execution times are between 2403s and 6634s, and method 4 have variations in the area under the curve of 65.295% to 84.4542%. As submitted earlier differences are 15% for method 3 and 17% for method 4, which shows that the parameters for the calculation of the LBP's varies considerably the classification results.

The ROI method that presented better performance when using method 2 for the CASIA database was the support vector machine classifier with a 91.6% of area under the CMC curve and method 3 for the PolyU database with 85.3% of area under the CMC curve.

---

## 1. INTRODUCCIÓN

---

La biometría es el estudio de métodos para el reconocimiento automático de individuos basándose en la diferenciación de rasgos fisiológicos o de comportamiento. Dentro de las características físicas que se usan en la verificación y en la identificación de personas, se encuentran las huellas dactilares, la retina, el iris, los patrones faciales, las líneas de la mano o la geometría de la palma de la mano, la voz, los dedos, los nudillos, entre otros.

La identificación y la verificación biométrica comprenden tecnologías emergentes que pueden resolver problemas de seguridad restringiendo el acceso a determinadas zonas (laboratorios, salas de sistemas, centros de operación, bóvedas), controlando la asistencia de empleados o el ingreso a instalaciones (clubes deportivos y sociales, empresas del estado, universidades, colegios). También permite el desarrollo de aplicaciones de acceso a redes o datos de empresas de manera segura, compras online, control de pagos, autenticación de usuarios de servicios (IPS, clínicas, hospitales), autenticación de clientes (Bibliotecas, puntos de venta), autenticación de padres en guarderías o colegios entre otras. La mayoría de las investigaciones en biometría se han basado en huellas dactilares, en la retina, en el iris y en el rostro. El reconocimiento de la retina y el iris proporcionan información de muy alta precisión, el reconocimiento del rostro presenta poca fiabilidad por problemas de pose, iluminación, orientación y gesto; estos tres métodos requieren un alto costo computacional.

La principal ventaja que se tiene para la identificación utilizando la palma de la mano es que a diferencia de los sistemas de reconocimiento mencionados anteriormente, este requiere un menor costo computacional, lo cual lo hace más apropiado para la implementación en línea. Estos sistemas son de fácil ejecución, uso, mantenimiento y poseen una gran aceptación en vista de que las personas no se sienten incómodas para que se tomen muestras de la palma de la mano para ser analizadas.

La hipótesis del proyecto plantea que el método de estimación de la región de interés (ROI), influye en el desempeño de los sistemas de identificación biométrica de personas basados en patrones binarios locales de la palma de la mano. El análisis de esta influencia permitirá desarrollar etapas de preprocesamiento de la imagen con el fin de mejorar el desempeño de estos sistemas.

### **Planteamiento del Problema**

Una de las mayores dificultades en los sistemas de reconocimiento de patrones y en particular en sistemas biométricos basados en el reconocimiento por la palma de la mano es la confiabilidad requerida y la variabilidad encontrada en la literatura a la hora de calcular la Región de Interés (ROI, *Region of Interest*). En los sistemas de seguridad, el reconocimiento automático de personas puede generar consecuencias delicadas y de alto riesgo si no se cuenta con un sistema biométrico adecuado, comenzando por un buen preprocesamiento, debido a que es en éste, donde se puede perder información relevante que afecta la caracterización. Así se cuente con una buena técnica de caracterización y un adecuado clasificador, si desde el comienzo hay problemas en el tratamiento inicial de las imágenes, los resultados se evidencian en la salida final del sistema.

La mayoría de los estudios (Han, Cheng, & Fan, 2002), (Han, Cheng, Lin, & Fan, 2003) (Han C. C., 2004) (Lin & Fan, 2004) (Lin, C. Chuang, & Fan, 2005) (Konga, Lua, Wang, Qi, & Li, 2008) (Chen, Moon, Wong, & Su, 2010) (Toro & Correa, 2009) (Kong & Zhang, 2002) (Zhang, Kong, You, & Wong, 2003) y (Zhang, Lu, Li, Zhang, & Luo, 2009) se han enfocado en encontrar una técnica de caracterización, pretendiendo la eliminación del error en la clasificación de patrones para identificación o autenticación, sin comparar técnicas de segmentación o variar la ubicación de la ROI. En algunos experimentos realizados por el grupo de Electrónica de Potencia Automática y Robótica (GEPAR) en conjunto con el Grupo de Procesado Digital de Señales (GPDS) se demostró que la ROI afecta el reconocimiento de un sistema biométrico

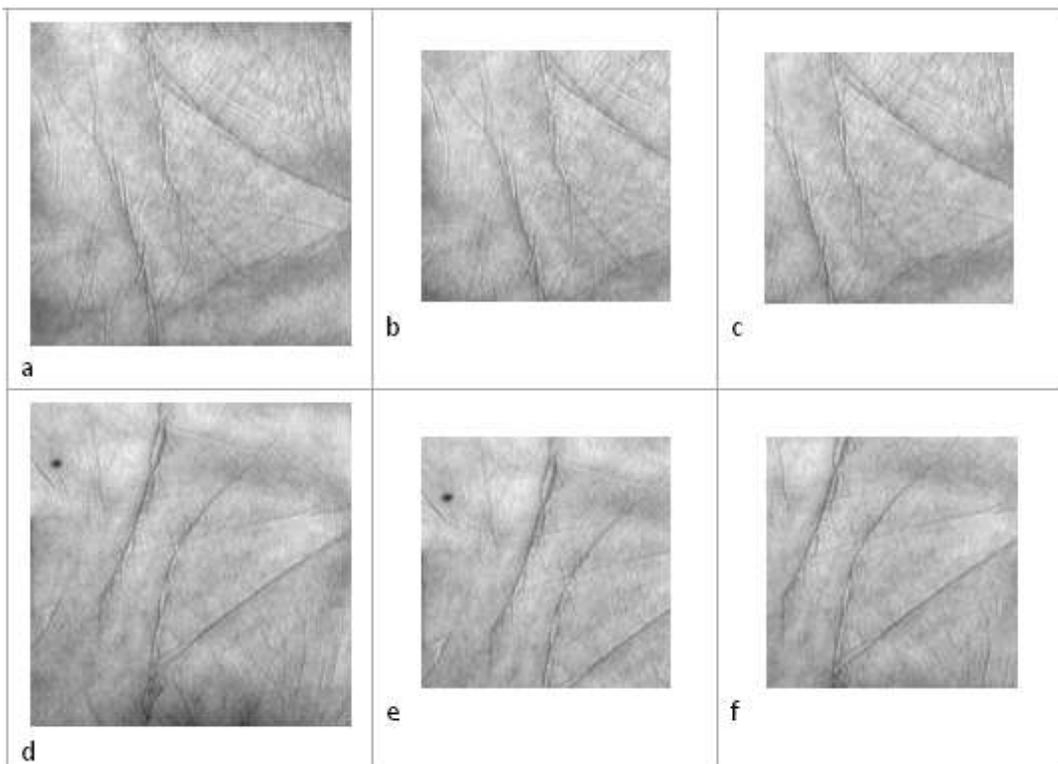
caracterizado mediante patrones binarios locales; esto se afirmó porque al cambiar las bases de datos ingresadas en el sistema, los resultados se alteraron. Se pretende dar continuidad a la idea original y realizar un estudio de diferentes métodos de extracción de la región de interés manteniendo la técnica de caracterización LBP y el clasificador SVM fijos, con el fin de evaluar el desempeño del sistema de identificación propuesto inicialmente.

La caracterización por LBP en imágenes de palma de la mano ha sido utilizada por (Wang, Gong, Zhang, Li, & Zhuang, 2006), (Wang, Ruan, & Pan, 2007), (Vargas, Travieso, Alonso, & Ferrer, 2009), (Xianji Wang, 2006), (Yanxia Wang, 2007) entre otros, debido a que es considerado como un poderoso método de descripción de texturas que es invariante a la escala de grises y a la rotación, ya que la textura es uno de los rasgos que se observan más claramente en las imágenes de baja resolución de la palma de la mano y muy discriminativo para la identificación de esta.

Así, en este proyecto se desarrolla una metodología de evaluación de robustez del sistema donde se evidencia como afecta el cambio de técnica para la obtención de la ROI, con el fin de desarrollar un sistema de detección automática de personas extrayendo características de imágenes de la palma de la mano, mediante la aplicación de técnicas para el análisis de la distribución de niveles de gris, relacionando cada píxel y calculando variables estadísticas que describan propiedades como variabilidad, contraste y valor medio. Se pretende entonces, determinar la afectación del cálculo de la ROI en la robustez del sistema biométrico basada en las texturas de la palma de la mano para obtener una adecuada identificación.

Las imágenes para desarrollo de la tesis son tomadas de dos bases de datos públicas PolyU y CASIA, no se pretende construir bases de datos propias con el fin de poder comparar a futuro con trabajos reportados en la literatura y además la adquisición de las imágenes sale de los objetivos propuestos en el trabajo.

Como ilustración del problema de la incidencia de la región de interés en un sistema biométrico y para visualizar la diferencia existente al utilizar diferentes ROI's con ubicación de centro aleatorio, en la Figura 1 se muestran tres cuadrados diferentes, que representan la ROI de dos imágenes pertenecientes a dos individuos diferentes. Las Figuras a, b y c pertenecen al individuo uno y la d, e y f pertenecen al individuo dos. Siendo a y d un cuadrado de 180 X 180 pixeles, b y e un cuadrado de 140 X 140 pixeles, y la Figura c y f se tomaron de un cuadrado 140 X 140 pixeles, pero el centro de la ROI es diferente al del cuadrado anterior.



*Figura 1. Muestras de diferentes ROI para dos individuos. a) Imagen del individuo 1, ROI 1. b) Imagen del individuo 1, ROI 2. c) Imagen del individuo 1, ROI 3. d) Imagen del individuo 2, ROI 1. e) Imagen del individuo 2, ROI 2. f) Imagen del individuo 2, ROI 3.*

En la literatura anterior los sistemas biométricos de palma de la mano, centran la problemática en la técnica de caracterización utilizada, pero no tienen en cuenta que al variar la región de interés para extraer la información contenida

en esta, cada autor presenta una ROI diferente por lo que al evaluar la técnica de caracterización utilizada sólo sería validado bajo los parámetros dados por esa región de interés en particular.

## **Objetivos del trabajo**

### **Objetivo general:**

Analizar la incidencia del cálculo de la ROI sobre un sistema de reconocimiento de la palma de la mano mediante patrones binarios locales para imágenes en niveles de gris orientado a la identificación biométrica de personas.

### **Objetivos específicos:**

1. Analizar seis métodos encontrados en la literatura para la estimación de la ROI de la palma de la mano.
2. Obtener un espacio de representación mediante el uso de patrones locales binarios como técnica de extracción/selección de características correspondiente a los diferentes parámetros de la palma de la mano orientados al reconocimiento de personas.
3. Realizar un análisis comparativo basado en la validación de las técnicas implementadas mediante un clasificador de máquinas de soporte vectorial, con el fin de determinar el nivel de influencia al generar variaciones en los valores EER que genera la estimación de la ROI.

Con el fin de darle cumplimiento a los objetivos propuestos en esta tesis, se encuentra dividida en tres capítulos el primero el marco teórico y el estado del arte, en el segundo se explica la metodología propuesta y el software del sistema de identificación biométrica y en el capítulo 3 donde se presentan los experimentos y resultados del trabajo y finalmente en el capítulo 4 se presentan las conclusiones.

---

## 2. MARCO TEÓRICO Y ESTADO DEL ARTE

---

### 2.1. INTRODUCCIÓN

En este capítulo se presentan las técnicas comúnmente utilizadas en el preprocesamiento de imágenes, enfocándose básicamente en las técnicas de umbralización y de ubicación de la región de interés en imágenes de palma de la mano, ya que el análisis principal de este trabajo se fundamenta en la confrontación de dichas técnicas. Además se definen los aspectos que conducen a la caracterización, en la cual se describe como se generan los Patrones Binarios Locales. Finalmente se realiza una breve descripción de las máquinas de soporte vectorial.

En la Figura 2.1 se puede observar que una de las aplicaciones del reconocimiento de patrones es la biometría, definida entonces como el estudio de los métodos para el reconocimiento automático de personas, basada en las características fisiológicas propias de cada individuo. Entre las características físicas utilizadas en la verificación e identificación se encuentran: el reconocimiento de las huellas dactilares, la retina, el iris, la voz, y finalmente el reconocimiento de personas a través de la palma de la mano, ya sea por geometría de la mano, las venas de la mano o las líneas de la palma de la mano.

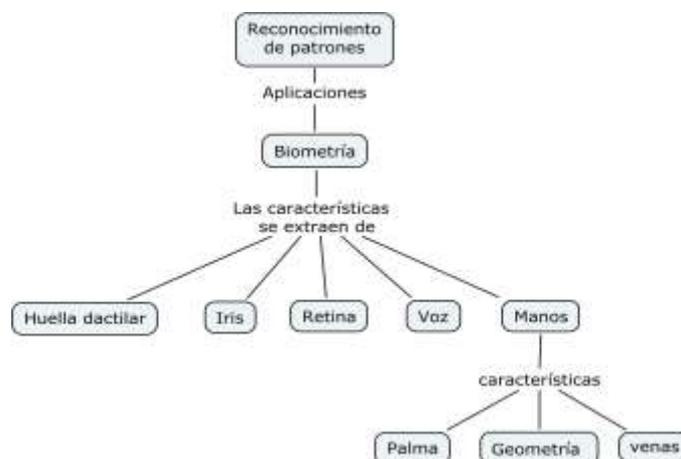


Figura 2. 1. Mapa conceptual de sistemas biométricos

Para un sistema de identificación biométrico basado en la palma de la mano lo primero que se requiere es capturar una imagen o fotografía a través de un dispositivo ya sea un escáner o cámara, es decir, el punto de partida es una imagen digital, la cual está representada por uno o más arreglos bidimensionales  $f(x,y)$  donde cada elemento o pixel se encuentra ubicado en una posición fila(x), columna(y) que representan un punto de la imagen, indicando el nivel de intensidad de luz que este contiene. “Matemáticamente un sistema para procesar imágenes se representa como:  $g(x,y)=T[f(x,y)]$ .” (Elizondo, 2002)

## **2.2. TRATAMIENTO DE IMÁGENES**

En la Figura 2.2 se aprecia las etapas en las que, de forma general, se divide el proceso de reconocimiento de patrones de sistemas biométricos. De acuerdo con la literatura reciente (Toro & Correa, 2009) (Chen, Moon, Wong, & Su, 2010) (Shang & Li, 2009), en la etapa de preprocesamiento de los sistemas biométricos de identificación por medio de la palma de la mano, se ven comprometidos los pasos de umbralización, detección de borde, localización de puntos máximos y mínimos de la imagen de la mano, para finalmente obtener la región donde se encuentra la información de interés. En cuanto a la etapa de caracterización se utilizará el método de patrones binarios locales, el cual es una técnica de análisis de texturas y finalmente para la etapa de clasificación se emplearán las máquinas de soporte vectorial para la identificación del individuo.



Figura 2. 2. Etapas del sistema biométrico de palma de la mano

Aunque el proyecto se centra en la etapa de preprocesamiento que corresponde a la ubicación de la ROI. Se explican en detalle cada uno de los pasos contenidos en esta etapa, con el fin de conceptualizar claramente el proceso.

Para analizar y comparar las imágenes generadas mediante el uso de las dos técnicas de segmentación y los dos métodos de ubicación de la ROI se utilizan métricas como la correlación, el error medio cuadrático, la relación de uniformidad de la imagen, la información mutua y el área común.

## 2.3. MÉTRICAS DE COMPARACIÓN DE IMÁGENES

### 2.3.1 Coeficiente de Correlación

La Correlación describe el grado de dependencia lineal que existe entre las imágenes. El coeficiente de correlación oscila entre  $-1$  y  $+1$ , encontrándose en medio el valor  $0$  que indica que no existe asociación lineal entre las dos imágenes en estudio, esta métrica está definida por (2.1)

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{(\sum_m \sum_n (A_{mn} - \bar{A})^2)(\sum_m \sum_n (B_{mn} - \bar{B})^2)}} \quad (2.1)$$

donde  $A$  y  $B$  representan las imágenes de la ROI que se comparan,  $\bar{A}$  y  $\bar{B}$  son las medias de las imágenes,  $n$  es el número de filas de la imagen y  $m$  es el número de columnas.

### 2.3.2 Error cuadrático medio

El error cuadrático medio (MSE) es utilizado usualmente como criterio objetivo de calidad para encontrar la diferencia entre una imagen original y una procesada o reconstruida. Cuando las imágenes tienen gran similitud el error cuadrático medio es pequeño. Se calcula con la ecuación (2.2)

$$MSE = \frac{1}{m \cdot n} \sum_m \sum_n (A_{mn} - B_{mn})^2 \quad (2.2)$$

donde  $m$  es el número de filas,  $n$  es el número de columnas.

### 2.3.3 Información mutua (MI)

Cantidad que mide la dependencia mutua de dos variables, para el caso particular dependencia entre las imágenes (Mark Holden, Voxel Similarity Measures for 3-D Serial MR Brain Image Registration, 2000).

La información mutua (2.3) es la cantidad por la cual la incertidumbre de  $B$  disminuye cuando  $A$  es dada, la cantidad de información de  $A$  que contiene a  $B$  o viceversa.

$$MI = \sum_{(A_i, B_i)} P(A_i, B_i) \log_2 \left( \frac{P(A_i, B_i)}{P(A_i)P(B_i)} \right) \quad (2.3)$$

Donde  $P(A_i)$  es la probabilidad de la imagen  $A$ ,  $P(B_i)$  la probabilidad de la imagen  $B$  y  $P(A_i, B_i)$  la probabilidad conjunta entre las distribuciones de las dos imágenes.

### 2.3.4 Relación de uniformidad de la imagen (RIU)

También conocida como relación de variación de intensidad. Para cada estimación de transformación registrada, se calcula la relación  $R$  de la imagen para dividir cada pixel en  $A$  por cada pixel en  $B$ ., la uniformidad de  $R$  se determina para calcular la desviación estándar de  $R$  normalizada. El algoritmo iterativo determina la transformación que minimiza la desviación estándar normalizada por ejemplo minimizando la uniformidad. (Sonka, 2004) (Mark Holden, Voxel Similarity Measures for 3-D Serial MR Brain Image Registration, 2000).

$$RIU = \frac{1}{\bar{R}} * \frac{1}{mn} \sum_m \sum_n \left( \bar{R} - \frac{B_{mn}}{A_{mn}} \right)^2 \quad \bar{R} = \frac{1}{mn} \sum_m \sum_n \left( \frac{B_{mn}}{A_{mn}} \right) \quad (2.4)$$

### 2.3.5 Área común (CA)

Una medida propuesta en este documento para relacionar la cantidad de pixeles en común que tienen las dos imágenes. (2.5)

$$\frac{A(x, y) \cap B(x, y)}{A(x, y)} \quad (2.5)$$

donde  $A$  y  $B$  representan las dos imágenes y  $(x, y)$  la ubicación de los pixeles.

## 2.4. UMBRALIZACIÓN

En el tratamiento de imágenes de la palma de la mano, se comienza por la imagen en escala de grises. El primer paso es binarizar esta imagen. El proceso de binarización es una técnica de segmentación que se emplea cuando existe una gran diferencia entre el objeto de análisis y el fondo de la imagen, evaluando la similitud y las diferencias entre los pixeles en escalas de grises, consiste entonces, en establecer un umbral óptimo que permita la mejor separación del objeto. El proceso de binarización finaliza comparando las intensidades con el umbral seleccionado, si es mayor la intensidad del pixel que la del umbral se le asigna blanco y de lo contrario se le asigna negro.

*Categorías de umbralización:* Cuando se detecta el umbral para generar la imagen binaria pueden presentarse problemas ocasionados por sombras

generadas por la ubicación del objeto con respecto a la fuente de iluminación, ruido en la imagen, rugosidades en los bordes, eliminación de áreas por zonas de baja iluminación. Todos estos problemas causan cambios en los bordes lo que ocasiona modificaciones en los puntos de ubicación de la ROI, que posiblemente alteren los resultados finales en un sistema de clasificación.

Existen diversas técnicas para obtener un umbral que están agrupadas en diferentes categorías basadas en: histograma, agrupación, entropía, atributos de los objetos, probabilidades de distribución y correlación, y métodos locales adaptativos (Sezgin, 2004).

Una de las categorías son los basados en histogramas, donde los picos, los valles y las curvas son analizadas mediante histogramas. (A Rosenfeld, 1983), (Sezan, 1985), (Ramesh, Yoo, & Sethi, 1995). Otra de las categorías son las basadas en grupos (cluster) donde los niveles de grises son agrupados en dos partes el fondo y el primer plano del objeto (Ridler & Calvard, 1978), (Lloyd, 1985), (Jawahar, Biswas, & Ray, 1997). También se encuentran grupos basados en entropía, que cruzan la entropía (variabilidad) entre la imagen original y la imagen binarizada (Li & Lee, 1993) (Li & Tam, An iterative algorithm for minimum cross-entropy thresholding, 1998), (Shanbag, 1994). Además, los basados en atributos del objeto, que buscan una medida de similitud entre el nivel de grises y la imagen binarizada (Tsai, 1985), (Leung & Lam, 1998). El método de distribución espacial que utiliza la mayor probabilidad de distribución y correlación (Abutaleb, 1989). El método locales adaptativos que como su palabra lo indica, adaptan el valor del umbral de cada píxel a las características de la imagen local. (White & Rohrer, 1983).

En la literatura se reportan diversos trabajos donde se comparan técnicas de umbralización mas no en biometría como es el caso de (Madrid, 1999) donde se probaron tres métodos de umbralización en imágenes de alambre de cobre: segmentación por umbralización del histograma (Sahoo, Soltani, & Wong, 1988), (Otsu 1979) y (Kapur, Sahoo, & Wong, 1985) obteniendo fallas con los tres algoritmos en las tres imágenes de prueba, Algoritmos estadísticos de

segundo orden (Abutaleb, 1989), (Brink, 1992) y (Pal N. R., 1991) presentando fallas y aislando la zonas donde se produce reflexión espectacular de la luz y último se presentan métodos basados en texturas como (Palmer P.L., 1995), (Laws, 1980) y (Jain A., 1991).

En (Rodríguez, 2005) se presenta la comparación de umbrales obtenidos con Otsu, Sharon y el método propuesto por estos aplicado en imágenes de vasos sanguíneos obteniendo los mejores resultados con el método propuesto, seguido del de Sharon y finalmente el de Otsu ya que este introduce mayor ruido. Como estos se encuentran muchos más ejemplos donde las técnicas de selección de umbral varían su eficiencia dependiendo de factores como la luminosidad y el ruido, es difícil establecer que método es mejor que otro para todas las aplicaciones por lo tanto es necesario obtener resultados experimentales en con las imágenes a tratar para posteriormente lograr mejores resultados con el sistema de identificación biométrica.

A continuación se describen los métodos de umbral que se han utilizado.

#### **2.4.1 Método Otsu**

Dentro de las técnicas de umbralización más utilizadas en la literatura se encuentra el método OTSU (Suárez Ruiz F.A, 2007), se encuentra clasificado dentro de los métodos de agrupamiento y selecciona el máximo valor umbral de la varianza entre clases del histograma.

El algoritmo consiste en buscar automáticamente un umbral global, para esto recorre todo el rango de niveles de grises tomando para cada valor umbral desde 0 a 255 y se selecciona el valor de umbral que genere una menor varianza ponderada, la varianza ponderada está dada por (2.6) (Arámbula, 2008)

$$\sigma_p^2 = P_f * \sigma_f^2 + P_o * \sigma_o^2 \quad (2.6)$$

donde  $P_f$  la probabilidad del fondo y  $P_o$  del objeto, se define como (2.7)

$$P_f = \sum_{i=0}^T P_i \quad P_o = \sum_{i=T+1}^{L-1} P_i \quad (2.7)$$

donde  $P_i$  es la probabilidad de intensidad  $i$  en la imagen. Las medias del objeto y el fondo se definen en (2.8) y sus varianzas en (2.9).

$$\mu_f = \frac{1}{P_f} \sum_{i=0}^T i * P_i \quad \mu_o = \frac{1}{P_o} \sum_{i=T+1}^{L-1} i * P_i \quad (2.8)$$

$$\sigma_f^2 = \frac{1}{P_f} \sum_{i=0}^T (i - \mu_f)^2 * P_i \quad \sigma_o^2 = \frac{1}{P_o} \sum_{i=T+1}^{L-1} (i - \mu_o)^2 * P_i \quad (2.9)$$

donde  $T$  es el valor del umbral y  $L$  es la cantidad de divisiones del histograma.

#### 2.4.2 Método de Huang

Es una técnica basada en lógica difusa (*Huang L-K. y M-J. J. Wang, 1995*). Se basa en la minimización de medidas difusas para una imagen de entrada. La función de pertenencia en el método de umbralización se utiliza para indicar la relación entre un pixel y su región de pertenencia (el objeto y el fondo). Dado un valor de umbral, la función de membresía de un pixel es definida por la diferencia absoluta entre el nivel de gris y el promedio del nivel de gris de la región de pertenencia. Cuanto mayor sea la diferencia absoluta, menor será la pertenencia. La función de pertenencia que asigna un valor de probabilidad a un pixel está dada por (2.10) (2.11)

$$\xi_x(x) = \left\{ \begin{array}{ll} \frac{1}{1 + \frac{|x - \xi_f|}{C}} & Si \ x < T \\ \frac{1}{1 + \frac{|x - \xi_o|}{C}} & Si \ x \geq T \end{array} \right\}$$

(2.10)

$$\xi_f = \frac{\sum_{g=0}^T i * h(i)}{\sum_{i=0}^T h(i)} \quad \xi_o = \frac{\sum_{i=T+1}^{L-1} i * h(i)}{\sum_{i=T+1}^{L-1} h(i)} \quad (2.11)$$

donde  $\xi_x(x)$  es la función de membresía del conjunto difuso  $x$ ,  $C$  es el contraste de la imagen,  $h(i)$  denota el número de ocurrencias del nivel  $i$  en la imagen,  $T$  el valor umbral,  $\xi_f$  el promedio de niveles de gris en el fondo y  $\xi_o$  en el objeto.

La estimación de similitud se hace seleccionando el valor de  $T$  que minimice  $E(t)$

$$E(t) = \frac{1}{n * m} \sum_{i=0}^{L-1} H_f(\xi_x(i))h(i) \quad H_f = - \sum_{i=0}^{T-1} h(i) \log_2(h(i)) \quad (2.12)$$

donde  $n$  y  $m$  representan las dimensiones de la imagen,  $H_f$  representa la entropía del fondo.

### 2.4.3 Método Isodata

Es una técnica iterativa que se utiliza para la obtención del umbral correcto (Ridler, 1978). El histograma de la imagen se segmenta en dos partes utilizando un umbral inicial. El valor del umbral inicial corresponde a la mitad del máximo valor de intensidad.

A continuación se calcula la media de cada segmento del histograma,  $m_1$ ,  $m_2$ . Utilizando esos valores se calcula un nuevo valor de umbral mediante la fórmula:

$$\alpha = (m_1 + m_2)/2 \quad (2.13)$$

El proceso continua hasta que en dos pasos consecutivos el valor umbral calculado no cambie. La ecuación genérica que calcula el umbral utilizando el histograma mediante este método es

$$T_k = \frac{\sum_{i=0}^{T_{k-1}} i * h(i)}{2 \sum_{i=0}^{T_{k-1}} h(i)} + \frac{\sum_{i=T_{k-1}+1}^N j * h(i)}{2 \sum_{i=T_{k-1}+1}^N h(i)} \quad (2.14)$$

donde  $T_k$  es el valor del umbral en la iteración  $k$ ,  $h(i)$  denota el número de ocurrencias del nivel  $i$  en la imagen y  $N$  el número máximo en el histograma.

## 2.5. DETECCIÓN DE BORDE

En la detección de borde o de contorno de una imagen se pretende resaltar el mayor cambio de intensidad producto de la diferencia entre el objeto y el fondo de la imagen, para obtener estos contornos se utiliza el gradiente, es decir, la primera derivada o se emplea el Laplaciano, es decir, la segunda derivada. El gradiente se basa en el cálculo de diferencias entre pixeles vecinos donde se buscan grandes picos. La magnitud del gradiente detecta la presencia del borde clasificando como puntos de borde los puntos en los cuales la derivada sea mayor a un umbral establecido. Algunos de los métodos más conocidos para la detección de borde son: Roberts, Prewitt, Sobel e Isotrópico (Kunzmann, 2005).

Entre los mayores problemas se encuentra la presencia de ruido, al seleccionar el umbral se debe tener en cuenta el compromiso entre la pérdida del borde y la eliminación del ruido. El filtro Laplaciano o de refinamiento de bordes se usa para amplificar y aislar los borde de una imagen, pero elimina la información de baja frecuencia, este operador es invariante a la rotación y la dirección (Kunzmann, 2005). El laplaciano representa la derivada de la función en todas las direcciones de la intensidad, presenta cruce por cero detectando si un punto del borde está del lado claro u oscuro de este, entre sus aspectos negativos, es excesivamente sensible al ruido y genera doble borde y cruces por cero. (Elizondo, 2002), (Universidad Nacional del Litoral, 2009).

De la imagen binaria se encuentra el contorno de la forma de la mano, con un algoritmo de detección de borde. Algunos de los artículos que coinciden en

este paso son (Han, Cheng, & Fan, 2002), (Lin & Fan, 2004), (Lin, C. Chuang, & Fan, 2005), (Han, Cheng, Lin, & Fan, 2003), (Savic & Pavešić, 2007), (Shang & Li, 2009), (Kong & Zhang, 2002), (Zhang, Kong, You, & Wong, 2003), (Chen, Moon, Wong, & Su, 2010). Otros autores como (Michael, Connie, & Teoh, 2008) no utilizan detección de borde, debido a que la misma imagen binaria propone un nuevo método (*competitive hand valley detection (CHVD)*) para encontrar los valles entre los dedos.

## 2.6. LOCALIZACIÓN DE PUNTOS

Lo que se pretende al obtener las coordenadas de los píxeles del borde, es encontrar los mínimos donde comienzan los dedos, es decir los cuatro valles y los máximos que son los cinco picos de los dedos; cada autor utiliza algunos de estos puntos según lo requiera la técnica, así, en (Han, Cheng, & Fan, 2002), (Han, Cheng, Lin, & Fan, 2003) y (Han C. C., 2004) utilizan segmentación basada en wavelet para localizar los puntos mínimos y máximos de la forma de la mano. Las coordenadas de los píxeles del borde son transformadas en el perfil de curvatura (Figura 2.3b), este perfil se convierte en señales de multiresolución de subbandas de baja y alta frecuencia (Figura 2.3c). De otra manera, en (Lin & Fan, 2004) antes de la utilizar wavelet, localizan el punto medio de la línea de intersección formada por la muñeca para calcular la distancia euclídea y sobre el diagrama de distribución de distancias (Figura 2.4a), se aplica transformada wavelet para la localización de los puntos. En (Lin, C. Chuang, & Fan, 2005) y (Konga, Lua, Wang, Qi, & Li, 2008), a diferencia de la anterior, de la distribución de distancias se ubican directamente los máximos y mínimos locales sin utilizar la transformada wavelet (Figura 2.4a). En (Chen, Moon, Wong, & Su, 2010) utilizan un algoritmo de curvatura máxima con las coordenadas de los píxeles del borde se encuentran los puntos donde existe mayor curvatura localizando entonces dos puntos valles como se muestra en la Figura 2.5. (Toro & Correa, 2009) con los puntos del borde construyen un diagrama de distribución para la localización de los puntos. (Kong & Zhang, 2002), (Zhang, Kong, You, & Wong, 2003) y (Zhang, Lu, Li, Zhang, & Luo, 2009) calculan el centro de gravedad de los espacios entre los

dedos y trazando una línea que pasa por este punto, localiza los valles del borde de la curvatura de la mano (Figura 2.6a).

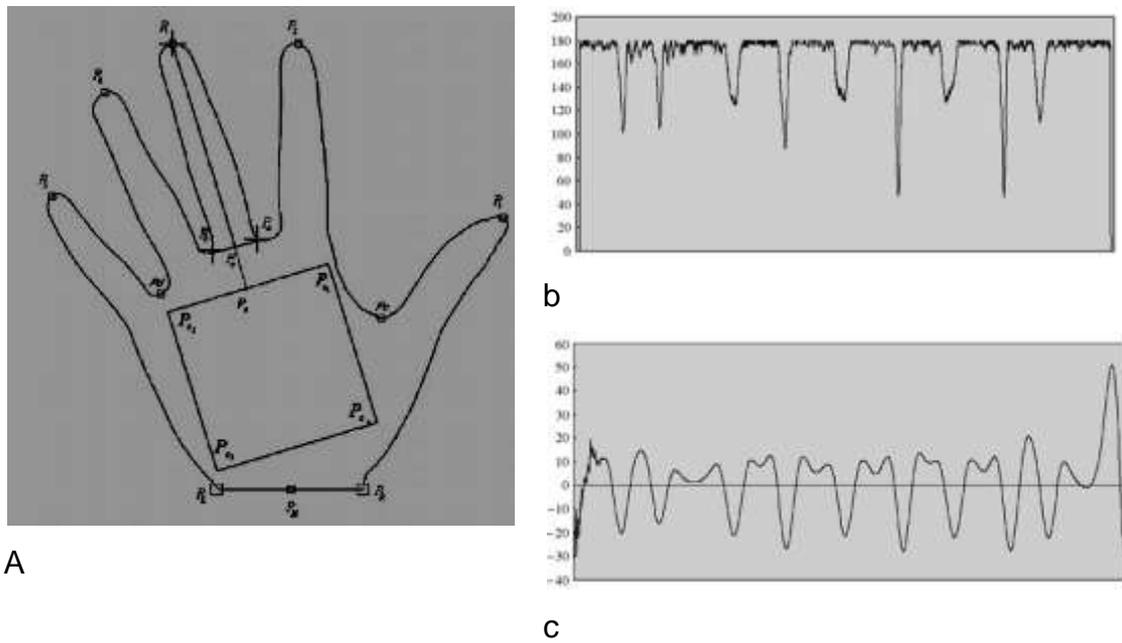


Figura 2. 3. Ubicación de mínimos y máximos (Han, Cheng, Lin, & Fan, 2003).  
 a) Perfil de curvatura de la forma de la mano. b) Perfil transformado en subbanda de alta frecuencia

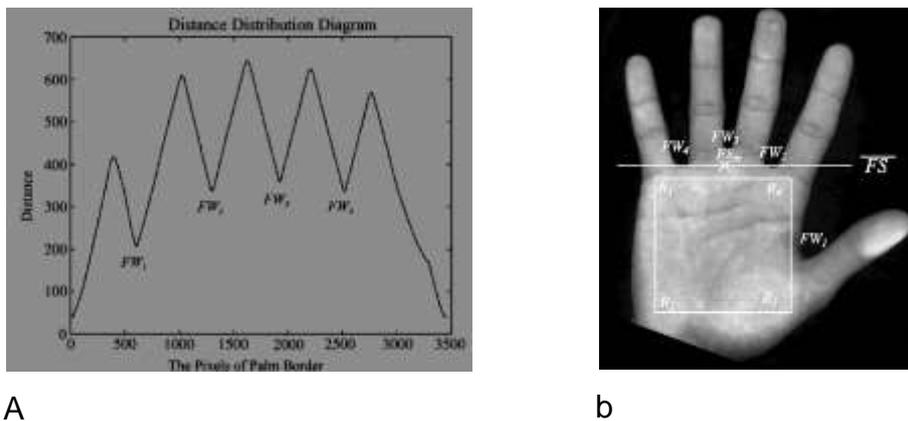


Figura 2. 4. Ubicación de mínimos y máximos (Lin, C. Chuang, & Fan, 2005).  
 a) Diagrama de distribución de distancias del borde de la palma. Construido con la distancia euclídea entre el punto medio de la muñeca y los pixeles del borde de la palma.



Figura 2. 5. Ubicación de mínimos y máximos (Chen, Moon, Wong, & Su, 2010)  
 a) Base de datos Poly U. b) Base de datos CANSIA.

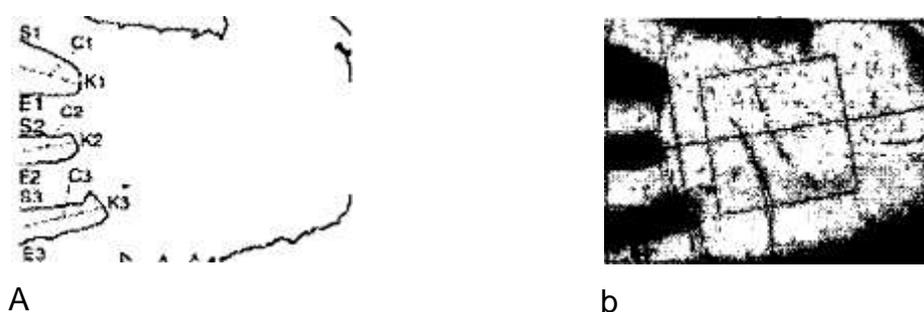


Figura 2. 6. Ubicación de mínimos y máximos (Kong & Zhang, 2002). a)  
 Detección de puntos. b) Ubicación de la ROI.

## 2.7. UBICACIÓN DE LA ROI

El procedimiento de ubicación de la región de interés, representada geoméricamente en un cuadrado, será determinada con cada uno de los procedimientos mencionados con anterioridad, así como en (Han, Cheng, & Fan, 2002) y (Han, Cheng, Lin, & Fan, 2003), como se muestra en la Figura 2.7a el punto medio,  $Q$ , del lado superior del cuadrado es aquel punto sobre la mediatriz del segmento  $V_1V_2$  tal que  $OQ$  es igual a  $V_1V_2$ , donde  $O$  es el punto medio de  $V_1V_2$ . En (Lin, C. Chuang, & Fan, 2005), (Figura 2.7b), el punto medio,  $Q$ , del lado superior del cuadrado se toma sobre la recta perpendicular al segmento  $V_1V_3$  que contiene a  $V_2$  y de tal forma que  $Q$  y  $V_2$  sean equidistantes respecto a  $V_1V_3$ . Algo parecido sucede en (Toro & Correa, 2009), (Figura 2.7c), donde el punto medio,  $Q$ , del lado superior del cuadrado es aquel punto sobre la mediatriz del segmento  $V_1V_3$  tal que  $OQ$  es igual a  $V_1V_3/2$ , donde  $O$  es el punto

medio de  $V_1V_3$ . En (Chen, Moon, Wong, & Su, 2010), (Kong & Zhang, 2002), (Zhang, Kong, You, & Wong, 2003), (Yue, Zuo, Zhang, & Wang, 2009) y (Wang, Yau, Suwandy, & Sung, 2008), (Figura 2.7d), el punto central de la ROI se ubica sobre la mediatriz del segmento  $V_1V_3$  a una distancia predefinida. En (Shang & Li, 2009), (Figura 2.7e), el centro de la ROI es el punto medio del segmento formado por  $V_2$  y el punto medio del segmento trazado sobre la muñeca. En (Konga, Lua, Wang, Qi, & Li, 2008) y (Michael, Connie, & Teoh, 2008), (Figura 2.7f), se prolongan los segmentos  $V_2V_3$  y  $V_2V_1$  hasta encontrar, el primero, el borde externo del dedo meñique en  $V_4$  y, el segundo, el borde externo del dedo índice en  $V_0$ . El lado superior del cuadrado es el segmento  $F_1F_4$ , siendo  $F_1$  y  $F_4$  los puntos medios de  $V_0V_1$  y  $V_3V_4$ , respectivamente.

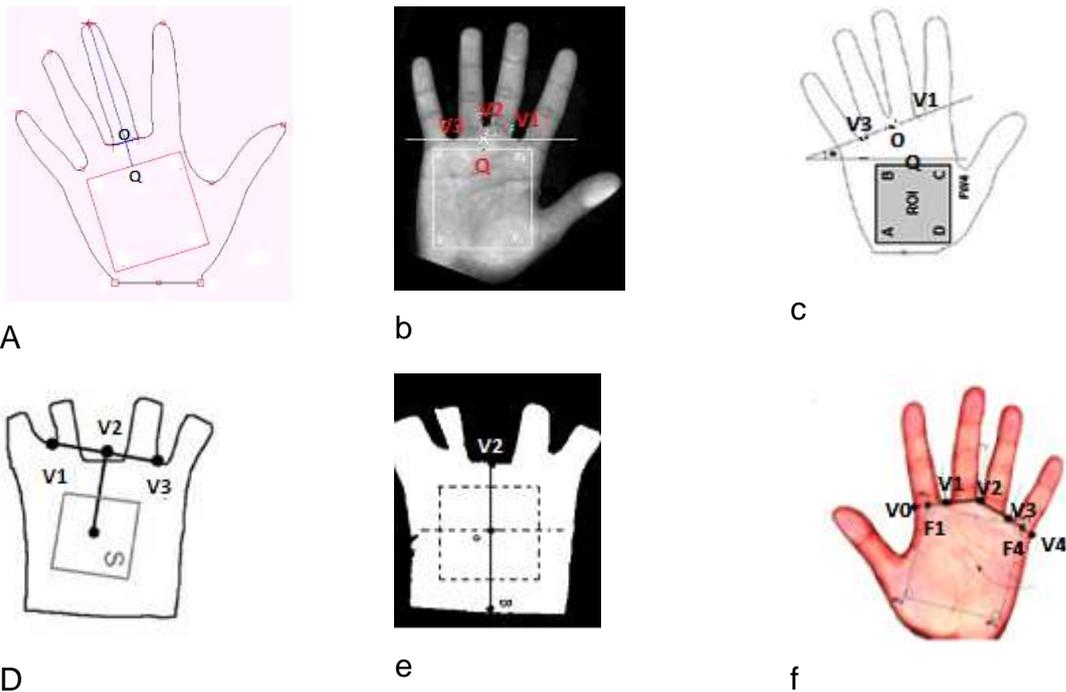


Figura 2. 7. Ubicación de la ROI.

Los métodos anteriormente descritos son los implementados y evaluados en el desarrollo de este trabajo, por facilidad en la redacción del documento, cada método será llamado como método 1, 2, 3, 4, 5 y 6 de manera consecutiva como se enuncian los trabajos de cada autor en el párrafo anterior, es decir la

Figura 2.7a corresponde al método 1, así sucesivamente, hasta la Figura 2.7f que corresponde al método 6.

## 2.8. CARACTERIZACIÓN

Para la caracterización se utiliza la técnica de análisis de texturas en imágenes, basada en patrones binarios locales, en la cual se entiende por textura a la variación de los datos a escalas menores que la escala de interés. La textura es importante si se requiere conocer el material con el cual está hecho el objeto o si se necesita extraer el borde de una imagen (Petrou & Sevilla, 2006). La textura es el resultado de la variación de la forma o del albedo de la superficie de la imagen. La forma es determinada por la rugosidad, la uniformidad de color y la interacción de las sombras y la iluminación. El albedo de una superficie es una función que caracteriza el material del que está hecha la superficie. Está dado por la fracción de luz incidente que el material refleja en cada longitud de onda, esto es apreciado en el cambio de color que genera la variación en el brillo de una imagen en escalas más pequeñas. El procesamiento de imágenes trata de resolver problemas concernientes a la textura como son: clasificación, segmentación y detección de defectos. (Petrou & Sevilla, 2006)

Las implementaciones computacionales de reconocimiento de palma de la mano, generalmente están basadas en herramientas de reconocimiento de patrones. En este sentido, es usual utilizar una técnica de caracterización basada en patrones binarios locales. Estos son descriptores de texturas usados en varias aplicaciones, debido a que son invariantes a la iluminación y a la rotación y también son adecuados para ser utilizados en sistemas de reconocimiento en línea debido a su simplicidad y alta capacidad computacional (Wang, Gong, Zhang, Li, & Zhuang, 2006) y (Wang, Ruan, & Pan, 2007).

La técnica de caracterización se basa en patrones binarios locales *Local binary patterns* (LBP), es un descriptor de texturas invariante a la iluminación y a la

rotación y adecuado para ser utilizado en sistemas de reconocimiento en línea debido a su simplicidad y alta capacidad computacional. En este algoritmo se examina para cada píxel de la imagen su conectividad 8 generando una cadena binaria de bits obtenida por cada píxel al utilizar el valor del píxel central como umbral de sus vecinos, Figura 2.8a, de este modo los pixeles mayores a este valor umbral se le asigna un cero y a los menores se asigna un uno, Figura 2.8b, estos bits indican la distribución de las intensidades alrededor de cada píxel para finalmente obtener un histograma.

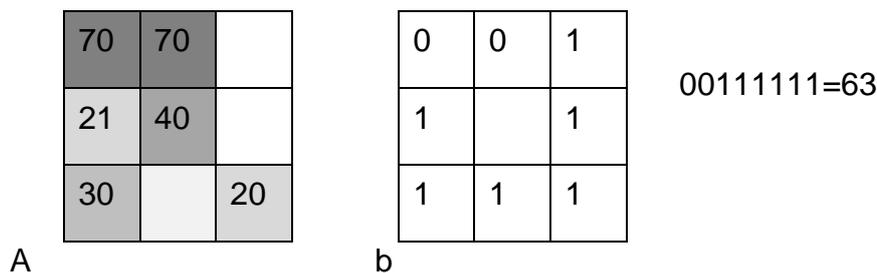


Figura 2. 8. LBP Patrones binarios locales.

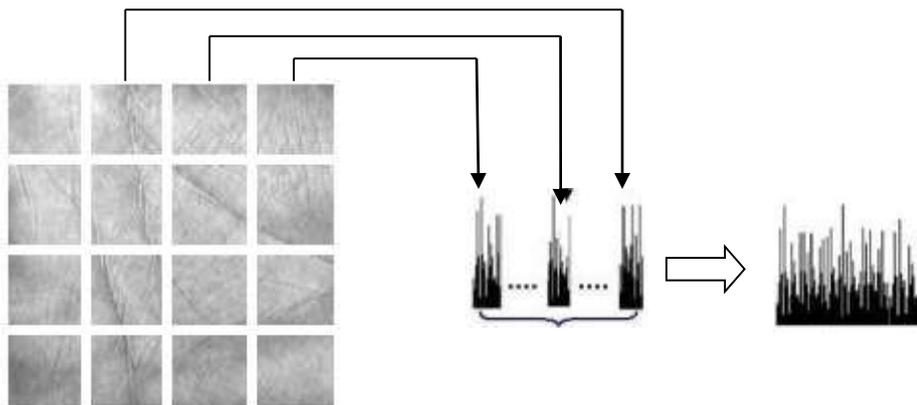
El LBP generalizado es obtenido sobre una simetría circular de radio fijo y un número definido de vecinos, donde el radio determina la resolución espacial del operador. Los valores de nivel de gris de los vecinos que no están exactamente en la posición de los píxeles, se calcula por interpolación. El LBP en una imagen de la textura con los vecinos de P y R radio se expresa por: (Vargas, Travieso, Alonso, & Ferrer, 2009)

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \tag{2.15}$$

Donde,  $s$  será 1 para  $x \geq 0$ , o 0 para  $x < 0$ ,  $g_p$  es el valor de nivel de gris del  $P^{th}$  vecino, y la  $g_c$  es el valor de nivel de gris del valor del centro.

En (Vargas, Travieso, Alonso, & Ferrer, 2009) se proponen un análisis por bloques utilizando bloques de diferentes tamaños para dividir cada imagen sin superposición (de 15 a 150 píxeles). El histograma LBP se calcula sobre cada bloque y finalmente el vector de características es construido por la concatenación de cada histograma LBP de los bloques. Para el cálculo de LBP

se emplea un enfoque multiresolución, se calcula utilizando tres radios diferentes (1, 2,5 y 3) y tres de vecinos de muestreo diferentes (8, 12 y 16, respectivamente). Por lo tanto, para cada bloque analizado (un ejemplo de esta división se muestra en la Figura 2.9), se generan tres histogramas de dimensión (10, 14 y 18) se obtienen y se combinan para obtener un vector de características final que contiene el número de bloques  $\times$  42 elementos. La caracterización por LBP en imágenes de palma de la mano ha sido utilizada por (Wang, Gong, Zhang, Li, & Zhuang, 2006) y (Wang, Ruan, & Pan, 2007) ya que es considerado como un poderoso método de descripción de texturas que es invariante a la escala de grises y a la rotación, debido a que la textura es uno de los rasgos que se observan más claramente en las imágenes de baja resolución de la palma de la mano y muy discriminativo para la identificación de esta.



*Figura 2. 9. Imagen de la ROI Dividida por bloques.*

Dentro de los trabajos más representativos en esta área se encuentran los siguientes. En (Xianji Wang, 2006) utilizan patrones binarios locales como descriptores para el reconocimiento de personas mediante palma de la mano y AdaBoost (Y. Freund, 1997) como clasificador. Éste es un algoritmo para seleccionar las sub-ventanas que son más discriminatorias para la clasificación. En (Yanxia Wang, 2007) también utilizan LBP pero como clasificador usan el vecino más cercano, En (Ajay Kumar, 2006) como descriptores de textura la transformada discreta del coseno y varios clasificadores como Bayes, Redes neuronales feed-forward y Máquinas de soporte vectorial y En (Vargas, 2009) utilizan LBP para los descriptores y SVM para la clasificación. Igualmente se

proponen estas dos últimas combinaciones en este proyecto ya en algunos experimentos realizados por el grupo de Electrónica de Potencia Automática y Robótica (GEPAR) en conjunto con el Grupo de Procesado Digital de Señales (GPDS) se demostró que la ROI afecta el reconocimiento de un sistema biométrico caracterizado mediante análisis de texturas ya que al cambiar las bases de datos ingresadas en el sistema los resultados se alteraron.

En esta tesis se tomarán las imágenes de la ROI de 128x128, así que se generan varios grupos de LBP's variando los parámetros de histograma (histograma adaptativo y no adaptativo), modificando los tamaños de bloques (64x64, 32x32, 16x16 y 8x8), y cambiando el radio (1, 2, 1 y 2).

## **2.9. CLASIFICACIÓN**

### **2.9.1 Selección de características**

Antes de llevar los resultados de la caracterización al clasificador, es recomendable reducir la dimensionalidad, esto se logra a partir de una selección o transformación de características. Se propone entonces realizar una selección de características ya que entre los datos pueden encontrarse atributos redundantes e irrelevantes que confunden y entorpecen el aprendizaje del sistema de clasificación y entre mayor número de características mayor es la dimensionalidad del problema y por lo tanto afecta la velocidad de respuesta.

Las técnicas de selección de características reducen los datos por lo tanto los clasificadores logran mayores velocidades en el aprendizaje, con mayor exactitud por lo que el clasificador generaliza mejor y evita obtener posteriormente atributos irrelevantes.

Para la selección de los datos se realiza un análisis de relevancia y de redundancia. En el primero pueden encontrarse características: relevantes, con relevancia baja y características irrelevantes, mientras en el análisis de redundancia se dividen en características redundantes y no redundantes,

finalizando estos dos análisis se tienen cuatro subgrupos de características: el primer grupo se encuentra formado por las características irrelevantes, el segundo grupo por las características de baja relevancia y redundantes, el tercero por las de baja relevancia pero no redundantes y el cuarto por las relevantes, por lo tanto el grupo de características óptimo lo conforman los dos últimos subgrupos de características. (Lei Yu, 2004)

Existen dos enfoques para la selección de características, uno es llamado selección individual y el otro, selección de subgrupo. En la selección individual, a las características se le asignan pesos según su grado de relevancia y el nuevo grupo de características es conformado por los subgrupos 2, 3 y 4 es decir se han eliminado las características irrelevantes solamente, por la asignación de pesos no se eliminan las características redundantes. En la selección de subgrupo se realiza una búsqueda continua del mejor subgrupo de características, de esta manera son eliminadas además de la irrelevantes las características redundantes. (Lei Yu, 2004)

El concepto de redundancia de características esta normalmente ligado a características de correlación. Es ampliamente aceptado que dos características son redundantes entre sí, si sus valores están completamente correlacionados. La correlación es ampliamente utilizada en máquinas de aprendizaje y estadística para análisis de relevancia. Debido a lo anterior se decide trabajar con el método propuesto en (Lei Yu, 2004) donde primero elimina las características irrelevantes aplicando la correlación entre alguna característica y la clase, seguido de esta eliminación se calcula la correlación entre un par de características para así determinar las características redundantes, obteniendo la correlación lineal es decir, hallando el coeficiente de correlación para establecer la dependencia o independencia lineal que tiene cada característica, de este modo si el coeficiente de correlación es igual a cero las variables son totalmente independientes, para casos no lineales, se calcula la incertidumbre simétrica que al igual que en el coeficiente de correlación, un valor igual a cero significa independencia entre las variables.

## 2.9.2 Máquinas de soporte vectorial

Las máquinas de vectores de soporte se basan en el concepto de planos de decisión. Un plano de decisión define los límites para separar objetos que pertenecen a diferentes clases.

La mayoría de los sistemas de clasificación requieren estructuras complejas para realizar una separación óptima. Las tareas de clasificación basadas en el trazado de líneas de separación para distinguir entre los objetos que pertenecen a diferentes clases son conocidas como hiperplanos de clasificación y las máquinas de soporte vectorial son especialmente adecuadas para manejar estas tareas.

SVM es uno de los principales métodos de clasificación que realiza tareas de clasificación mediante la construcción de hiperplanos en espacios multidimensionales separando los casos de las etiquetas de clase diferente. Para construir un hiperplano óptimo, SVM emplea un algoritmo de entrenamiento iterativo, el cual es utilizado para minimizar una función de error, de acuerdo con la forma de la función de error, los modelos SVM se pueden clasificar en cuatro grupos distintos: C- Clasificación, nu- Clasificación, épsilon regresión y nu- regresión. El modelo utilizado en este trabajo es C-Clasificación donde el entrenamiento involucra la minimización de la función de error. (2.16)(2.17)

$$fe = \frac{1}{2}w^T w + C \sum_{i=1}^N \xi_i \quad (2.16)$$

$$y_i(w^T \varphi(x_i) + b) \geq 1 - \xi_i \quad \text{and} \quad \xi_i \geq 0, i = 1, \dots, N \quad (2.17)$$

Donde  $C$  es la capacidad constante,  $w$  es el vector de coeficientes,  $b$  una constante y  $\xi_i$  son parámetros para el manejo de los datos no separables, el índice  $i$  representa cada etiqueta de los  $N$  casos de entrenamiento, y puede

tomar valores de 1 ó -1 según a la clase a la que pertenezca,  $x_i$  es la variable independiente y el kernel  $\varphi$  es usado para la transformación de los datos de entrada para el espacio de características. Es importante anotar que cuanto mayor es  $C$  el error es más penalizado, por lo tanto,  $C$  debe elegirse con cuidado para evitar el exceso de adaptación.

Las máquinas de soporte vectorial al igual que otro de tipo de clasificadores como las redes neuronales, k-vecinos, bayesiano, entre otros, lo que pretenden es separar, en principio dos conjuntos de características o de descriptores obtenidos de los objetos, a los cuales se pretende identificar. Los sistemas de reconocimiento de patrones siempre requieren de un clasificador que a partir de unos primeros conjuntos de entrenamiento modelen, separen y generalicen para posteriormente ingresar datos desconocidos y el sistema pueda identificar con el menor error posible a que conjunto pertenecen estos datos o a cual conjunto tiene mayor nivel de pertenencia.

Para trabajar con una máquina de soporte vectorial es necesario seleccionar el Kernel adecuado ya que de este depende en gran medida la adecuada clasificación de los datos. Estos Tipos de Kernel pueden ser: Gausiano, polinomial, sigmoideal, RBF Funciones de base radial.

El kernel de base radial está definido por (2.18)

$$\exp(-\gamma|u - v|^2) \quad \text{para} \quad \gamma > 0, \quad \gamma = \frac{1}{2\sigma^2} \quad (2.18)$$

Siendo  $\gamma$  una constante de proporcionalidad cuyo rango de valores útiles debe ser estimado para cada aplicación en particular.

Entre las ventajas de una máquina de soporte vectorial se encuentran: la capacidad de generalización al minimizar el riesgo estructural, son pocos los parámetros de ajuste y la estimación de los parámetros se realiza a través de la optimización de una función de costo convexa, lo cual evita la existencia de un mínimo local. (Resendiz, 2006)

Esta es una técnica de clasificación, en principio biclase, basada en encontrar un hiperplano que separa las clases minimizando el error de clasificación y maximizando el margen entre las clases. La solución de un problema multiclase con una máquina de soporte vectorial puede realizarse de dos maneras, la primera consiste en utilizar un clasificador por cada dos clases, se requieren  $(C-1)*C/2$  siendo C el número de clases. El segundo método consiste en utilizar una clase contra el resto de las clases, se obtendrían entonces C clasificadores, para entrenar este tipo de clasificadores se requiere de una técnica de sobremuestreo que balancee el número de muestras por clase ya que si se trata de un número alto de clases, la clase a comparar con el resto quedaría en minoría de muestras.

---

## 3. METODOLOGÍA PROPUESTA

---

### 3.1 INTRODUCCIÓN

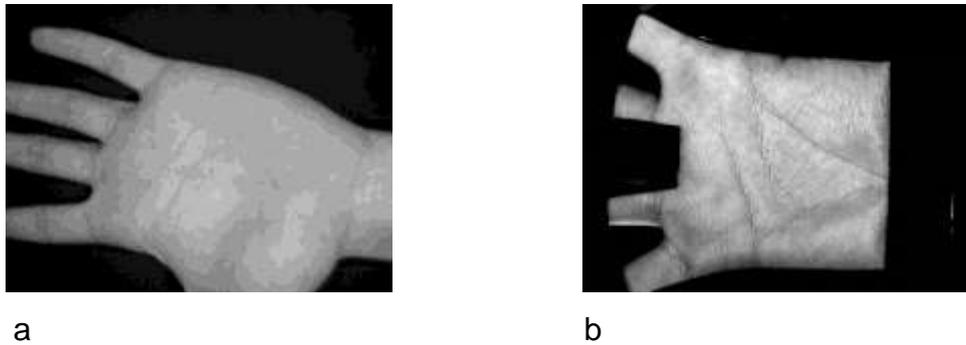
En este capítulo se describen las bases de datos de las imágenes a procesar, se presenta el diseño del software de identificación biométrica y se detalla la metodología de desarrollo propuesta para la implementación del sistema biométrico.

### 3.2. BASES DE DATOS

Se utilizaron dos bases de datos públicas, la primera base de datos PolyU Palmprint Database (Figura 3.1b), es la segunda versión (Centro de Investigación biométrica (UGC / CRC) Universidad Politécnica de Hong Kong) contiene 7752 de imágenes en escala de grises correspondiente a 386 diferentes palmas en formato BMP. (384 x 284 píxels, 96 dpi). La segunda base de datos CASIA Palmprint Database (Figura 3.1a), (Center for Biometrics and Security Research (CBSR) Institute of Automation, Chinese Academy of Sciences (CASIA).), contiene 5239 imágenes de palma de la mano en escala de grises (640 x 480 píxeles, 72 dpi) recogidos de 301 individuos en formato JPG (con compresión de la imagen se altera la textura). La diferencia entre estas dos bases de datos, es que las imágenes de CASIA contienen mayores distorsiones, desenfoques y cambios de posición y ligeras rotaciones ya que estas fueron tomadas con menores límites físicos, en cambio en PolyU las imágenes son tomadas con plantillas y sólo contienen el inicio de los dedos, además esta plantilla no deja visualizar el punto valle formado por el dedo medio y el dedo anular, mientras en las imágenes de CASIA, si contienen los dedos y no son tomadas con ningún tipo de plantilla.

Las bases de datos de la Figura son utilizadas en artículos donde (Shang & Li, 2009), (Yuea, Zuo, Zhang, & Wang, 2009) y (Zhang, Kong, You, & Wong, 2003)

trabajan con la base de datos de PolyU palmprint y (Chen, Moon, Wong, & Su, 2010) utilizan PolyU palmprint y CASIA.



*Figura 3. 1. Imágenes de las bases de datos. a) CASIA. b) PolyU*

### **3.3. METODOLOGÍA PROPUESTA**

En base a la literatura actual y a pruebas experimentales surge la propuesta del desarrollo del sistema de identificación (Figura 3.2). Donde la etapa de preprocesamiento del sistema biométrico de identificación por medio de la palma de la mano, está conformada paso a paso por: la lectura de la imagen en niveles de gris, rotación, binarización, eliminación de objetos pequeños, operación morfológica de apertura, detección de borde, localización de puntos máximos y mínimos, ubicación de la ROI y finalmente un filtro para detectar las imágenes que no se encuentran dentro del área de interés. En cuanto a la etapa de caracterización se utiliza el método de patrones binarios locales, seguido de la eliminación de características relevantes y redundantes, finalmente concluye el proceso con la etapa de clasificación donde se realiza un análisis de con y sin balance de muestras, se realiza una validación cruzada para la máquina de soporte vectorial y se evalúa el desempeño mediante las curvas CMC.

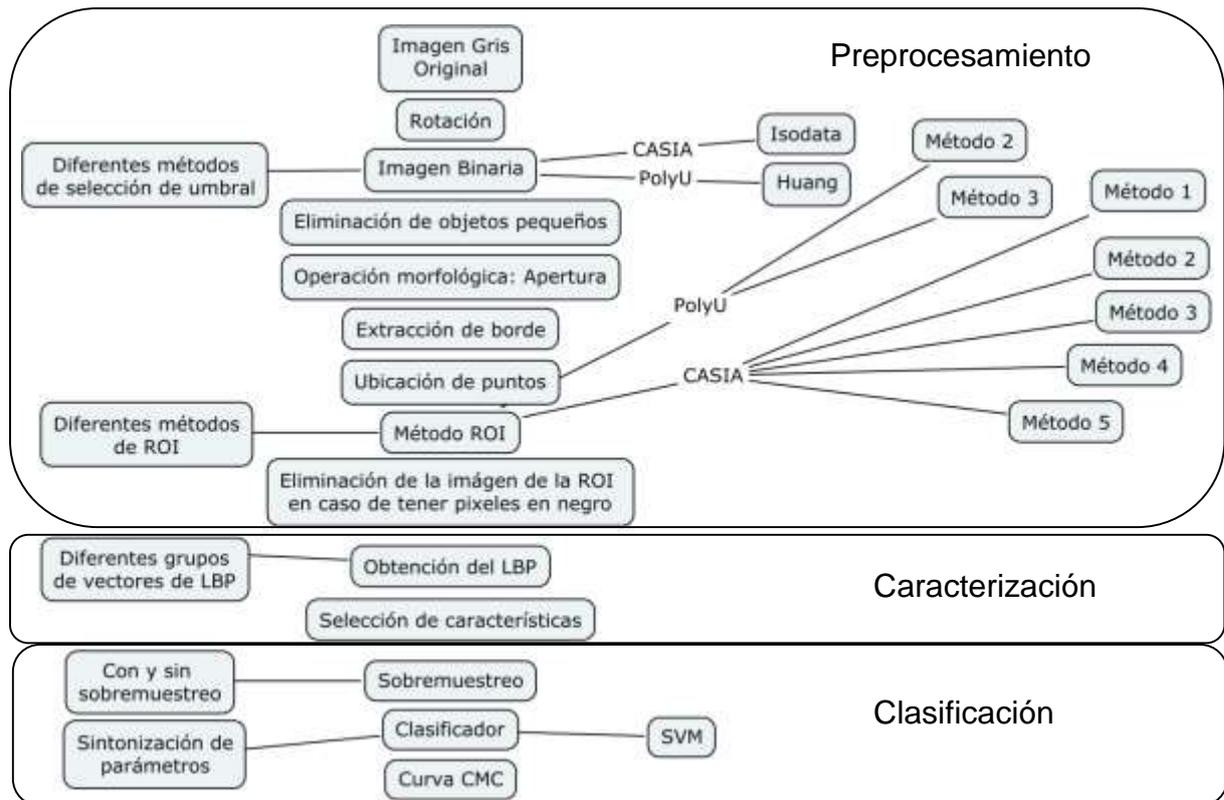


Figura 3. 2. Estructura del sistema de identificación

### 3.4. DISEÑO DEL SOFTWARE

Los procedimientos anteriormente mencionados conforman la metodología de desarrollo del sistema de clasificación biométrico propuesto en esta tesis y fueron implementados sobre la plataforma Matlab (Figura 3.3) utilizando un entorno gráfico sencillo y práctico que permite seleccionar el método de ROI, el método umbral y de ser necesario modificar las rutas donde se encuentran las bases de datos de las imágenes, para automáticamente procesar cada una de las imágenes y generar los resultados finales. En los anexos se presentan los diagramas de flujo del software diseñado y algunos de los algoritmos en Matlab.

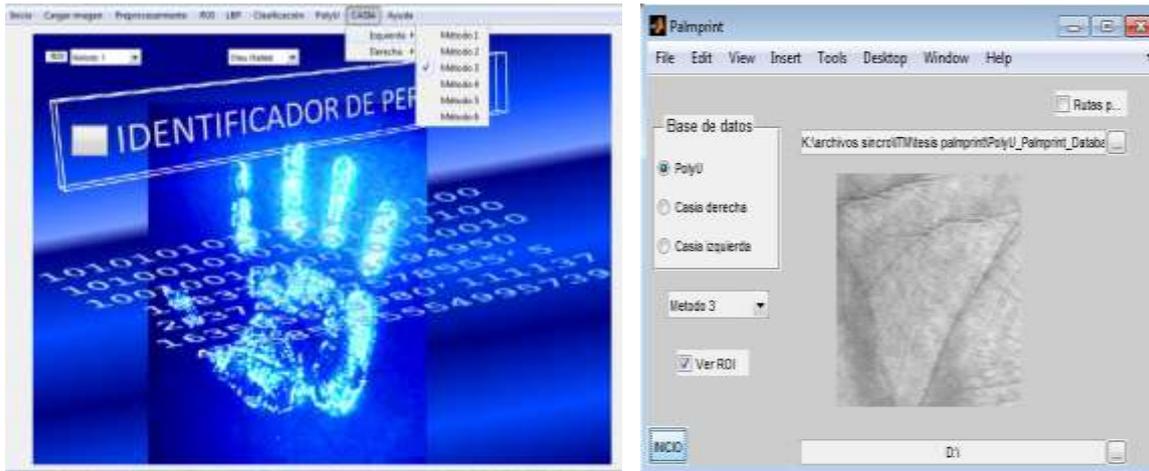


Figura 3. 3 Software del sistema biométrico

El programa principal comienza por la selección de base de datos por parte del usuario, PolyU o CASIA tal como se aprecia en el diagrama de flujo del programa principal (Figura 3.4)

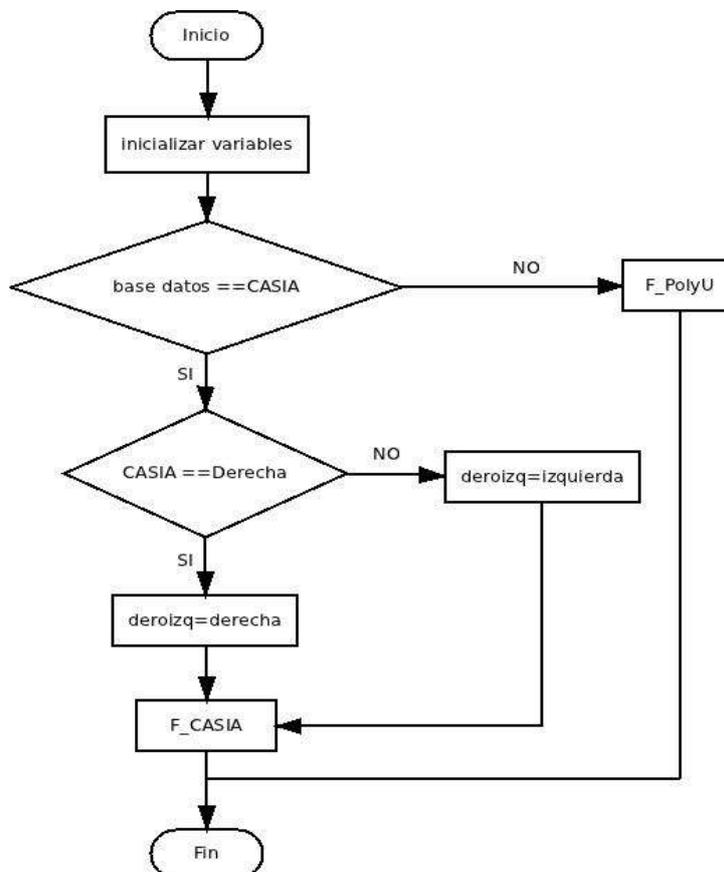


Figura 3. 4. Diagrama de flujo del programa principal

Las funciones de las bases de datos están conformadas por la lectura de cada una de las imágenes en la ruta previamente especificada por el usuario del programa, luego son preprocesadas utilizando el método de ubicación de ROI seleccionado. Las imágenes de la ROI son almacenadas en una carpeta, se calculan y se almacenan los LBP's con diferentes configuraciones para posteriormente ser llevados al clasificador. (Figura 3.5)

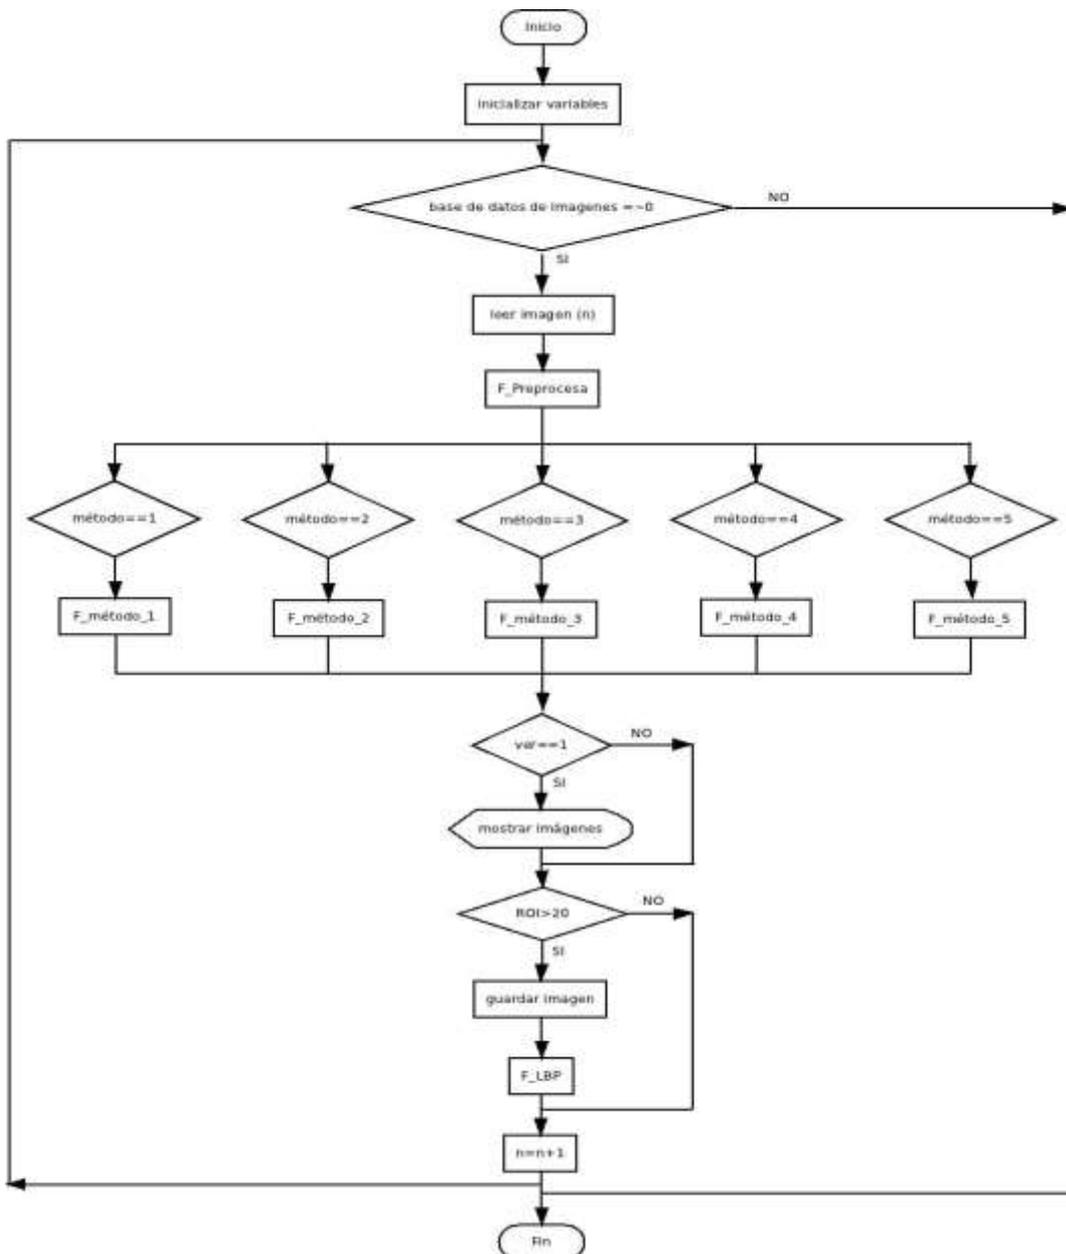


Figura 3. 5 Diagrama de flujo de las funciones de las bases de datos

### 3.5. PREPROCESAMIENTO

Luego de leer la imagen, esta debe ser rotada con un ángulo de -90 grados para facilitar más tarde la ubicación de los puntos valles, de tal modo que la imagen quede vertical. La nueva imagen rotada contiene totalmente a la imagen original. Para seleccionar la técnica de umbral a utilizar se probaron diferentes métodos comparando los contornos obtenidos sobre la imagen original.

A partir de los resultados obtenidos se decide utilizar el método isodata, propuesto en (Ridler, 1978) y el planteado por Huang (Huang L-K. y M-J. J. Wang, 1995). Estos se seleccionaron debido a que se realizaron varias pruebas con varios métodos de umbralización y para la base de datos de PolyU, se observaron mejores resultados al comparar el borde generado por el método Huang sobre la imagen original, mientras que, para la base de datos de CASIA el contorno que mejor bordeaba la imagen fue el obtenido con el método Isodata. Según la base de datos se trabaja con un método umbral, así para CASIA se calcula el umbral con Isodata y para PolyU el umbral es calculado con el método desarrollado por Huang, ya que fueron los contornos que mejor definían las imágenes para cada caso. Adicionalmente cada método es comparado con el método Otsu, ya que este es ampliamente utilizado en la mayoría de trabajos reportados en la literatura. A continuación se describen los métodos de umbral que se han utilizado.



Figura 3. 6. Pasos para ubicar la ROI

Los pasos que se realizan con cada una de las imágenes (Figura 3.6), partiendo de la imagen binaria son: Eliminación de objetos pequeños, Operación morfológica de apertura, Extracción de borde, Ubicación de puntos, Método ROI. Luego de obtener la imagen binaria se procede a eliminar los objetos pequeños o ruido que pueda contener la imagen, para ello se etiquetan los objetos que se encuentran en la imagen, se calcula el área de los objetos y son eliminados los objetos pequeños que pueda contener la imagen, con esto se asegura que el único objeto presente en la imagen es la mano y con el fin de mejorar y suavizar los bordes de la imagen de la mano se recurre a un proceso morfológico de apertura, que es usualmente utilizado para suavizar el contorno del objeto y que consiste en eliminar los píxeles que se salen un poco del borde y los que forman pequeñas uniones, esto se consigue mediante una erosión (cambian los píxeles por cero si los vecinos están en cero) seguida de una dilatación (cambiar de cero al valor mayor si alguno de sus vecinos está en el máximo).

Para la detección de contorno en las imágenes, se inicia la búsqueda comenzando con las coordenadas del extremo inferior derecho de la imágenes binarias es decir "x" máxima y "y" máxima, se recorre todo el borde de la palma y se almacenan en dos vectores las coordenadas pertenecientes a las filas y las columnas de borde, para esta función, se debe especificar las coordenadas de inicio del trazo y la cadena que especifica la dirección de búsqueda inicial para el píxel siguiente del objeto, lo que hace la función, es que traza el contorno de un objeto en una imagen binaria, cuyos píxeles diferentes de cero pertenecen al objeto y los que son iguales a cero corresponden al fondo. Obtenido el contorno se procede con la localización de los puntos, encontrando los mínimos o valles formados por los dedos, esto se realiza a partir del vector de contorno definiendo un umbral definido empíricamente (5 para PolyU y 20 para CASIA) para identificar lo que se considera valle de lo que no lo es (Figura 3.7), el algoritmo se basa en el cálculo de la derivada para encontrar los mayores cambios y los cambios de sentido, finalmente se ubican los puntos que definen el cuadrado que compone la región de interés.

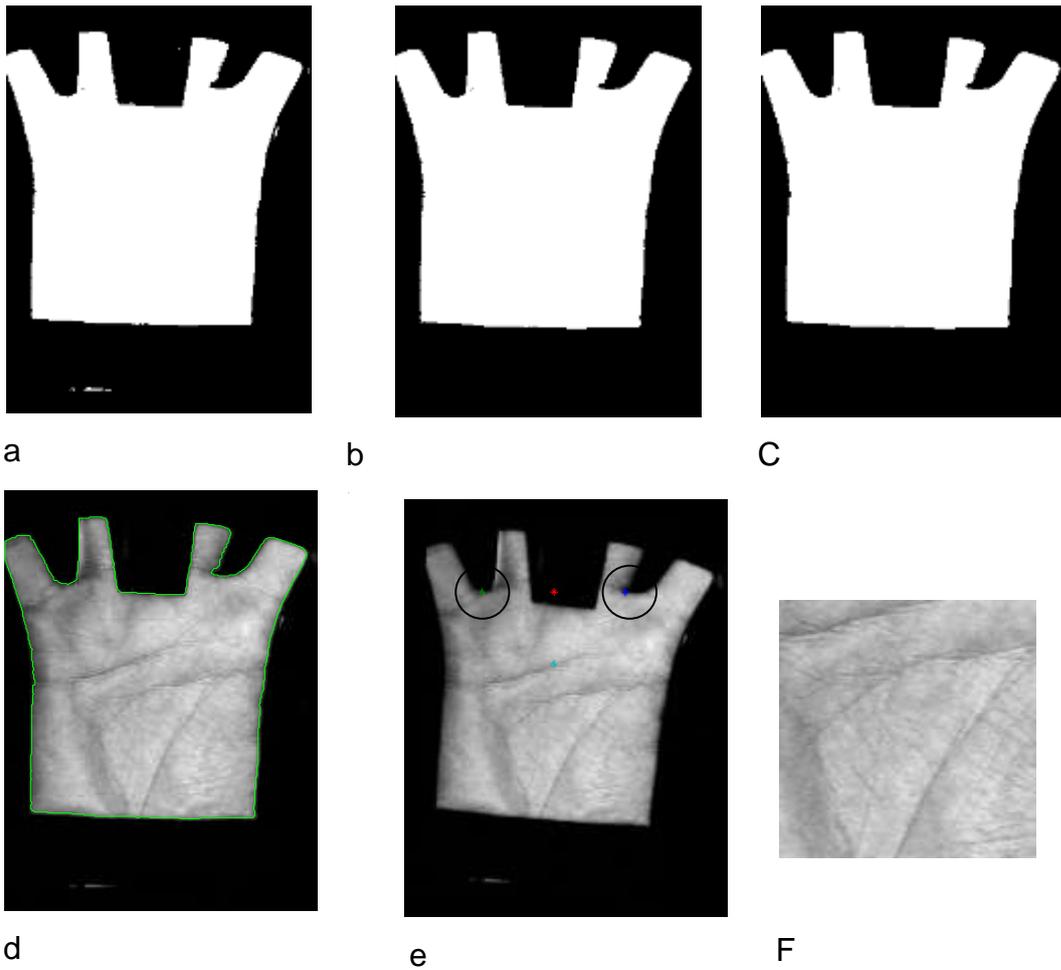


Figura 3. 7. Pasos del preprocesamiento.

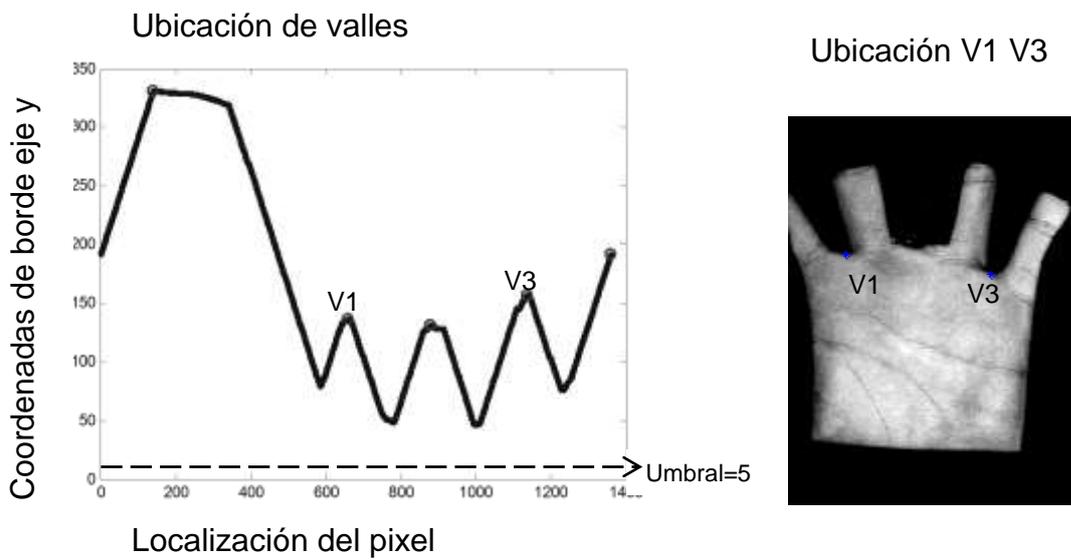


Figura 3. 8. Puntos valles

Con los puntos definidos se realiza el siguiente procedimiento, se rota la imagen para ubicar los puntos que requiere cada método y dejarlos sobre el mismo valor de ordenada, para esto se obtiene el valor del ángulo formado por los puntos ya sea  $V1$  y  $V2$  Figura 3.8 para el método de obtención de ROI 1 y  $V2$  y  $V3$  para el método 2 y 3. Tal y como se describe en la ecuación (2.19)

$$AR = \tan^{-1} \left( \frac{V1_y - Vn_y}{V1_x - Vn_x} \right) \quad (2.19)$$

Donde  $AR$  es el ángulo de rotación que requiere la imagen y los  $Vn$  son los valores de  $V2$  o  $V3$  para cada coordenada dependiendo según el del método aplicado.

La imagen es rotada según el ángulo calculado, garantizando que la nueva imagen contienen en su totalidad la imagen anterior, debido a la rotación y a la traslación de imagen se requieren recalcular los puntos valles, para esto se debe tener en cuenta si la rotación es positiva o negativa. Figura 3.9. De modo que para ángulos positivos los nuevos puntos son calculados según las siguientes ecuaciones, haciendo uso de la ley de senos que dice que la razón entre la longitud de cada lado y el seno del ángulo opuesto a él en todo triángulo es constante.

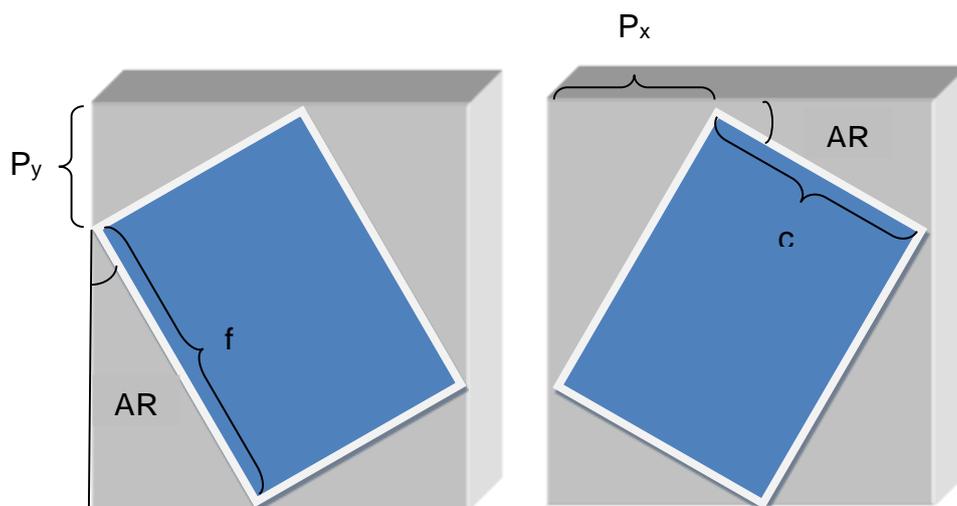


Figura 3. 9. Rotación.

Se obtiene el valor de traslación de la ordenada ecuación (2.20).

$$P_y = \left| \frac{c \times \sin(AR)}{\sin\left(\frac{\pi}{2}\right)} \right| \quad (2.20)$$

Donde  $c$  es el número de columnas de la imagen y corresponde al valor de la hipotenusa que forma el triángulo.

La rotación para cada punto está dada por la ecuación (2.21)

$$Vnr_x = Vn_x \times \cos(AR) + Vn_y \times \sin(AR) \quad (2.21)$$

$$Vnr_x = |Vn_x \times \sin(AR) - Vn_y \times \cos(AR)| + P_y \quad (2.22)$$

Para valores de ángulo ( $AR$ ) negativo son tomadas las ecuación (2.23)

$$P_x = \left| \frac{f \times \sin(\pi - AR)}{\sin\left(\frac{\pi}{2}\right)} \right| \quad (2.23)$$

Donde  $f$  es el número de filas de la imagen y corresponde al valor de la hipotenusa que forma el triángulo.

La rotación para cada punto está dada por las ecuaciones (2.24) y (2.25).

$$Vnr_x = |Vn_x \times \sin(AR) - Vn_y \times \cos(AR)| \quad (2.24)$$

$$Vnr_x = Vn_x \times \cos(AR) + Vn_y \times \sin(AR) + P_y \quad (2.25)$$

Como se mencionó en el capítulo 2 - ubicación de la ROI -, por facilidad en la redacción del documento, cada método será llamado como método 1, 2, 3, 4, 5 y 6 de manera consecutiva como se enuncian los trabajos de cada autor, en la

Tabla 3.1 se muestra el nombre del método y los respectivos autores donde fueron previamente descritos y empleados.

*Tabla 3. 1 Métodos ROI.*

<b>Método</b>	<b>Autor</b>
<b>Método 1</b>	(Han, Cheng, & Fan, 2002) (Han, Cheng, Lin, & Fan, 2003)
<b>Método 2</b>	(Lin, C. Chuang, & Fan, 2005)
<b>Método 3</b>	(Toro & Correa, 2009)
<b>Método 4</b>	(Chen, Moon, Wong, & Su, 2010) (Kong & Zhang, 2002) (Zhang, Kong, You, & Wong, 2003) (Yue, Zuo, Zhang, & Wang, 2009) (Wang, Yau, Suwandy, & Sung, 2008)
<b>Método 5</b>	(Shang & Li, 2009)
<b>Método 6</b>	(Kong, Lua, Wang, Qi, & Li, 2008) (Michael, Connie, & Teoh, 2008)

### **3.6. PATRONES BINARIOS LOCALES (LBP)**

Como se mencionó en el capítulo anterior, cuando se realizó el análisis con cada base de datos se tomó para CASIA el método Isodata y para PolyU el método Huang, lo cual significa que para el análisis de patrones binarios locales y para la clasificación los demás métodos de umbralización no se tendrán en cuenta.

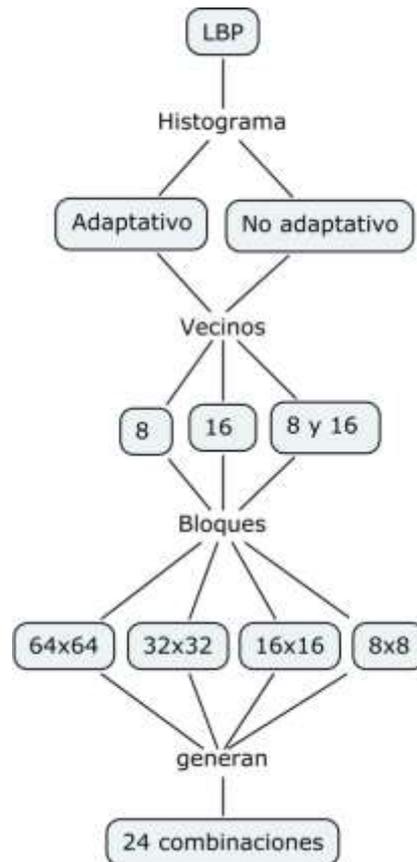


Figura 3. 10 Configuraciones de los LBP's

Las imágenes de la ROI son 128x128, así que se generaron varios grupos de LBP's variando los parámetros de histograma (histograma adaptativo y no adaptativo), modificando los tamaños de bloques (64x64, 32x32, 16x16 y 8x8) (Figura 3.11), y cambiando el radio(1, 2, 1 y 2) Figura 3.12. Las combinaciones fueron las mostradas en la Tabla 3.2. y en la Figura 3.10 donde por facilidad en la nomenclatura, las etiquetas de cada uno de los nombres comienza con las letras LBP, después va un 0 ó 1 dependiendo si el histograma es adaptativo (1) o si no lo es (0), lo que sigue corresponde al número de vecinos 8, 16 o la combinación de ambos y finalmente se adiciona la dimensión del bloque, que puede ser 8x8, 16x16, 32x32 o 64x64. Cada combinación genera un vector de características que son tomados como descriptores independientes, para comparar cada grupo de LBP (Tabla 3.2).

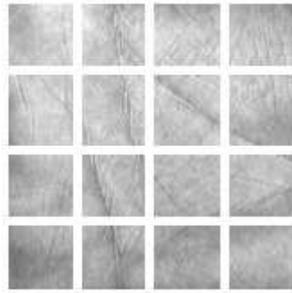
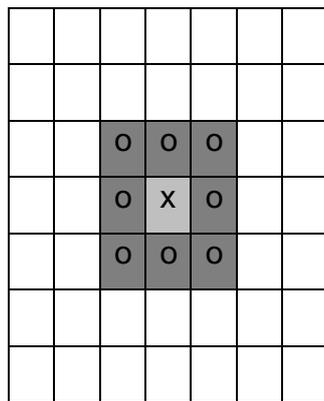
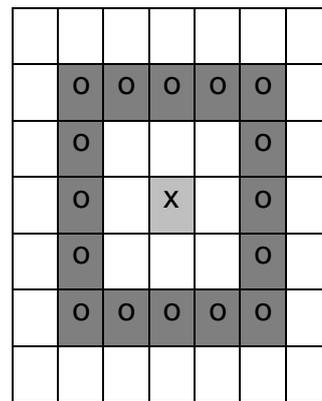


Figura 3. 11 División de la imagen por bloques



a. Radio 1 – 8 Vecinos



b. Radio 2 – 16 Vecinos

Figura 3. 12 Conjuntos de vecinos y Radios

El histograma de una imagen es la representación gráfica de la distribución que existe de las distintas tonalidades de grises con relación al número de píxeles o porcentaje de los mismos. La representación de un histograma ideal sería la de una recta horizontal, ya que esto indicaría que todos los posibles valores de grises están distribuidos de manera uniforme en la imagen. Cuando se dice que el histograma es adaptativo se refiere al histograma ecualizado, la ecualización del histograma es un método de transformación que se aplica para darle mayor uniformidad a los niveles de gris de la imagen, tratando de aproximarse a un histograma ideal. La ecualización del histograma se realiza sobre la imagen antes de calcular los LBP's.

Tabla 3. 2 Configuración de los LBP's

LBP	Histograma adaptativo	Histograma no adaptativo	Radio 1	Radio 2	Tamaño del bloque
LBP 0 8_64		x	x		64 x 64
LBP 0 8_32		x	x		32 x 32
LBP 0 8_16		x	x		16 x 16
LBP 0 8_8		x	x		8 x 8
LBP 1 8_64	x		x		64 x 64
LBP 1 8_32	x		x		32 x 32
LBP 1 8_16	x		x		16 x 16
LBP 1 8_8	x		x		8 x 8
LBP 0 8		x	x	x	64 x 64
LBP 0 8		x	x	x	32 x 32
LBP 0 8		x	x	x	16 x 16
LBP 0 8 16_8		x	x	x	8 x 8
LBP 1 8	x		x	x	64 x 64
LBP 1 8	x		x	x	32 x 32
LBP 1 8	x		x	x	16 x 16
LBP 1 8 16_8	x		x	x	8 x 8
LBP 0 16_64		x		x	64 x 64
LBP 0 16_32		x		x	32 x 32
LBP 0 16_16		x		x	16 x 16
LBP 0 16_8		x		x	8 x 8
LBP 1 16_64	x			x	64 x 64
LBP 1 16_32	x			x	32 x 32
LBP 1 16_16	x			x	16 x 16
LBP 1 16_8	x			x	8 x 8

**Nota:** la nomenclatura de las etiquetas (Tabla 3.2) de cada uno de los nombres comienza con las letras LBP, después va un 0 ó 1 dependiendo si el histograma es adaptativo (1) o si no lo es (0), lo que sigue corresponde al número de vecinos 8, 16 o la combinación de ambos y finalmente se adiciona la dimensión del bloque, que puede ser 8x8, 16x16, 32x32 o 64x64. No se utilizan mayores combinaciones de LBP's para reducir el costo computacional.

### 3.7. CLASIFICACIÓN

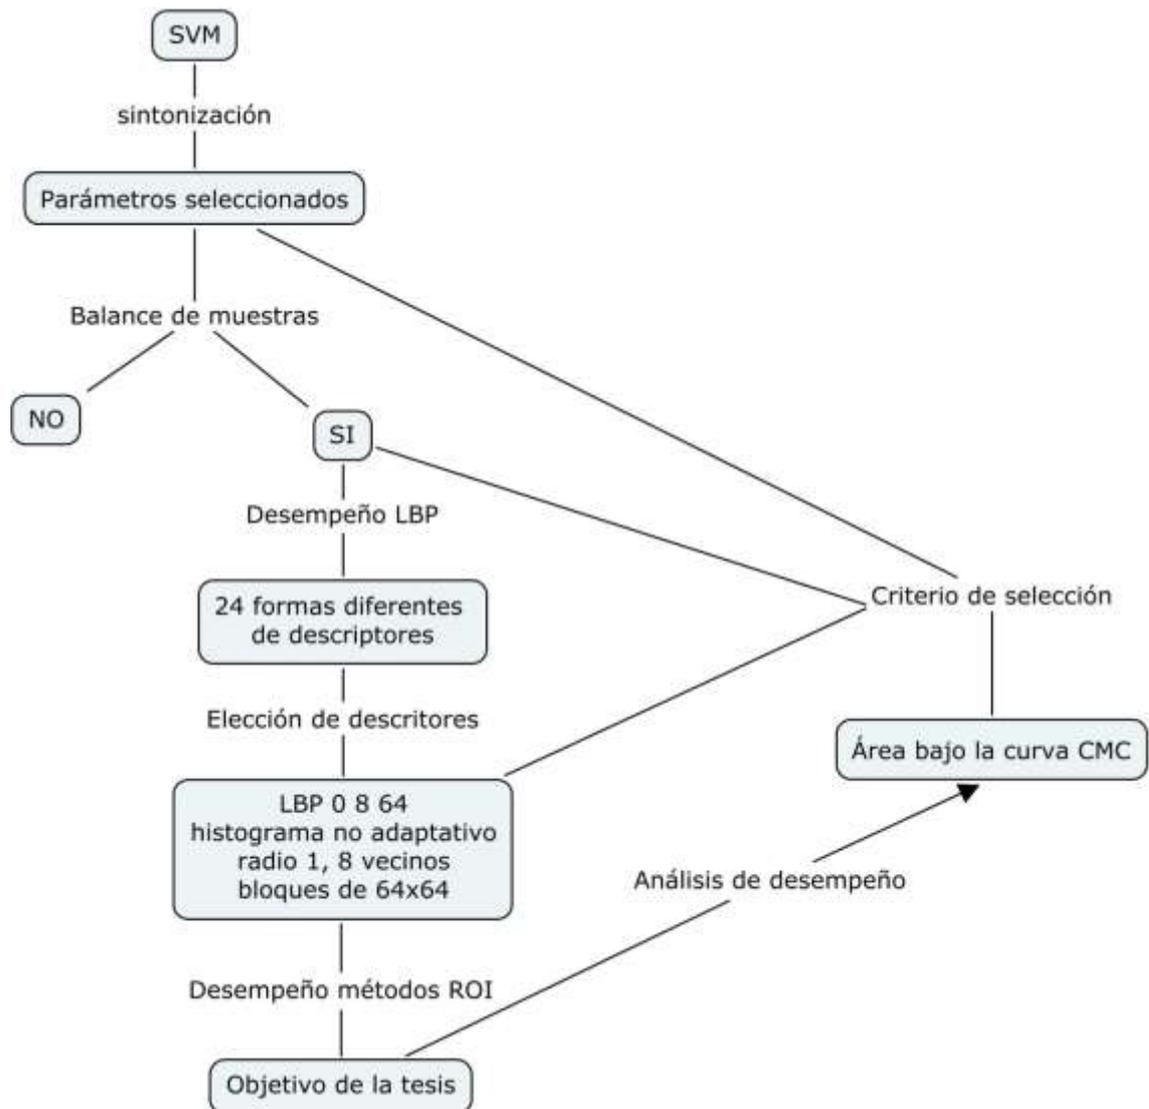


Figura 3. 13. Esquema de la clasificación

#### 3.7.1 Selección de Características

Después de calcular los LBP's y antes de llevar los datos al clasificador, es necesario reducir su dimensionalidad, para esto se realiza un análisis de relevancia y de redundancia utilizando una correlación lineal con exigencia de 0.01 con el fin de aceptar las características relevantes y se usó un parámetro de correlación igual a 1, para determinar la redundancia entre las características. Basando en (Lei Yu, 2004) como se mencionó anteriormente.

### **3.7.2 Sobremuestreo**

Después de calcular los LBP's y antes de llevar los datos al clasificador, es necesario reducir la dimensionalidad, para la selección de los datos se realiza un análisis de relevancia y de redundancia. Para ingresar los datos al clasificador el número de datos que representa una clase debe ser aproximadamente igual al número de datos de la otra clase, de lo contrario es posible que se generen problemas en la clasificación (Tang, Zhang, Chawla, & Krasser, 2002), es por esto que si no se tiene el número de datos adecuado como en este caso, se requiere de técnicas como la de sobremuestreo, por ejemplo SMOTE (*Synthetic Minority Over-sampling Technique*), la cual es una técnica que sirve para generar muestras sintéticas a partir de patrones y poder balancear los datos que ingresan al clasificador. Las muestras sintéticas son generadas tomando la diferencia entre el vector característico de una muestra de la clase minoritaria y su vecino más cercano, luego se multiplica esta diferencia por un número aleatorio entre 0 y 1, y después se le adiciona el mismo vector característico de la muestra tomada. Los detalles de esta técnica se encuentra en (Nitesh V. Chawla, 2002). Se seleccionó esta técnica de sobremuestreo por su amplia utilización y porque los resultados obtenidos al comparar con otras técnicas de balance de muestras son adecuados (Bunghumpornpat, Sinapiromsaran, & Lursinsap, 2009), (Tang, Zhang, Chawla, & Krasser, 2002).

### **3.7.3 Selección de parámetros para la SVM**

Para obtener un buen desempeño en el clasificador SVM es necesario realizar la sintonización de parámetros, que para el caso del kernel gaussiano serian el parámetro C (que determina el equilibrio entre la minimización del error del entrenamiento y la minimización de la complejidad del modelo) y el parámetro  $\sigma$  (define el mapeo no lineal del espacio de entrada de de un espacio de características multidimensional) (Duan, Keerthi, & Poo, 2003).

En la selección del modelo de la SVM, es necesario realizar la sintonización de los parámetros del kernel y el coeficiente de penalización, En este trabajo se usó el kernel gaussiano, que tiene como argumento la dispersión de la

campana gaussiana, este valor fue sintonizado con una aproximación heurística que involucra la dimensionalidad del problema, el cálculo exacto se realizó en base a  $\sigma = 1/\text{número de muestras}$ , ya que después de haber probado con diferentes valores donde se obtenían errores y no finalizaba el entrenamiento se decidió utilizar el calculo que función empleada trae por defecto. El parámetro de penalización C se sintonizó de manera heurística haciendo una búsqueda en malla realizando variaciones de este parámetro, tomando como métrica de comparación el área bajo la curva CMC para cada valor del parámetro C.

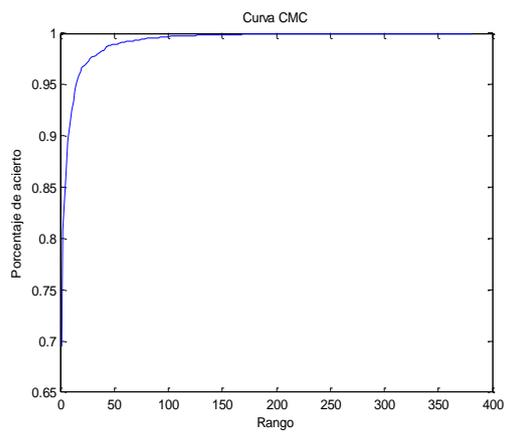
### **3.8. EVALUACIÓN DE DESEMPEÑO**

La evaluación de desempeño en sistemas biométricos está dada generalmente en términos de tasa de falsa aceptación (False Acceptance Rate FAR) que mide el porcentaje de error al reconocer a un individuo que no se encuentra en la base de datos y la tasa de falso rechazo (False Rejection Rate FRR) mide el porcentaje de error al no reconocer a un individuo que si forma parte de la base de datos. La tasa de error igual (Error Equal Rate EER) es la ubicación en una curva ROC donde la tasa de falsa aceptación y la tasa de falso rechazo son iguales, mientras el error sea menor más preciso es el sistema.

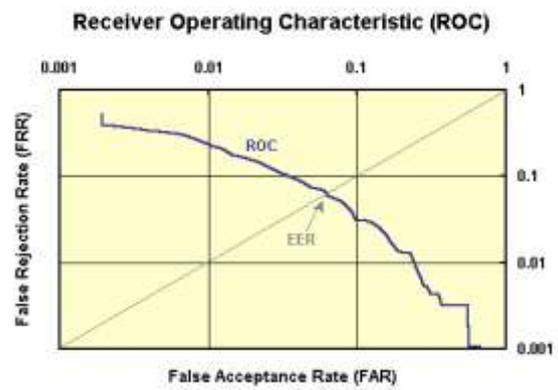
La curva *Receiver Operating Characteristic* (ROC) (Figura 3.14b) es una técnica estándar para resumir el desempeño de un clasificador entre las tasas de verdaderos positivos y falsos negativos. El área bajo la curva es una métrica de desempeño de la curva de ROC.

La curva CMC (*The Cumulative Match Curve*) (Figura 3.14a) se utiliza como medida del desempeño de un sistema de identificación multiclase juzgando las capacidades de un sistema de identificación. Para graficar la curva CMC es necesario generar una tabla, de los resultados del clasificador, con las probabilidades de pertenencia de cada muestra a cada clase, tomando de esta tabla los valores de máxima pertenecía para evaluar el porcentaje de acierto se tendría el primer dato, para elaborar la curva, el dato siguiente se obtiene con la sumatoria de los aciertos de los máximos obtenidos anteriormente con los

aciertos obtenidos de los segundos máximos y así sucesivamente. Por cada iteración se tendrá el acumulado del porcentaje de aciertos hasta que el número de iteraciones coincida con el número de clases y el porcentaje final de la curva llegue al 100%. En (R.M. Bolle, 2005) se explican las curvas CMC y las relacionan con las ROC, En este trabajo se utilizó la curva CMC debido a que el identificador biométrico plantea un problema multiclase y en esta curva se aprecia mejor las respuestas obtenidas.



a)



b)

Figura 3. 14 Curvas de desempeño. a) Curva CMC. b) Curva ROC

---

## 4. EXPERIMENTOS Y RESULTADOS

---

### 4.1 INTRODUCCIÓN

En este capítulo se realiza una comparación entre imágenes que contienen la región de interés de la palma de la mano, variando el método de ubicación de la ROI y la técnica de umbralización. Las medidas de similitud utilizadas fueron: la correlación, la información mutua, el error cuadrático medio, la relación de uniformidad de la imagen y el área común entre las imágenes. También se realiza un análisis para determinar la configuración de los LBP's que presenta mejor desempeño, se compara la respuesta del clasificador con y sin sobremuestreo y finalmente se evalúan las diferencias entre los métodos de ROI sobre la curva CMC.

### 4.2. SELECCIÓN DEL MÉTODO DE UMBRALIZACIÓN

#### 4.2.1 Base de datos CASIA

Se probaron tres técnicas de umbralización, Isodata, Huang y Otsu con cada uno de los métodos de ROI, para todas las imágenes de la base de datos. Se determinó el porcentaje de imágenes de ROI que fueron correctamente extraídas con cada una de las técnicas umbral. (Figura 4.1)

Después de realizar la umbralización mediante diversas técnicas como se aprecia en la figura 4.1, se decide utilizar un umbral global calculado con el método iterativo "Isodata" por presentar menor error. Para la comparación de imágenes se utilizan Isodata con Otsu con el fin de establecer las diferencias presentadas por ambos métodos umbral sobre las imágenes de la ROI.

## Métodos umbral CASIA

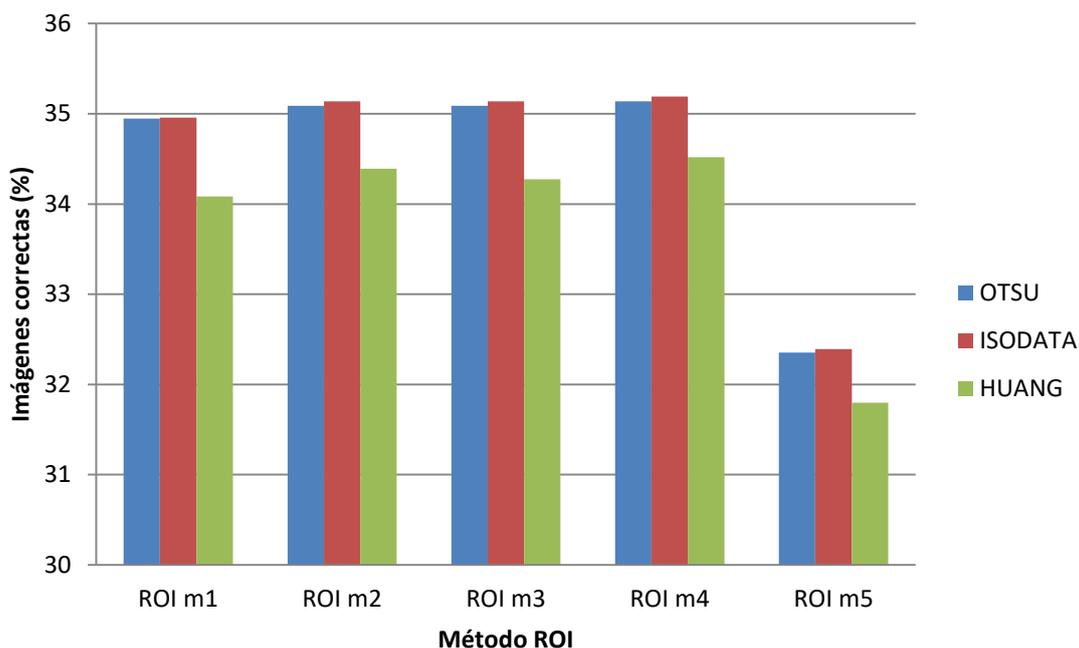


Figura 4. 1 Desempeño de los métodos umbral para CASIA

### 4.2.2 Base de datos PolyU

De forma similar a como se trabajo la base de datos de CASIA se prueba en matlab los métodos Isodata, Otsu y Huang para la base de datos de PolyU, donde, para una de las imágenes perteneciente a un individuo, al aplicar el algoritmo del método Otsu se obtuvo un valor umbral de 85, consiguiendo los resultados mostrados en la Figura 4.2a y al ubicar el borde generado de la imagen binaria y superponerlo sobre la imagen original los resultados son los apreciados en la Figura 4.2b. Para el método desarrollado por Huang se obtuvo un valor umbral de 42 para una imagen correspondiente a la base de datos de PolyU, Figura 4.2c y 4.2d.

El punto A marcado en la Figura 4.2 muestra como las sombras en las imágenes causan problemas para algunos casos de segmentación, se ve como al obtener el umbral Otsu el contorno de la imagen se daña y en otros casos inclusive se desaparecen los dedos y la imagen binaria obtenida no es la

adecuada. Al evaluar este tipo de situaciones fue que se decidió trabajar con Huang para la base de datos de PolyU.

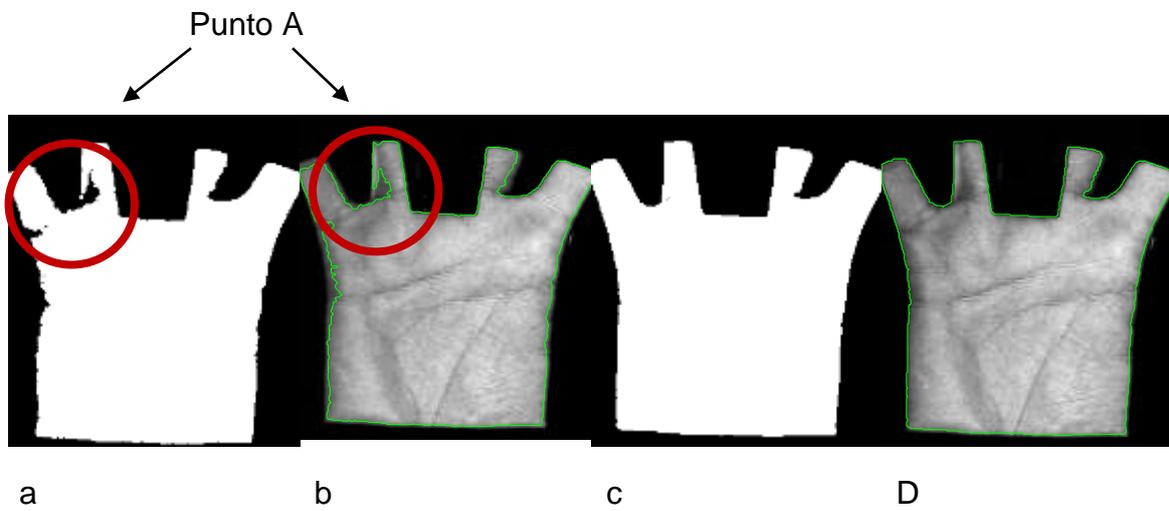


Figura 4. 2. Segmentación PolyU. a) Imagen binaria Otsu. b) Imagen original con el borde Otsu. c) Imagen binaria Huang. d) Imagen con el borde Huang.

### Métodos umbral PolyU

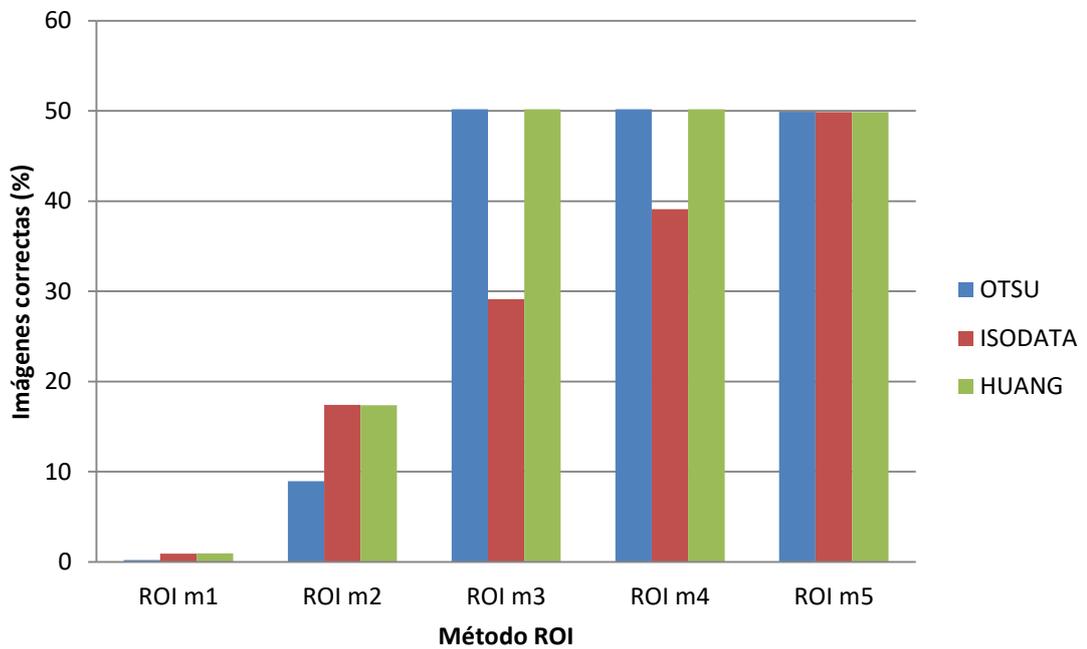
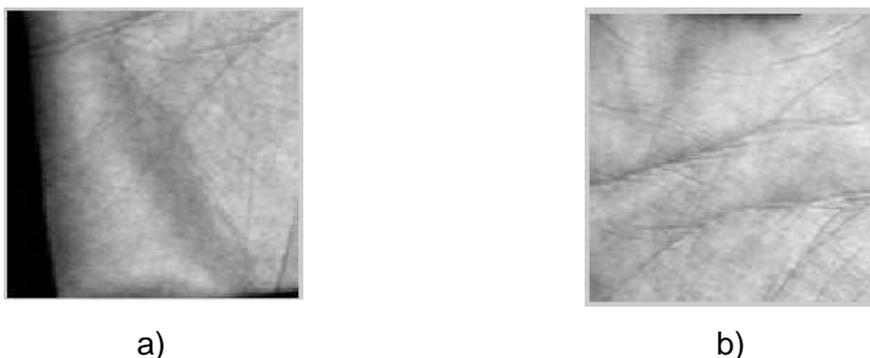


Figura 4. 3 Desempeño de los métodos umbral para PolyU

Finalmente después de realizar la umbralización mediante diversas técnicas como se aprecia en la figura 4.3, se decide utilizar un umbral calculado con el método “Huang” por el costo computacional y por tener menor error en los métodos de ROI 3, 4 y 5. Y en la comparación de imágenes se utiliza Huang y Otsu para esta base de datos.

En la figura 4.3 se observa que las imágenes de la base de datos de PolyU extraídas correctamente se encuentran en bajo porcentaje, esto se debe a que estos dos métodos no son aplicables a esta base de datos debido a que no se puede definir el punto V2 (entre el dedo medio y el anular) de los dedos por que la plantilla no permite diferenciarlo. En la figura 4.4 se presenta lo que sucede con la imagen de la ROI cuando se trata de aplicar el método ROI 1 (Figura 4.4a) y el método ROI 2 (Figura 4.4b).



*Figura 4. 4 Imágenes ROI a) Método 1. b) Método 2*

Para ingresar los datos en el clasificador se determino el 8 como número mínimo de muestra por individuo. En el caso del método 2 solo se cuenta con dos clases que cumplen esta condición por lo tanto se decide que para esta base de datos los métodos de ROI 1 y 2 no son aplicables. Más adelante se presentan las curvas CMC de estos métodos.

En la comparación de las imágenes se trabaja con los métodos umbral Otsu e Isodata para la base de datos de CASIA, Otsu y Huang para la base de datos de PolyU. Los métodos ROI 3 y 4 fueron seleccionados para establecer las diferencias entre imágenes.

Resumiendo la metodología de diferenciación umbral y de métodos ROI en la Figura 4.5 se observan los pasos hasta la obtención de las imágenes de la ROI.

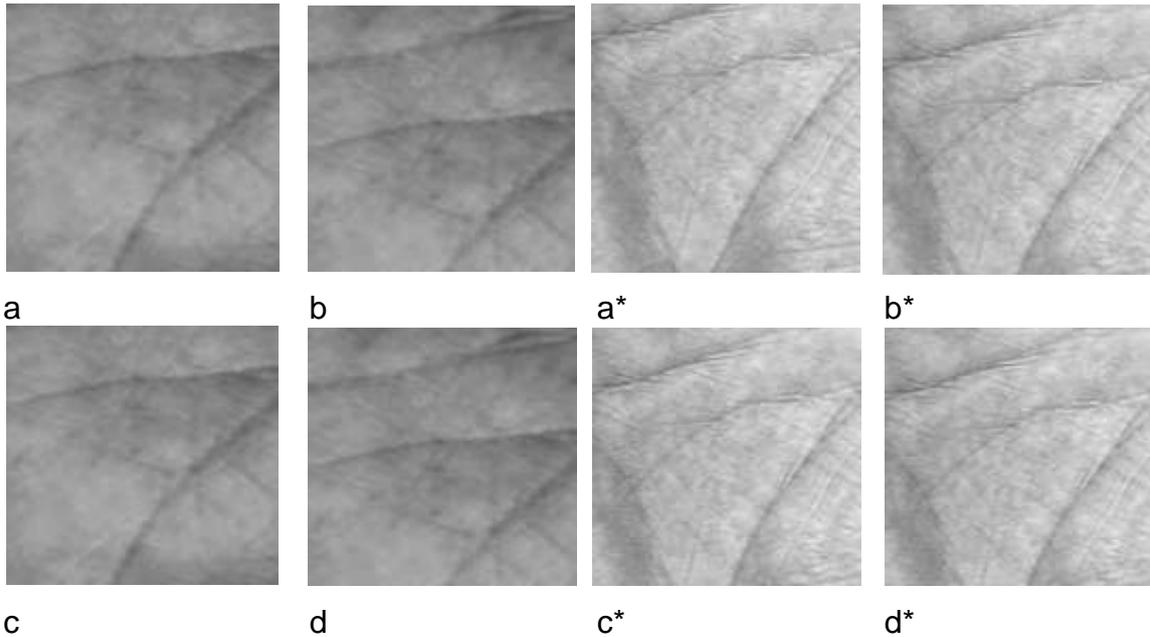


*Figura 4. 5 Mapa conceptual de la metodología diferenciación método umbral y método ROI.*

Al implementar los dos métodos de obtención de la ROI y de los dos métodos umbral para cada una de las bases de datos se obtienen las imágenes de la Figura 4.6. Las figuras correspondientes a la base de datos de CASIA fueron mejoradas para la visualización.

En la Figura 4.6 es evidente la variación que presentan las imágenes al cambiar el método ROI. Por ejemplo, al comparar 4.6a con 4.6b, se aprecia la diferencia entre las dos imágenes obtenidas por el mismo método umbral pero diferente ROI, lo mismo sucede entre las imágenes 4.6c y 4.6d. También se observa que la variación de umbral comparando el método Otsu con Isodata no es notoria mientras que entre Otsu y Huang si se presenta una variación apreciable.

Cabe anotar que el procedimiento final consiste en un filtrado de las imágenes de la ROI, en el cual se eliminan las imágenes que poseen píxeles en negro, es decir donde la ROI se sale de la imagen de la mano y coge píxeles del fondo.



*Figura 4. 6. Región de interés. a) Isodata método ROI 3 CASIA. b) Isodata método ROI 4. CASIA c) Otsu método ROI 3 CASIA. d) Otsu método ROI 4 CASIA. a\*) Huang método ROI 3 PolyU. b\*) Huang método ROI 4 PolyU. c\*) Otsu método ROI 3 PolyU. d\*) Otsu método ROI 4 PolyU.*

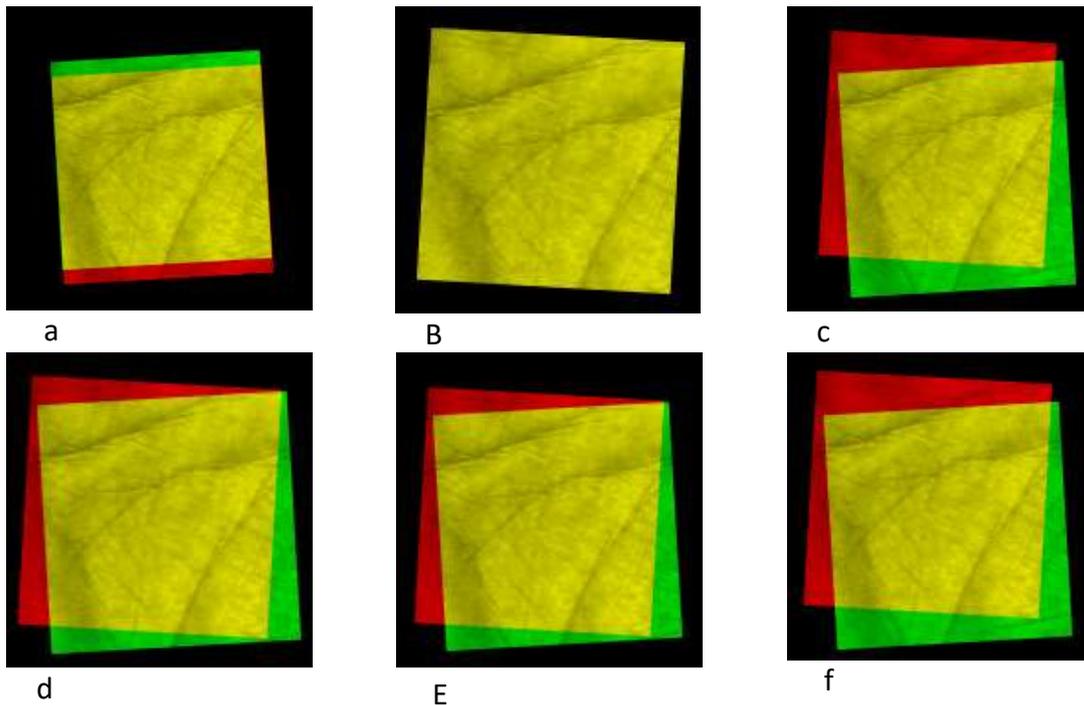
### **4.3. COMPARACIÓN DE IMÁGENES**

Para comparar los cuadros de la ROI obtenidos, sólo se utilizaron los métodos de ROI3 y ROI4 debido a que estos fueron aplicados a las dos bases de datos, además se comparan dos métodos de obtención de umbral con el fin de establecer si los cambios por método umbral varían el cuadrado de la ROI (Arroyave, Restrepo, & Vargas, 2011).

Para cada base de datos se procede a realizar comparaciones de las ROI's obtenidas variando el umbral y los métodos de ubicación de la ROI. Para la base de datos CASIA se emplean los métodos de umbralización Isodata y Otsu, mientras que para la base de datos PolyU se emplean Huang y Otsu. Debido a que con Isodata se obtuvo un mejor desempeño al generar el contorno de la mano para las imágenes de CASIA y con Huang se obtuvo un mejor contorno para las de PolyU.

Para realizar la comparación entre las ROI's, inicialmente se rota cada ROI al espacio que ocupaba antes en la imagen original. Para esto se coloca una de las imágenes sobre un fondo negro y luego sobreponer la otra imagen desplazándola hasta donde exista la mayor coincidencia entre el valor de intensidad de los píxeles, donde las imágenes coinciden espacialmente. En las Figura 4.7a y 4.7b se muestra el ajuste obtenido utilizando el umbral Huang y Otsu para los dos métodos de ubicación de la ROI, respectivamente. En las Figura 4.7c y 4.7d se muestra el ajuste obtenido utilizando los métodos de ubicación de la ROI 3 y 4 para los métodos de umbralización Huang y Otsu.

En la Figura 4.7e se muestra el ajuste obtenido utilizando el método de ubicación de la ROI 3 con umbral Otsu y la ROI 4 con umbral Huang. Mientras que en la Figura 4.7f se muestra el ajuste obtenido utilizando el método de ubicación de la ROI 4 con umbral Otsu y la ROI 3 con umbral Huang.



*Figura 4. 7. a) Umbral Huang el método ROI3 y ROI4. b) Umbral Otsu el método ROI3 y ROI4. c) Método ROI3 con umbral Huang y Otsu. d) Método ROI4 con umbral Huang y Otsu. e) Método ROI3 con umbral Otsu y ROI4 con Huang. f) Método ROI4 con umbral Otsu y ROI3 con Huang.*

En la Tabla 4.1 se presentan los promedios y sus desviaciones estándar de cada medida de comparación sobre la base de datos CASIA con 2694 imágenes.

*Tabla 4. 1 Resultados promedios de las medidas de comparación de ROI's para la base de datos CASIA.*

Métricas					
Método	Correlación	MSE	RIU	MI	AC
<b>ROI3 Otsu</b>					
<b>ROI4 Isodata</b>	0.66±0.11	2387.9±1277.7	0.99±0.005	0.43±0.15	0.71±0.09
<b>ROI3 Otsu</b>					
<b>ROI3 isodata</b>	0.99±0.02	38.14 ±130.97	0.97±0.06	1.03±0.27	1.01±0.02
<b>ROI3 isodata</b>					
<b>ROI4 Otsu</b>	0.66±0.11	2381.6±1272.4	0.99±0.005	0.43±0.15	0.72±0.09
<b>ROI4 Otsu</b>					
<b>ROI4 isodata</b>	0.99±0.02	27.955±91.892	0.97±0.07	1.03±0.27	1.01±0.01
<b>ROI3 isodata</b>					
<b>ROI4 isodata</b>	0.66±0.11	2373.3±1272.3	0.99±0.005	0.43±0.15	0.72±0.09
<b>ROI3 Otsu</b>					
<b>ROI4 Otsu</b>	0.66±0.11	2378.6±1272.7	0.99±0.005	0.43±0.15	0.72±0.09

De la Tabla 4.1 se puede observar que sobre un solo método de ubicación de la ROI, (ROI3 o ROI4) sin importar el método de umbral (Otsu o Isodata) que se utilice, se obtiene la mayor similitud en la información contenida por ambas imágenes (ROI3 Otsu – ROI3 isodata y ROI4 Otsu – ROI4 Isodata) obteniendo en ambos casos una correlación de 0.99, una información mutua de 1.03 y 1.01 de área común, estos son los máximos valores de cada métrica presentados en la tabla. Además, la información anterior es confirmada por los valores de los errores cuadráticos medios que para el caso de la ROI3 es de 38.14 y para la ROI4 es de 27.955 y para la combinación de las ROI's, el menor valor es 2373.3, que al compararlo con los errores anteriores es mucho mayor. Si lo que se varía es el método de ubicación de la ROI y se deja constante el método umbral se obtiene una correlación de 0.66.

En la Tabla 4.2 se presentan los promedios y las desviaciones estándar de cada medida de comparación sobre la base de datos PolyU con 3889 imágenes.

*Tabla 4. 2 Resultados promedios de las medidas de comparación de ROI's para la base de datos PolyU.*

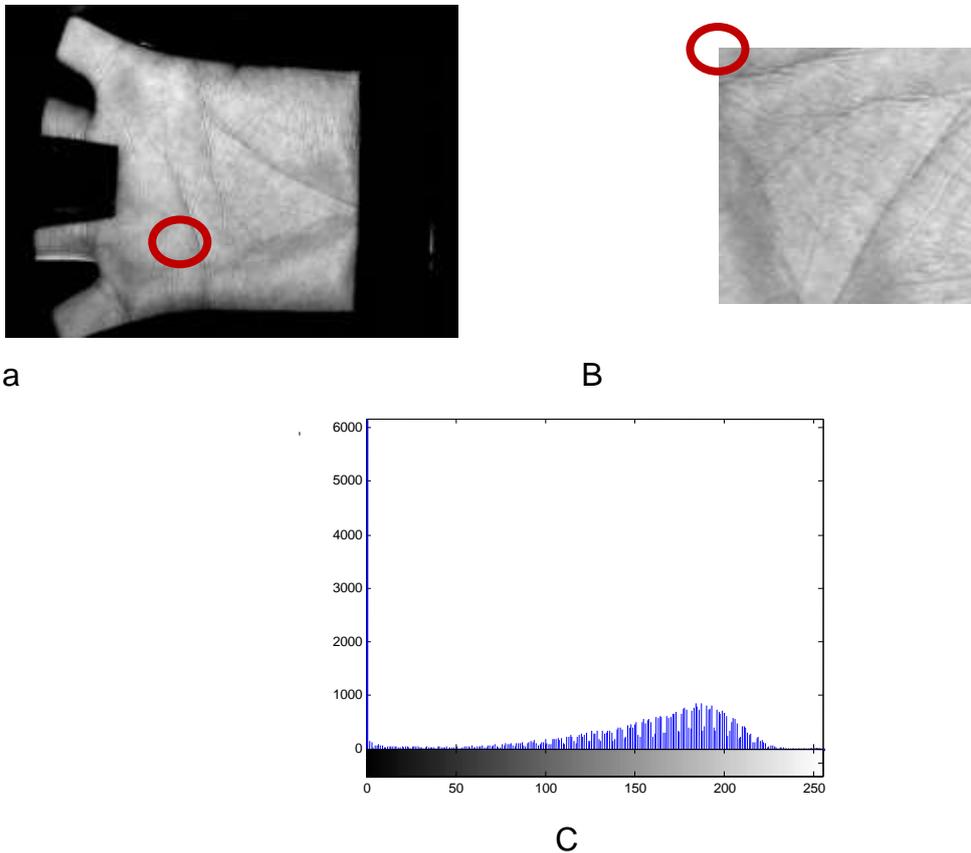
Métricas					
Método	Correlación	MSE	RIU	MI	AC
ROI3 Otsu ROI4 Huang	0.85±0.08	1799.7±1035.4	0.97±0.04	0.94±0.18	0.88±0.07
ROI3 Otsu ROI3 Huang	0.93±0.08	868.04±907.22	0.94±0.05	1.11±0.23	0.95±0.06
ROI3 Huang ROI4 Otsu	0.88±0.08	1425.6±958.89	0.96±0.04	1.00±0.20	0.91±0.07
ROI4 Otsu ROI4 Huang	0.94±0.07	734.41±845.4	0.93±0.05	1.13±0.23	0.96±0.06
ROI3 Huang ROI4 Huang	0.89±0.05	1357.2±602.04	0.96±0.03	1.19±0.26	0.92±0.04
ROI3 Otsu ROI4 Otsu	0.89±0.05	1283.9±673.33	0.96±0.04	1.19±0.28	0.92±0.05

En la Tabla 4.2, al igual que en la Tabla 4.1, se observa que sobre un solo método de ubicación de la ROI (ROI3 o ROI4) sin importar el método de umbral que se utilice (isodata y Otsu), se obtiene la mayor similitud en la información contenida por ambas ROI's. A diferencia de la base de datos CASIA, las muestras de PolyU son registradas utilizando una plantilla para poner las manos, en consecuencia se reduce la variabilidad espacial de las imágenes.

#### 4.4. VARIACIÓN EN EL BRILLO

En la Figura 4.8 se muestra una imagen de la clase 1, seleccionada de manera aleatoria y verificada en el clasificador. Donde la Figura 4.8a es la imagen original, la Figura 4.8b es la ROI de la imagen anterior y la Figura 4.8c es el

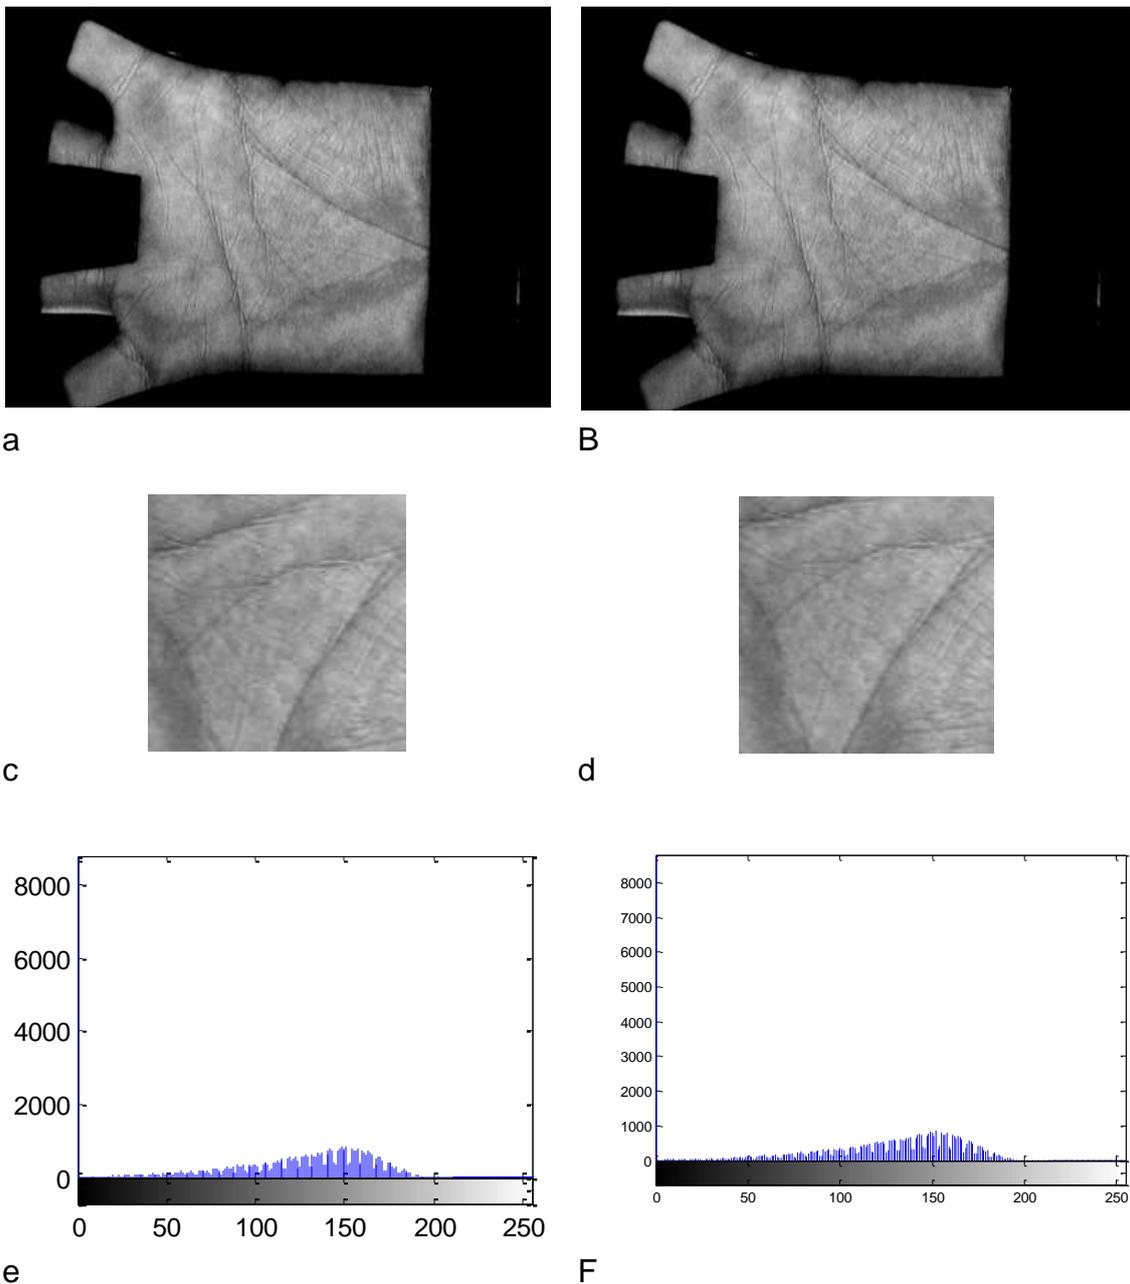
histograma de la imagen original. Las pruebas que a continuación se describen se realizaron en base a esta imagen. Como referencia y para comparar con cada prueba se tomaron las coordenadas de inicio de la ROI ( $x = 68$ ,  $y = 154$ ) como se resalta en la Figura por medio de los círculos.



*Figura 4. 8 a) Imagen original. b) Imagen de la ROI. c) Histograma*

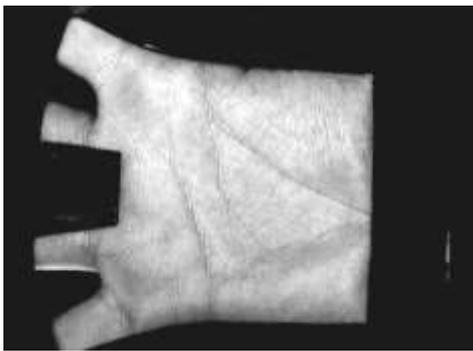
Se seleccionó una imagen de la base de datos de PolyU clase1 como se aprecia en la Figura 4.8a, esta imagen original es llevada al clasificador lineal y este la etiqueta correctamente como clase 1, luego se comienza a variar el brillo de dicha imagen y se ingresa nuevamente al clasificador en cada variación. Se detectó que el clasificador etiqueta correctamente la imagen para cambios en disminución de brillo hasta de -35, (Figura 4.9b), para -36 no se obtiene una clasificación adecuada (Figura 4.9a). En la Figura 4.9f y 4.9e se aprecian los histogramas correspondientes a la imagen 4.9b y 4.9a, respectivamente. En la Figura 4.9d y 4.9c se aprecia la ROI de las imágenes 4.9b y 4.9a respectivamente. Para el caso de la Figura 4.9c que no clasifica

adecuadamente, los puntos de la ubicación final fueron (70,144) lo cual significa que la ROI se ha desplazado (2,10) con respecto a la original ( $x = 68$ ,  $y = 154$ ). Para el caso de la Figura 4.9d que si clasifica correctamente como clase 1, los puntos de la ROI fueron (74,157) y la diferencia con respecto a la imagen original es de (6,3).



*Figura 4. 9 a) Imagen con disminución de brillo de 36 (no clasifica). b) Imagen con disminución de brillo de 35 (si clasifica). c) Imagen de la ROI (Figura a). d) Imagen de la ROI (Figura b). e) Histograma (Figura a).f) Histograma (Figura b).*

En la imagen 4.10 el clasificador etiqueta correctamente la imagen para cambios en el incremento del brillo hasta un valor de 26, (Figura 4.10b), para un valor de 27 no se obtiene una clasificación adecuada (Figura 4.10a). En las Figuras 4.10f y 4.10e se aprecian los histogramas correspondientes a las imágenes 4.10b y 4.10a respectivamente. En las Figuras 4.10d y 4.10c se muestra la ROI de las imágenes 4.10b y 4.10a respectivamente. Para el caso de la Figura 4.10c que no clasifica adecuadamente, los puntos de la ubicación final fueron (67,152) esto significa que la ROI se ha desplazado (-1,-2) con respecto a la original (x = 68, y = 154). Para el caso de la Figura 4.10d que si clasifica correctamente como clase 1, los puntos de la ROI fueron (71,152) y la diferencia con respecto a la imagen original es de (3,-2).



a



B



c



D

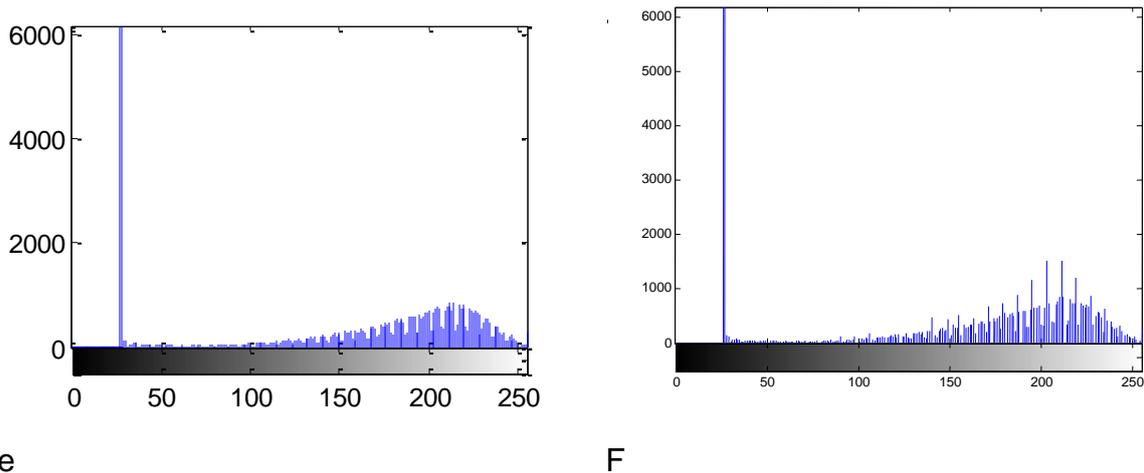
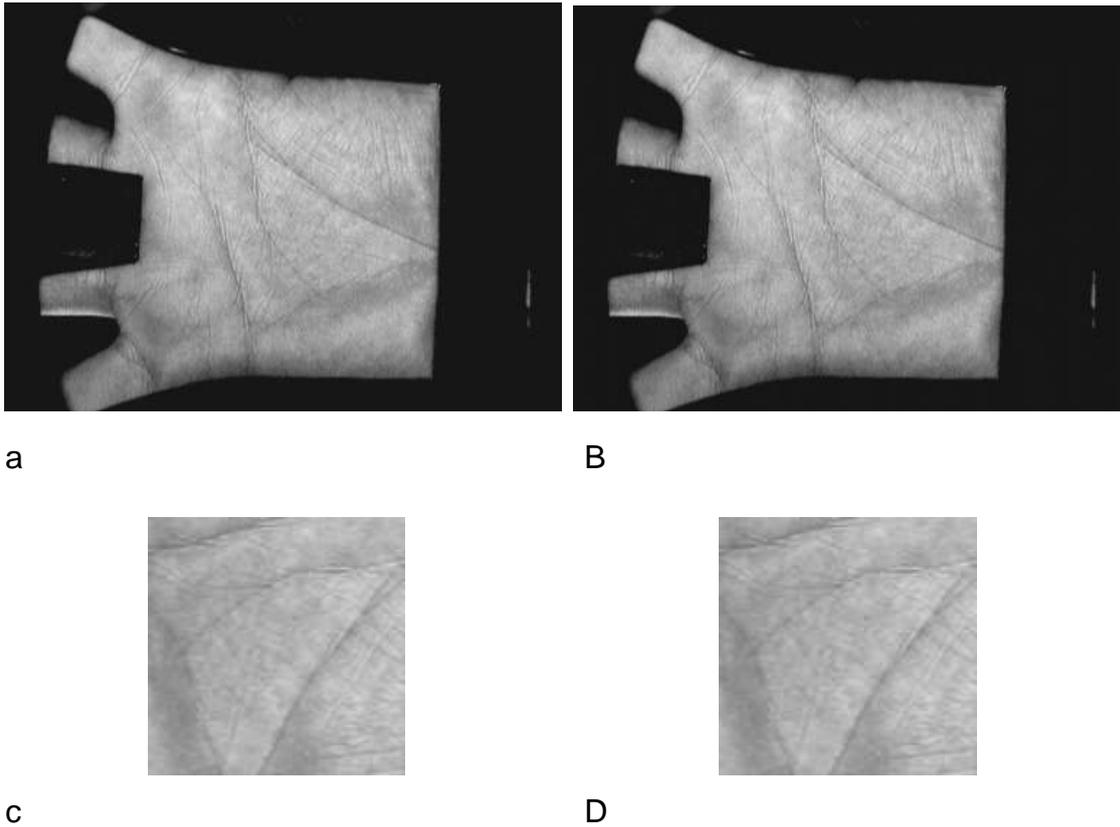


Figura 4. 10. a) Imagen con incremento de brillo de 27 (no clasifica). b) Imagen con incremento de brillo de 26 (si clasifica). c) Imagen de la ROI (Figura a). d) Imagen de la ROI (Figura b). e) Histograma (Figura a).f) Histograma (Figura b).

#### 4.5. VARIACIÓN EN EL CONTRASTE

Como se dijo anteriormente la imagen originalmente es clasificada como clase 1. Se detectó que el clasificador etiqueta correctamente la imagen para cambios en disminución de contraste hasta (19 a 200) (Figura 4.11b). Para una variación desde (20 a 210), no se obtiene una clasificación adecuada (Figura 4.11a). En la Figura 4.11c y 4.11d se aprecia la ROI de las imágenes 4.11a y 4.11b respectivamente. Para el caso de la Figura 4.11c que no clasifica adecuadamente los puntos de la ubicación final fueron (71,153) esto significa que la ROI se ha desplazado (3,-1) con respecto a la original (x=68,y=154). Para el caso de la Figura 4.11d que si clasifica correctamente como clase 1, los puntos de la ROI fueron (71,153) y la diferencia con respecto a la imagen original es de (3,-1), obteniendo el mismo desplazamiento.



*Figura 4. 11 a) Imagen con disminución de contraste de (20 -210) (no clasifica). b) Imagen con disminución de contraste de (19 -200) (si clasifica). c) Imagen de la ROI (Figura a). d) Imagen de la ROI (Figura b).*

En la imagen 4.12 el clasificador etiqueta correctamente la imagen para cambios en disminución de contraste entre 102 y 179 (Figura 4.12b) y para un rango entre 77 y 179 no se obtiene una clasificación adecuada (Figura 4.12a). En la Figura 4.12d y 4.12c se aprecian las imágenes de la ROI de las imágenes 4.12b y 4.12a respectivamente. Para el caso de la Figura 4.12c la cual no clasifica adecuadamente, los puntos de la ubicación final fueron (82,167) esto significa que la ROI se ha desplazado (14,-13) con respecto a la original (x = 68, y = 154). Para el caso de la Figura 4.12d que si clasifica correctamente como clase 1, los puntos de la ROI fueron (110,164) y la diferencia con respecto a la imagen original es de (42,10).

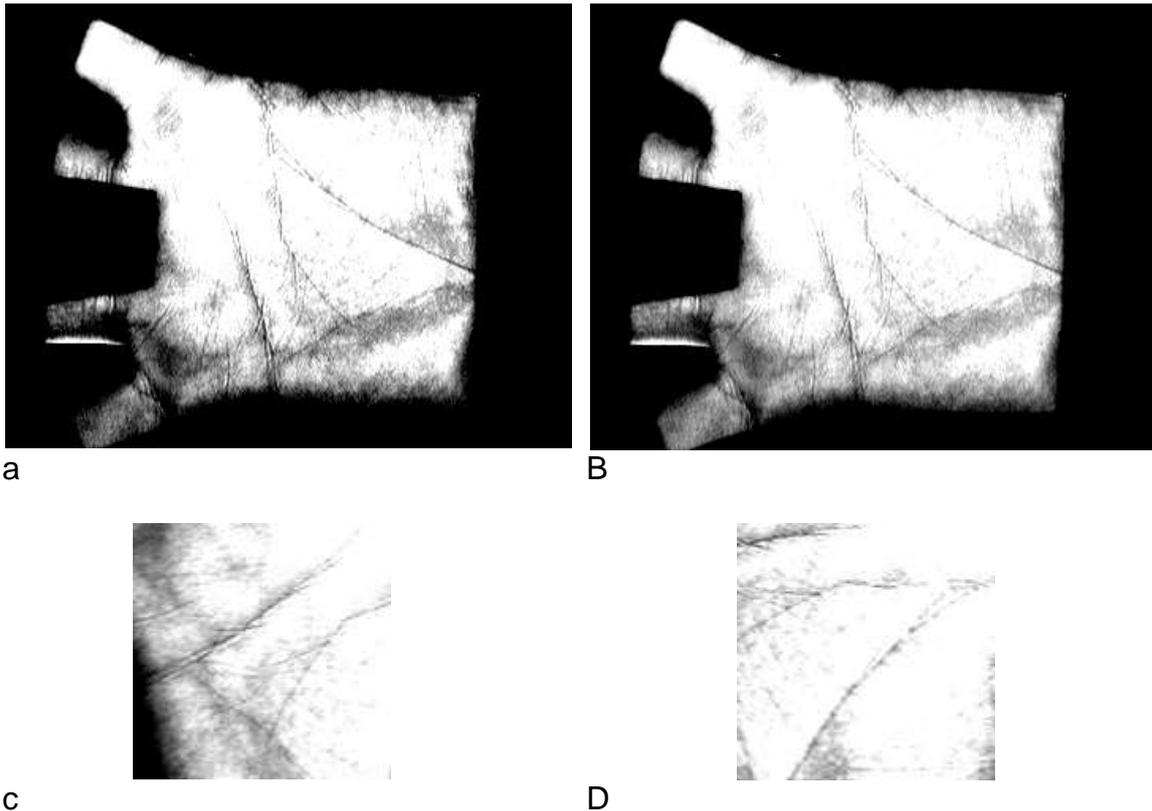


Figura 4. 12 a) Imagen con incremento de contraste de 77 a 179 (no clasifica). b) Imagen con incremento de contraste de 102 a 179 (si clasifica). c) Imagen de la ROI (Figura a). d) Imagen de la ROI (Figura b).

#### 4.6. VARIACIÓN EN EL DESPLAZAMIENTO DE LA ROI

Se realizaron pruebas de la ROI (método 3 clase 1, base de datos PolyU) con desplazamiento en x y en y positivos (hacia la derecha y hacia abajo respectivamente) y negativos (hacia la izquierda y hacia arriba). En la Figura 4.13a se aprecia la imagen al desplazar la ROI 30 pixeles hacia la izquierda del eje x, este es el desplazamiento máximo permitido en esta dirección para que el clasificador acierte. En la Figura 4.13b se aprecia el mayor desplazamiento permitido hacia la derecha sobre el eje x (17 pixeles). En la Figura 4.13c se aprecia el máximo desplazamiento negativo en el eje y (8 pixeles) y finalmente la Figura 4.13d muestra el desplazamiento de 19 pixeles en sentido positivo sobre el eje y que permiten una adecuada clasificación.

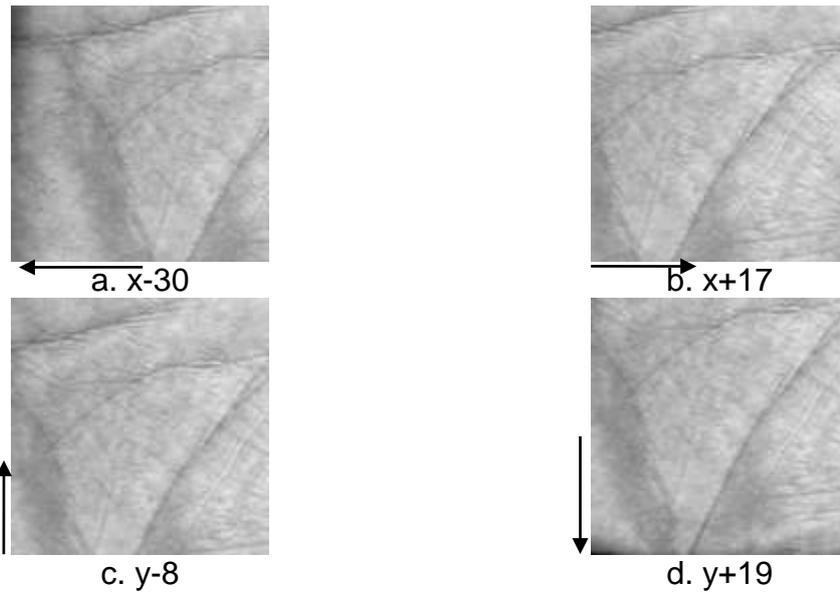


Figura 4. 13. Desplazamiento de la ROI. a) desplazamiento en x de - 30. b) desplazamiento en x de +17. c) desplazamiento en y de -8. d) desplazamiento en y de +19.

En la Figura 4.14 se aprecian los desplazamientos de la ROI para igual número de pixeles en diagonal, es decir, en la Figura 4.14a se muestra un desplazamiento positivo de 13 pixeles en x y 13 pixeles en y. En la Figura 4.14b se muestra un desplazamiento positivo de 5 pixeles en x y un desplazamiento negativo de 5 pixeles en y. En la Figura 4.14c se muestra un desplazamiento negativo de 14 pixeles en x y 14 pixeles en y. Y finalmente en la Figura 4.14d se muestra un desplazamiento negativo de 16 pixeles en x y un desplazamiento positivo 16 pixeles en y. Estos son los máximos desplazamientos en diagonal que permite la ROI sin error en la clasificación.





Figura 4. 14 Desplazamientos diagonales de la ROI. a) Desplazamiento en x de +13 y en y de +13. b) Desplazamiento en x de +5 y en y de -5. c) Desplazamiento en x de -14 y en y de -14. d) Desplazamiento en x de -16 y en y de +16.

Como se aprecia en la Figura 4.15 al generar desplazamientos en diagonal para la ROI los LBP's se modifican un poco, sin embargo estas variaciones no afectan la clasificación.

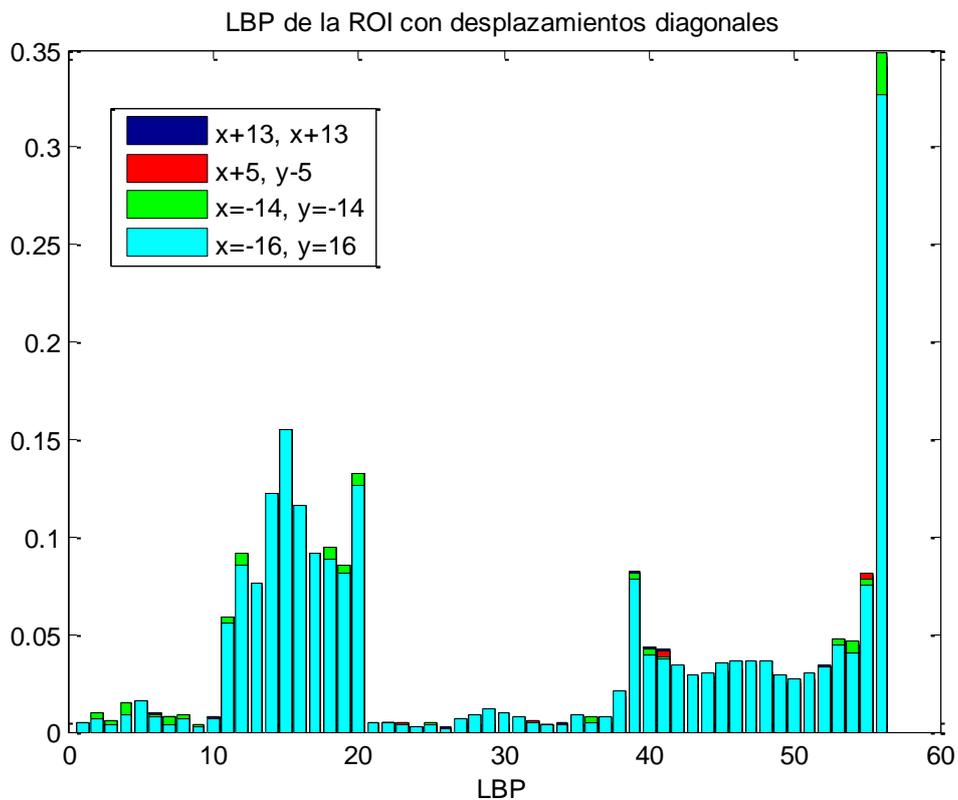


Figura 4. 15. LBP's de la ROI con desplazamientos en diagonal

#### 4.7. ANÁLISIS DE SINTONIZACIÓN

Se realizaron varias pruebas en la clasificación con la función de sobremuestreo (SMOTE) y con selección de características. Se seleccionó una configuración de LBP aleatoria para con el fin de simplificar la pruebas y no realizarlo con todas las configuraciones de LBP, se trabajo con las imágenes de PolyU método 3 y con el LBP de histograma no adaptativo, de radio 8 y con bloques de 16X16, con valores de dispersión de la campana gaussiana (parámetro C) desde 0.001 hasta 100, obteniendo resultados con variaciones de 0.0001 en el área bajo la curva CMC (Figura 4.16), lo cual no representa una cifra significativa en los resultados obtenidos. En cuanto a los tiempos requeridos para el cálculo se aprecia en la Tabla 4.3 como mejor tiempo de repuesta el clasificador programado con  $c=1$ , seguido de  $c= 0.1$  con un tiempo de ejecución de 4929 segundos (El equipo utilizado para las pruebas fue un Intel Core i7-740QM, 1.73GHz, con 8GB de RAM), este último por tener el segundo mejor tiempo de ejecución y por tener mayor área bajo la curva, fue el seleccionado para la continuación del trabajo y el análisis de los patrones binarios locales con diferentes parámetros de sintonización.

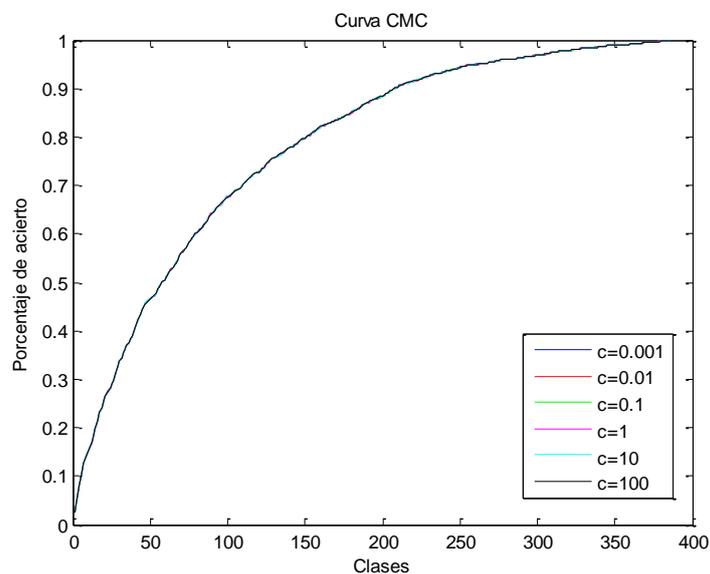


Figura 4. 16. Sintonización del clasificador

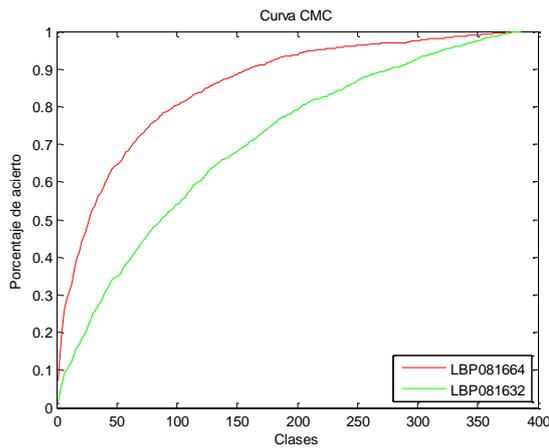
Tabla 4. 3 Área bajo la Curva CMC de sintonización

	Área bajo la curva CMC	Tiempo de cálculo(seg)
<b>C=0.001</b>	0.780774729095314	5111
<b>C=0.01</b>	0.780815327007545	4979
<b>C=0.1</b>	0.780834762178294	4929
<b>C=1</b>	0.780766955027015	4907
<b>C=10</b>	0.780762636100182	5175
<b>C=100</b>	0.78084599138806	5829

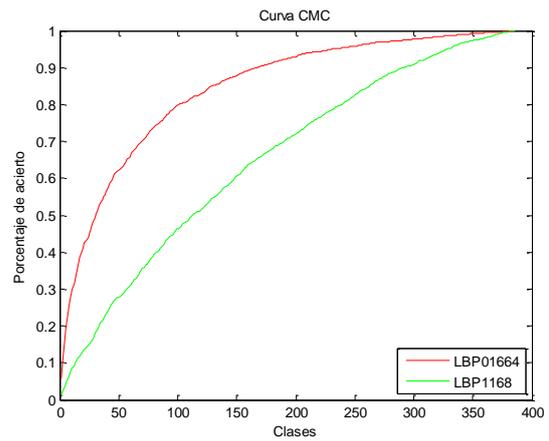
#### 4.8. EVALUACIÓN DE LOS LBP'S

##### 4.8.1 Base de datos PolyU

Se tabularon los valores de área bajo la curva y de tiempo requerido para el cálculo en cada caso de LBP. En la Tabla 4.4 se muestran los resultados para los métodos de ROI 3 y ROI 4, de la base de datos PolyU (solo se aplicaron estos 2 métodos debido a que las plantillas utilizadas en esta base de datos no permitían diferenciar los puntos valles de los dedos que se requerían para los métodos 1, 2 y 5, debido a que los dedos en estas imágenes están cortados) , para el método 3 se presentan variaciones en el área bajo la curva desde 0.702231 para LBP0816\_32 hasta 0.852758 para LBP0816\_64, esto se aprecia gráficamente en la Figura 4.17, además las variaciones en los tiempos de ejecución se encuentran entre 2403s para LBP0816\_64 y 6634s para LBP016\_32. Y para el método 4 se presentan variaciones en el área de 0.65295 (LBP116\_8) a 0.844542 (LBP016\_64). En la Figura 4.17 se aprecian las variaciones entre la mayor y la menor área que se genera con la curva CMC para cada método de la ROI, que para el método 3 la diferencia es del 15% y para el método 4 es del 17%. De lo anterior se deduce que los parámetros para el cálculo de los LBP's varían considerablemente los resultados de la clasificación.



a)



b)

Figura 4. 17. Curva CMC para la base de datos PolyU. a) Método 3, b) método 4

Tabla 4. 4 Área bajo la curva para la base de datos PolyU.

ÁREA BAJO LA CURVA CMC				
	Método ROI 3	Tiempo(seg)	Método ROI 4	Tiempo(seg)
LBP 0 8_64	0.780809	5103	0.771712	6330
LBP 0 8_32	0.808411	4481	0.735252	8687
LBP 0 8_16	0.756251	5269	0.733478	8753
LBP 0 8_8	0.733509	5700	0.72858	9135
LBP 1 8_64	0.776262	5037	0.734032	9468
LBP 1 8_32	0.77687	4951	0.73578	8645
LBP 1 8_16	0.742057	5382	0.734135	8738
LBP 1 8_8	0.720639	5822	0.711392	9199
LBP 0 8 16_64	<b>0.852758</b>	2403	0.843263	3290
LBP 0 8 16_32	<b>0.702231</b>	4914	0.809958	4746
LBP 0 8 16_16	0.81626	3186	0.708864	7334
LBP 0 8 16_8	0.721221	4947	0.690176	5912
LBP 1 8 16_64	0.80176	3524	0.818232	4854
LBP 1 8 16_32	0.80176	3624	0.794869	5738
LBP 1 8 16_16	0.81041	4317	0.777551	7451
LBP 1 8 16_8	0.723504	5433	0.666462	7195
LBP 0 16_64	0.818722	3780	<b>0.844542</b>	4100
LBP 0 16_32	0.708498	6634	0.810118	4717
LBP 0 16_16	0.816107	3053	0.708927	7406
LBP 0 16_8	0.721309	4708	0.670065	7159
LBP 1 16_64	0.807115	3298	0.818129	4827
LBP 1 16_32	0.826728	3531	0.794822	5583
LBP 1 16_16	0.810697	3708	0.711221	9006
LBP 1 16_8	0.725214	6022	<b>0.65295</b>	

#### 4.8.2 Base de datos CASIA

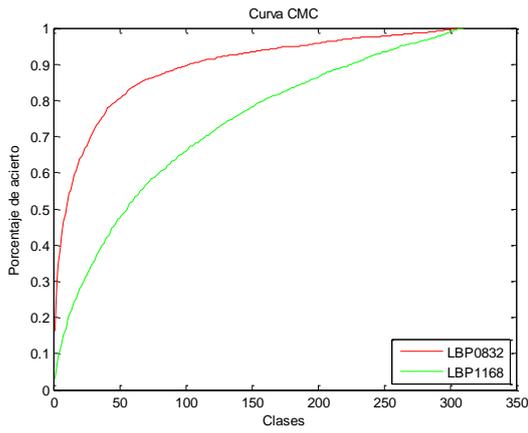
En la Tabla 4.5 para los métodos de 1 a 5 de la base de datos de CASIA, de manera similar a la tabla anterior, se resaltan y subrayan los valores máximos de área bajo la curva, se resaltan y se ponen en cursiva los valores mínimos, además debajo de cada valor de área se encuentra el tiempo de ejecución requerido en segundos para entrenar y validar el clasificador. No se realizó el análisis para el método 6 debido a que dicho método requiere mayor costo computacional al necesitar varias rotaciones de la imagen y requerir ubicar puntos adicionales y además era necesario eliminar gran cantidad de muestras de la base de datos debido a que no en todas las imágenes se lograba extraer la ROI adecuada (sin píxeles en negro).

También en la Tabla 4.5 se aprecia que la menor área bajo la curva CMC es para los LBP's con histograma adaptativo de 16 vecinos y con bloques de 8x8 esto sucede para todos los métodos de la ROI lo cual muestra similitud en las curvas de cada uno de los métodos. Para el caso de la menor área coinciden todos los métodos de la ROI (1, 2, 3, 4 y 5) en el LBP116\_8. Los métodos 1, 2, 3 y 4 presentan mayor área para el LBP 0 8\_64 a diferencia del método 5 que el área mayor corresponde a LBP 0 8\_32; esto muestra de algunas de las diferencias en los métodos de ROI, además se observa en la gráfica que el mejor desempeño se presenta al utilizar el método 2.

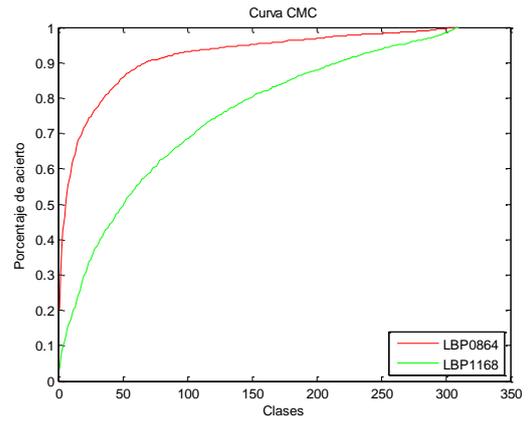
La variación tanto en el área bajo la curva como en el tiempo de cálculo cambia significativamente al modificar los parámetros de obtención de los LBP's como se aprecia en las tablas anteriores. Analizando la base de datos de CASIA se observa en la Figura 4.18a, la diferencia entre las curvas (máximo y mínimo) es de 16.9%, para las Figuras 4.18b y 4.18d es 17.6% y para las Figuras 4.18c y 4.18e es de 17%. Se concluye que con tamaños grandes en los bloques en los LBP's (64x64 y 32x32) se obtienen mejores resultados que para bloques pequeños (8x8).

Tabla 4. 5 Área bajo la curva para la base de datos CASIA.

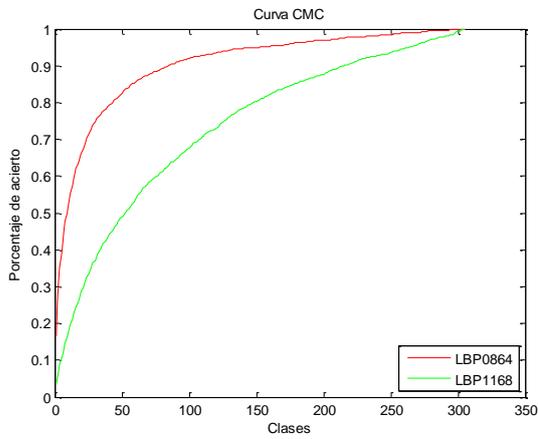
ÁREA BAJO LA CURVA CMC					
	Método ROI 1	Método ROI 2	Método ROI 3	Método ROI 4	Método ROI 5
<b>LBP 0 8_64</b>	<b>0.895312</b> 1168	<b>0.916332</b> 1113	<b>0.904044</b> 1171	<b>0.908577</b> 1197	0.885617 1024
<b>LBP 0 8_32</b>	0.89083 1210	0.902178 1188	0.89555 1210	0.901861 1197	<b>0.898856</b> 1029
<b>LBP 0 8_16</b>	0.864479 1352	0.89489 1269	0.815297 1692	0.850424 1485	0.876025 1180
<b>LBP 0 8_8</b>	0.85793 1607	0.892245 1378	0.812775 2096	0.872757 1556	0.873089 1335
<b>LBP 1 8_64</b>	0.847028 1487	0.877112 1462	0.849192 1429	0.868195 1426	0.831718 1336
<b>LBP 1 8_32</b>	0.852028 1400	0.861105 1427	0.863839 1330	0.86833 1383	0.842314 1288
<b>LBP 1 8_16</b>	0.841569 1476	0.861246 1458	0.83912 1438	0.886738 1285	0.873565 1204
<b>LBP 1 8_8</b>	0.817641 1754	0.849752 1656	0.84335 1472	0.848259 1656	0.833198 1396
<b>LBP 0 8 16_64</b>	0.884866 1505	0.902065 1355	0.88859 1428	0.901862 1477	0.896894 1148
<b>LBP 0 8 16_32</b>	0.887675 1487	0.897941 1523	0.887585 1536	0.903379 1881	0.881521 1165
<b>LBP 0 8 16_16</b>	0.867714 1515	0.885724 1456	0.871923 1472	0.890338 1778	0.879026 1145
<b>LBP 0 8 16_8</b>	0.824652 1461	0.861156 1401	0.81022 1479	0.833999 1757	0.841181 1266
<b>LBP 1 8 16_64</b>	0.866123 1521	0.878721 1437	0.869497 1542	0.894283 1820	0.873466 1301
<b>LBP 1 8 16_32</b>	0.867492 1600	0.876744 1527	0.863204 1574	0.896285 1849	0.885635 1240
<b>LBP 1 8 16_16</b>	0.883419 1628	0.882783 1602	0.859386 1551	0.877346 1940	0.867848 1348
<b>LBP 1 8 16_8</b>	0.800512 1548	0.845891 1408	0.848839 1522	0.851223 1560	0.824453 1402
<b>LBP 0 16_64</b>	0.861971 1373	0.893676 1219	0.869886 1332	0.876515 1354	0.882851 1297
<b>LBP 0 16_32</b>	0.856412 1459	0.878051 1366	0.850314 1379	0.875672 1439	0.85947 1363
<b>LBP 0 16_16</b>	0.81518 1547	0.855976 1402	0.835943 1430	0.844704 1464	0.851303 1364
<b>LBP 0 16_8</b>	0.778213 1765	0.792487 1598	0.78357 1626	0.782037 1683	0.776631 1535
<b>LBP 1 16_64</b>	0.776759 1694	0.822157 1472	0.785558 1567	0.809554 1591	0.803494 1340
<b>LBP 1 16_32</b>	0.775359 1715	0.783566 1543	0.779605 1567	0.80182 1602	0.8104 1319
<b>LBP 1 16_16</b>	0.779947 1745	0.784847 1606	0.771857 1591	0.759641 1717	0.771311 1428
<b>LBP 1 16_8</b>	<b>0.725537</b>	<b>0.740567</b>	<b>0.73401</b>	<b>0.732691</b>	<b>0.728279</b>



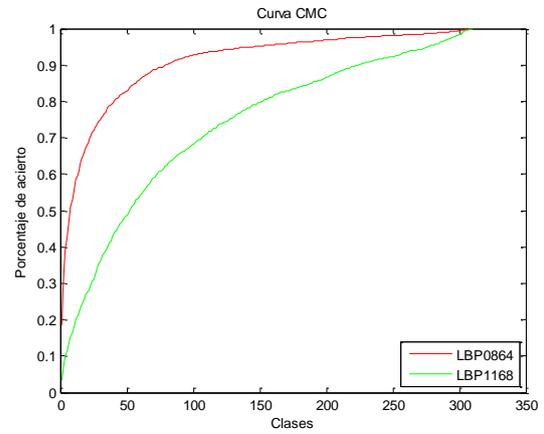
a



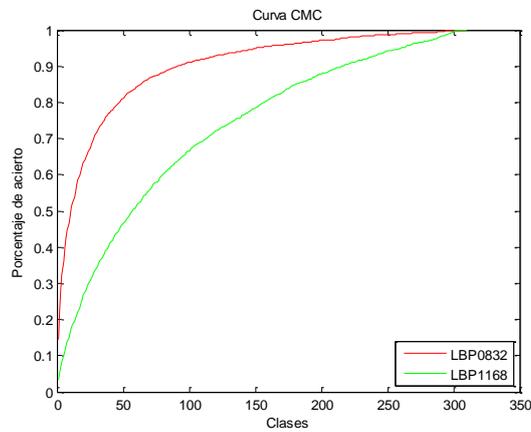
b



c



d



e

Figura 4. 18. Curvas CMC para la base de datos CASIA a). Método 1, b) Método 2, c). Método 3, d) Método 4, e). Método 5.

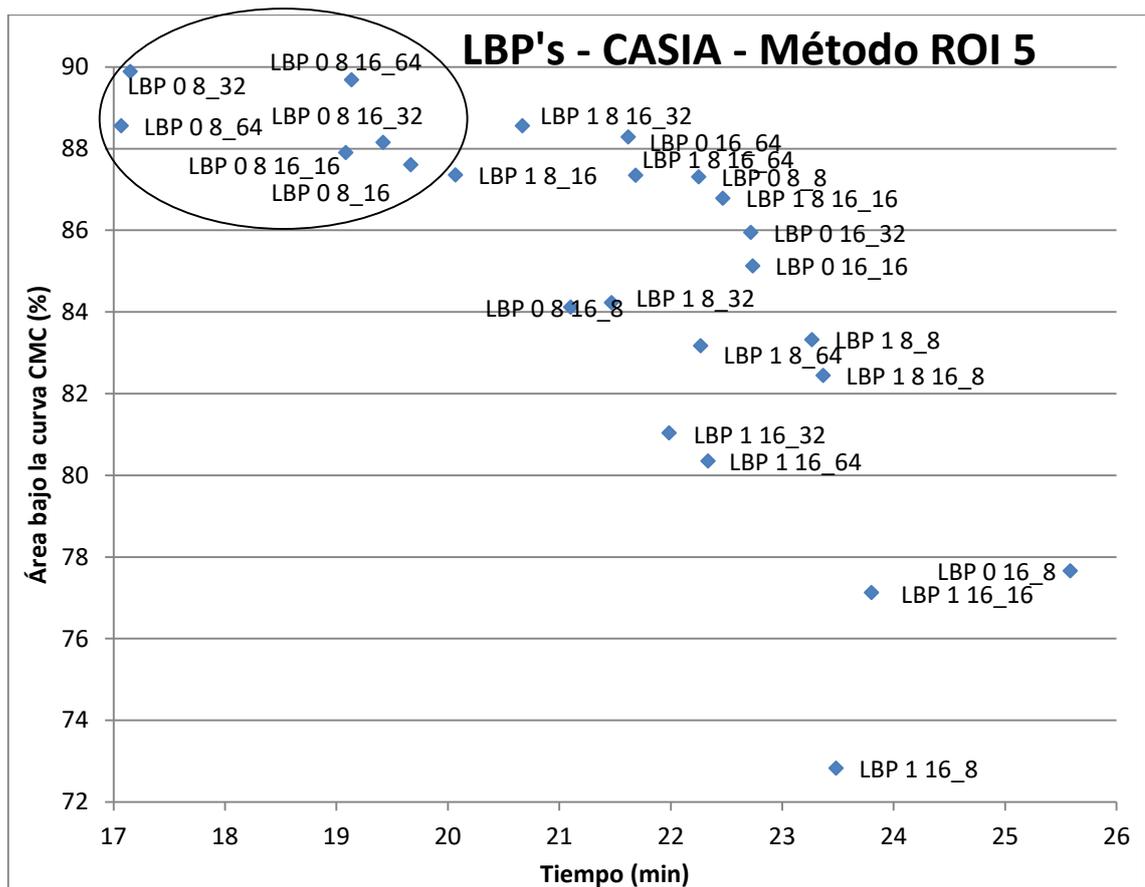


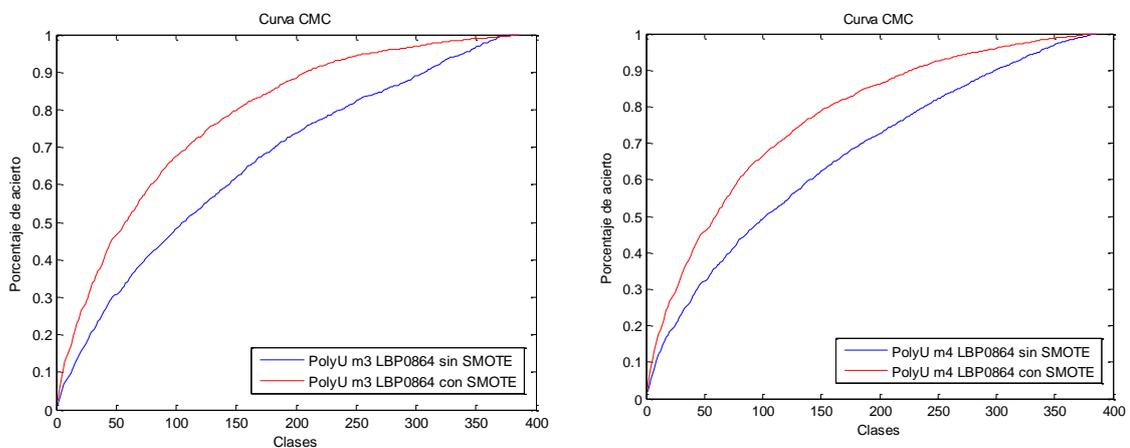
Figura 4. 19. LBP's CASIA Método 5

En la Figura 4.19 se presentan los diferentes grupos de LBP's, evaluando el tiempo de ejecución del programa y el porcentaje de acierto con el área bajo la curva CMC. Se resaltan las configuraciones donde se obtuvieron los mejores resultados. Para todos los métodos de ROI de ambas bases de datos se concluye que el mejor desempeño tanto en tiempo como en área lo tienen los LBP's con histogramas no adaptativos y tamaños de bloque grandes (32x32 y 64x64). Los histogramas adaptativos al mejorar el contraste generan cambios en la textura de la imagen original y por lo tanto alteran la clasificación. Las graficas de los otros métodos de ROI se encuentran en los anexos. Estos tiempos se refieren al entrenamiento del clasificador, esto implica que por las diferencias de los descriptores se requiere un mayor entrenamiento para poder separar las clases.

#### 4.9. ANÁLISIS DE LA TÉCNICA DE SOBREMUESTREO

Se desarrollaron dos programas a los cuales se le ingresaron los mismos LBP's para cada uno de los métodos se seleccionó el LBP0864 por presentar mayor área bajo la curva CMC en tres de los siete métodos utilizados, uno de los programas realizó todo el proceso de clasificación en la SVM pero sin la función SMOTE y el otro programa tenía exactamente el mismo código pero con la función SMOTE, esto se utilizó con el fin de verificar si el proceso de clasificación presentaba mejoras al balancear las muestras antes de ingresarlas al clasificador, los resultados se aprecian en la Figura 4.7 y en la Figura 4.8 donde se pueden ver las curvas, la roja representa los resultados al utilizar SMOTE y la azul al no utilizarlo.

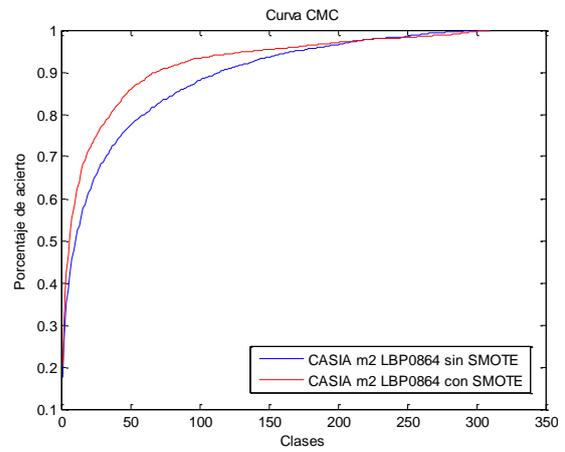
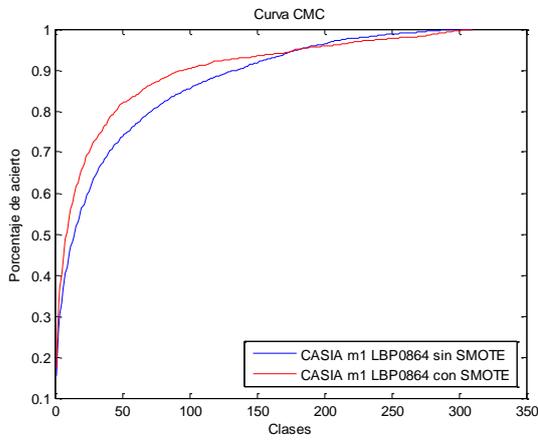
Como se aprecia en la Figura 4.20 y en la Figura 4.21, para todos los métodos evaluados los mejores resultados se presentan cuando se utiliza el sobremuestreo, aunque en la Figura 4.20 se observa un punto crítico donde después de varias iteraciones la curva CMC del clasificador sin balance supera a la curva del clasificador con SMOTE. La función SMOTE a pesar de ser una técnica donde se manejan datos sintéticos, el clasificador logra un mejor entrenamiento. Además de las curvas se realizaron varios experimentos para obtener el número de aciertos y para todos los casos los mejores resultados se obtuvieron con el balance de las muestras.



a

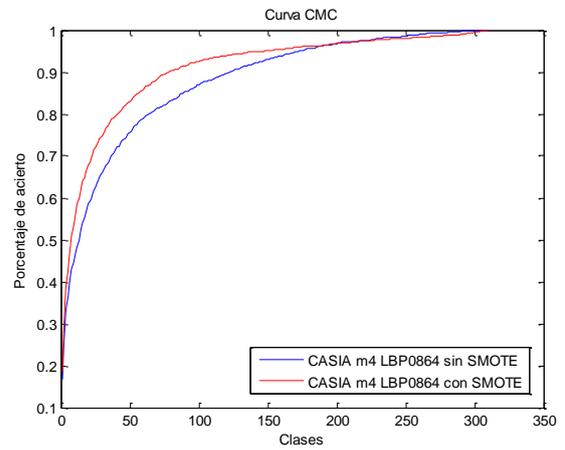
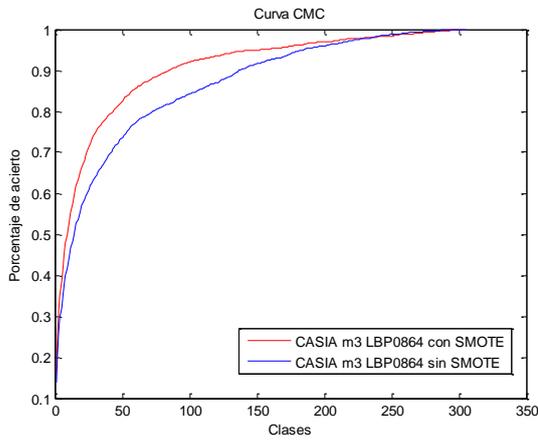
b

Figura 4. 20 CMC PolyU con y sin SMOTE. a) Método 3, b) método 4.



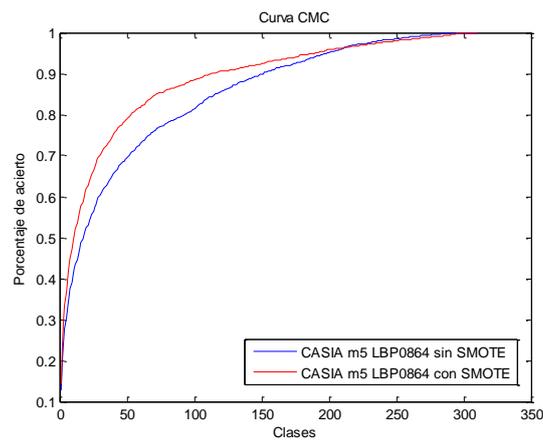
a

b



c

d



e

Figura 4. 21 CMC CASIA con y sin SMOTE. a) Método 1, b) método 2, c) método 3, d) método 4, e) método 5.

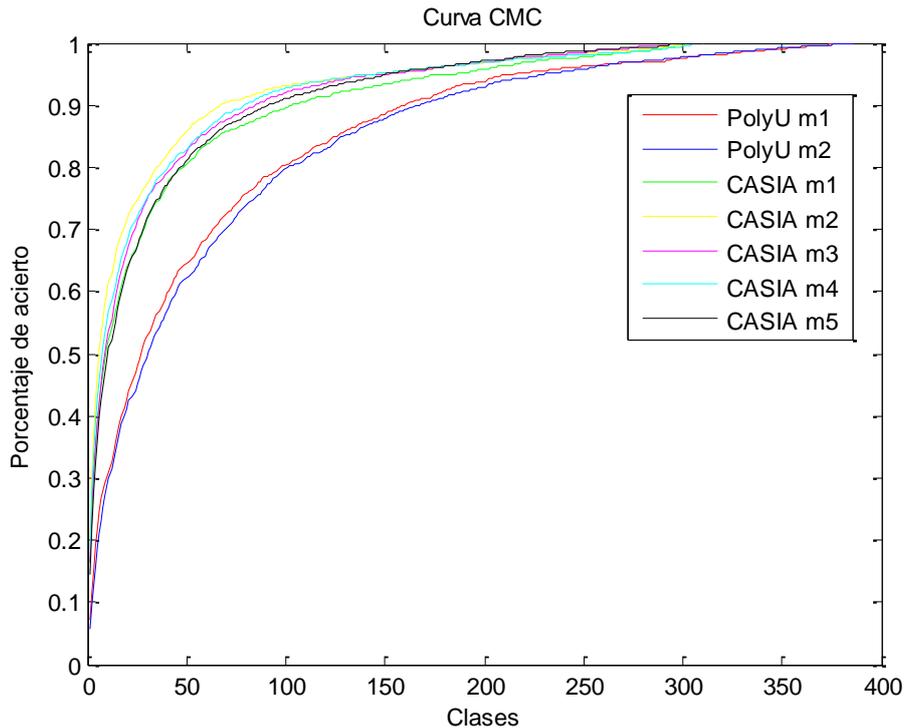
En la Tabla 4.6 se muestra el porcentaje de área bajo la curva y los errores que se pueden evitar al utilizar una técnica de sobremuestreo como SMOTE, en todos los casos de estudio se obtuvieron los mejores resultados al utilizar esta técnica. La baja cantidad de individuos afecta el entrenamiento por lo tanto es necesario utilizar técnicas de ajuste y balance de muestras.

*Tabla 4. 6 Porcentaje de acierto área bajo la curva CMC*

<b>MÉTODOS</b>	<b>Con balance de muestras</b>	<b>Sin balance de muestras</b>
<b>CASIA m1</b>	89.51958	86.86158
<b>CASIA m2</b>	91.73748	88.54171
<b>CASIA m3</b>	90.40444	86.28326
<b>CASIA m4</b>	90.81449	87.77214
<b>CASIA m5</b>	88.42202	84.80970
<b>PolyU m3</b>	78.08252	66.01388
<b>PolyU m4</b>	77.17406	66.54504

#### **4.10. ANÁLISIS DE LOS MÉTODOS DE LA ROI**

En la Figura 4.22 se aprecian los LBP's que presentaron la mayor área bajo la curva CMC para cada método de ROI, donde se evidencian pocas diferencias entre las curvas de cada base de datos.

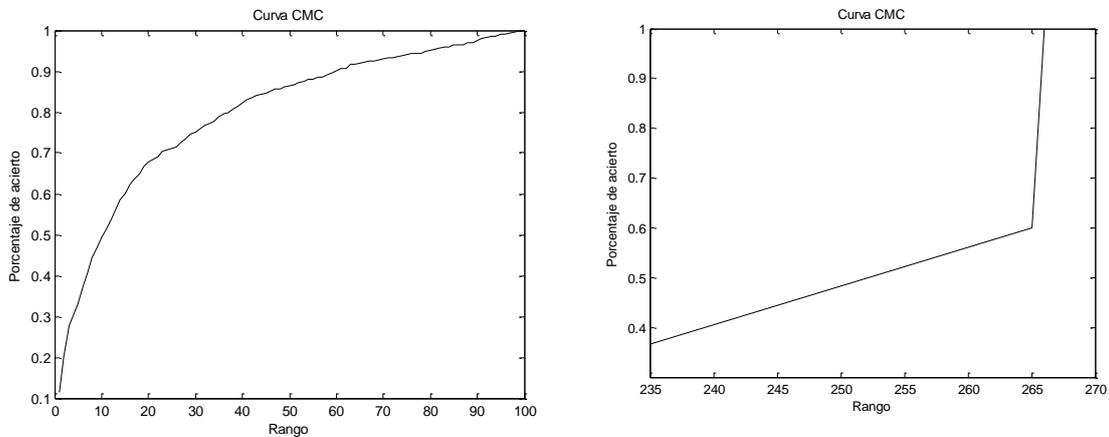


*Figura 4. 22 Mejores Curvas LBP's.*

Para realizar la comparación de la variación de los métodos de la ROI se fijó un método de obtención de LBP para comparar bajo los mismos criterios el cambio de la curva al variar cada método, el LBP seleccionado se obtuvo con histograma no adaptativo, con radio 8 y bloque de 64x64 (LBP08\_64), los resultados se aprecian en la Figura 4.24.

Como se mencionó anteriormente los métodos de ROI 1 y 2 en PolyU no se utilizaron para el análisis, debido a que estas imágenes incluían zonas en negro que no pertenecían a la palma, sin embargo se generaron las graficas CMC de los resultados del clasificador para el LBP 0 8 64. Para el método ROI 1 (Figura 4.23a) se obtuvo una área bajo la curva de 80% pero solo con 100 clases y en el método ROI 2 (Figura 4.23b) solo se generaron 2 clases que tuvieran al menos ocho muestras por individuo. El bajo número de clases y el estado de las imágenes por no poder ubicar uno de los puntos fueron las razones que no permitieron evaluar estos dos métodos contra los demás métodos. El método ROI5 en PolyU tampoco se contempla en el análisis

debido a que la máquina de soporte no podía concluir su entrenamiento después de cinco intentos.



*Figura 4. 23. Curvas CMC con LBP 0 8 64 PolyU a) método 1. b) método 2*

En la Figura 4.24 las primeras dos curvas (roja y azul) representan la curva acumulativa CMC para la base de datos de PolyU, la diferencia tanto entre las curvas como en las áreas es poco significativa, igualmente sucede con las curvas de CASIA, aunque en estas últimas las diferencias son más notorias. En la Tabla 4.6 se puede apreciar los valores dados por las diferencias entre las áreas con las curvas generadas para la base de datos de CASIA y de PolyU.

Nota: Se encuentran diferencias en la base de datos de imágenes que se utiliza, lo cual afecta las regiones de interés.

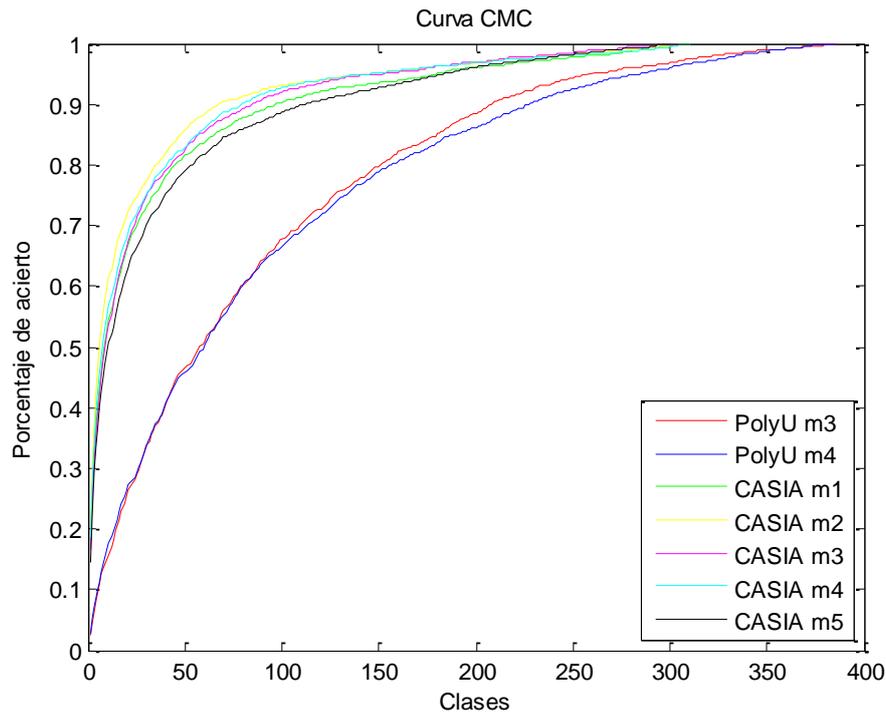


Figura 4. 24 Curvas CMC con LBP 0 8 64.

Tabla 4. 7 Diferencias entre áreas CMC

Métodos	Diferencia
Método 1-2 CASIA	0,02102
Método 3-2 CASIA	0,012288
Método 4-2 CASIA	0,007755
Método 5-2 CASIA	0,030715
Método 3-4 PolyU	0,009495

Como base de comparación entre las áreas obtenidas con la base de datos de CASIA, se tomó el valor generado por el método de la ROI 2 para establecer la diferencia con cada uno de los métodos restantes y para la base de datos de PolyU se toma sólo el error entre los dos métodos (3 y 4). En la Tabla 4.7 se aprecia la diferencia de errores absolutos entre estas áreas.

Comparando las variaciones encontradas al utilizar diferentes parámetros para el cálculo de los LBP's y las variaciones generadas por los métodos de ROI se aprecia que la mayor afectación se da por la selección de los parámetros de los

LBP's (descriptores), debido a que estos presentan diferencias en promedio del 17% y para el caso de los métodos de la ROI la mayor diferencia es de 3% y la menor de 0.9%, así que la selección del método de la ROI no presenta variaciones considerables, mientras que la variación en los descriptores realmente afecta los resultados finales. El tipo de muestras de adquisición también afecta los resultados.

Con los tiempos de ejecución y ajuste de la máquina de soporte se verificó lo presentado en (Resendiz, 2006), donde se argumenta que la complejidad de SVM es dependiente del número de datos de entrenamiento, presentando una dependencia entre el costo computacional y el número de datos de entrenamiento, haciendo que este método sea admisible solamente para aprendizaje fuera de línea.

Como se mencionó anteriormente se decidió visualizar los resultados mediante las curvas CMC por tratarse de una clasificación multiclase, sin embargo para visualizar la matriz de confusión solo para dos de las clases, se selecciono el mejor resultados para el LBP08\_64, este es el de la clase 310 con el método 5 de la base de datos de CASIA Tabla 4.8a y el peor resultado para este mismo método ROI es el mostrado en la Tabla 4.8b para la clase 263. En la Tabla 4.8 la clase 1 es tomada como la clase minoritaria que corresponde a uno de los individuos tomados separadamente y la clase 2 corresponde al resto de las clases.

*Tabla 4. 8 Matriz de confusión.*

	<b>Clase 1</b>	<b>clase 2</b>
<b>Clase 1</b>	11	1
<b>clase 2</b>	1	2455

A

	<b>Clase 1</b>	<b>clase 2</b>
<b>Clase 1</b>	0	10
<b>clase 2</b>	37	2421

b

Para la Tabla 4.8a se calcula la tasa de falsa aceptación y la tasa de falso rechazo, ecuaciones (4.1) y (4.2) respectivamente:

$$FAR = \frac{FP}{FP + VN} = \frac{1}{1 + 2455} = 0.04\% \quad (4.1)$$

$$FRR = \frac{FN}{FN + VP} = \frac{1}{1 + 11} = 8.33\% \quad (4.2)$$

Como se observa en las ecuaciones en el mejor de los casos existe un error con una tasa de falsa aceptación de 0.04% y una tasa de falso rechazo del 8.33%. Para el peor de los casos la FAR = 0.4% y la FRR = 100%, estas diferencias se deben en gran parte al desbalance de los datos.

#### 4.11. CLASIFICADOR LINEAL

Con el fin de obtener resultados de las variaciones de los métodos de ROI con dos clasificadores diferentes. Se decide probar con otros tipos de clasificadores, con las configuraciones por defecto y la optimización de parámetros que tiene el PRtools de Matlab para verificar los resultados obtenidos con respecto a la variación de los métodos de la ROI. Al igual que para el clasificador SVM se utiliza como método de selección de umbral Huang para PolyU e Isodata para CASIA, para las pruebas con todos los clasificadores se utilizo LBP0816\_64 para ser aplicados solo en los métodos de ROI 2 debido a que este es aplicable para las dos bases de datos. Finalmente se selecciona es el clasificador Lineal por simplicidad y porque después de ser evaluado con otros clasificadores con el K-vecinos (k = 10), el Naive Bayes, el Fisher y el cuadrático (m=10, r y s=0) se obtiene mayor área bajo la curva con el clasificador lineal (Figura 4.24) (Tabla 4.9).

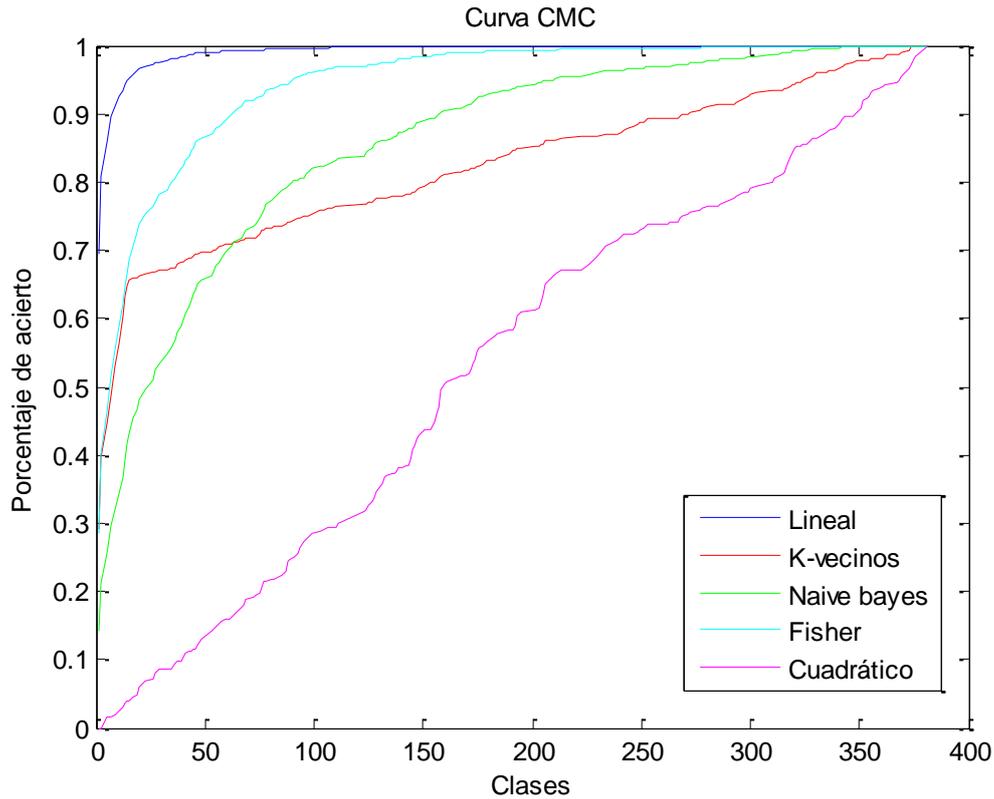


Figura 4. 25 Clasificadores

Tabla 4. 9 Área CMC de los clasificadores

Clasificador	Tiempo (segundos)	Área bajo la curva %
Naive Bayes	398.447754	85.9664
K vecinos	25778.484228	82.5260
Fisher	27555.518932	94.6897
Cuadrático	2208.889838	53.0009
Lineal	2948.35	99.2357

Los clasificadores lineales son unos de los clasificadores más simples para implementar y están directamente relacionados con técnicas como la correlación y la distancia euclideana. Una de las desventajas de los clasificadores es que son óptimos sólo para distribuciones normales y con matrices de covarianza iguales. (Fukunaga, 1990)

Para el cálculo del clasificador lineal entre las clases de un grupo de datos, se requiere la matriz de covarianza conjunta se construye con el promedio de los pesos de las matrices de covarianza de cada clase. Los parámetros para encontrar la matriz de covarianza son R, S y M. R y S son parámetros de regularización usados para encontrar la matriz de covarianza que se encuentran entre 0 y 1 y M es la dimensión de la estructura del subespacio en la matriz de covarianza.

### Análisis de sintonización

Para el análisis de sintonización se variaron los parámetros M, R y S con el fin de encontrar los mejores resultados de clasificación. En la Tabla 4.10 se modificaron los valores de M y los valores de R y S quedan fijos en 0. En la Tabla 4.11 se fija R en 0, M es el total de los datos y se varía S y finalmente en la Tabla 4.12 se fija M sigue teniendo el total de los datos, S en 0 y se varía R.

*Tabla 4. 10 Clasificador lineal variando M*

M	Área bajo la curva CMC	Número de aciertos	Acierto (%)	Tiempo( s)
<b>Todos los datos</b>	0.992357	1920	95.61753	2948.35
<b>10</b>	0.979489	1706	84,960159	3009.25
<b>100</b>	0.992357	1922	95,717131	3178.57

Al observar los datos obtenido en la Tabla 4.10 se evidencia que el mejor ajuste del parámetro M es con total de los datos, debido a que presenta mayor área y menor tiempo de ejecución.

*Tabla 4. 11 Clasificador lineal variando S*

S	Área bajo la curva CMC	Número de aciertos	Acierto (%)	Tiempo (s)
0.3	0.984847	1809	90,0896414	2904.31
0.6	0.979223	1718	85,5577689	3029.89
1	0.96521	1496	74,501992	3112.70

Se observa en la Tabla 4.11 que el área aumenta cuando S disminuye y el tiempo de ejecución disminuye cuando S se acerca a cero. Se selecciona S en cero como mejor valor para este parámetro.

*Tabla 4. 12 Clasificador lineal variando R*

R	Área bajo la curva CMC	Número de aciertos	acierto %	Tiempo s
0.3	0.987072	1891	94,1733068	2679.21
0.6	0.982359	1858	92,5298805	2704.8
1	0.975756	1811	90,189243	2685.5

En la Tabla 4.12 se observa que para valores de R cercanos a cero el área bajo la curva aumenta por lo tanto se concluye que el mejor valor para R es cero.

Al evaluar las áreas bajo la curva CMC y variar sus parámetros la mejor configuración coincide con la configuración por defecto que tiene el PRtools esta es R =0, S =0, y M el total de los datos.

### **Evaluación de los LBP's**

Para este análisis solo se tomaron los métodos tres y cuatro de ambas bases de datos como se puede observar en la Tabla 4.13 donde se muestra el área bajo la curva CMC, el porcentaje de acierto y el tiempo de ejecución en segundos. Para ambos métodos de la ROI los parámetros de los LBP's con los cuales se obtiene una mayor área es con LBP016\_64 y un mayor número de aciertos con el método 4, esto no ocurre para el método 3 pero el porcentaje de acierto para esta configuración de LBP es de los más altos.

En la Figura 4.25 se observa la curva de menor área (color verde) y la de mayor área (color rojo), para apreciar la separación y diferencia que existe al utilizar parámetros diferentes para obtener los descriptores.

Tabla 4. 13 LBP Clasificador lineal PolyU

POLYU						
	Método ROI 3			Método ROI 4		
	Área	Acierto	Tiempo	Área	Acierto	Tiempo
<b>LBP 0 8_64</b>	97.306	61,4542	2035	96.505	59,9437	4655
<b>LBP 0 8_32</b>	96.764	56.7729	2054	96.115	58,1837	4399
<b>LBP 0 8_16</b>	96.222	53.6853	2055	95.800	55,2622	4365
<b>LBP 0 8_8</b>	95.852	62.0020	2058	94.974	48,8912	4356
<b>LBP 1 8_64</b>	96.466	57.5199	2056	95.481	55,5438	4357
<b>LBP 1 8_32</b>	95.897	54.0837	2052	95.329	55,0510	4354
<b>LBP 1 8_16</b>	95.422	50.0498	2059	95.143	51,7423	4352
<b>LBP 1 8_8</b>	95.197	<b>95.7171</b>	2063	94.496	48,2929	4351
<b>LBP 0 8 16_64</b>	<b>99.235</b>	93.3267	2113	<b>99.118</b>	<b>94,0162</b>	4457
<b>LBP 0 8 16_32</b>	98.986	92.0817	2112	98.936	93,6290	4461
<b>LBP 0 8 16_16</b>	98.534	85.9064	2116	98.347	90,9187	4455
<b>LBP 0 8 16_8</b>	96.820	94.5717	2118	96.404	83,1397	4467
<b>LBP 1 8 16_64</b>	99.161	92.7789	2115	99.007	93,0306	4469
<b>LBP 1 8 16_32</b>	98.933	89.9402	2114	98.837	92,9250	4452
<b>LBP 1 8 16_16</b>	98.361	83.6155	2113	98.216	89,6515	4453
<b>LBP 1 8 16_8</b>	96.498	81.9223	2116	96.058	82,0838	4457
<b>LBP 0 16_64</b>	97.805	79.9303	2079	97.632	81,0630	4411
<b>LBP 0 16_32</b>	97.068	73.4562	2091	97.183	78,2823	4393
<b>LBP 0 16_16</b>	95.817	54.2829	2081	95.664	71,5945	4405
<b>LBP 0 16_8</b>	<b>90.349</b>	81.8725	2085	89.764	51,0736	4401
<b>LBP 1 16_64</b>	97.788	79.8307	2082	97.607	80,2182	4401
<b>LBP 1 16_32</b>	97.330	73.2570	2084	97.095	78,0359	4997
<b>LBP 1 16_16</b>	95.981	54.2331	2098	95.448	70,4681	5081
<b>LBP 1 16_8</b>	90.681	61.4542	2428	<b>89.505</b>	51,6015	5101

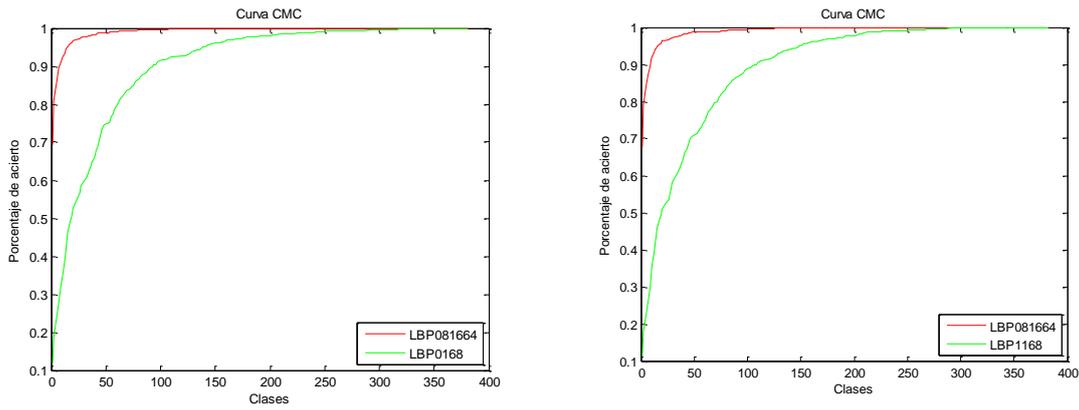


Figura 4. 26 Mínimo y Máximo LBP PolyU. a) Método 3, b) Método 4.

Al igual que con la máquina de soporte, se obtienen diferencias apreciables en las curvas CMC para las diferentes configuraciones de los LBPs, aunque con el clasificador lineal estas diferencias son menores, para el método 3 las mayores diferencias (99.235 - 90.349) son del 8.886% y para el método 4 de 9.613%.(Tabla 4.13)

En la Figura 4.26 se aprecian las curvas generadas por la configuración de LBP's que arrojaron el área mínima (curva verde) y máxima (curva roja), en el método 3 hay una diferencia del 42.025% y en el método 4 existe una diferencia de 36.642%. Esto muestra que para esta base de datos las diferencias entre las configuraciones de los LBP's generan grandes cambios.

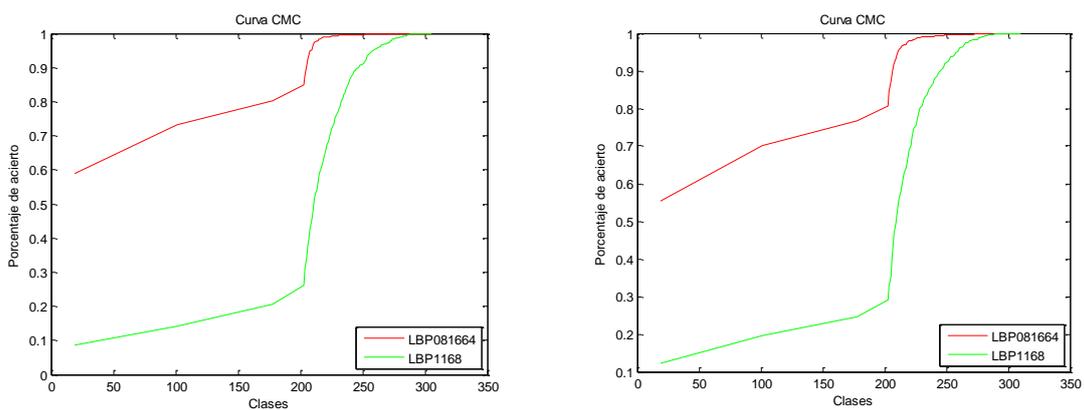


Figura 4. 27 Mínimo y Máximo LBP CASIA. a) Método 3, b) Método 4,

Tabla 4. 14 LBP Clasificador lineal CASIA

CASIA						
	Método ROI 3			Método ROI 4		
	Área	Acierto	Tiempo	Área	Acierto	Tiempo
LBP 0 8_64	72.271	66,7302	582	71.589	66,0839	599
LBP 0 8_32	68.392	62,9171	583	69.633	64,2483	603
LBP 0 8_16	66.372	62,7264	581	67.205	63,5490	599
LBP 0 8_8	62.458	57,1973	580	63.277	55,9441	599
LBP 1 8_64	69.164	65,7769	583	69.633	65,1224	599
LBP 1 8_32	67.961	64,0610	582	67.210	61,1014	601
LBP 1 8_16	65.052	60,7245	580	65.348	60,6643	603
LBP 1 8_8	60.772	55,3861	580	60.871	54,7203	601
LBP 0 8 16_64	<b>82.207</b>	93,4223	602	<b>80.604</b>	91,7832	618
LBP 0 8 16_32	76.737	91,8017	602	78.845	91,3462	618
LBP 0 8 16_16	73.102	90,2765	601	73.853	88,7238	622
LBP 0 8 16_8	61.723	85,4147	602	64.390	83,6538	622
LBP 1 8 16_64	79.455	93,9943	605	79.684	91,5210	622
LBP 1 8 16_32	75.976	91,0391	602	77.423	91,0839	622
LBP 1 8 16_16	71.08	90,3718	601	71.750	86,9755	622
LBP 1 8 16_8	61.188	86,7493	601	62.168	82,6049	622
LBP 0 16_64	72.885	83,6988	596	72.100	81,5559	610
LBP 0 16_32	66.806	77,3117	586	69.749	79,1958	610
LBP 0 16_16	62.637	74,6425	660	64.412	72,7273	610
LBP 0 16_8	49.664	61,3918	673	50.346	60,2273	612
LBP 1 16_64	63.773	74,4519	596	63.569	73,6888	611
LBP 1 16_32	57.542	69,2088	595	61.365	71,5035	611
LBP 1 16_16	52.764	65,4909	594	55.108	65,7343	612
LBP 1 16_8	<b>40.182</b>	52,8122	593	<b>43.962</b>	53,3217	610

En la Tabla 4.14 se observan las áreas de la CMC, el porcentaje de aciertos y el tiempo de ejecución del clasificador para la base de datos de CASIA, donde la misma configuración de LBP's que fue la mejor para la base de datos de PolyU, también fue la mejor para esta base de datos, es decir que los mejores parámetros de LBP para el clasificador lineal fueron siempre los mismos, tanto al variar el método de ROI como al varia la base de datos. Los LBP's obtenidos del histograma no adaptativo con 8 y 16 vecinos y con bloque de 64x64 presentaron el mejor desempeño. En general el LBP que presento mejor

comportamiento fue el (LBP 0 8 16\_64) con histograma no adaptativo, 8 y 16 vecinos y bloque de 64x64.

### Análisis de los métodos de ROI.

Para comparar los métodos de ROI se tomó el LBP0816\_64, ya que este presentó la mayor área bajo la curva CMC para todos los métodos y para ambas bases de datos (Tabla 4.13 y Tabla 4.14), se tomó el método 2 para ser comparado con los demás métodos y presentar los errores generados al variar la ubicación de la ROI, estos errores son mostrados en la Tabla 4.14.

Como se aprecia en la Figura 4.27 y en la Tabla 4.15 los errores mayores fueron presentados por los métodos 5 y 1 teniendo errores de 4,8913% y 3,9748% respectivamente, igualmente como sucedió con la SVM los errores son mayores al variar los parámetros para obtener los LBP's que los errores que se obtienen al variar la ubicación del cuadrado que define la región de interés.

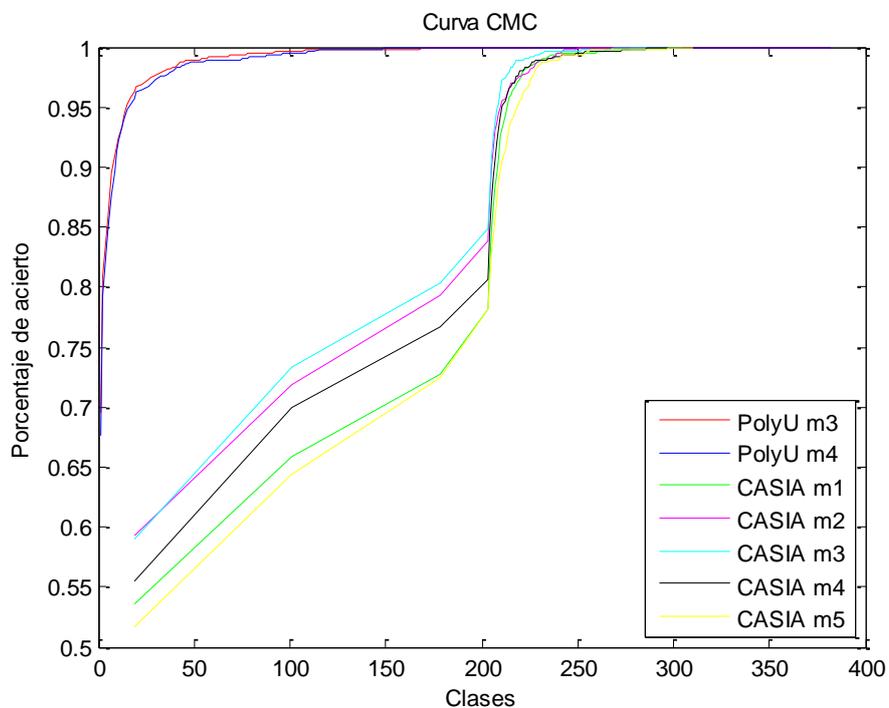


Figura 4. 28 CMC Métodos de la ROI

Tabla 4. 15 Diferencias entre los métodos ROI

Métodos	Error absoluto
Método 1-2 CASIA	3,9748%
Método 3-2 CASIA	0,4059%
Método 4-2 CASIA	1,7158%
Método 5-2 CASIA	4,8913%
Método 3-4 PolyU	0,117%

La exactitud de la base de datos de CASIA es mucho menor que el de PolyU. Esto se debe principalmente a tres razones. En primer lugar, el tamaño de la base de datos de CASIA es mucho mayor que la de PolyU, lo que trae dificultad para la clasificación. En segundo lugar, no hay plantillas para restringir las posturas y posiciones de las manos durante la recopilación de datos de CASIA, que aporta en mayor libertad de posición. Finalmente, la imagen de calidad de CASIA no es tan buena como la de PolyU. (Guo, Zuo, Zhang, & Zhang, 2010)

Para obtener mejores resultados en los sistemas biométricos de palma de la mano utilizando patrones binarios locales se sugiere una combinación con otros métodos de obtención de características que complementen este tipo de descriptores así como en (Nanni & Lumini, 2009) donde proponen un método de fusión con tres conjuntos de descriptores de emplean diferentes sistemas de representación de las características de imágenes estos son los coeficientes discretos de coseno, los filtros de Gabor y los patrones binarios locales, con los resultados experimentales confirman que los tres métodos dan información complementaria, de esta manera es posible disminuir los errores presentados por el uso solo de los LPB's. También en otros trabajos como en (Jia, Ling, & Chau, 2008) proponen una combinación entre las principales líneas de la mano y los LBP's, explotando las mejores ventajas de cada técnica, resaltando la importancia y la estabilidad que reflejan las principales líneas de la mano en la estructura de la palma y los LBPs que son considerados como la función estadística de la palma de la mano.

En (Yue, Zuo, Zhang, & Li, Fast palmprint identification with multiple templates per subject, 2011) trabajan con la bases de datos de PolyU y evalúan el desempeño mediante las curvas CMC, obteniendo mejores resultados, ya que las curvas desde la primera iteración generan resultados 99%, las posibles causas de error para esta tesis se encuentran en los descriptores utilizados, debido a que estos requieren ser complementados con otro tipo de descriptores, además de la sintonización de parámetros de entrenamiento de la máquina de soporte vectorial.

## **4.12. DISCUSIONES**

### **4.12.1 Respecto a la segmentación**

Como no se contaba con una métrica ni con una metodología para verificar la diferenciación entre las imágenes, se propuso utilizar métricas como la correlación, el error medio cuadrático, la relación de uniformidad, la información mutua y el área común para establecer diferencias entre las imágenes de ROI obtenidas utilizando los diferentes métodos de ubicación y tres métodos de umbral.

El coeficiente de correlación no es suficiente para saber si las dos imágenes están correlacionadas o no lo están, sin embargo, al tomarlo como una métrica de similitud en todos los casos de la base de datos de PolyU se obtuvieron valores altos de correlación (cercaos a uno) y en el caso de la base de datos de CASIA se obtuvieron valores de 0.99 sólo en los casos donde el método de la ROI no variaba. De esto se concluye que hay variación en las imágenes obtenidas por diferentes métodos, además estas variaciones dependen de las bases de datos.

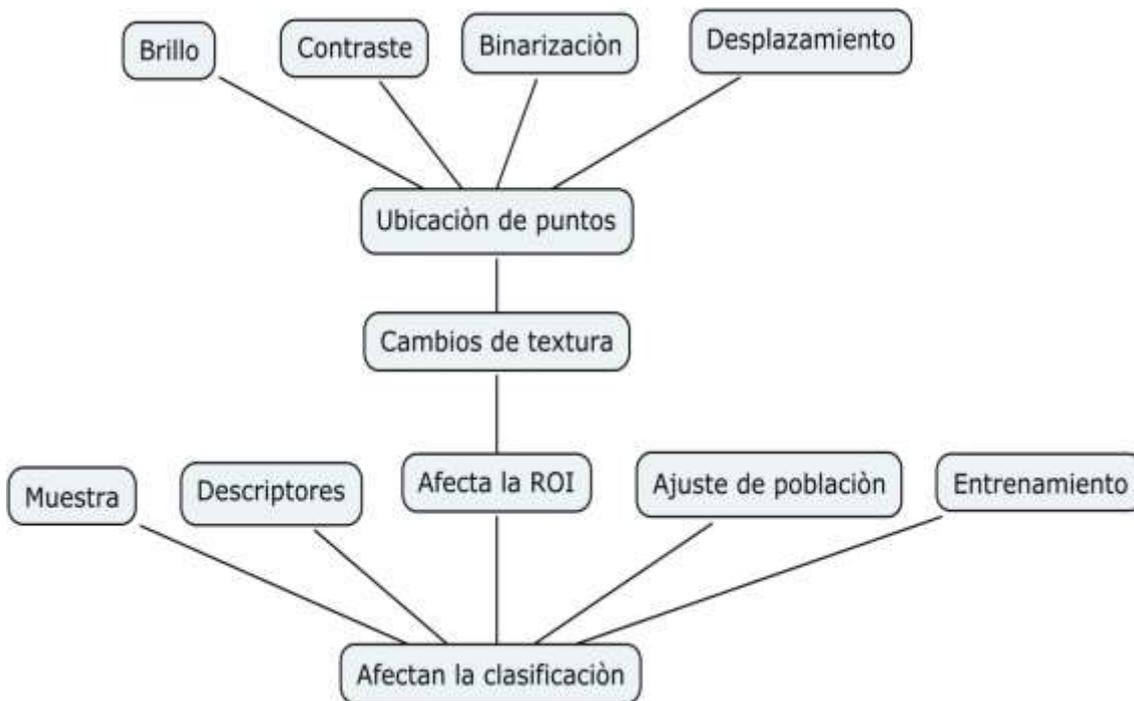
Los resultados muestran consistencia entre las métricas empleadas y evidencian mayores diferencias al variar el método ROI que al variar el método umbral. Es así, como para la base de datos de PolyU la relación entre las diferentes métricas es apreciable y consecuente (Tabla 4.2), ya que en los casos donde se presenta mayor correlación (93,94) hay mayor área común (95,96) y además el error cuadrático medio (868.04, 734.41) y la relación de uniformidad de la imagen (94,93) disminuyen. Esta coherencia entre los métodos también aplica para la base de datos de CASIA (Tabla 4.1).

#### **4.12.2 Respecto a la influencia de las condiciones de captura.**

Tanto los cambios de brillo como de contraste en la imagen inicial, generan desplazamientos en la ubicación de las coordenadas que definen la ROI, los experimentos realizados muestran que al variar los puntos de la ROI, cambian los descriptores y por lo tanto el clasificador puede asignarle una etiqueta de clase incorrecta al individuo. La ubicación de la ROI influye en los resultados finales de clasificación debido a que los LBP's se alteran al modificar la textura de la imagen.

#### **4.12.3 Respecto a los factores que afectan la clasificación.**

La Figura 4.29 resume los factores que afectan la ROI, desde el preprocesamiento para obtener el cuadrado que describe la región de interés, hasta las demás etapas que componen el sistema biométrico. La ROI es afectada por el brillo, el contraste, la binarización y el desplazamiento, esto a la vez afecta la ubicación de los puntos de la ROI, lo que genera cambios de la textura afectando los descriptores y repercutiendo en la clasificación. Todo esto se puede evidenciar cuando se comparan los métodos de ROI usando las curvas CMC.



*Figura 4. 29. Factores que afectan la ROI y la Clasificación*

#### **4.12.2 Respecto a los mejores desempeños.**

El método de la ROI que presentó mejor desempeño al utilizar el clasificador de máquinas de soporte vectorial, fue el método 2 para la base de datos de CASIA con 91.6% de área bajo la curva CMC y el método 3 para la base de datos de PolyU con 85.3% de área bajo la curva CMC.

En todos los métodos de ROI de ambas bases de datos se concluye que el mejor desempeño tanto en tiempo como en área, lo tienen los LBP's con histogramas no adaptativos y con tamaños de bloque grandes (32x32 y 64x64). Para cada uno de los métodos se seleccionó el LBP0864 por presentar mayor área bajo la curva CMC en tres de los siete métodos de ROI utilizados.

El clasificador lineal presentó mejor desempeño en la base de datos de PolyU con una área bajo de curva CMC de 99.235% como valor máximo y como valor mínimo 89.505%. La base de datos de PolyU presenta mayor resolución y fue

tomada utilizando más restricciones que la base de datos de CASIA por lo tanto su desempeño es el mejor.

En este trabajo se utilizó la curva CMC debido a que el identificador biométrico plantea un problema multiclase y en esta curva se aprecia mejor las respuestas obtenidas. Con el fin de facilitar la observación en los resultados debido a la cantidad de clase, se cambió la tasa de error igual EER en las curvas ROC por el área bajo las curvas CMC.

---

## CONCLUSIONES

---

En un sistema de identificación biométrica de palma de la mano, con patrones binarios locales el cálculo de la región de interés de la imagen, afecta los resultados finales del sistema biométrico. Este trabajo demostró que el cambio de los métodos de umbralización influyen en la ubicación de la ROI generando variaciones en la imagen final de la palma de la mano, debido a que la localización de los puntos valle cambia según el método utilizado, tanto para la base de datos de CASIA como para la base de datos de PolyU.

Las imágenes de la ubicación de la ROI presentan menores diferencias al variar el método de umbralización que al variar el método de la ROI, lo que implica que la selección del tipo de ROI es una condición de diseño que se debe tener presente al desarrollar un método biométrico de la palma de la mano.

La información contenida por cada método de obtención de la ROI es diferente y depende de las condiciones en que se capturaron o registraron las muestras de la base de datos, esto se debe a que no es lo mismo contar con imágenes que fueron tomadas bajo condiciones controladas (iluminación, contraste y apertura de mano) a las que no lo fueron, porque estas condiciones afectan la extracción del borde y por lo tanto la ubicación de la ROI. Esto implica que las muestras de las palmas de la mano deben ser tomadas de una forma estandarizada,

En la clasificación se obtienen mayores diferencias al variar los parámetros para los patrones binarios locales (que para este caso de evaluación la variación es de 17%), que al cambiar los puntos de ubicación de la ROI (donde se obtienen variaciones del 3%), por lo que se concluye que hay mayor incidencia en los descriptores que en la segmentación (Figuras 5.5, 5.6 y 5.10). Todo esto se debe a que la capacidad de describir la textura debe ser

seleccionada adecuadamente pues si se escogen tamaños pequeños para LBP's estos no logran hacer una adecuada partición de las clases.

Debido a los resultados obtenidos en las curvas CMC con las diferentes combinaciones de LBP's, se recomienda no utilizar histogramas adaptativos, porque estos al mejorar el contraste generan cambios en la textura de la imagen original. Además se sugiere utilizar para la imagen un tamaño de bloques de división de mayor área (32x32 y 64x64), ya que estos presentaron un mejor desempeño, permitiendo describir en la textura mayores características. Para cada uno de los métodos se seleccionó el LBP0864 por presentar mayor área bajo la curva CMC en tres de los siete métodos de ROI utilizados.

Los métodos umbral que presentaron los mayores porcentajes de imágenes correctas para cada uno de los métodos fueron, Huang para la base de datos de PolyU e Isodata para la base de datos de CASIA. El segundo mejor método para ambas bases de datos fue Otsu. La selección del método umbral es importante para definir los puntos sobre los cuales se seleccionaran la ROI

El método de la ROI que presentó mejor desempeño al utilizar el clasificador de máquinas de soporte vectorial fue el método 2 para la base de datos de CASIA con 91.6% de área bajo la curva CMC y el método 3 para la base de datos de PolyU con 85.3% de área bajo la curva CMC. Esto significa que según las características de las imágenes es necesario seleccionar una ROI que logre capturar los comportamientos texturales más importantes de las palmas de la mano.

La utilización de una técnica de balance de muestras mejora la clasificación de las máquinas de soporte vectorial. Para la sintonización de la máquina de soporte vectorial se seleccionó la dispersión de la campana gaussiana de 0.1 por tener mayor área bajo la curva (78.083%) y menor tiempo de ejecución (4929 segundos). El balance de las muestras es necesario usarlo para

entrenar los clasificadores cuando se tiene más clases que muestras por individuo, no hacerlo afecta el desempeño del sistema.

Al evaluar diferentes clasificadores como el Fisher, Naive Bayes, Cuadrático y lineal, se obtuvo con el clasificador lineal una mayor área bajo la curva CMC (99.24%) y un tiempo bajo de ejecución (de 2948 segundos).

El tiempo de ejecución de los algoritmos es un factor importante para la elección de los métodos empleados. Los sistemas biométricos deben de generar respuestas rápidas en el tiempo para poder ser utilizados en línea y prestar un servicio ágil y efectivo.

Al desarrollar la metodología propuesta se concluye que la ROI es afectada por el brillo, el contraste, la binarización y el desplazamiento. Esto a la vez afecta la ubicación de los puntos de la ROI, lo que genera cambios de la textura afectando los descriptores y repercutiendo en la clasificación. Todo esto se puede evidenciar cuando se comparan los métodos de ROI usando las curvas CMC

## **TRABAJOS FUTUROS**

Para un adecuado entrenamiento de la máquina de soporte vectorial y en general de cualquier clasificador se requiere contar con un gran número de muestras por individuo. Lo cual no fue posible para este trabajo debido a que se deseaba trabajar con bases de datos utilizadas en la literatura, por lo tanto este desarrollo se limitó a trabajar con las bases de datos públicas, en donde además no se contaba con condiciones controladas de iluminación y brillo. Se propone generar una base de datos con menor número de individuos y mayor número de muestras por clase.

Con los cambios en la iluminación se pierde información. Los descriptores obtenidos no son lo suficientemente robustos como para soportar grandes

variaciones. Se propone generar una base de datos con condiciones controladas.

Para un mismo individuo si se modifica la región de interés se modifica la textura y por lo tanto los patrones binarios locales serán diferentes. Se propone definir el método de ubicación de ROI que genere menor carga computacional y menor error en la clasificación.

Para mejorar el desempeño de la máquina de soporte vectorial se propone realizar una sintonización más exhaustiva y probar con otro tipo de kernel.

Se propone como trabajos futuros crear una base de datos con condiciones controladas y mayor número de muestras por individuo y menor número de clases, de esta manera se podrán obtener resultados mejores y que brinden mayor confiabilidad al sistema biométrico.

---

## REFERENCIAS

---

- A Rosenfeld, P. D. (1983). Histogram concavity analysis as an aid in threshold selection. *IEEE Trans. Syst. Man Cybern* , 231-235.
- Abutaleb, A. S. (1989). Automatic thresholding of gray-level pictures using two-dimensional entropy. *Comput. Vis. Graph. Image Process* , 22-32.
- Ajay Kumar, D. Z. (2006). Personal Recognition Using Hand Shape and Texture. *IEEE transactions on image processing* .
- Arámbula, F. (2008). Segmentación de Imágenes médicas.
- Arroyave, M., Restrepo, A., & Vargas, F. (2011). Incidencia de la Segmentación en la Obtención de Región de Interés en Imágenes de la Palma de la Mano. *Revista Tecno-lógicas* , 119-138.
- Bunkhumpornpat, C., Sinapiromsaran, K., & Lursinsap, C. (2009). Safe-Level-SMOTE: Safe-Level-Synthetic Minority Over-Sampling TEchnique for Handling the Class Imbalanced Problem. *Springer-Verlag Berlin Heidelberg* , 475–482.
- Center for Biometrics and Security Research (CBSR) Institute of Automation, Chinese Academy of Sciences (CASIA). (s.f.). *Center for Biometrics and Security Research*. Recuperado el 2010, de [www.cbsr.ia.ac.cn/](http://www.cbsr.ia.ac.cn/)
- Centro de Investigación biométrica (UGC / CRC) Universidad Politécnica de Hong Kong. (s.f.). Recuperado el 2010, de [www.comp.polyu.edu.hk/](http://www.comp.polyu.edu.hk/)
- Chen, J., Moon, Y.-S., Wong, M.-F., & Su, G. (2010). Palmprint authentication using a symbolic representation of images. *Image and Vision Computing* .
- Duan, K., Keerthi, S. S., & Poo, A. N. (2003). Evaluation of simple performance measures for tuning SVM hyperparameters. *Neurocomputing* , 41-59.
- Elizondo, J. J. (2002). Fundamentos de Procesamiento de Imágenes. *Evento CONATEC 2002* .
- Fukunaga, K. (1990). *Introduction to Statistical Pattern Recognition*.
- Guo, Z., Zuo, W., Zhang, L., & Zhang, D. (2010). A unified distance measurement for orientation coding in palmprint verification. *Neurocomputing* , 94 4 –950.
- Han, C. C. (2004). A hand-based personal authentication using a coarse-to-fine strategy. *Image and Vision Computing* , 909–918.

- Han, C.-C., Cheng, H.-L., & Fan, K.-C. (2002). Personal Authentication Using Palm Print Features. *The 5th Asian Conference on Computer Vision*. Melbourne, Australia.
- Han, C.-C., Cheng, H.-L., Lin, C.-L., & Fan, K.-C. (2003). Personal authentication using palm-print features. *Pattern Recognition* .
- Hernández, J. M., Sanz, G. P., & Guijarro, M. (2011). Técnicas de procesamiento de imágenes estereoscópicas.
- Huang L-K. y M-J. J. Wang. (1995). Image Thresholding by Minimizing the Measures of Fuzziness. *Pattern Recognition* , pp. 341-347.
- Jawahar, C. V., Biswas, P. K., & Ray, A. K. (1997). Investigations on fuzzy hresholding based on fuzzy clustering. *Pattern Recogn* , 1605-1613.
- Jia, W., Ling, B., & Chau, K.-W. (2008). Palmprint identification using restricted fusion; Laurent Heutte. *Applied Mathematics and Computation* , 927–934.
- Kong, J., Lua, Y., Wang, S., Qi, M., & Li, H. (2008). A two stage neural network-based personal identification system using handprint. *Neurocomputing* , 641–647.
- Kong, W. K., & Zhang, D. (2002). Palmprint texture analisis based on low-resolution images for personal authentication. *IEEE Computer Society* .
- Kunzmann, K. (2005). Reconocimiento de Patrones en Imágenes de videos Endoscopicos utilizando Redes Neuronales Artificiales. *Tesis de Maestria* .
- Lei Yu, H. L. (2004). Efficient Feature Selection via Analysis of Relevance and Redundancy. *Journal of Machine Learning Research* .
- Leung, C. K., & Lam, F. K. (1998). Maximum segmented image information thresholding. *Graph. Models Image Process.* , 57-76.
- Li, C. H., & Lee, C. K. (1993). Minimum cross-entropy thresholding. *Pattern Recogn* , 617-625.
- Li, C. H., & Tam, P. K. (1998). An iterative algorithm for minimum cross-entropy thresholding. *Pattern Recogn* , 771-776.
- Lin, C.-L., C. Chuang, T., & Fan, K.-C. (2005). Palmprint verification using hierarchical decomposition. *Pattern Recognition* .
- Lloyd, D. E. (1985). Automatic target classification using moment invariant of image shapes. *Technical Report, RAE IDN AW126* .

Mark Holden, D. L. (2000). Voxel Similarity Measures for 3-D Serial MR Brain Image Registration. *IEEE Transactions On Medical Imaging* , 94-102.

Mark Holden, D. L. (2000). Voxel Similarity Measures for 3-D Serial MR Brain Image Registration. *IEEE transactions on medical imaging* , 94-102.

Michael, G. K., Connie, T., & Teoh, A. B. (2008). Touch-less palmprint biometrics: Novel design and implementation. *Image and Vision Computing* , 1551–1560.

Nanni, L., & Lumini, A. (2009). Ensemble of multiple Palmprint representation. *Expert Systems with Applications* , 4485–4490.

Neto, A. M., Rittner, L., Leite, N., & Zampieri, D. (2007). Pearson's correlation coefficient for discarding redundant information real time autonomous navigation system. *Ieee International conference* , 426 - 431.

Nitesh V. Chawla, K. W. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research* , 321-357.

Otsu, N. (1979). A threshold selection method from gray level histograms. *Systems, Man and Cybernetics, IEEE Transactions on* , 62-79.

Petrou, M., & Sevilla, P. G. (2006). *Image Processing Dealing with Texture*. John Wiley & Sons, Ltd.

R.M. Bolle, J. C. (2005). The Relation Between the ROC Curve and the CMC. *Automatic Identification Advanced Technologies, 2005. Fourth IEEE Workshop on* .

Ramesh, N., Yoo, J. H., & Sethi, I. K. (1995). Thresholding based on histogram approximation. *IEE Proc. Vision Image Signal Process* , 271-279.

Resendiz, J. A. (2006). Las máquinas de vectores de soporte para identificación en línea. *Tesis de Maestría en Ciencias - Control automático* .

Ridler, T. &. (1978). Picture thresholding using an iterative selection method. *IEEE Transactions on Systems, Man and Cybernetics* , 8: 630-632.

Ridler, T. W., & Calvard, S. (1978). Picture thresholding using an iterative selection method. *IEEE Trans. Syst. Man Cybern* , 630-632.

Sezan, M. I. (1985). A peak detection algorithm and its application to histogram-based image data reduction. *Graph. Models Image Process* , 47-59.

Sezgin, M. (2004). Survey over image thresholding techniques. *Journal of Electronic Imaging* 13(1) , 146-165.

- Shanbag, A. G. (1994). Utilization of information measure as a means of image thresholding. *Comput. Vis. Graph. Image Process* , 414-419.
- Shang, P., & Li, T. (2009). Multifractal characteristics of palmprint and its extracted algorithm. *Applied Mathematical Modelling* .
- Sonka, M. (2004). *Handbook of Medical Imaging: Medical image processing and analysis*. Bellingham Washington: The international society for optical engineering.
- Suárez Ruiz F.A, R. F. (2007). Autenticación de Personas a partir de la Biometría de las Venas de la parte Posterior de la Mano.
- Tang, Y., Zhang, Y.-Q., Chawla, N. V., & Krasser, S. (2002). SVMs Modeling for Highly Imbalanced classification. *IEEE Transactions* , 281 - 288.
- Toro, Ó. F., & Correa, H. L. (2009). Identificación biométrica utilizando imágenes infrarrojas de la red vascular de la cara dorsal de la mano. *Revista ingeniería e investigación* , 90-100.
- Tsai, W. H. (1985). Moment-preserving thresholding: A new approach. *Graph. Models Image Process* , 377-393.
- Universidad Nacional del Litoral. (20 de Abril de 2009). Captura y Procesamiento Digital de Señales e imágenes.
- Vargas, J. F., Travieso, C. M., Alonso, J. B., & Ferrer, M. A. (2009). Palm-print Verification using Block-based and Multi-resolution LBP Features.
- Wang, J.-G., Yau, W.-Y., Suwandy, A., & Sung, E. (2008). Person recognition by fusing palmprint and palm vein images based on “Laplacianpalm” representation. *Pattern Recognition* , 1514–1527.
- White, J. M., & Rohrer, G. D. (1983). Image thresholding for optical character recognition and other applications requiring character image extraction. *IBM J. Res.* , 400-411.
- Xianji Wang, H. G. (2006). Palmprint Identification Using Boosting Local Binary Pattern. *The 18th International Conference on Pattern Recognition* .
- Y. Freund, R. S. (1997). A Decision-Theoretic Generalization of On-line Learning and An Application to Boosting. *Journal of Computer and System Sciences* , 119-139.
- Yanxia Wang, Q. R. (2007). Palprint recognition method using dual -tree complex wavelet transform and local binary pattern histogram. *International Symposium on Intelligent Signal Processing and Communication Systems* .

Yue, F., Zuo, W., Zhang, D., & Li, B. (2011). Fast palmprint identification with multiple templates per subject. *Pattern Recognition Letters* , 1108–1118.

Yue, F., Zuo, W., Zhang, D., & Wang, K. (2009). Orientation selection using modified FCM for competitive code-based palmprint. *Pattern Recognition* .

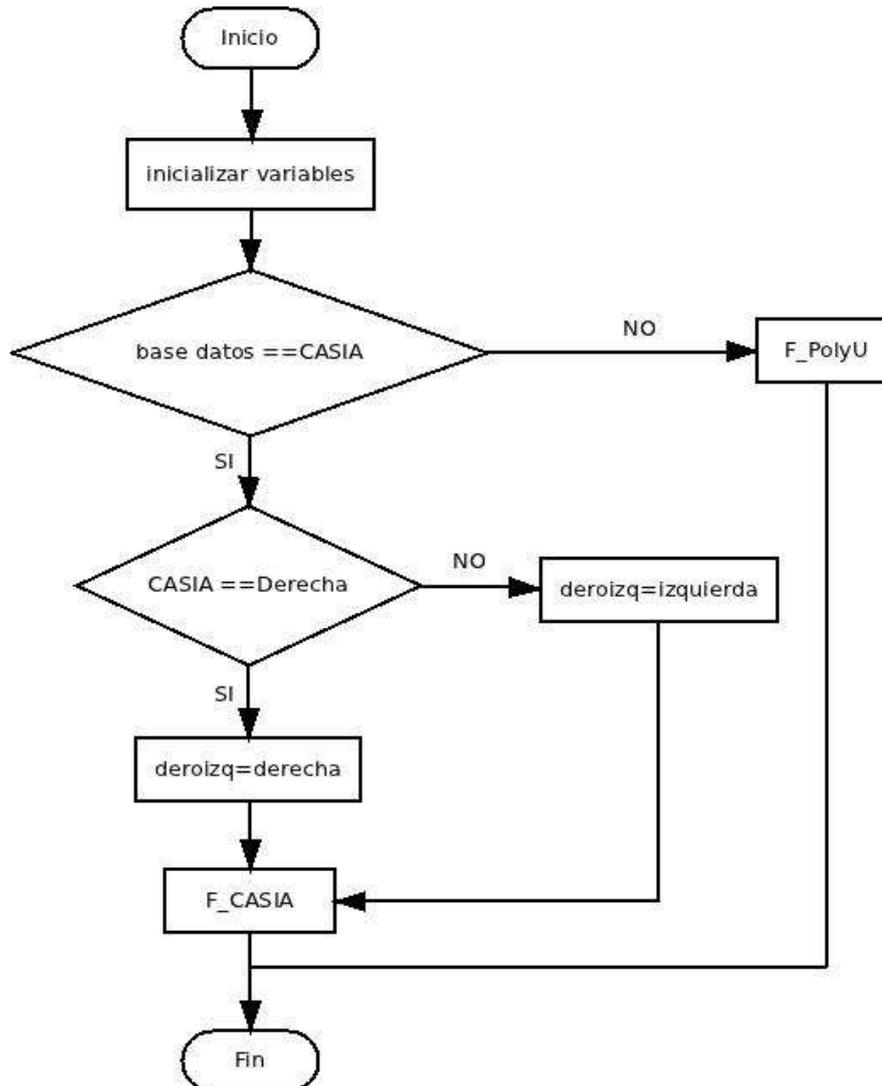
Yue, F., Zuo, W., Zhang, D., & Wang, K. (2009). Orientation selection using modified FCM for competitive code-based palmprint. *Pattern Recognition* .

Zack GW, R. W. (1977). Automatic measurement of sister chromatid exchange frequency. *J. Histochem. Cytochem* , 25 (7): 741–53.

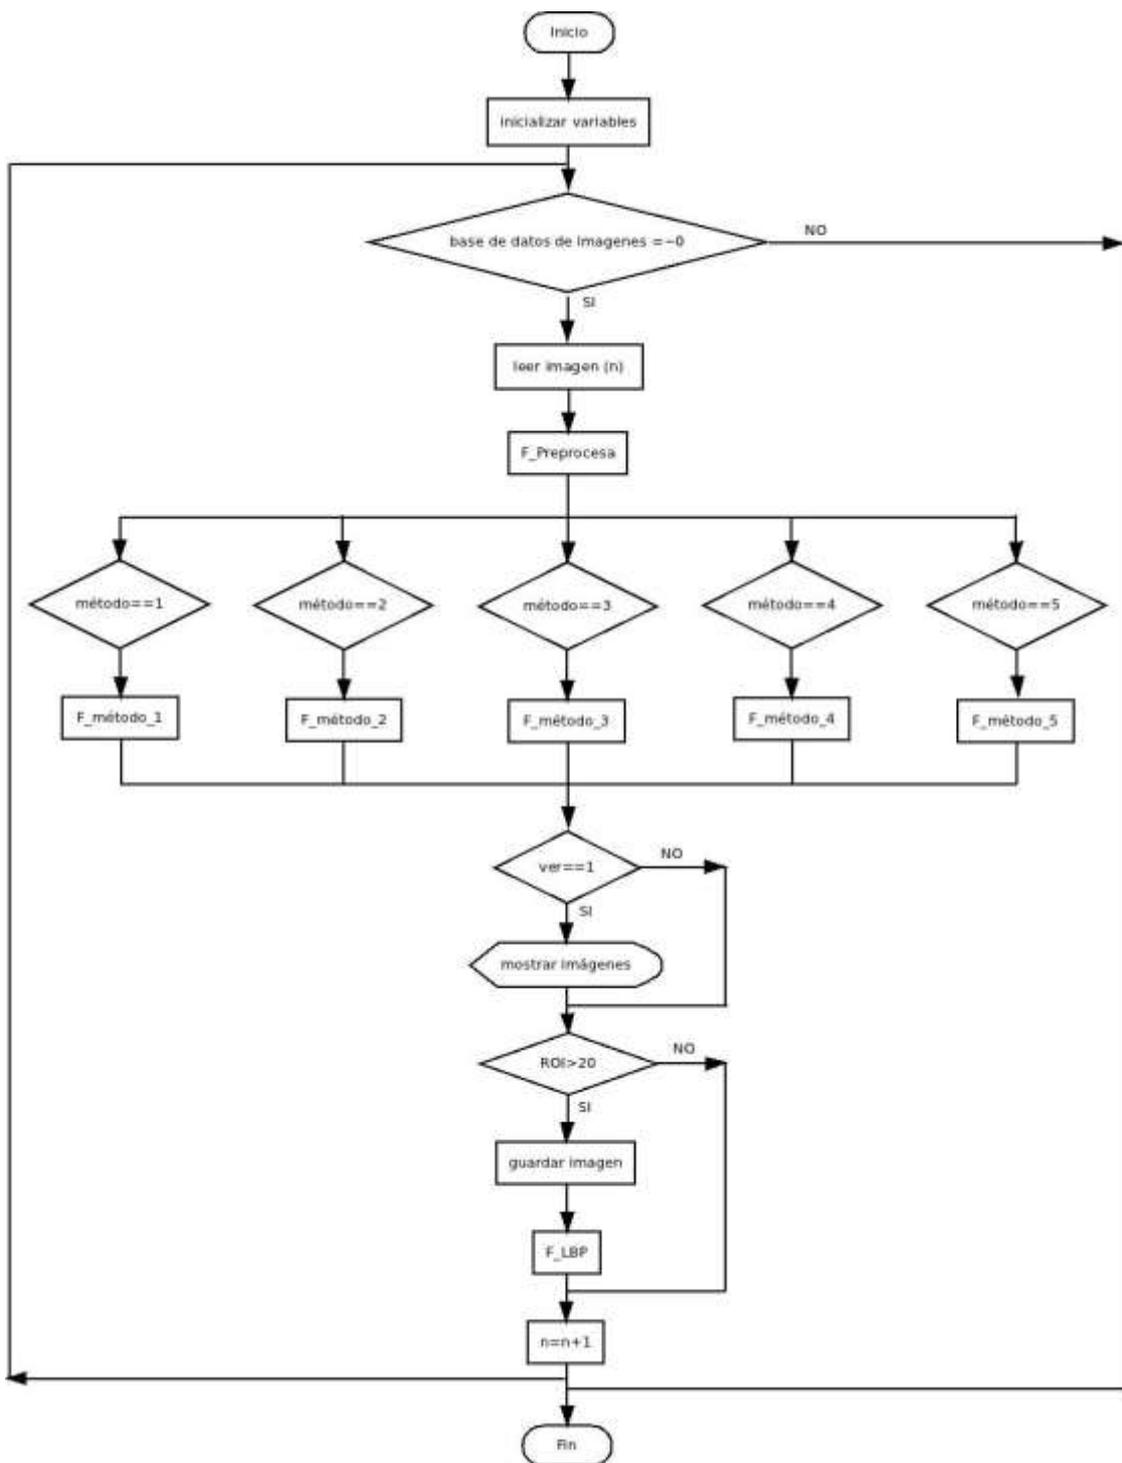
Zhang, D., Kong, W.-K., You, J., & Wong, M. (2003). Online Palmprint Identification. *IEEE Transactions on pattern analysis and machine intelligence* .

A continuación de presentan algunos de los diagramas de flujo del software diseñado.

Programa principal



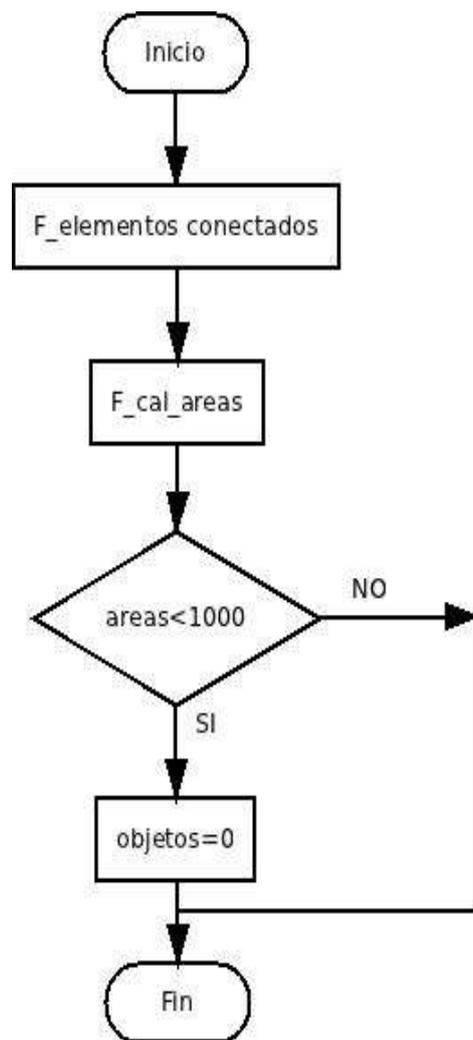
# Función F\_CASIA



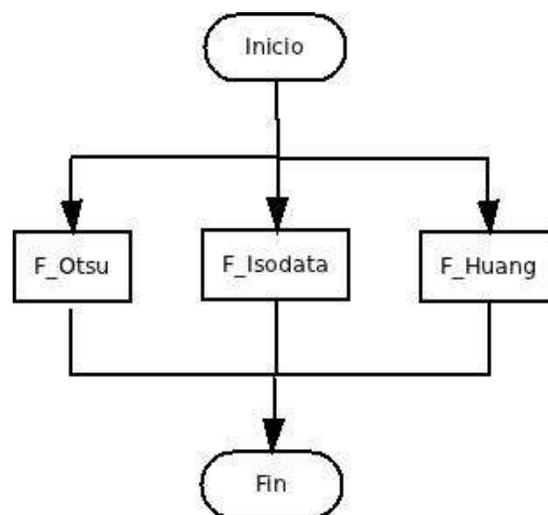
## Función F\_Preprocesa



Función F\_eliminar objetos



Función F\_umbral



A continuación se presentan fragmentos de algunos de los algoritmos desarrollados en Matlab para la implementación del sistema biométrico.

## ENTORNO GRAFICO

```

posscre=get(0,'screensize');
h = figure('Name','Palmprint','NumberTitle','off','Position',
[posscre(3)/2, posscre(4)/2,500,300]);

base = uibuttongroup('Title','Base de datos',...
    'FontSize',10,...%'BackgroundColor','white',...
    'Position',[.01 .5 .25 .4]);
polyu =
uicontrol('Parent',base,'String','PolyU','style','radiobutton',...
    'Position',[3 61 70 36])
cansia_der = uicontrol('Parent',base,'String','Cansia
derecha','style','radiobutton',...
    'Position',[3 31 100 36])
cansia_izq = uicontrol('Parent',base,'String','Cansia
izquierda','style','radiobutton',...
    'Position',[3 1 100 36])

m = uicontrol('Parent',h,'String',{'Metodo 1','Metodo 2','Metodo
3','Metodo 4','Metodo 5','Metodo 6'},'style','popupmenu',...
    'Position',[20 100 100 36]);
fig=axes('Parent',h,'Position',[.35 .15 .4 .6])
d = uicontrol('Parent',h,'String','/media/DATA/archivos/ITM/tesis
palmprint/CASIA_Palmprint','style','edit',...
    'Position',[150 240 300 20])
dirr = uicontrol('Parent',h,'String','...','style','pushbutton',...
    'Position',[450 240 20 20],'Callback','rutadir(d)');
rut = uicontrol('Parent',h,'String','/media/DATA/archivos/ITM/tesis
palmprint/Cansia_ROI_met1_der','style','edit',...
    'Position',[150 1 300 20]);
stop = uicontrol('Parent',h,'String','...','style','pushbutton',...
    'Position',[450 1 20 20],'Callback','rutadir(rut)');
inicio =
uicontrol('Parent',h,'String','INICIO','style','pushbutton',...
    'Position',[1 1 40 30],'Callback','iniciar');
verroi = uicontrol('Parent',h,'String','Ver
ROI','style','checkbox',...
    'Position',[30 70 70 20]);
rutdef = uicontrol('Parent',h,'String','Rutas por
defecto','style','checkbox',...
    'Position',[400 270 70 20],'Callback','rutas');

```

## PROGRAMA PRINCIPAL

```

for num= 3:length(D)-3
    lista=D(num).name

```

```

if findstr(lista,'S')
try
    imaor=imread(strcat(name1,'\ ',lista));
preprocesa;
switch metodo
    case 1
        m1
    case 2
        m2
    case 3
        m3
    case 4
        m4
    case 5
        m5
    case 6
        m6
end
    imaroil=imcrop(imarot,[clx cly dim-1 dim-1]);
    figuras
catch me
    malos=[malos num]
end
if (find(imaroil<=20))
    defe_negro=[defe_negro num]
elseif (isempty(imaroil))
    defe_negro=[defe_negro num]
else
    archivon=strcat(ruta,lista)
    imwrite (imaroil,archivon);
    cont=cont+1
    Lbpss
end
IndiviLBPeval(cont,:)=str2num(lista(7))*100+str2num(lista(8))*10+str2num(lista(9))
end
end
end

```

## **FUNCIÓN PREPROCESAMIENTO**

```

ima= imrotate(imaor,-90,'bilinear','loose');
imabin=umbral(ima,metodo_umb);
[imabin]=eliminar_areas(imabin,10000);%10000
imabin=im2double(imabin);
[f,c]=size(imabin);
imabin= bwmorph(imabin,'open');
[infi,inco,punt]=bus_puntos_inbor(imabin,f,c,basedatos);
bor = borde(imabin,[infi,inco],'N');
borx=bor(:,2);
bory=bor(:,1);
puntos

```

## **FUNCIÓN ROTAR**

```

imarot = imrotate(ima,ang,'bilinear','loose');
if ang>0

```

```

    tras=round(abs(c/sind(90)*sind(ang)));
    vecx=vecxi*cosd(ang)+vecyi*sind(ang);
    vecy=abs(vecxi*sind(ang)-vecyi*cosd(ang))+tras;

else
    tras=abs(f/sind(90)*sind(180-(ang)));
    vecx=vecxi*cosd(ang)+vecyi*sind(ang)+tras;
    vecy=abs(vecxi*sind(ang)-vecyi*cosd(ang));

end

```

## **MATLAB - R**

```

dataR=vLBP08_64;
[datos,etiq]=elimina_pocas_muestras(dataR,indiviLBP,3);
save -V6 datasR datos etiq
system('R CMD BATCH "./principalT.R" ');
load resultados.mat
save Tpm4 Tablas etiq Tablasp

```

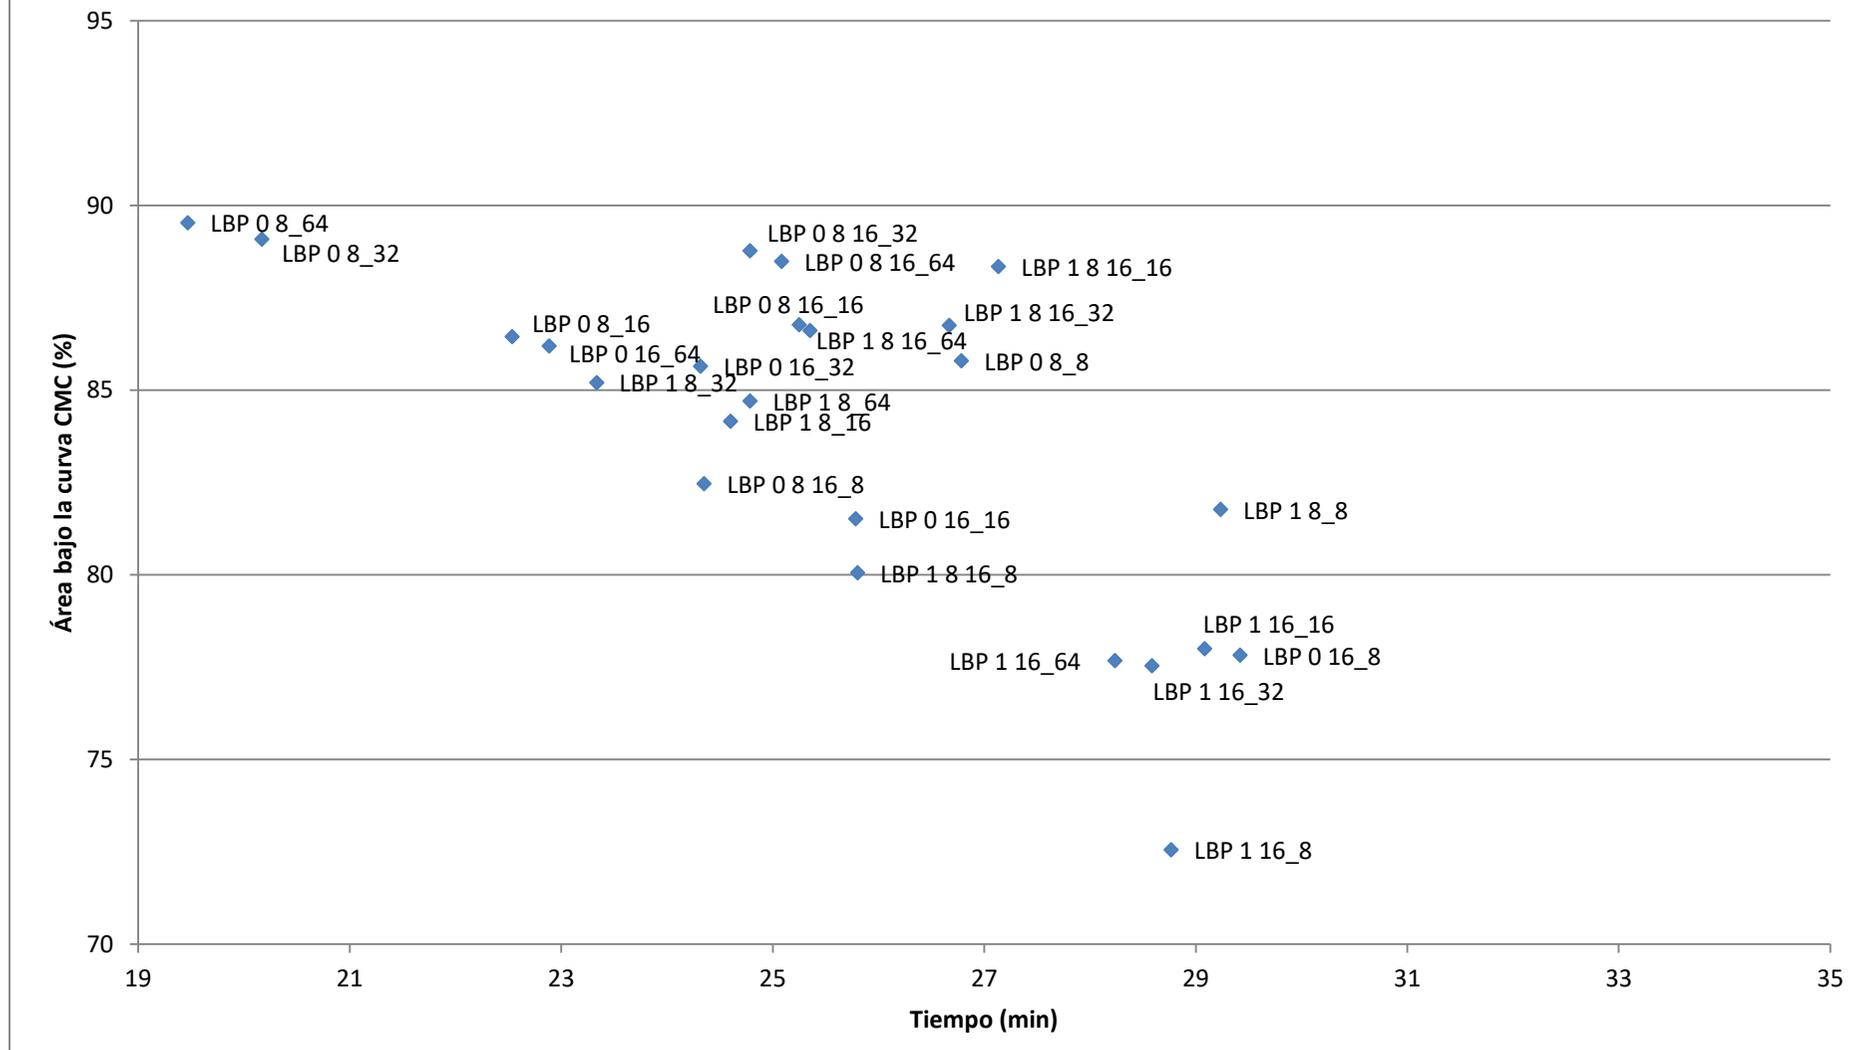
## **CURVA CMC**

```

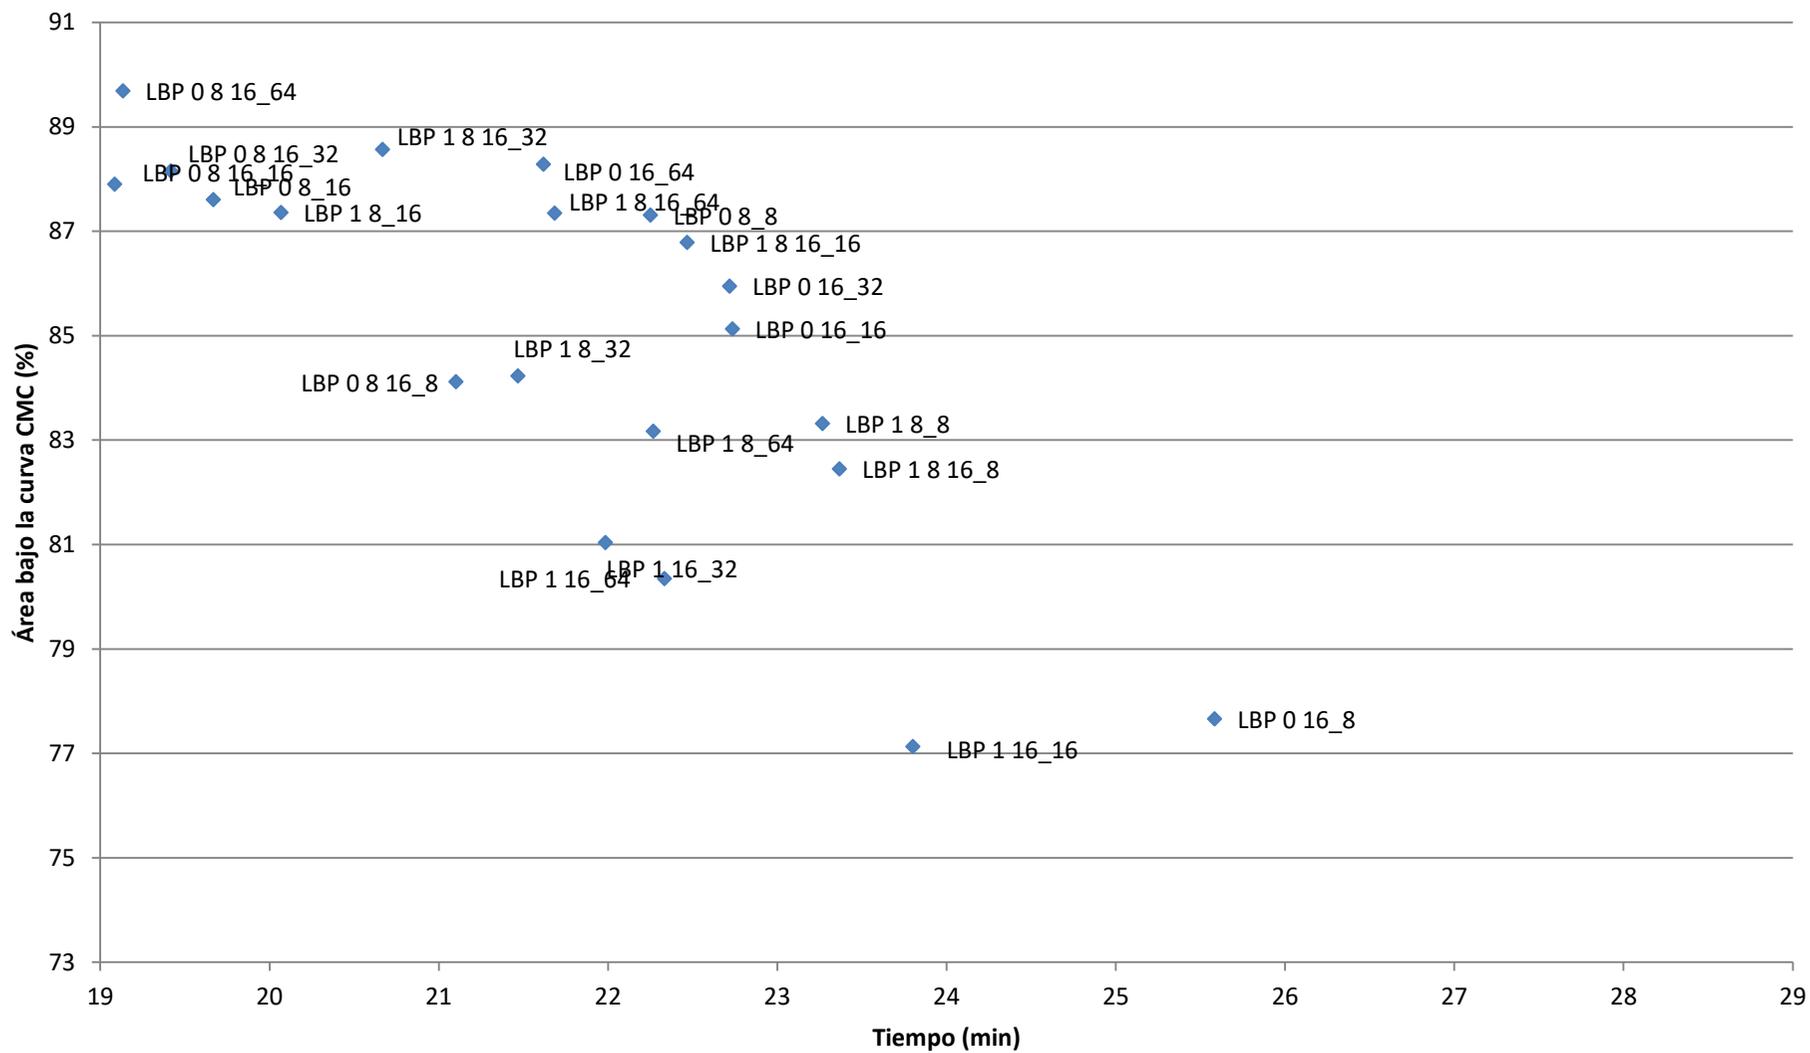
for i=1:nclas
    [vall,max1]=max(data');
    for j=1:c
        data(j,max1(j))=0;
    end
    al=etiq==u(max1);
    a=[a al];
    at=sum(a');
    porceacier(i)=sum(at>=1)/c;
end
areabcurv=trapz(u,porceacier);
areanor=areabcurv/trapz(u,ones(1,nclas));
areanor=vpa(areanor,6)

```

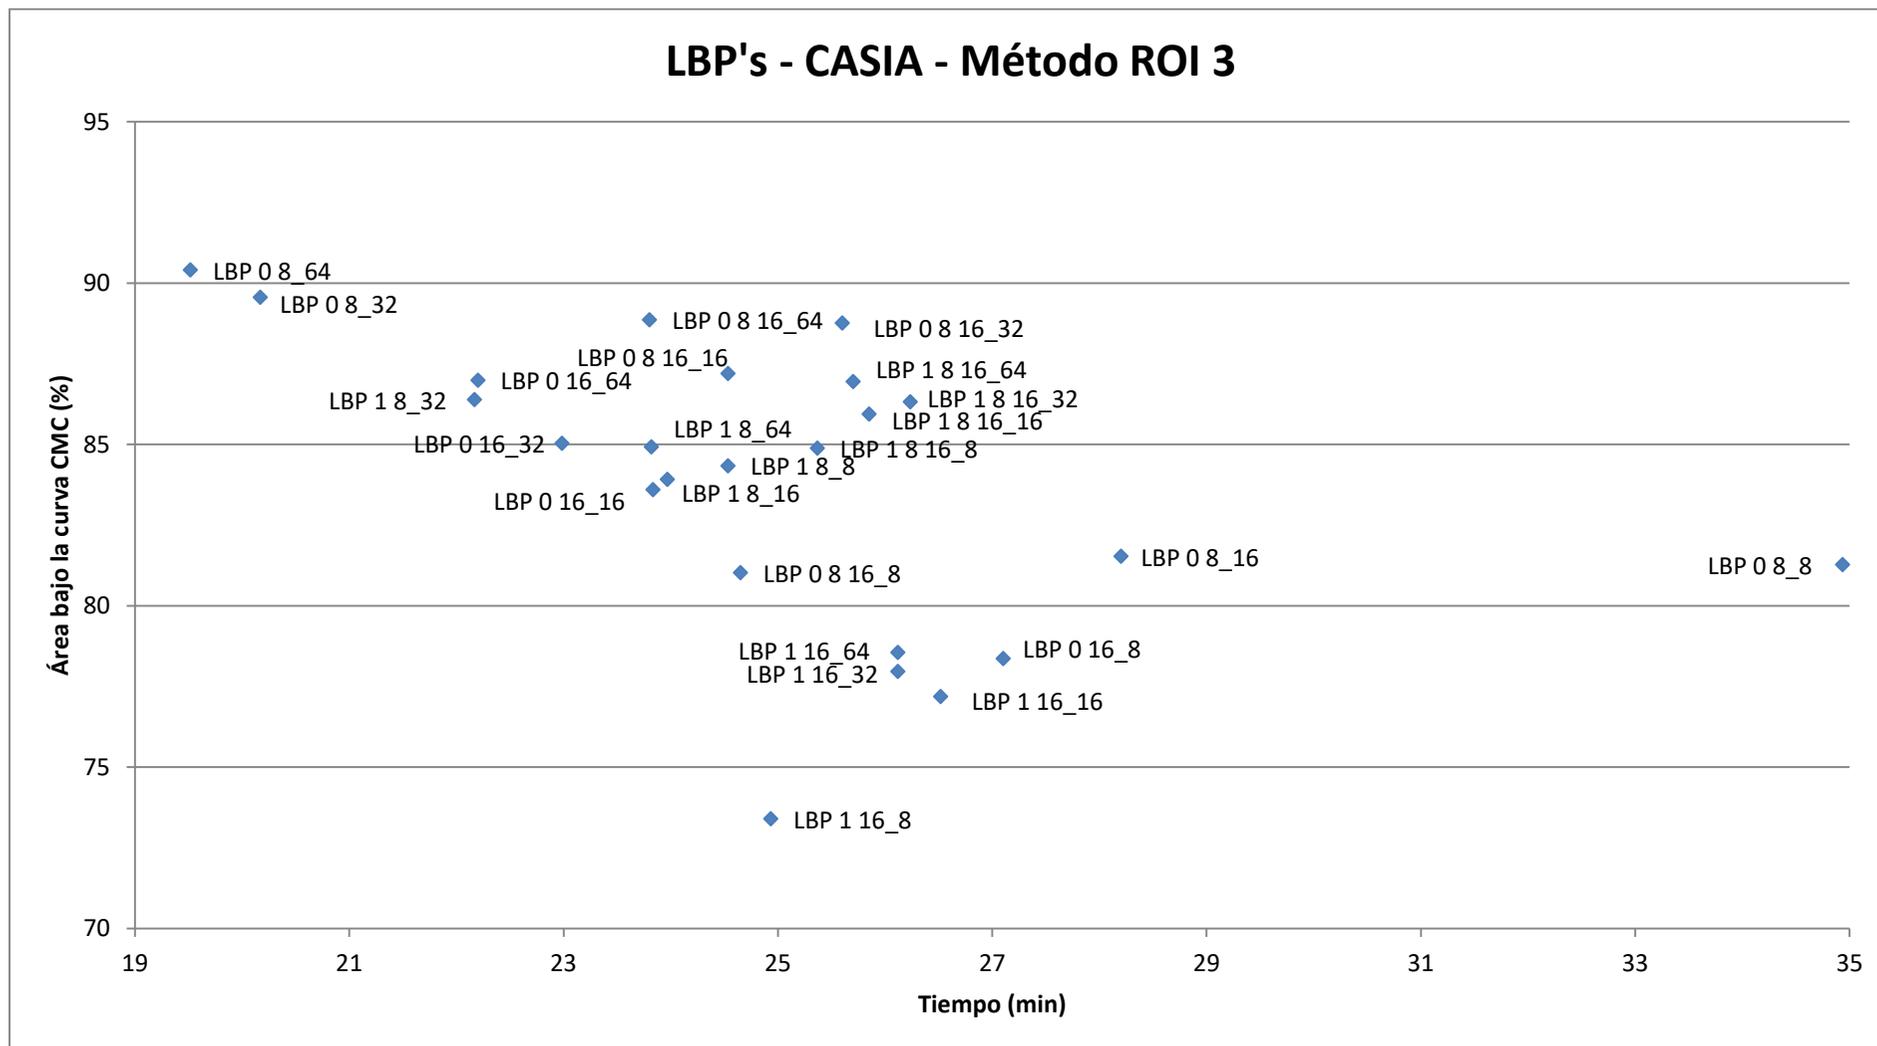
### LBP's - CASIA - Método ROI 1



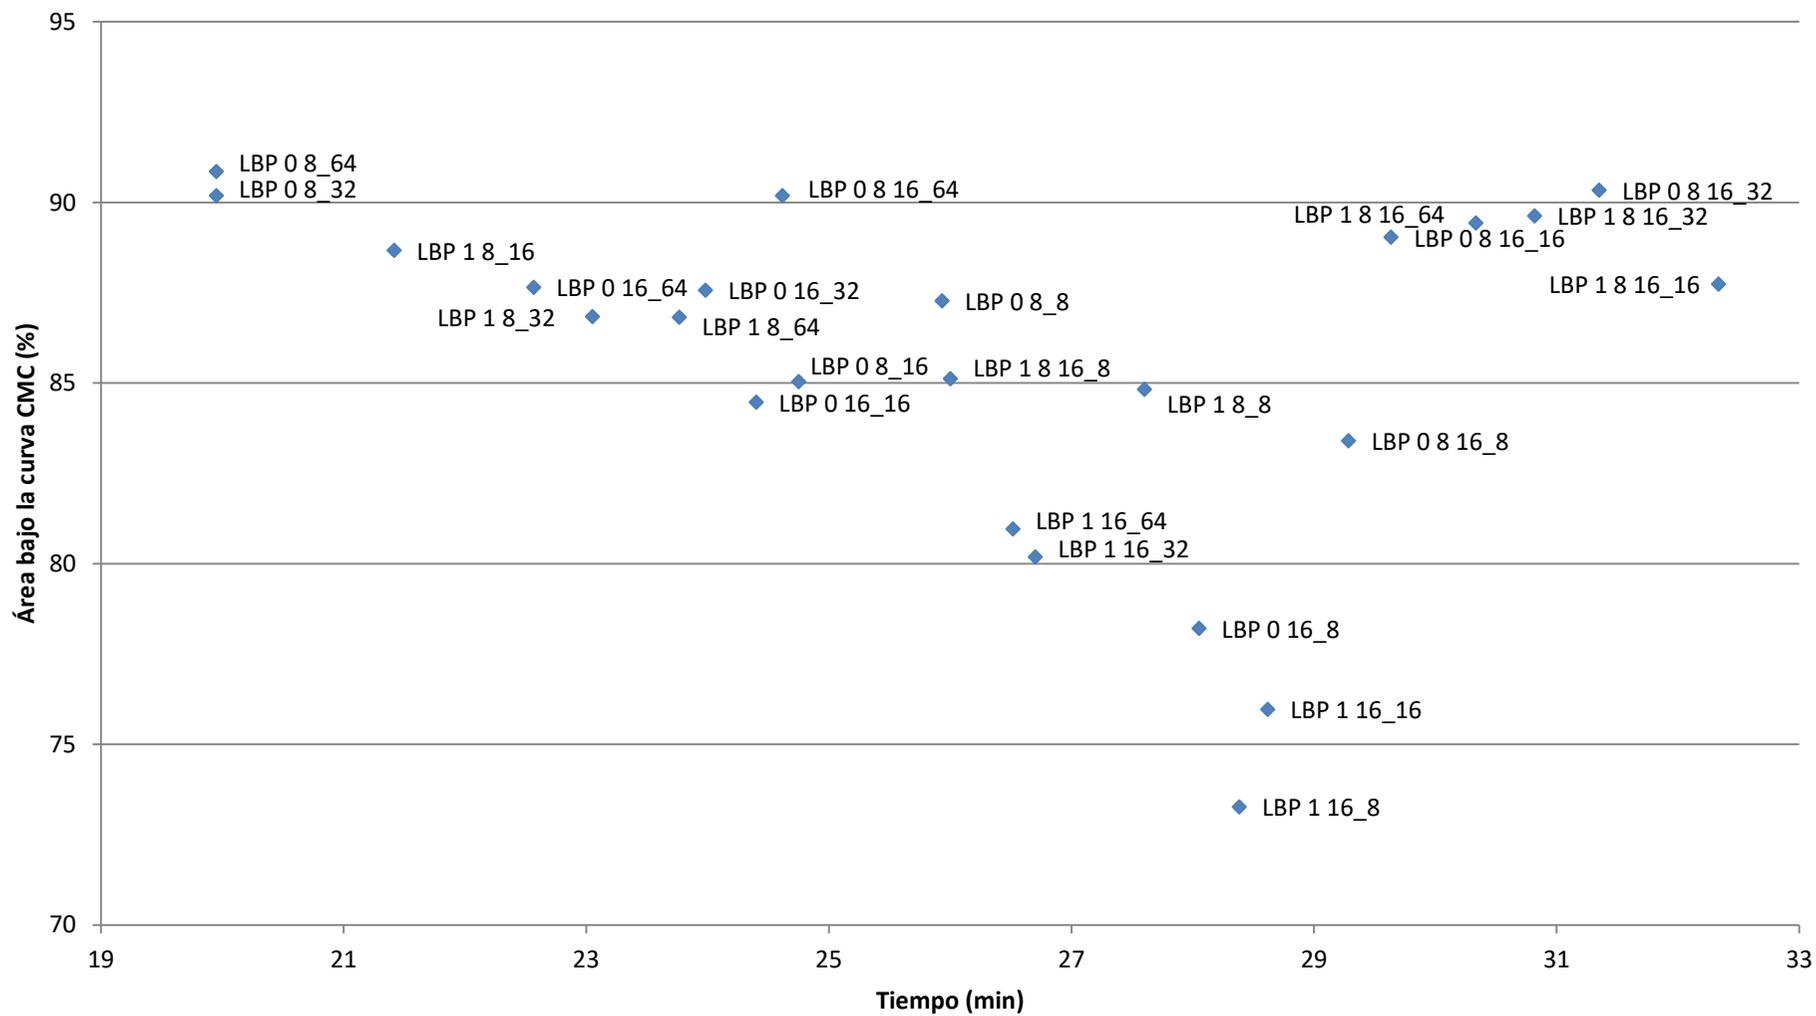
## LBP's - CASIA - Método ROI 2



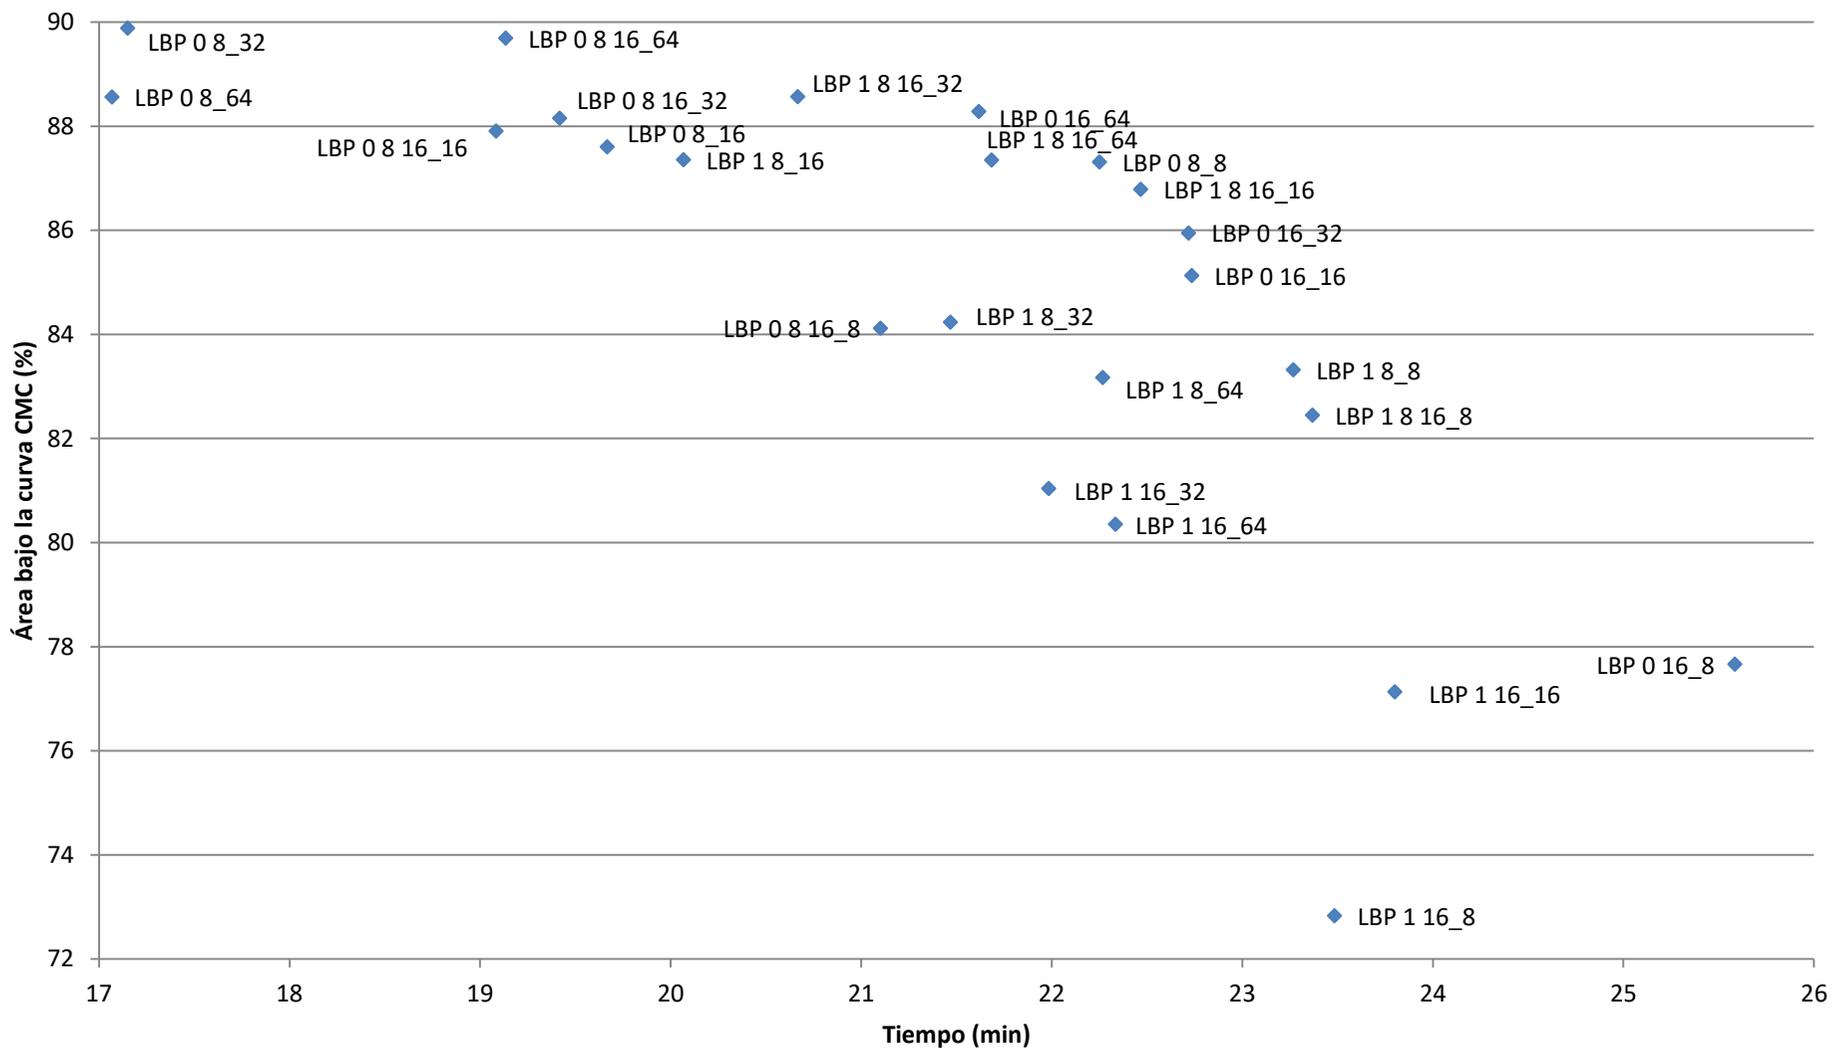
### LBP's - CASIA - Método ROI 3



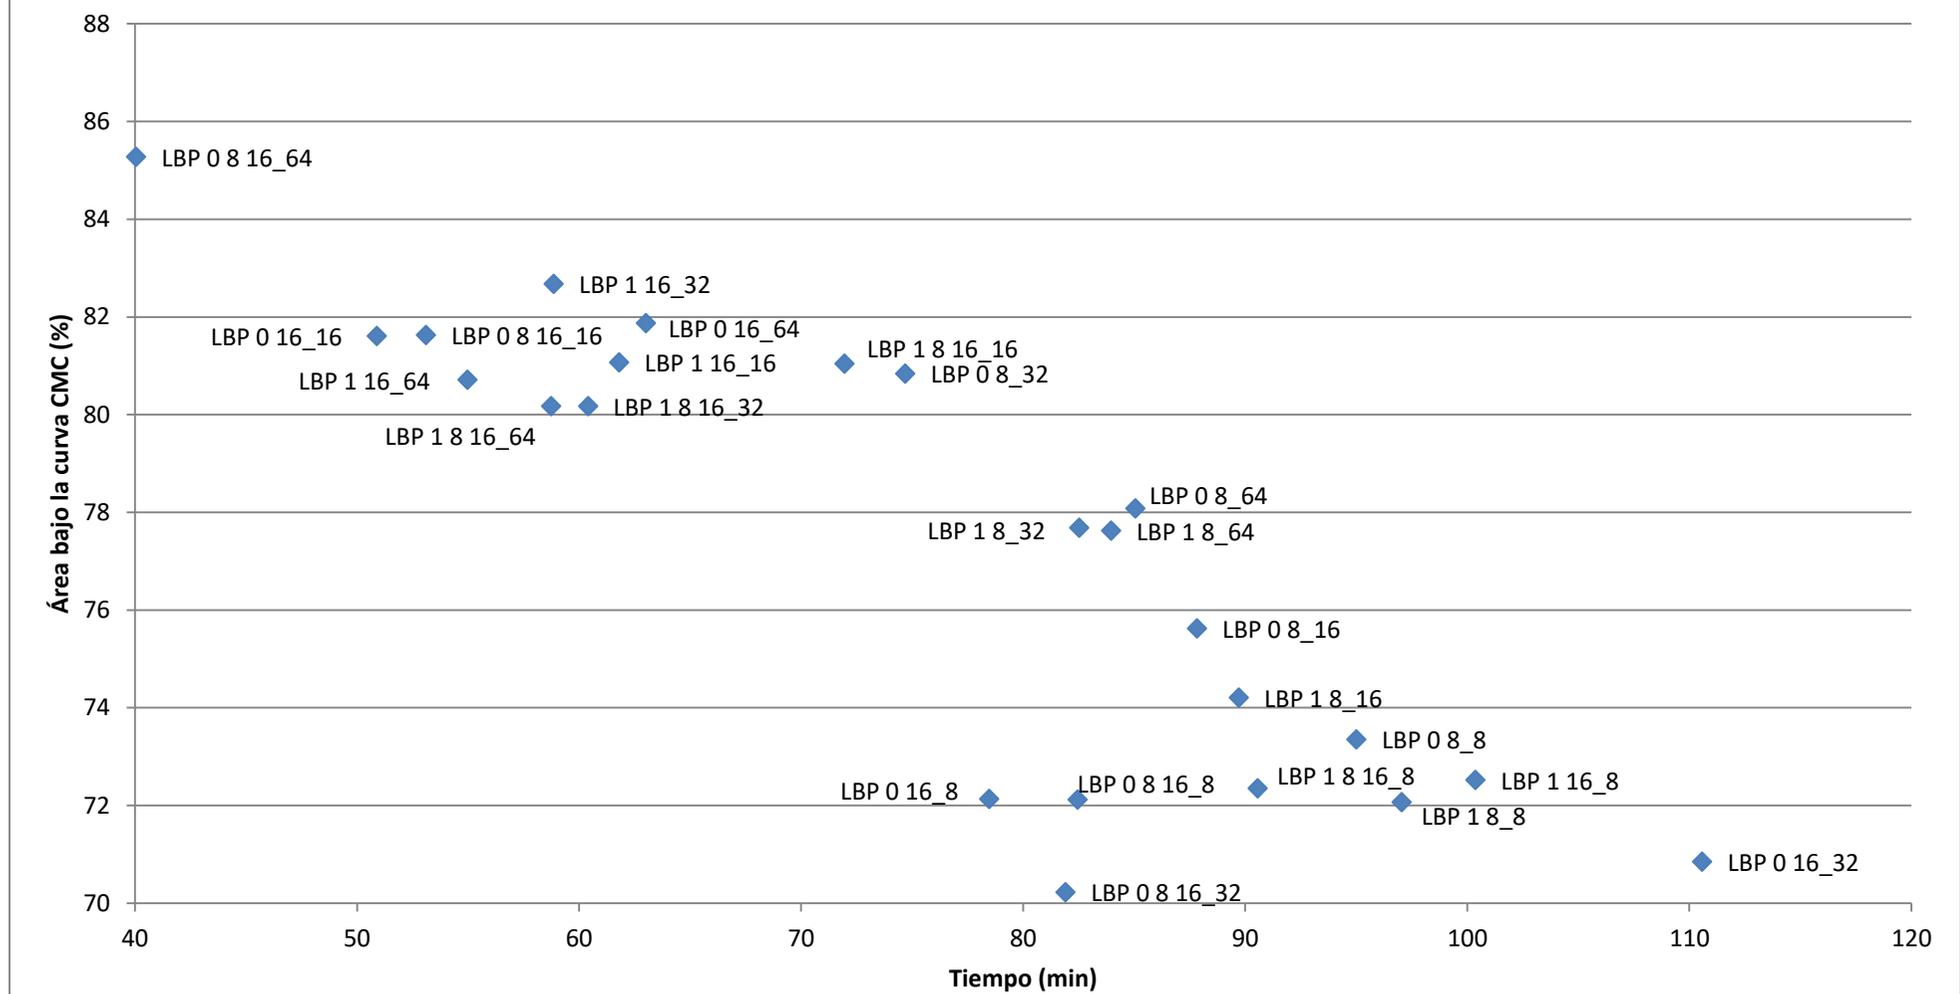
## LBP's - CASIA - Método ROI 4



### LBP's - CASIA - Método ROI 5



### LBP's - PolyU - Método ROI 3



## LBP's - PolyU - Método ROI 4

