

4.5. APLICACIONES DE LOS MÉTODOS DE REDUCCIÓN POR BLOQUES 75


de los datos si es considerada en los métodos de reducción propuestos y que los métodos *PCA3*, *PCA2PCA* y “Eigenfaces” no tienen en cuenta la información topológica por ello el desempeño de la reducción es bajo cuando se cambia el tipo de clasificador bayesiano por un clasificador con base radial.

4.5.1. Señales de voz


En la Tabla 4.1 se observan las dimensiones que alcanzaron los diferentes reductores de dimensionalidad por bloques. Se tomaron bloques de datos de [100] relacionados con imágenes y señales de voz, que contiene 53 registros de personas con disfonía (4.2(a)) y 53 registros de personas sin disfonía (4.2(b)), pronunciando la letra A. La descripción detallada se encuentra en [50]. En la primera columna se indica el porcentaje de variabilidad de los datos iniciando en 90 % y terminando en el 100 %. En las columnas dos a la nueve, se encuentran las dimensiones que logró cada método de reducción. En la Tabla 4.1 se puede observar que los métodos propuestos *PCA3D1-PCA3D5* alcanzan dimensiones menores que los demás métodos salvo en “Eigenfaces” cuando la varianza acumulada es 99 % y 100 %.

Tabla 4.1: Dimensiones alcanzadas por los métodos de reducción por bloques

Varianza Acumulada	Dimensiones de la obtenida de los Métodos de Reducción por bloques							
%	PCA3	PCA2PCA	EIGENFACES	PCA3D1	PCA3D2	PCA3D3	PCA3D4	PCA3D5
90	110 x 33	12,63 x 8	39,81 x 0	1 x 2	1 x 2	1 x 2	5 x 2	1 x 1
91	110 x 25,54	14,09 x 9	37,09 x 0	2 x 2	2 x 2	2 x 2	5 x 2	2 x 2
92	110 x 28,54	18,090 x 9	45,90 x 0	2 x 2	2 x 2	2 x 2	5 x 2	2 x 2
93	110 x 32,54	22,36 x 9	44,90 x 0	2 x 2	2 x 2	2 x 2	6 x 2	2 x 2
94	110 x 31,72	27,63 x 9,90	49,90 x 0	3 x 2	3 x 2	3 x 2	6 x 2	3 x 3
95	110 x 35,18	31,81 x 10	49,18 x 0	3 x 2	3 x 2	3 x 2	7 x 2	3 x 3
96	110 x 35,36	39 x 10,81	49 x 0	4 x 3	4 x 3	4 x 3	8 x 3	4 x 3
97	110 x 34,72	46,63 x 11	52,63 x 0	5 x 3	5 x 3	5 x 3	9 x 3	5 x 5
98	110 x 37,45	56,09 x 12	54,63 x 0	6 x 5	6 x 5	6 x 5	16 x 5	6 x 6
99	110 x 38,27	70,90 x 13	54,36 x 0	8 x 7	8 x 7	8 x 7	21 x 7	8 x 12
100	110 x 39	110 x 39	56 x 0	38 x 79	38 x 79	38 x 79	39 x 79	38 x 110



(a) Datos persona con disfonía



(b) Datos persona sin disfonía

Figura 4.2: Datos de persona pronunciando la letra A

4.5. APLICACIONES DE LOS MÉTODOS DE REDUCCIÓN POR BLOQUES 77

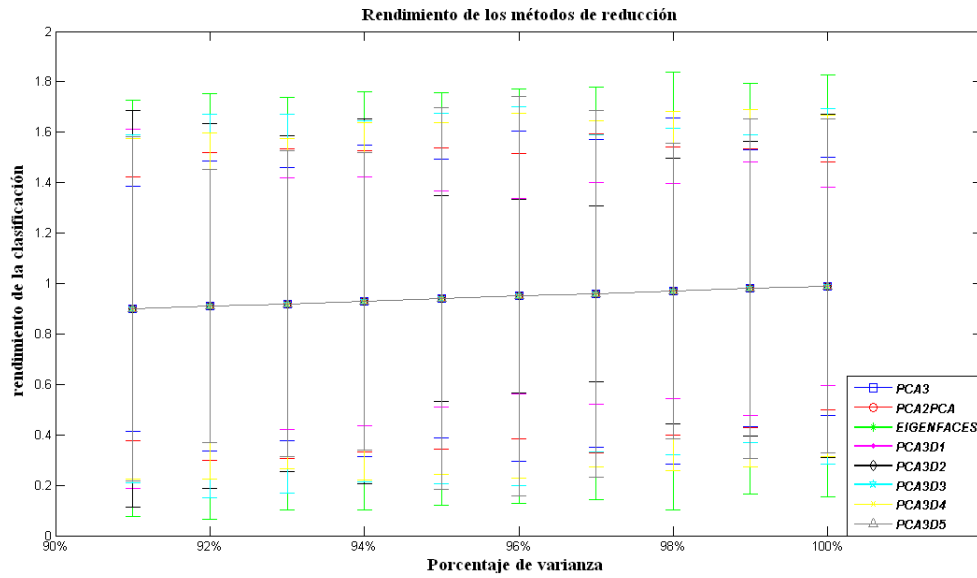
En la Figura 4.3(a) se muestra, en un diagrama de barras, el desempeño promedio de los 8 métodos de reducción en bloque sobre el mismo bloque de datos [100], en donde el eje vertical representa la correcta clasificación de los métodos, mientras que en el eje horizontal están los porcentajes de varianza total acumulada. También se observa que quizás el método más estable para estos datos fué “*Eigenfaces*”, porque obtiene menor variabilidad conforme se aumenta el porcentaje de varianza del 90 % al 99 %; sin embargo, los métodos propuestos PCA3D se desempeñan de forma aceptable; las dimensiones de reducción alcanzadas por los métodos PCA3D superaron a los demás métodos. En la Figura 4.3(b) se muestran los métodos de reducción vs el tiempo de ejecución. Se observa que los métodos propuestos *PCA3D1-PCA3D5* logran hacer la reducción en menor tiempo que los demás reductores de dimensión.

4.5.2. Bloques de imágenes de dos personas

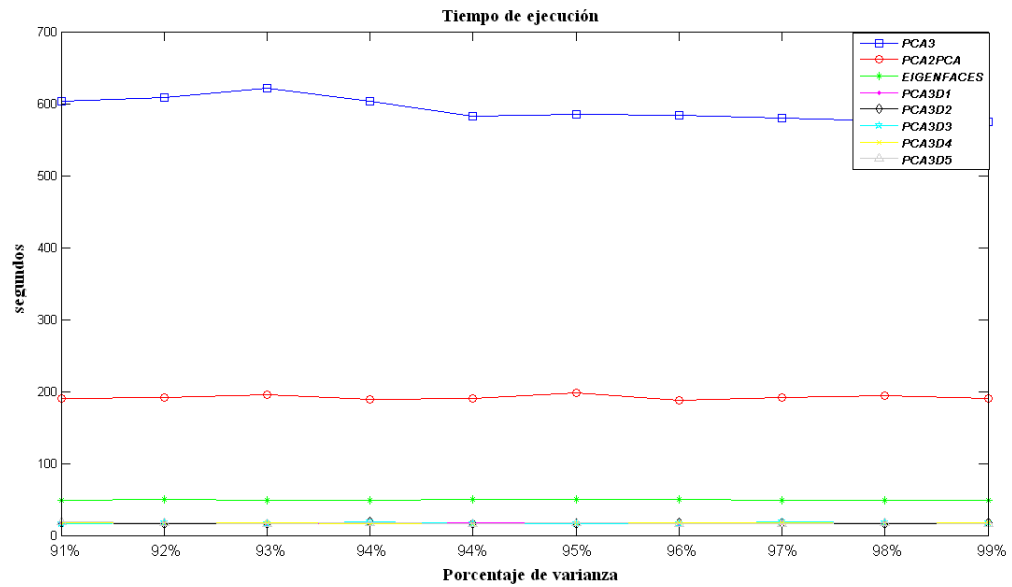
En este experimento se considera un bloque de datos de [100] relacionados con imágenes de dos personas, que contiene 40 imágenes (20 por cada uno) en diferentes ubicaciones (Figuras 4.4(a), y 4.4(b)). En la Tabla 4.2 se observan los desempeños que alcanzan los diferentes reductores de dimensionalidad por bloques propuestos. Al cambiar el clasificador Bayesiano por una máquina de vectores de soporte, se observa que los reductores propuestos tienen desempeños mayores que “*Eigenfaces*”; una justificación posible es que la máquina de vectores de soporte si tiene en cuenta la topología, o distancia entre píxeles presentes en cada imagen. Por el contrario, cuando se usó el clasificador Bayesiano, en el proceso de reducción el método, *Eigenfaces* alcanzaba los puntajes más altos, evidenciando que al cambiar el criterio de clasificación por uno que tenga en cuenta la distribución geométrica, el desempeño de la reducción cambia.

La descripción detallada se encuentra en [50]. En la primera columna se indica el porcentaje de variabilidad de los datos iniciando en 90 % y terminando en el 100 %. En la columna dos a la nueve se encuentran la dimensiones obtenidas por cada método de reducción. Se puede observar que los métodos propuestos *PCA3D1-PCA3D5* alcanzan dimensiones menores que los demás hasta antes del 99 % de la varianza. Además el rendimiento fue el mejor mientras que el comportamiento de *Eigenfaces* se redujo.

En la Figura 4.5(a) se muestra el desempeño promedio de los 8 métodos de reducción sobre el mismo bloque de datos [100], en donde el eje vertical representa




(a) Desempeño promedio



(b) Tiempo de ejecución

Figura 4.3: Desempeño y tiempos de ejecución de los métodos de reducción por bloques

4.5. APLICACIONES DE LOS MÉTODOS DE REDUCCIÓN POR BLOQUES 79



(a) Persona 1



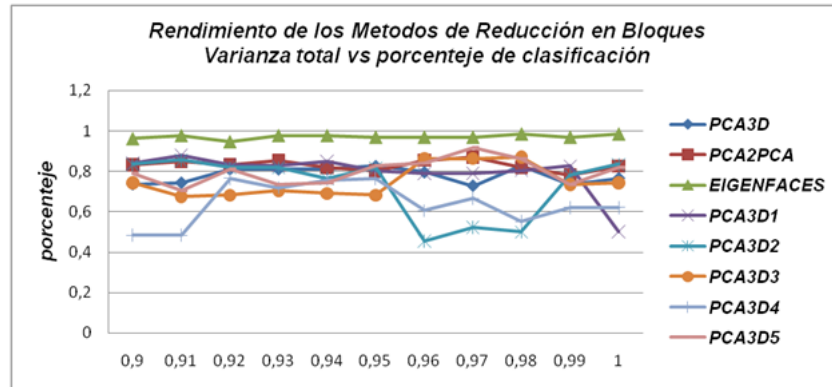
(b) Persona 2

Figura 4.4: Imágenes de 2 personas

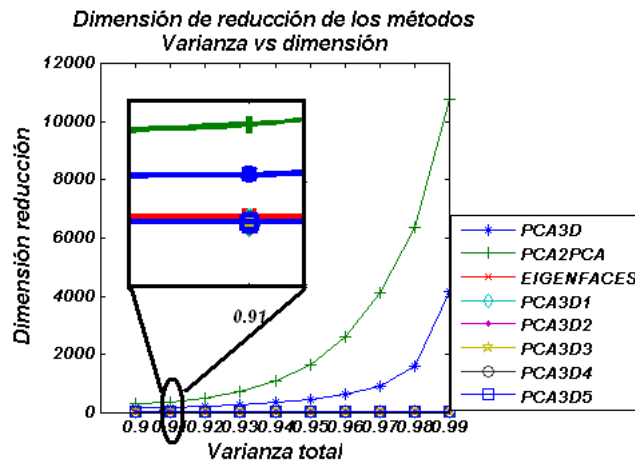
Tabla 4.2: Dimensiones alcanzadas por los métodos de reducción por bloques

Varianza Acumulada	Rendimiento promedio de la reducción los Métodos de Reducción por bloques								
	<i>%</i>	PCA3	PCA2PCA	EIGENFACES	PCA3D1	PCA3D2	PCA3D3	PCA3D4	PCA3D5
90		0.82 ± 0.14	0.91 ± 0.08	0.50 ± 0.00	0.77 ± 0.09	0.90 ± 0.07	0.80 ± 0.11	0.92 ± 0.08	0.88 ± 0.07
91		0.78 ± 0.14	0.86 ± 0.09	0.50 ± 0.00	0.80 ± 0.08	0.91 ± 0.09	0.86 ± 0.07	0.98 ± 0.04	0.90 ± 0.06
92		0.83 ± 0.17	0.86 ± 0.11	0.50 ± 0.00	0.80 ± 0.08	0.89 ± 0.07	0.85 ± 0.08	0.99 ± 0.03	0.89 ± 0.08
93		0.80 ± 0.15	0.81 ± 0.11	0.50 ± 0.00	0.76 ± 0.11	0.88 ± 0.09	0.81 ± 0.11	0.98 ± 0.03	0.85 ± 0.10
94		0.80 ± 0.12	0.81 ± 0.12	0.50 ± 0.00	0.77 ± 0.08	0.94 ± 0.08	0.87 ± 0.07	0.95 ± 0.04	1.00 ± 0.00
95		0.74 ± 0.15	0.74 ± 0.11	0.50 ± 0.00	0.80 ± 0.10	0.86 ± 0.09	0.83 ± 0.07	0.95 ± 0.06	1.00 ± 0.00
96		0.81 ± 0.17	0.72 ± 0.11	0.50 ± 0.00	0.78 ± 0.08	0.90 ± 0.07	0.84 ± 0.08	0.93 ± 0.09	0.95 ± 0.04
97		0.70 ± 0.11	0.67 ± 0.13	0.50 ± 0.00	0.80 ± 0.09	0.89 ± 0.08	0.84 ± 0.09	0.89 ± 0.09	0.97 ± 0.04
98		0.71 ± 0.11	0.61 ± 0.11	0.50 ± 0.00	0.86 ± 0.08	0.82 ± 0.10	0.83 ± 0.07	0.95 ± 0.04	0.96 ± 0.04
99		0.64 ± 0.11	0.55 ± 0.07	0.50 ± 0.00	0.89 ± 0.04	0.92 ± 0.07	0.90 ± 0.10	0.93 ± 0.06	0.93 ± 0.07
100		0.55 ± 0.07	0.50 ± 0.00	0.50 ± 0.00	0.87 ± 0.09	0.55 ± 0.09	0.70 ± 0.09	0.51 ± 0.03	0.50 ± 0.00

la correcta clasificación de los métodos, mientras que en el eje horizontal están los porcentajes de varianza total acumulada usando un clasificador Bayesiano. Debe notarse en la Figura 4.5(b) las dimensiones de reducción alcanzadas por los métodos, se observa que los métodos propuestos $PCA3D1-PCA3D5$ hacen la reducción en menor tiempo.



(a) Desempeño promedio



(b) Tiempo de ejecución

Figura 4.5: Desempeño y dimensión obtenida por los métodos sobre bloques de imágenes de dos personas

4.6. Análisis de complejidad

En esta sección se comparan la complejidad de el método de *Eigenfaces* vs *PCA3D1* el resultado es semejante para los demás métodos *PCA3D2-PCA3D5*. Considere $A_{n \times n \times n}$ un bloque de datos, el objetivo es calcular el número de operaciones necesarias para calcular la matriz de varianzas y covarianzas de A para los dos métodos. Ya que *Eigenfaces* convierte cada rebanada $A(i, :, :)$ de tamaño $n \times n$ en un vector de tamaño $1 \times n^2$ para todo $i \in \{1, \dots, n\}$ luego calcula la matriz $cov(A)$ de varianza y covarianza para estos nuevos vectores. Esta matriz de covarianza tiene tamaño $n^2 \times n^2$. Por lo tanto, el número de operaciones básicas para calcular $cov(A)$ es $cov(A) \in o(n^4)$.

De otra forma, al considerar el método *PCA3D1*, se requiere calcular las rebanadas $A(i, :, :)$ y $A(:, j, :)$ de tamaños $n \times n$ para cada $i, j \times 1, \dots, n$ y se necesita determinar las matrices de varianzas y covarianzas $cov(A(i, :, :))$, $cov(A(:, i, :))$ con tamaños $n \times n$. El número de operaciones para obtener $cov(A(i, :, :))$ es n^2 . Al calcular estas covarianzas tantas veces como filas y columnas posea el bloque, es decir; $2n$ veces, se obtiene la complejidad del proceso de reducción propuesto *PCA3D1* para calcular $cov(A) \in o(n^3)$. Esto concluye que los métodos propuestos tiene complejidad de orden $O(n^3)$ mientras que *Eigenfaces* tiene una complejidad de $O(n^4)$.

4.7. Conclusiones

1. En este capítulo se extiende el concepto de reducción de dimensión cuando los datos no son vectores sino bloques de datos. Se encuentra que los métodos *PCA3D1-PCA3D5* realmente consigue la reducción del bloque y se efectúan validaciones de los métodos comparándolos con otros métodos de reducción. Aunque *PCA3D1* no fue el mejor, si ocupó el segundo lugar realizando una mayor reducción en menos tiempo de ejecución cuando el clasificador fue Bayesiano.
2. Se comparan los métodos de reducción por bloques cambiando el clasificador por una máquina de vectores de soporte lineal y se observa que los métodos propuestos se desempeñaron mejor que los demás métodos, en cuanto a la reducción y al tiempo en ejecución. El método *Eigenfaces* arroja los peores resultados debido probablemente a la pérdida de la conexidad entre

píxeles vecinos.

3. Se calcula la complejidad frente al cálculo de las matrices de varianza y covarianza de los métodos propuestos y del método *Eigenfaces*: Se obtiene que los métodos propuestos tienen una menor complejidad frente al método de *Eigenfaces*; la complejidad del método propuesto fue $O(n^3)$ mientras que la complejidad de *Eigenfaces* fue $O(n^4)$.

Capítulo 5

Caracterización de imágenes capilares

Lo más incomprensible del mundo es que sea comprensible.
Albert Einstein (1879-1955).

5.1. Introducción

La microscopia ungueal es una técnica sencilla no invasiva y económica (in-vivi e in-situ) que permite caracterizar las microcirculaciones del tejido [26]. Esta caracterización puede dar información acerca de enfermedades vasculares del tejido conectivo tales como lupus eritematoso, dermatomiositis, fenómeno de Raynaud y esclerodermia. La información más relevante obtenida a partir de las imágenes capilares es: capilares gigantes o alargados o dilatados (capilares más largos y anchos de lo normal), pérdida capilar o avascularidades (distancia entre

capilares consecutivos mayor a lo normal), desorden del arreglo vascular o polaridad (cambios de orientaciones de los capilares), y finalmente la tortuosidad (cambios abruptos y varios giros del borde). El análisis de características como polaridad, avascularidad y tortuosidad capilar no ha sido automatizada.

Usualmente estas características son evaluadas cualitativamente y los resultados dependen fuertemente de la experiencia del dermatólogo. La falta de similitud, al escoger la magnificación y la orientación que debe tomar la imagen, hace que la cuantificación de la tortuosidad sea un problema aún no resuelto. El propósito de este capítulo es establecer de características usando conceptos de geometría fractal, geometría diferencial y estadísticos, además de realizar una reducción de dimensionalidad, buscando características relevantes a la clasificación de las imágenes (normal, Lupus, Esclerodermia).

El capítulo se organiza de la siguiente forma: En la segunda sección se trata la extracción de características utilizadas en la tesis y se presentan resultados de las mismas. En la tercera sección se presentan las reducciones de dimensionalidad propuestas aplicadas a las características capilares. En la última sección se presentan las conclusiones.

5.2. Búsqueda de características

En esta sección se mencionan las características morfológicas más útiles desde el punto de vista clínico. Para una descripción detallada ver el Apéndice C. La zona de interés es la fila capilar más próxima a la cutícula de los dedos anular y corazón de cada mano, para las que se calculan las siguientes densidades:

Densidad capilar: Número de capilares por milímetro (ver Figura 5.1(a)).

Densidad de capilares gigantes: Número de capilares gigantes por milímetro (ver Figura 5.1(b)).

Densidad avascular: Número de zonas avasculares por milímetro (ver Figura 5.1(c)).

Densidad de tortuosidad: Número de capilares con alta tortuosidad por milímetro (ver Figura 5.1(d)).

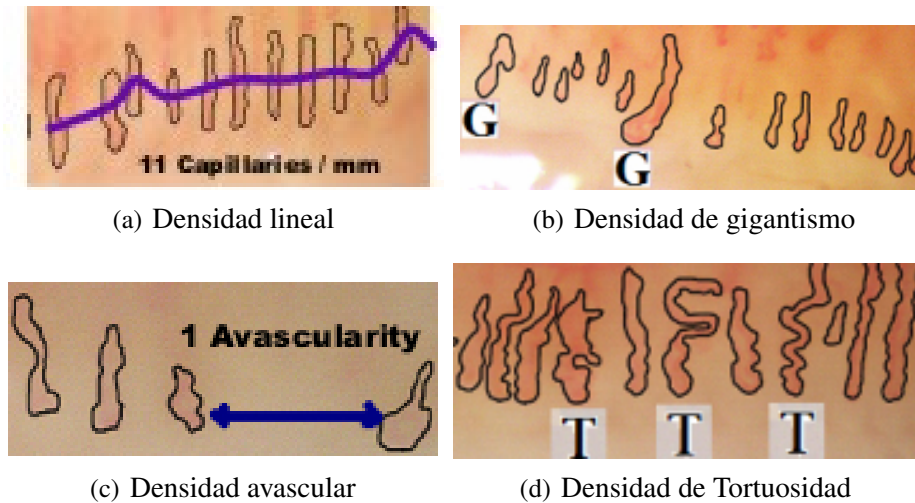


Figura 5.1: Cantidades morfológicas obtenidas a partir de las imágenes capilares.

En [67], se señala que para la mayoría de estas densidades, el cálculo respectivo no ha sido automatizado. Sin embargo, algunos autores han usado la videocapilaroscopia para realizar medidas, que han permitido registrar leves diferencias en cuanto al ancho y alto capilar entre personas que padecen esclerodermia sistémica; confirmando la conjetura en cuanto a la posible automatización de la clasificación de características relacionadas con propiedades morfológicas de la zona de interés [68]. [69] muestra la complejidad que tienen las imágenes capilaroscópicas, debido a la presencia de ruido y usa la geometría diferencial y teoría de grafos para eliminar artefactos presentes en las imágenes capilaroscópicas.

La descripción detallada de éstas y nuevas características implementadas en el trabajo son presentadas en este capítulo, donde se proponen alternativas que no solo tienen en cuenta la forma o la geometría del capilar, sino la intensidad del color usando características estadísticas como la entropía, los momentos y medianas de las intensidad capilar (ver apéndice C). En la segunda sección se presentan resultados preliminares.

Índice de tortuosidad

En la literatura, la dimensión fractal DF ha sido usada para calcular el grado de complejidad de regiones. Se calcula esta dimensión sobre el borde capilar. Por

ello daremos una serie de conceptos básicos como: bola abierta y cubrimiento abierto. Empleando la métrica del máximo se tiene:

Definición 14 Sea $\epsilon \in \mathbb{R}^+$, $\vec{x}_0 = (x_0, y_0) \in \mathbb{R}^2$ un punto en el plano real. Se llama una bola abierta con centro \vec{x}_0 y radio ϵ (ver Figura 5.2(a)) al conjunto:

$$B_\epsilon(\vec{x}_0) = \left\{ \vec{x} \in \mathbb{R}^2 : \max \{|x_0 - x|; |y_0 - y|\} \leq \epsilon \right\}. \quad (5.1)$$

Se pretende rellenar la imagen por piezas, baldosa o bolas. Este proceso se denomina cubrimiento.

Definición 15 Sea $A \subset \mathbb{R}^2$ y $C = \{U_i \in \mathbb{R}^2 : i \in I\}$ una colección de subconjuntos no vacíos de \mathbb{R}^2 , se denomina un cubrimiento de A , si $A \subset \bigcup_{i \in I} U_i$ (ver Figura 5.2(b)). Además, si la colección es disyunta dos a dos, es llamado un cubrimiento abierto disyunto de A .

Definición 16 Sea $A \subset \mathbb{R}^2$, $\beta_\epsilon = \{B_\epsilon : B_\epsilon \text{ cubrimiento de } A\}$ una colección de todos los cubrimientos disyuntos de A con bolas abiertas de radio fijo $\epsilon > 0$. Es denotado por $N_\epsilon = \min \{|B_\epsilon| : B_\epsilon \in \beta_\epsilon\}$ el menor cardinal de los cubrimientos de A con radio fijo $\epsilon > 0$.

A medida que el radio de las bolas decrece, el número de baldosas que cubren la región crece. El cociente entre el número de baldosas que cubren la región versus el radio de la bola se denomina la dimensión fractal de la región (FD).

Definición 17 Sea $A \subset \mathbb{R}^2$ la dimensión fractal de A , denotada por $dim_f(A)$, dada por la siguiente Ecuación:

$$dim_f(A) = \lim_{\epsilon \rightarrow 0} \left(\frac{\log(N_\epsilon)}{\log(\epsilon^{-1})} \right). \quad (5.2)$$

Ejemplo 1 Dada una región $A \subset \mathbb{R}^2$, una bola abierta con centro $\vec{x}_0 = (x_0, y_0)$, y radio $\epsilon > 0$, que tiene forma de un cuadrado abierto de longitud 2ϵ centrado en \vec{x}_0 . Un cubrimiento de A con bolas de radio $\epsilon = 2$ donde $N_\epsilon = 5$ o $\epsilon = 1$ y $N_\epsilon = 14$ son mostrados en la Figura 5.2(a), 5.2(b) respectivamente.

Para la implementación discreta de DF es necesario hacer una regresión lineal del conjunto de las parejas $(\log(\epsilon^{-1}), \log(N_\epsilon))$. Para reducir el costo computacional se han considerado radios potencias de 2. La pendiente de esta regresión

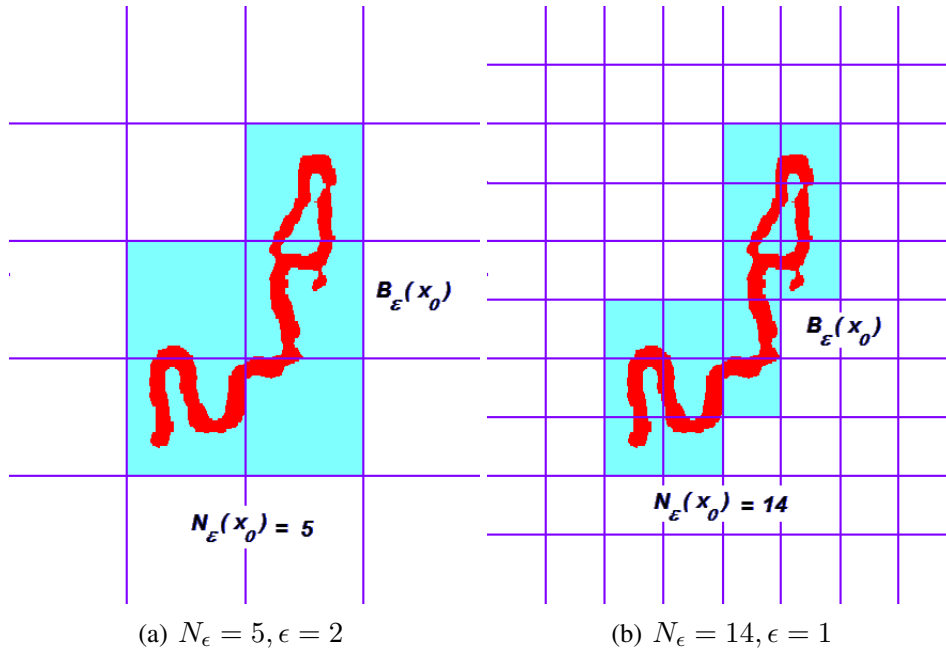


Figura 5.2: Cálculo de N_ϵ cubrimientos de A .

es interpretada como DF de la región. DF tuvo problemas con el cálculo de algunos capilares gigantes no tortuosos; por esta razón se tuvo que normalizar DF con el área de la región. A este cociente lo llamamos índice de tortuosidad IT , que permite separar capilares que poseen tortuosidad baja de aquellos que tienen tortuosidad alta.

Definición 18 *El índice de tortuosidad IT para una región capilar R es el cociente entre el área y la dimensión fractal de la región. La dimensión fractal es invariante a rotaciones, traslaciones y escalamientos; dichas pruebas se presentan [99] y pueden ser extendidas al nuevo índice de tortuosidad IT . En el Apéndice D, se definen algunas proposiciones de propiedades que cumple el índice fractal.*

5.2.1. Determinación de la orientación, ancho y alto capilar

Una vez localizada la región R por el proceso de segmentación, se calcula la posición de los píxeles en R y usando la métrica de Mahalanobis se determina una elipse que delimita la región R . A partir de los dos autovalores λ_1, λ_2 y sus correspondientes autovectores \vec{v}_1, \vec{v}_2 podemos definir:

Definición 19 El ancho y el alto del capilar son relacionados o asignados como los ejes mayor y menor de la elipse que fue obtenida por el PCA con la métrica Mahalanobis, según se indicó en el párrafo anterior. Así, el alto del capilar es el doble del autovalor más pesado λ_1 , mientras que el ancho del capilar es el doble del autovalor menos pesado λ_2 , como se muestra en la Figura 5.3(a).

Definición 20 La orientación planar capilar es el ángulo formado por el vector unitario $\vec{i} = (0, 1)$ y el autovector asociado con el autovalor mayor \vec{v}_1 , (ver Figura 5.3(b)).

Definición 21 La polaridad de la imagen es la desviación estándar de todas las orientaciones planares de los capilares presentes en la imagen.

Una avascularidad o ausencia capilar se presenta si la distancia entre los centros de gravedad de capilares contiguos es mayor que el promedio de las distancias consecutivas de capilares, más una desviación estándar entre estas distancias.

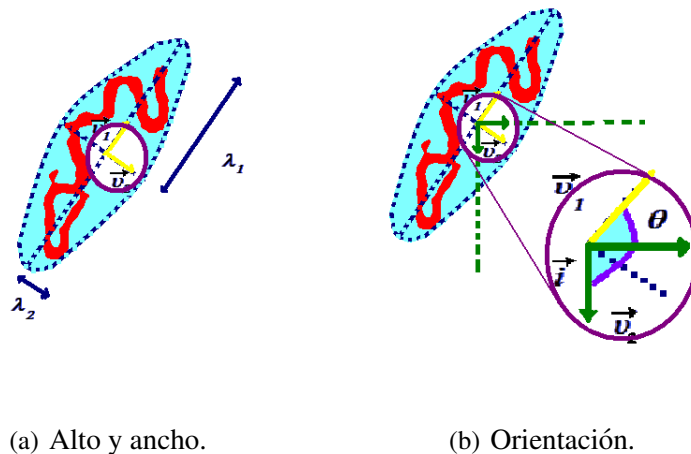


Figura 5.3: Características morfológicas usando PCA.

Como se mencionó anteriormente, se usa la curvatura como concepto de la geometría diferencial al considerar el borde de la zona capilar (ver Figura 5.4). La curvatura de cada píxel (x, y) es calculada usando la siguiente ecuación:

$$C(x, y) = \frac{\left| \frac{\partial I(x,y)}{\partial x} * \frac{\partial^2 I(x,y)}{\partial y^2} - \frac{\partial I(x,y)}{\partial y} * \frac{\partial^2 I(x,y)}{\partial x^2} \right|}{\left(1 + \left(\frac{\partial I(x,y)}{\partial x} \right)^2 + \left(\frac{\partial I(x,y)}{\partial y} \right)^2 \right)^{3/2}}. \quad (5.3)$$

La curvatura no pudo caracterizar la tortuosidad, pero si caracteriza los capilares gigantes o dilatados (ver Figura 5.4).




Figura 5.4: Curvatura de imágenes sintéticas con valores 0.41, 0.40, 0.37, 1.01 y 1.03 respectivamente

5.2.2. Resultados de la caracterización capilar

Se implementa un clasificador *k-medias* con 5 clases: tortuosidad alta, tortuosidad mediana, tortuosidad media, tortuosidad baja y sin tortuosidad. Este clasificador fue aplicado sobre 3362 capilares correspondientes a 135 imágenes de personas sin enfermedad vascular del tejido conectivo (ver Figura 5.5), donde 135 capilares fueron calificados con tortuosidad alta. Su evaluación se puede observar en la Tabla 5.1, notándose una eficiencia alta.

Tabla 5.1: Eficiencia del índice de tortuosidad *IT* evaluado sobre 3362 capilares

	Verdadera Aceptación	Verdadero Rechazo	Falsa Aceptación	Falso Rechazo
Porcentaje	95	99	1	5

Se segmentan 3362 capilares de personas sin enfermedades vasculares del tejido conectivo y 250 capilares de personas con lupus eritematoso. Los capilares