

Compensación de iluminación en imágenes del fondo de ojo por descomposición bidimensional en modos empíricos

Raúl Andrés Vargas Ramírez

Universidad Tecnológica de Bolívar

Facultad de ingeniería
Programa de Ingeniería Mecatrónica

Trabajo de grado

**Compensación de iluminación en imágenes del
fondo de ojo por descomposición bidimensional
en modos empíricos**

Raúl Andrés Vargas Ramírez

1. Revisor **Sonia Contreras, PhD**
Facultad de ingeniería
Universidad Tecnológica de Bolívar

2. Revisor **Oscar Acevedo, PhD**
facultad de ingeniería
Universidad Tecnológica de Bolívar

Director **Andrés Marrugo, PhD**

2016

Raúl Andrés Vargas Ramírez

Compensación de iluminación en imágenes del fondo de ojo por descomposición bidimensional en modos empíricos

Trabajo de grado, 2016

Revisores: Sonia Contreras, PhD y Oscar Acevedo, PhD

Director: Andrés Marrugo, PhD

Universidad Tecnológica de Bolívar

Programa de Ingeniería Mecatrónica

Facultad de ingeniería

Cartagena, Bolívar.

Resumen

El presente trabajo de grado tuvo como propósito estimar y compensar la iluminación de imágenes del fondo de ojo por medio de la técnica de Descomposición Bidimensional en Modos Empíricos (BEMD, por sus siglas en inglés), la cual descompone una imagen separando sus contenidos frecuenciales en otras imágenes. La última imagen de descomposición, conocida como residuo, guarda contenido frecuencial que podemos asociar a la iluminación. Las imágenes retinianas utilizadas como objeto de estudio son del servicio de oftalmología del hospital Miguel Servet en Zaragoza, España y se usó el entorno de Matlab para hacer el procesamiento de las mismas. Nuestro se ha basado en la implementación de BEMD por John D'Errico y SasiKanth, para hacer la estimación de iluminación. Luego de estudiar esta función y caracterizarla, encontramos que la calidad y el tiempo de la estimación dependen del número de modos y la resolución con que se haga la descomposición y el contenido de información irrelevante en las imágenes que no hacen parte de la retina. Por último, comparamos BEMD con otra técnica propuesta para estimar la iluminación de las imágenes del fondo de ojo y exponemos las ventajas de la técnica de estudio de este trabajo. La metodología propuesta se probó en imágenes retinianas convencionales y angiografías, obteniendo resultados satisfactorios en términos de mejorar la calidad de la imagen.

Palabras claves: imágenes del fondo de ojo, descomposición bidimensional, contenidos frecuenciales, residuo, iluminación, modos empíricos, estimación, retina, modos, tiempo de estimación.

Agradecimientos

Primeramente agradezco a Dios, mis padres y a mi hermana por haberme hecho crecer como persona y apoyarme constantemente en las etapas de mi vida.

Agradezco muy sinceramente a mi asesor de tesis, Andrés Marrugo; sus conocimientos, esfuerzo y dedicación han sido fundamentales para mi formación como investigador.

Finalmente, agradezco a la Universidad Tecnológica de Bolívar y dirección de investigaciones y a la empresa Tenaris TuboCaribe por mi formación profesional.

Índice general

1 Introducción	3
1.1 Motivación y alcance	3
1.2 Divulgación de resultados	4
1.3 Estructura del contenido	5
2 Conceptos	7
2.1 Imágenes de Fondo de ojo	7
2.1.1 Adquisición y procedimiento	9
2.1.2 Calidad de imagen	10
2.1.3 Enfermedades asociadas	11
2.2 Descomposición en modos empíricos (EMD)	12
2.3 Descomposición bidimensional en modos empíricos (BEMD)	14
3 Implementación y resultados	17
3.1 Segmentación de regiones	18
3.2 Selección del área de interés	20
3.3 Extrapolación de zonas oscuras	23
3.4 Descomposición en modos	25
3.4.1 Descomposición por reducción	27
3.4.2 Tiempo de descomposición	29
3.5 Compensación de iluminación	31
3.6 Comparación entre métodos	32
4 Discusión y conclusiones	35
Bibliografía	37
5 Anexos	41

Índice de figuras

2.1	Estructura de un ojo humano (Ilustración por Holly Fischer).	7
2.2	Estructura del fondo de ojo. Extraído de amf-semfyc Web.	8
2.3	Retinografía con etiquetas y zonas oscuras.	8
2.4	Imágenes del fondo de ojo obtenidas por diferentes procedimientos.	9
2.5	Esquema del sistema óptico de una cámara retiniana. Extraído de Marrugo, 2013	10
2.6	Ejemplo de retinografías con baja calidad. Extraído de Marrugo, 2013. . .	11
2.7	Imagen retiniana simulada. Se muestran los problemas generados por la retinopatía diabética (Extraído de A.D.A.M images)	12
2.8	Descomposición de una señal por EMD. Extraído de Marrugo y col., 2015.	14
3.1	Esquema del procedimiento llevado a cabo para compensar la iluminación en una imagen retiniana. Se muestran las etapas de preprocesado y las etapas posteriores junto con a sus respectivas variables de entrada y salida.	17
3.2	(a) Es una imagen de fondo de ojo común, la cual posee etiquetas, una mala distribución de iluminación, entre otras. (b) Es la matriz semilla usada en la función <code>RegionGrow()</code> para segmentar las regiones. Es importante que las semillas se ubiquen cerca a las esquinas, en la región de baja intensidad, ya que esta región se segmentará de las demás regiones.	18
3.3	Regiones segmentadas. Se muestra la máscara $M(x,y)$ obtenida luego de la etapa de segmentación por regiones.	20
3.4	Regiones segmentadas encerradas por su correspondiente <code>BoundingBox</code> . El <code>boundingBox</code> que encierra la mayor área se usará para recortar la imagen y la mascara a un tamaño óptimo como se muestra en las figuras 3.5a y 3.5b, respectivamente.	21
3.5	Se muestran la imagen de entrada (a) junto a las imágenes de salida de la etapa de preprocesado.	22
3.6	Esquema de extrapolación de zonas oscuras.	23
3.7	Prrocesado de tres imágenes retinianas. Se muestra la imagen resultado de las tres etapas de preprocesado y la máscara conseguida al segmentar la topografía retiniana.	25

3.8	BIMFs obtenidos luego de hacer una descomposición a 4 y 5 modos a la imagen de la figura 3.9a.	27
3.9	Se muestra la variación en la estimación y compensación de iluminación en base al factor de reducción <i>a</i> propuesto para el ahorro del tiempo de computo. El factor <i>a</i> =0.44 fue el resultado escalar la imagen a 512 píxeles en el tamaño de las filas.	28
3.10	Relación entre el factor de escala (donde un factor de escala de '1' representa la resolución completa) y el tiempo de computo para la descomposición de la imagen 3 de la figura 3.7 (Resolución original: 1152x1612 píxeles) a 4 y 5 modos.	30
3.11	Estimación y compensación de iluminación de 3 imágenes retinianas en 4 y 5 modos.	31
3.12	(a) Imagen retiniana original con iluminación no uniforme.(b) perfil de intensidad de la imagen (linea punteada). (c) Estimación de iluminación con EMD. (d) Estimación de iluminación por el método propuesto por Foracchia y col.	32
3.13	Compensación de iluminación en el nervio óptico. (a) Perfil de intensidad original (b) Compensación por EMD y (C) compensación por el método de Foracchia y col.	34
3.14	Estimación y compensación de iluminación de la imagen 3.12a por BEMD y el método de Foracchia y col.	34

Índice de tablas

3.1	Tiempo de cómputos para la descomposición en 4 y 5 modos para cuatro imágenes con igual resolución.	30
-----	---	----

Índice de algoritmos

1	Algoritmo para la descomposición en modos empíricos (EMD).	13
2	Algoritmo para la descomposición bidimensional de una imagen en modos empíricos (BEMD). Propuesto por Bouledjfane y col., 2013.	16
3	Algoritmo para la segmentación de regiones en Matlab.	19
4	Algoritmo para la selección del área de interés en Matlab.	22
5	Algoritmo para la extrapolación de zonas oscuras en imágenes retinianas usando Matlab.	24
6	Algoritmo para descomposición bidimensional en modos empíricos de una imagen, usando funciones de Matlab.	26

Introducción

Las imágenes retinianas son utilizadas por oftalmólogos, personal médico y recientemente por sistemas computacionales para la detección oportuna de enfermedades y patologías. Es posible también que sean utilizadas para observar la evolución de un paciente a través del tiempo y poder brindarle un mejor tratamiento. La calidad de estas imágenes dependen de algunos factores variantes como la preparación del paciente para la prueba y otros invariantes como la calidad del sistema de adquisición. Una imagen retiniana de baja calidad puede conllevar a malos diagnósticos o procedimientos médicos. En este trabajo buscamos mejorar la calidad de estas imágenes mejorando digitalmente su iluminación por medio de la técnica de Descomposición Bidimensional (BEMD, por sus siglas en inglés), la cual separa los contenidos frecuenciales de una imagen en varias imágenes llamadas BIMFs más un residuo, el cual posee el contenido frecuencial más bajo y lo utilizamos en este trabajo para caracterizar la iluminación de la imagen.

1.1 Motivación y alcance

Entre las enfermedades que afecta la retina encontramos *la diabetes mellitus* (DM). Esta enfermedad genera la complicación microvascular, llamada *retinopatía diabética* (RD), la cual afecta una de cada tres personas con DM. Según la Organización Mundial de la Salud la retinopatía diabética produce casi el 5 % de los 37 millones de ciegos en el mundo. Sin embargo, esta puede prevenirse en un 80 % de los casos con una detección y tratamiento temprano asociados a un manejo general.

En este trabajo de grado nos planteamos como objetivo principal mejorar la calidad de las imágenes de fondo de ojo, mejorando su iluminación. Para alcanzar este objetivo, se implementaron algoritmos en Matlab para, el preprocessado de las imágenes, realizar la caracterización de la descomposición por BEMD, compensar la iluminación y comprobar que esta técnica estima correctamente la iluminación sin afectar información relevante de la retina.

DIVULGACIÓN DE RESULTADOS - LINEA DE TIEMPO

Abr, 2015. Vargas Raúl, Chirino Melet, Marrugo Andrés, Millan María. *Estimación y compensación de la iluminación en imágenes de fondo de ojo por descomposición en modos empíricos.* XII encuentro departamental de semilleros de investigación (EDESI, 2015).

Oct, 2015. Vargas Raúl, Chirino Melet, Marrugo Andrés y Millán María. *Estimación y compensación de la iluminación en imágenes de fondo de ojo por descomposición en modos empíricos.* XVIII Encuentro Nacional Y XII Internacional de Semilleros de Investigación (ENISI, 2015).

Nov, 2015. Marrugo Andrés, Vargas Raúl y Millán María. *On the Compensation of Uneven Illumination in Retinal Images for Restoration by Means of Blind Deconvolution.* XIV encuentro nacional de óptica y V conferencia andina y del caribe en óptica y sus aplicaciones (ENO-CANCOA, 2015).

Nov, 2015. Marrugo Andrés G., Vargas Raúl, Chirino Melet, y Millán María S. *On the Illumination Compensation of Retinal Images by Means of the Bidimensional Empirical Mode Decomposition.* 11th International Symposium on Medical Information Processing and Analysis (SIPAIM, 2015).

Ago, 2016. Marrugo Andrés, Vargas Raúl, Pineda Jesús y Romero Lenny. *Background Intensity Removal in Fourier Transform Profilometry: A Comparative Study.* The Latin America Optics & Photonics Conference (LAOP, 2016).

Ago, 2016. Marrugo Andrés G., Vargas Raúl, Contreras Sonia, y Millán María S. *On the Compensation of Uneven Illumination in Retinal Images for Restoration by Means of Blind Deconvolution.* The 21st Symposium on Image, Signal Processing and Artificial Vision (STSIVA, 2016).

Ago, 2016. Vargas Raúl, Pineda Jesús, Romero Lenny y Marrugo Andrés. *Background Intensity Removal in Structured Light Three-Dimensional Reconstruction.* The 21st Symposium on Image, Signal Processing and Artificial Vision (STSIVA, 2016).

1.2 Divulgación de resultados

Desde mi vinculación al semillero de investigación en visión artificial de la universidad en el 2014, he participado en diferentes proyectos de investigación liderados por el profesor Andrés Marrugo. Inicialmente comencé investigando sobre reconstrucción 3D por proyección de franjas. Luego, en el primer periodo del 2015 junto a Melet chirino, el profesor Andrés Marrugo y la profesora María Millan de la Universidad Politécnica de Cataluña comenzamos a investigar sobre la compensación de iluminación en imágenes del fondo de ojo por BEMD en el marco del proyecto de investigación sistemas de profundidad de foco extendida y lentes intraoculares para la salud visual, financiada por el ministerio de economía y competitividad de España. Esta investigación se sustenta en este trabajo de grado y en algunos congresos nacionales como el XII

encuentro departamental de semilleros de investigación, el XVIII Encuentro Nacional Y XII Internacional de Semilleros de Investigación. También contamos con una participación internacional en noviembre de 2015 en el *12th International Symposium on Medical Information Processing and Analysis*.

Esta investigación también ha permitido complementar otros trabajos; por ejemplo, hemos propuesto usar la técnica BEMD para, compensar la iluminación en imágenes retinianas para su restauración por el método de deconvolución ciega y para la remoción del espectro cero en imágenes de reconstrucción 3D por proyección de franjas, obteniendo participaciones en varios eventos como el *XIV encuentro nacional de óptica y V conferencia andina y del caribe en óptica y sus aplicaciones* (eno-cancoa, 2015), *The Latin America Optics & Photonics Conference (LAOP 2016)* y en *The 21st Symposium on Image, Signal Processing and Artificial Vision (STSIVA, 2016)*.

1.3 Estructura del contenido

Este trabajo de grado está estructurado de la siguiente manera :en el capítulo 2 se exponen los conceptos usados durante el trabajo, junto al estado del arte de los mismos. Los conceptos van relacionadas con las imágenes del fondo de ojo y la técnica de descomposición BEMD.

El capítulo 3, llamado implementación y resultados, se divide por secciones. En cada sección de este capítulo se plantea un objetivo-problema, se emplea un algoritmo en Matlab que ayude a resolverlo, se muestran y se analizan los resultados obtenidos y por último se evidencia el nuevo problema a resolver en la siguiente sección.

En el último capítulo se hace una discusión sobre los resultados obtenidos en el capítulo 3 y se llegan a conclusiones en base los objetivos de la investigación.

En la parte anexos se encuentran las publicaciones obtenidas por la participación en eventos nacionales e internacionales. Algunas de estas publicaciones tienen como tema principal el estudiado en este trabajo, mientras que otras lo utilizan como complemento para llevar a cabo sus propios objetivos planteados.

Conceptos

2.1 Imágenes de Fondo de ojo

Las imágenes de fondo de ojo son una fotografía de la retina que nos permiten apreciar con detalles las características y estado de algunas partes del interior del ojo como, la papila o nervio óptico, los vasos sanguíneos, el área macular, la fóvea, la pigmentación de la retina, entre otros (ver Figura 2.1). Ademas, la retina se considera parte integrante del sistema nervioso central (SNC), siendo la única parte de este que se puede examinar visualmente de forma directa (José María Ruiz Moreno, Luis Arias Barquet, 2013).

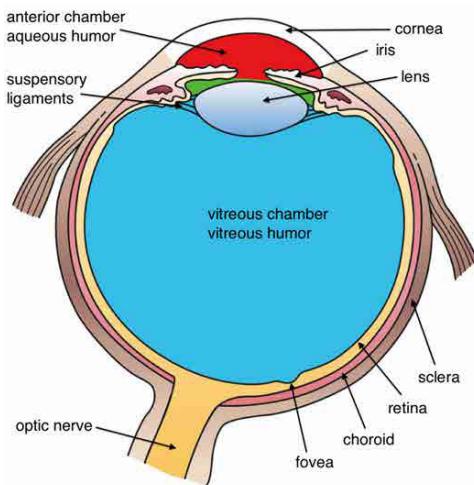


Figura 2.1: Estructura de un ojo humano (Ilustración por Holly Fischer).

En la Figura 2.2 se muestra una imagen retiniana común y se resaltan las partes que son objeto de estudio por el medico especialista, las cuales son, el disco óptico, los vasos sanguíneos y la mácula (incluye la Fóvea), entre otras.

Las imágenes retinianas contienen la información de la retina en la parte central y ésta se encuentra rodeada por una máscara negra la cual es propia del sistema de adquisición y se utiliza para enfocar correctamente una sección del fondo de ojo. En la digitalización de estas imágenes, los píxeles de la máscara tienen valores entre un rango de intensidades bajas, es decir, no es completamente negro. Por otra parte,

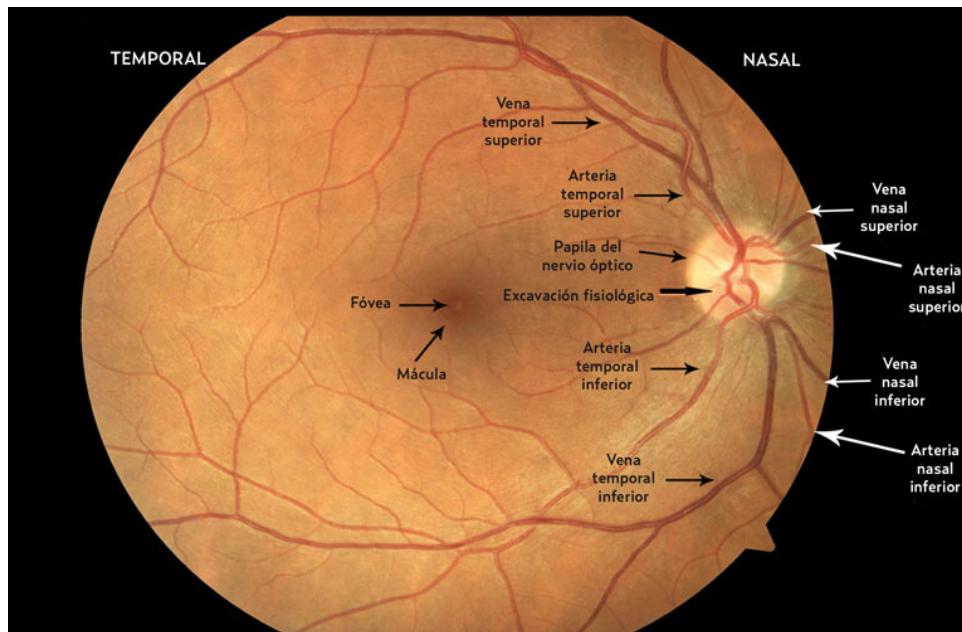


Figura 2.2: Estructura del fondo de ojo. Extraído de amf-semfyc Web.

las etiquetas que se colocan en las imágenes como se muestra en la Figura 2.3, son colocadas digitalmente con información del paciente, fecha y hora del procedimiento, entre otras.

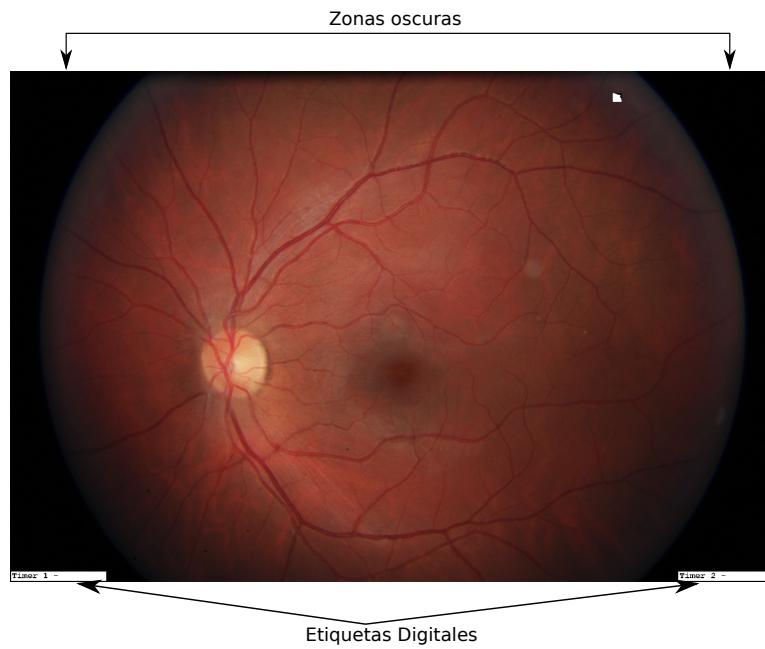


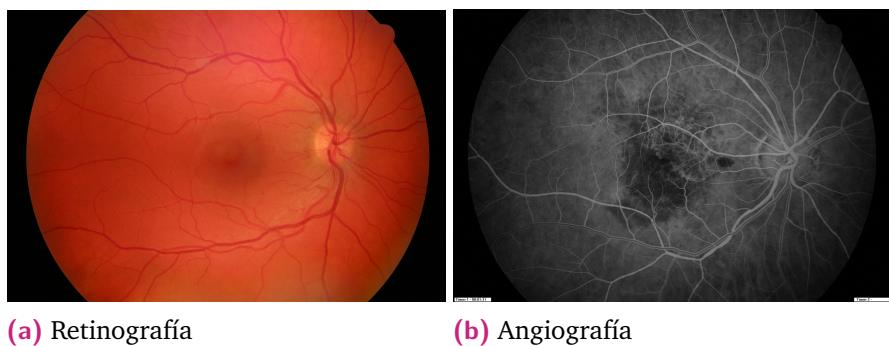
Figura 2.3: Retinografía con etiquetas y zonas oscuras.

2.1.1 Adquisición y procedimiento

La *retinografía* y la *angiografía ocular* son los procedimientos más comunes a la hora de adquirir una imagen del fondo de ojo. Ambos procedimientos tienen como objetivo fotografiar la retina para el estudio de la misma, sea la prevención de enfermedades y/o evolución en tratamientos.

La *retinografía* permite obtener una imagen a color de la retina como la mostrada en la Figura 2.4a. El procedimiento de captura de estas imágenes se muestra en la Figura 2.5, donde el ojo del paciente se coloca en la posición (E) y se hace incidir una haz de luz a través de la pupila. Este haz proviene de una lámpara (A) o un flash electrónico (B), luego es filtrado en (C) y dirigido por unos espejos hasta (D). Luego de haber incidido el haz de luz en la retina, la imagen es visualizada en una pantalla en (F) y es capturada por un sensor en (G). Para este procedimiento se suele suministrar un fármaco midriático al paciente para dilatar la pupila; aunque, hay *Retinógrafos no midriáticos* que no necesitan dilatar la pupila para adquirir la imagen. Es común hacer la dilatación para obtener imágenes de mejor calidad.

La *Angiografía Ocular con fluoresceína* se utiliza también para adquirir imágenes de fondo de ojo. En este procedimiento se inyecta al paciente un medio de contraste llamado *fluoresceína* en el antebrazo, el cual se mezcla con la sangre y luego de unos 10-15 segundos de su aplicación alcanza los vasos sanguíneos del ojo (National Eye Institute, 2016). Esto permite examinar el flujo sanguíneo en la retina y la coroides en una imagen en escala de grises con la red de vasos sanguíneos bien definidos como se muestra en la Figura 2.4b. El sistema de adquisición de imágenes es similar a la retinografía; sin embargo, difieren en que el filtro que se ubica en (C) en la figura 2.5 deja pasar luz azul la cual estimula la fluoresceína emitiendo una intensa luz que es capturada por un angiógrafo.



(a) Retinografía

(b) Angiografía

Figura 2.4: Imágenes del fondo de ojo obtenidas por diferentes procedimientos.

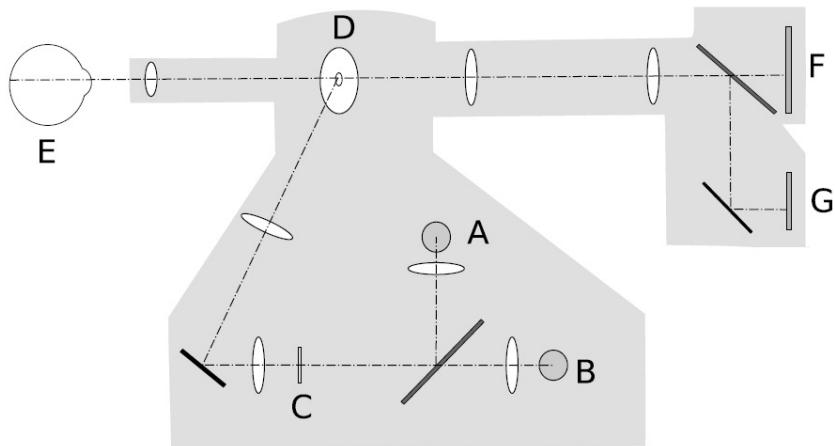


Figura 2.5: Esquema del sistema óptico de una cámara retiniana. Extraído de Marrugo, 2013

2.1.2 Calidad de imagen

Estas imágenes pueden presentar problemas de iluminación no uniforme (figura 2.6a), bajo contraste (figura 2.6b), emborronamiento (figura 2.6c) o aberraciones debido a diferentes factores como los movimientos del paciente, la dilatación de la pupila, la calidad del sistema de adquisición, la superficie curva de la retina, entre otros. Algunos de estos factores se pueden controlar fácilmente y garantizar que no afecten la calidad de las imágenes adquiridas. Sin embargo, hay otros factores propios del sistema de adquisición que no se pueden controlar en su totalidad. En general, no existen definiciones estándar para calificar la calidad de las imágenes retinianas mas que garantizar que las regiones estructurales de la retina se encuentren bien definidas.

Una imagen retiniana de mala calidad provocar que el médico no pueda hacer un diagnóstico seguro o hacerle un seguimiento a la evolución de alguna enfermedad del paciente correctamente. También, puede generar que se tengan resultados erróneos en algoritmos de detección automática de retinopatías. Por ejemplo, una iluminación no adecuada puede provocar que no se aprecien con claridad zonas en la imagen; contrastes bajos y emborronamiento. Por ejemplo, no se contrastan bien los vasos sanguíneos y no se puede determinar su tamaño adecuadamente. Algunas técnicas se han desarrollado para mejorar la calidad de estas imágenes, como las expuestas en Intajag y col., 2009, Miri y Mahloojifar, 2009, Vázquez y col., 2010 y contribuir al diagnóstico de enfermedades por software.

Con respecto al problema relacionado con la iluminación, no hay un criterio numérico estándar que caracterice adecuadamente que tan buena es la distribución de la iluminación.

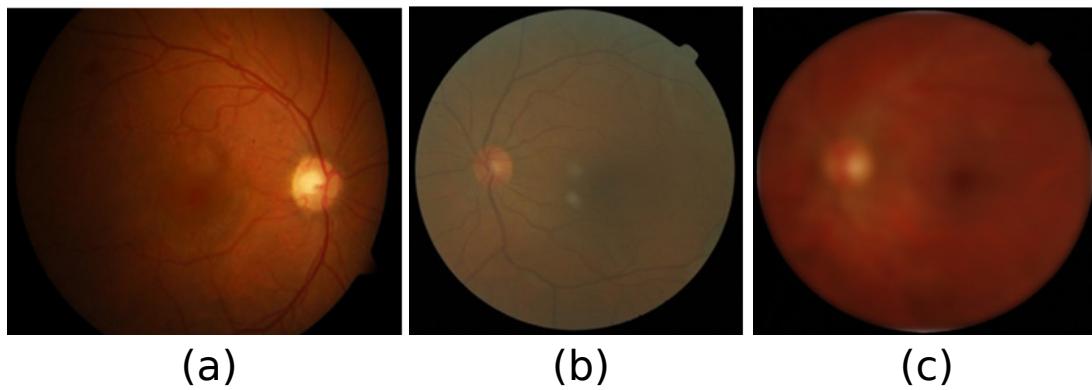


Figura 2.6: Ejemplo de retinografías con baja calidad. Extraído de Marrugo, 2013.

ción en la imagen. Por esta razón, en este trabajo se hace una validación cualitativa de los resultados con respecto a la compensación de las imágenes.

2.1.3 Enfermedades asociadas

Las imágenes del fondo de ojo son importante para el diagnóstico y seguimiento de enfermedades, entre ellas, la más común es la retinopatía diabética, la cual puede causar ceguera en quien la padezca. Las causas de esta patología pueden ir de un mal estilo de vida del paciente a falta de un procedimiento médico ante señales tempranas. En la figura 2.7 se muestran dos etapas de la retinopatía diabética, la primera muestra la etapa mas temprana de esta enfermedad (no proliferativa) en la que se observa la presencia de aneurismas (pequeñas zonas de inflamación en los vasos sanguíneos), hemorragias, la otra etapa es la retinopatía diabética proliferativa en donde se han crean nuevos vasos sanguíneos frágiles con tamaños anormales a causa del taponamiento de los viejos vasos sanguíneos (American Academy of Ophthalmology, 2013).

La importancia de estas imágenes en la detección temprana de enfermedades y de un tratamiento posterior, están permitiendo que investigadores desarrollen algoritmos de detección automática de retinopatías. Entre estos trabajos encontramos la detección automática de micro-aneurismas como primer paso a la detección de un retinopatía diabética planteado por Niemeijer y col., 2010, la detección automática de retinopatía diabética por Sinthanayothin y col., 2002, Nayak y col., 2008, degeneración macular relacionada por la edad en Agurto y col., 2011, entre otros trabajos.

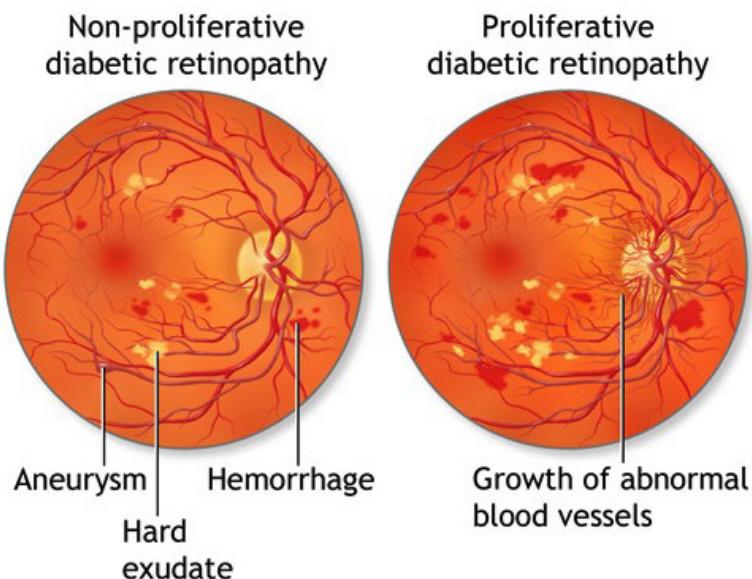


Figura 2.7: Imagen retiniana simulada. Se muestran los problemas generados por la retinopatía diabética (Extraído de A.D.A.M images)

2.2 Descomposición en modos empíricos (EMD)

Esta técnica fue desarrollada por Huang y col., 1998. La cual, según sus autores, realiza una descomposición adaptativa de señales no estacionarias como una suma de componentes de media cero, moduladas en amplitud (AM) y frecuencia (FM), llamados en la literatura como *Intrinsic mode functions* (IMF). La descomposición por *EMD* se lleva a cabo mediante un proceso iterativo (*sifting process*) el cual es explicado en el Algoritmo 1.

Las salidas del Algoritmo 1 son un j señales más un residuo, las cuales contienen el contenido espacio-frecuencial de la señal original. Los primeros modos contienen un alto contenido frecuencial y los últimos el contenido de bajas frecuencias. Ademas, la descomposición satisface la ecuación

$$s(t) = \sum_j IMF_j + r(t). \quad (2.1)$$

Esto representa que la señal original puede ser reconstruida a partir de la suma de sus *IMFs* y el residuo ($r(t)$).

En la Figura 2.8 se aprecia la descomposición por EMD de una señal en 5 modos intrínsecos más un residuo. Podemos notar que cada IMF contiene una modulación en

Algoritmo 1: Algoritmo para la descomposición en modos empíricos (EMD).

Entrada: $s(t)$

Salida: $IMF_1, IMF_2 \dots IMF_n + R$ // Paso 0: Inicialización de variables

- 1: Inicializar residuo como la señal de entrada $r_0 = s(t)$.
- 2: Inicializar índice del numero de IMF como $j = 1$.

// Paso 1: Extracción del IMF_j

- 3: Definir una desviación estándar máxima (SD_{max}) empíricamente.
 - 4: **mientras** (numero de picos + numero de valles >2) **hacer**
 - 5: Iniciarizar (SD_{ij}) mayor que SD_{max} .
 - 6: Iniciarizar $h_0 = r_{j-1}$ e $i = 1$.
 - 7: **mientras** $SD_{ij} \geq SD_{MAX}$ **hacer**
 - 8: Extraer picos y valles de h_{i-1} .
 - 9: Interpolan la envolvente mínima ($e_{min}(t)$) y máxima ($e_{max}(t)$).
 - 10: Calcular la envolvente media $m(t) = \frac{e_{min}(t) + e_{max}(t)}{2}$.
 - 11: Actualizar $h_i = h_{i-1} - m$ e incrementar $i = i + 1$.
 - 12: Calcular $SD_{ij} = \sum_{k=1}^K \left[\frac{|h_{j(i-1)}(k) - h_{ij}(k)|}{h_{j(i-1)}^2(k)} \right]$
 - 13: **fin mientras**
 - 14: Definir $IMF_j = h_i$ y actualizar residuo $r_j = r_{j-1} - IMF_j$
 - 15: Incrementar: $j = j + 1$.
 - 16: **fin mientras**
-

frecuencia y amplitud, es decir, que cada uno de ellos contienen diferentes frecuencias y amplitudes a lo largo del tiempo (o espacio). Esta modulación de frecuencia no se consigue con otras técnicas que emplean filtrados en frecuencia, donde solo se obtiene uno o varios componentes de frecuencia para la señal filtrada. Por otra parte, el residuo producto de la descomposición contiene las variaciones más suaves de la señal y a diferencia de los modos intrínsecos, éste no posee media cero.

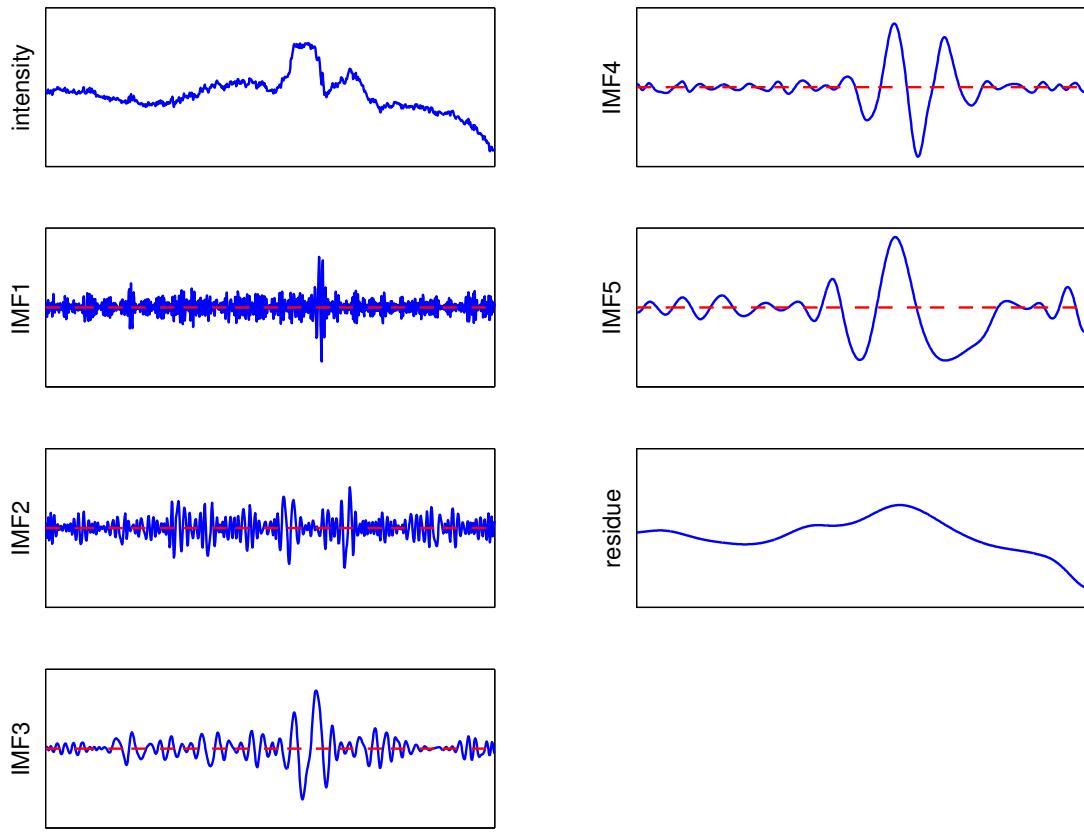


Figura 2.8: Descomposición de una señal por EMD. Extraído de Marrugo y col., 2015.

2.3 Descomposición bidimensional en modos empíricos (BEMD)

Nunes y col. (2003) propusieron usar el mismo principio de la técnica de descomposición en modos empíricos de una señal en imágenes. Igual que en una dimensión, la descomposición bidimensional en modos empíricos garantiza que los primeros modos contienen altas frecuencias espaciales (detalles de la imagen), y el residuo contenga información de las bajas frecuencias en la misma, asociadas en este trabajo a la iluminación. La ecuación que caracteriza la descomposición en dos dimensiones se define como

$$I = \sum_n BIMF_n + R , \quad (2.2)$$

donde I es la imagen original, n es el número de modos, $BIMF$ son los modos producto de la descomposición y R representa el residuo.

De la Ecuación (2.2) se puede inferir que si se obtiene un residuo adecuado, que represente la distribución de iluminación, se le podría restar a la imagen original para obtener una imagen con distribución uniforme de la iluminación y con las características estructurales (detalles) locales resaltados, como muestra en la siguiente ecuación

$$I' = I - R = \sum_n BIMF_n , \quad (2.3)$$

donde I' es la imagen con iluminación compensada. Observamos que la imagen compensada también es igual a la sumatoria de los *BIMF* producto de la descomposición, los cuales tienen media cero. Esto provocaría que la imagen I' no tenga los niveles de energía de la imagen original, de modo que se debe hacer un ajuste a la Ecuación (2.3) como

$$I' = I - R + \bar{I} , \quad (2.4)$$

agregándole la intensidad media de la imagen original (\bar{I}) a la imagen compensada.

El proceso iterativo de descomposición en dos dimensiones es análogo al de una dimensión. Sin embargo, los procesos de extracción de picos e interpolación de las envolventes en dos dimensiones requieren de un tiempo de computo mucho mayor y de algoritmos más complejos. Por tal motivo, se han propuesto varias técnicas y modificaciones del método *BEMD* para optimizar el tiempo de descomposición; por ejemplo, Nunes y col., 2003 emplean reconstrucción morfológica *basados en operadores geodésicos* para la detección de extremos en la imagen y utilizan *funciones de bases radial* para la interpolación de superficies. En otros trabajos se emplean *operaciones morfológicas* para la detección de extremos y un *weighted moving average algorithm* para la estimación de envolventes (Zhou y col., 2012).

En este trabajo usamos las modificaciones al algoritmo *BEMD* propuestas por D'Errico y SasiKanth¹, en el que se realiza la estimación de envolventes por *Gridfit* (D'Errico, 2005) y la detección de extremos se realiza por filas, columnas y diagonales propuesta por Vargas Carlos, 2014².

¹Repositorio: <https://www.mathworks.com/matlabcentral/fileexchange/28761>

²Repositorio: <http://www.mathworks.com/matlabcentral/fileexchange/12275>

Algoritmo 2: Algoritmo para la descomposición bidimensional de una imagen en modos empíricos (BEMD). Propuesto por Bouledjfane y col., 2013.

Entrada: Imagen original : $I(x, y)$

Salida: Modos : $BIMF_1, BIMF_2 \dots BIMF_N + R$ // Paso 0: Inicialización de variables

- 1: Inicializar residuo como la señal de entrada $r_0 = I(x, y)$.
 - 2: Inicializar índice del numero de BIMF como $j = 1$.
 // Paso 1: Extracción del $BIMF_j$
 - 3: Definir una desviación estándar máxima (SD_{max}) empíricamente.
 - 4: Definir el número de modos en que se desea descomponer la imagen, ej : $N = 4$;
 - 5: **mientras** (numero de picos + numero de valles >2 y $j < N$) **hacer**
 - 6: Definir una desviación estándar (SD_{ij}) mayor que SD_{max} .
 - 7: Iniciarizar $h_0 = r_{j-1}$ e $i = 1$.
 - 8: **mientras** $SD_{ij} \geq SD_{MAX}$ **hacer**
 - 9: Hallar picos y valles de h_{i-1} .
 - 10: Generar las envolventes 2D mínima ($e_{min}(x, y)$) y máxima ($e_{max}(x, y)$).
 - 11: Calcular la envolvente media $m(x, y) = \frac{e_{min}(x, y) + e_{max}(x, y)}{2}$.
 - 12: Actualizar $h_i(x, y) = h_{i-1}(x, y) - m(x, y)$ e incrementar $i = i + 1$.
 - 13: Calcular $SD_{ij} = \sum_{l=1}^L \sum_{k=1}^K \left[\frac{|h_{j(i-1)}(k, l) - h_{ij}(k, l)|}{h_{j(i-1)}^2(k, l)} \right]$
 - 14: **fin mientras**
 - 15: Definir $BIMF_j = h_i$ y actualizar residuo $r_j = r_{j-1} - BIMF_j$
 - 16: Incrementar: $j = j + 1$.
 - 17: **fin mientras**
-

Implementación y resultados

Las imágenes de fondo de ojo usualmente contienen etiquetas y zonas oscuras que pueden afectar el algoritmo de estimación de iluminación y muchas veces su tamaño suele ser grande, lo que genera un costo computacional innecesario. Por tales motivos, es necesario preprocesar las imágenes para adecuarlas y garantizar que no se generen problemas en la estimación de iluminación. En la figura 3.1 se muestra un diagrama de bloques en el cual se realiza el preprocesado de estas imágenes y el procesado de las mismas (Descomposición bidimensional y estimación de iluminación). Cada bloque en este diagrama se le dedica una sección en este capítulo donde se expone el problema que se desea resolver, el algoritmo desarrollado en Matlab para resolverlo y un análisis de los resultados obtenidos. También es importante destacar que los primeros tres bloques, correspondientes a las secciones: Segmentación de regiones, selección del área de interés y extrapolación de zonas oscuras son etapas de preprocesado.

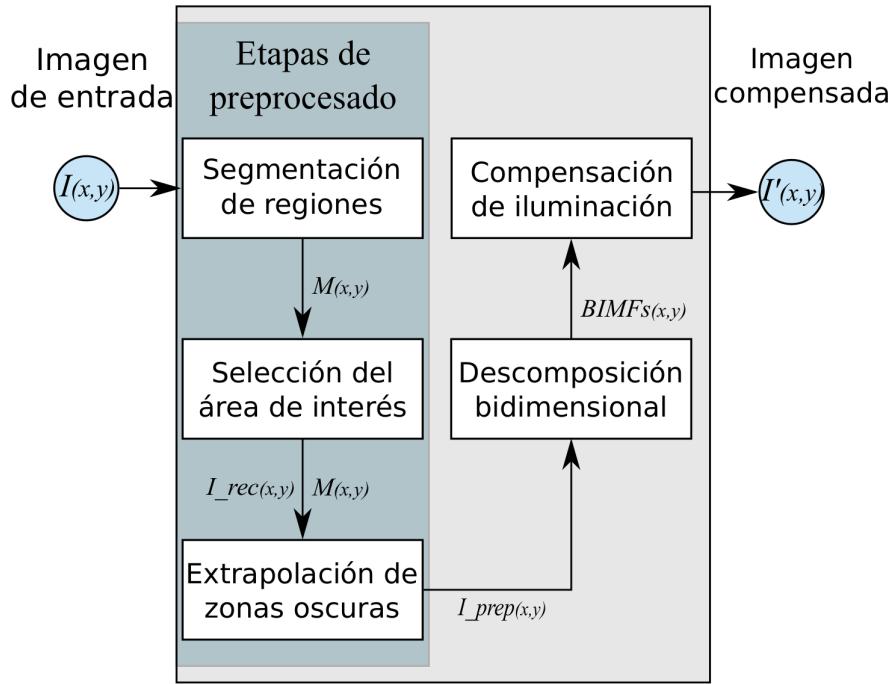


Figura 3.1: Esquema del procedimiento llevado a cabo para compensar la iluminación en una imagen retiniana. Se muestran las etapas de preprocesado y las etapas posteriores junto con sus respectivas variables de entrada y salida.

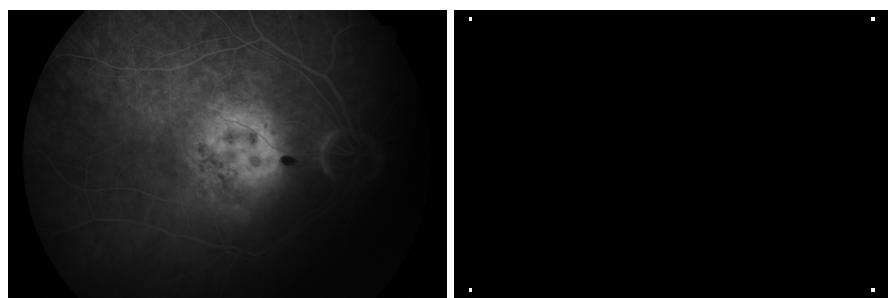
3.1 Segmentación de regiones

Para segmentar las regiones usamos un procedimiento conocido como crecimiento por regiones o *Region Growing*. Como su nombre lo indica, el método consiste en identificar una región comenzando por unos “pixeles semillas” y posteriormente ir creciendo añadiendo pixeles vecinos que tengan propiedades similares a la región (color o nivel de gris). La implementación de la técnica de crecimiento de regiones que utilizamos es propuesta por Gonzalez y Woods, 2008, la función se define como

$$[G, NR, SI, TI] = \text{regiongrow}(I, S, T),$$

donde I es la imagen que se desea segmentar; S es una matriz semilla del mismo tamaño que la matriz I , la cual debe contener valores de ‘1’ en las coordenadas donde comenzará la segmentación y el resto de pixeles se coloca con valor ‘0’, El parámetro T es un umbral de intensidad que sirve como criterio para identificar pixeles de una región. En los parámetros de salidas G es la imagen segmentada, NR el número de regiones segmentadas, SI es la matriz semilla y TI contiene los pixeles que cumplieron con la condición de umbral (Gonzalez y Woods, 2008). En el algoritmo 3 se muestra como fue empleado el algoritmo de segmentación de regiones.

El crecimiento de regiones a diferencia de otras técnicas de segmentación como la umbralización, no genera que se segmenten pixeles oscuros que pertenecen a la retina, sino que logra segmentar pixeles oscuros interconectados que pertenezcan sólo a la región oscura de la máscara que rodea la retina.



(a) Imagen retiniana original. (b) Matriz semilla S

Figura 3.2: (a) Es una imagen de fondo de ojo común, la cual posee etiquetas, una mala distribución de iluminación, entre otras. (b) Es la matriz semilla usada en la función `Regiongrow()` para segmentar las regiones. Es importante que las semillas se ubiquen cerca a las esquinas, en la región de baja intensidad, ya que esta región se segmentará de las demás regiones.

Algoritmo 3: Algoritmo para la segmentación de regiones en Matlab.

Entrada: Imagen original : $I(x, y)$

Salida: Máscara con regiones segmentadas $M(x, y)$

```
// EtapaI de preprocessado
1: Definir una matriz binaria semilla  $S(x, y)$ .
2: Definir un valor de umbral de intensidad inicial  $T=10$ .
3: Inicializar Bandera=0
4: mientras Bandera==0 hacer
5:   Segmentar regiones:  $[G, NR] = \text{RegionGrow}(I, S, T)$ 
6:   Visualizar la imagen segmentada: imagesc(G)
7:   si Se segmentó correctamente la imagen entonces
8:     Bandera=1;
9:   sino
10:    Actualizar el umbral  $T=\text{input}('Ingrrese nuevo valor')$ ;
11:   fin si
12:    $M = \text{not}(G)$ ;
13: fin mientras
```

La Figura 3.2a muestra una imagen de fondo de ojo que contiene etiquetas en las esquinas inferiores de la imagen. Ademas, posee zonas de baja intensidad debido a la máscara de la pupila de la cámara del retinografo. De este modo, aplicar BEMD sin un preprocessado podría generar un mayor costo computacional y resultados erróneos.

La matriz semilla S se muestra en la Figura 3.2b, donde se escogieron cuatro semillas en cada esquina de la imagen con un *offset* del 4 % del tamaño de la imagen. Esto es propuesto por Giancardo y col., 2010 y se basa en los siguientes criterios experimentales:

1. Colocar 4 semillas ubicadas en cada extremo de la imagen garantiza que se segmente la máscara aunque sus zonas estén interconectadas.
2. Un 4 % de *offset* en la posición de la semilla garantiza que ésta se ubique en una posición que coincida con la mascara pero no se ubique en una etiqueta.

Los píxeles semillas serán los puntos de inicio de la segmentación y la idea es identificar el fondo oscuro, el cual posee un nivel de energía muy similar en todos sus píxeles. La función `Regiongrow()` permite separar el fondo oscuro de la retina y las etiquetas. Nótese también que al final del algoritmo 3, la instrucción $M=\text{not}(G)$ niega la máscara obtenida por la función `Regiongrow()` y es ésta la que se muestra en la figura 3.3.

En la máscara se observan algunos píxeles aislados segmentados, esto se debe a que en esas zonas el niveles de grises sobrepasó el umbral de intensidad que fue seleccionado.

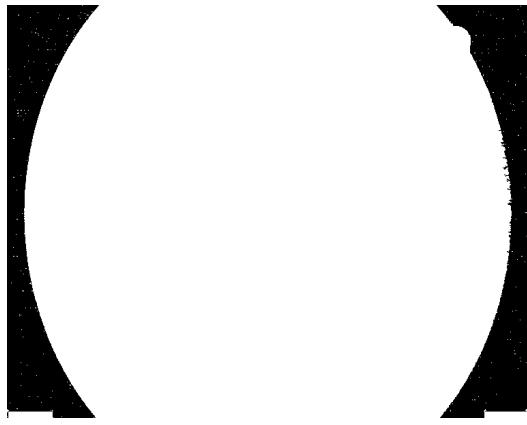


Figura 3.3: Regiones segmentadas. Se muestra la máscara $M(x,y)$ obtenida luego de la etapa de segmentación por regiones.

Para esta imagen usamos un umbral de $T=10$, el cual fue hallado experimentalmente y segmentaba correctamente las imágenes con intensidades entre 0-255 niveles de gris. También podemos notar que se han segmentado las regiones de las etiquetas y la zona de la retina que es la de mayor tamaño.

3.2 Selección del área de interés

En la etapa anterior se observó que la presencia de ruido y de etiquetas generan que se segmenten zonas irrelevantes. Debido a esto, en esta etapa se modifica la máscara para que solo contenga la información perteneciente a la retina, eliminando las demás regiones. El área de interés o la superficie retiniana comprende mayor número de píxeles que las otras zonas segmentadas. Por lo tanto, es necesario calcular el área en píxeles de las regiones, compararlas y hallar la región de área máxima, la cual se corresponde a nuestra área de interés. También es necesario encontrar un recuadro que encierre ésta región para recortar la imagen a un tamaño óptimo. Para obtener las propiedades de las regiones como su área y el recuadro que las encierra completamente, como se muestran en la figura 3.3, usamos la función del toolbox de procesamiento de imágenes de Matlab

```
props = regionprops(I, 'Area', 'BoundingBox');
```

Esta función como parámetro de salida nos da las propiedades de las regiones presentes en la imagen I , tales como el área en píxeles que ocupan en la imagen y el BoundingBox

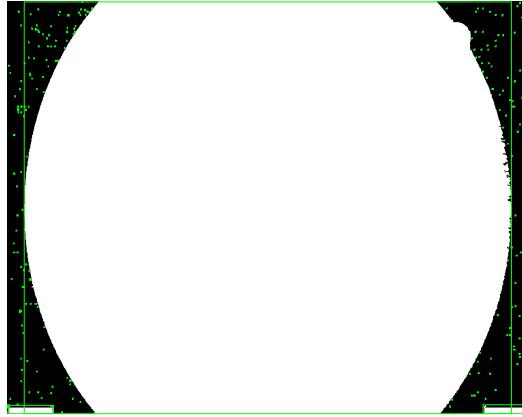


Figura 3.4: Regiones segmentadas encerradas por su correspondiente BoundingBox. El boundingBox que encierra la mayor área se usará para recortar la imagen y la mascara a un tamaño óptimo como se muestra en las figuras 3.5a y 3.5b, respectivamente.

que encierra a la región. La primera propiedad la usamos para identificar el área de mayor tamaño, es decir, la región de interés. La segunda propiedad la usamos para identificar la ubicación de la región en la imagen y posteriormente recortarla usando la función

```
I2 = imcrop(I,rect),
```

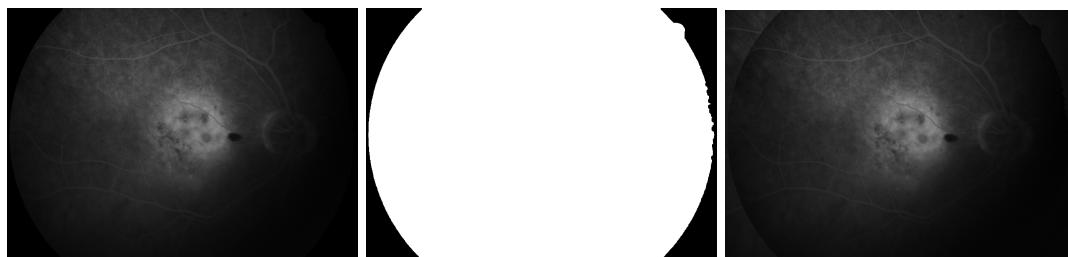
como se muestra en el Algoritmo 4, linea 24. Donde, I es la imagen original, $I2$ la imagen recortada y $rect$ es un vector posición de cuatro elementos de la forma $[xmin, ymin, width, height]$ que especifica la talla y posición del rectángulo de corte.

En esta etapa se obtiene la mascara final de preprocesado mostrada en la Figura 3.5b y la imagen original recortada en la Figura 3.5a, se observa que las zonas de etiquetas y de ruido segmentadas en la primera etapa de preprocesado han sido eliminadas y solo ha quedado la región perteneciente a la retina.

Algoritmo 4: Algoritmo para la selección del área de interés en Matlab.

Entrada: Máscara con regiones segmentadas : $M(x, y)$, Imagen original: $I(x, y)$
Salida: Máscara con el área de interés: $M(x, y)$, Imagen original recortada I_{rec}

```
// EtapaII de preprocesado
1: Calcular las propiedades de las regiones segmentadas en  $M(x, y)$  :
2: props=regionprops(I, 'Area' , 'BoundingBox');
3: calcular el número de regiones :
4: NR=size(props,1);
5: Encontrar el área mayor y su BoundingBox correspondiente:
6: para (i=1:NR) hacer
7:   Almacenar todas las áreas y los BoundingBox en dos vectores :
8:   areas(i) =props(i,1).Area;
9:   rect(:,i) =props(i,1).BoundingBox;
10: fin para
11: Calcular la posición del área de interés :
12: [area_max, posicion]=max(areas);
13: rect_interes = props(posicion,1).BoundingBox;
14: Rellenar con '0' en  $M(x, y)$ , en las regiones que no pertenecen a la retina:
15: para (i=1:NR) hacer
16:   si posicion != i entonces
17:     Xi = rect(1,i); Yi = rect(2,i), Xf = rect(3,i)
18:     Yf = rect(4,i)
19:     M(Yi:Yf,Xi:Xf)=0;
20:   fin si
21: fin para
22: Recortar  $M(x, y)$  y  $I(x, y)$  a un tamaño que solo contenga el área de interés:
23: M= imcrop(M,rec_interes);
24: I_rec= imcrop(I,rec_interes);
```



(a) Imagen original recortada. (b) Máscara final de la fase de (c) Imagen final de preprocesado.

Figura 3.5: Se muestran la imagen de entrada (a) junto a las imágenes de salida de la etapa de preprocesado.

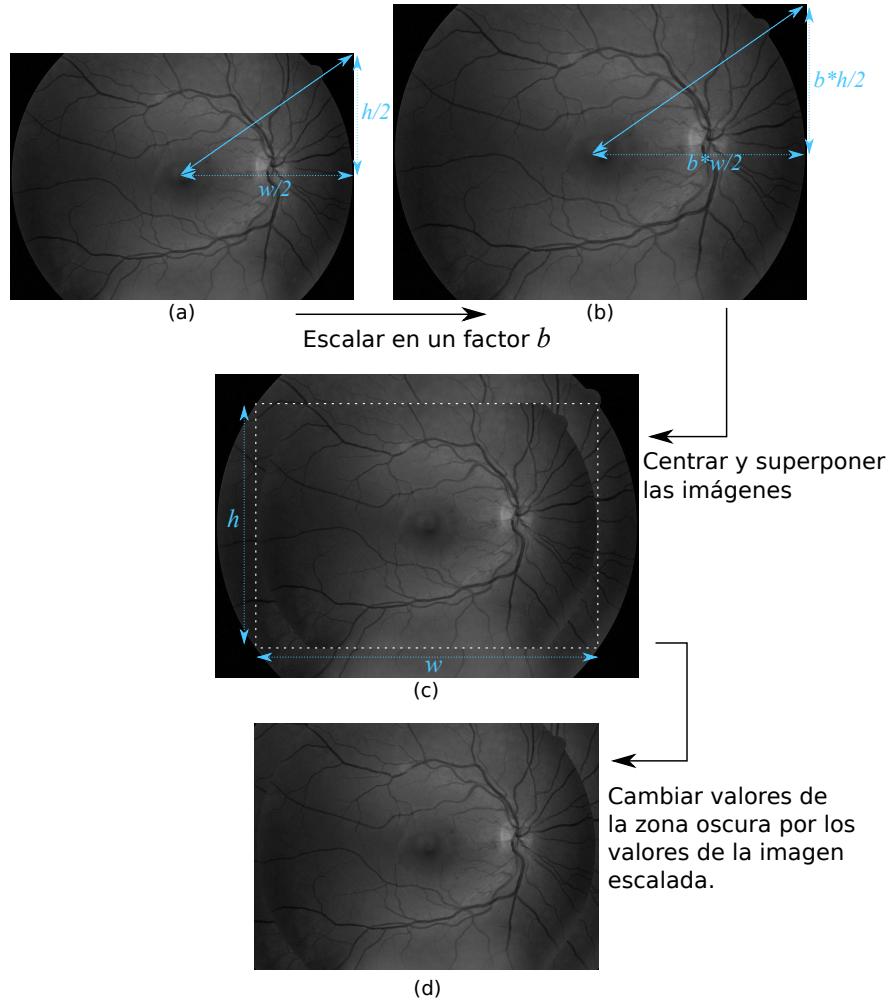


Figura 3.6: Esquema de extrapolación de zonas oscuras.

3.3 Extrapolación de zonas oscuras

La etapa anterior nos da como resultado que tiene segmentado la retina y los demás píxeles que no hacen parte de ella se le ha asignado valor de 0. La transición de los niveles de intensidad de la retina al marco negro provocará que la estimación de iluminación por BEMD no sea la correcta, es por esto que las zonas de intensidad $I(x,y)=0$, se cambian con una información similar a la retina como se muestra en la Figura 3.5c.

La estrategia usada para extender la retina a las zonas oscuras se muestra en la Figura 3.6, la cual consiste en escalar la imagen retiniana (Figura 3.6a) en un factor b (calculado en el Algoritmo 5, linea 6) de tal forma que al alinear los centros de ambas imágenes,

Algoritmo 5: Algoritmo para la extrapolación de zonas oscuras en imágenes retinianas usando Matlab.

Entrada: Imagen recortada : $I_{rec}(x, y)$ y máscara $M(x, y)$
Salida: Imagen preprocesada con retina extrapolada $I'(x, y)$

```
// Etapa III de preprocesado
1: Calcule el tamaño del la imagen recortada como:
2: [h,w]=size(I_rec);
3: Aumentar el tamaño de la imagen  $I_{rec}$  en un factor  $b$  :
4: Ir = imresize(I_rec,b);
5: El factor  $b$  se calcula como :
6:  $b = \sqrt{\left(\frac{h}{w}\right)^2 + 1}$ 
7: Recortar la imagen aumentada desde su centro a un tamaño de  $hxw$ .
8: [Cy,Cx] = round(size(Ir)/2);
9: H=round(h/2); W=round(w/2);
10: I_r = I_r(Cy-H:Cy-H+h, Cx-W:Cx-W+w);
11: Indexar la zona extrapolada usando el negado de la máscara (not(M)) en  $I_r$  y la
    zona de la retina indexando la máscara (M) en la imagen recortada original (I_rec)
    :
12: I' = I_rec.*uint8(Mask) + I_r.*uint8(not(Mask));
```

las zonas oscuras de la imagen sin escalar coincidan con información de la retina de la imagen escalada (Figura 3.6c). Una vez alineadas las imágenes se procede a cambiar las zonas de intensidad '0' con la información retiniana de la imagen escalada, dando como resultado la imagen que se muestra en la Figura 3.6d.

La imagen con la retina extendida es usada en la etapa de descomposición de modos para estimar la iluminación y la máscara se usará en las siguientes secciones para ocultar las zonas extrapoladas y solo apreciar la retina. En la Figura 3.7 se muestran imágenes retinianas originales y después del preprocesado, junto con la máscara que segmenta la retina.

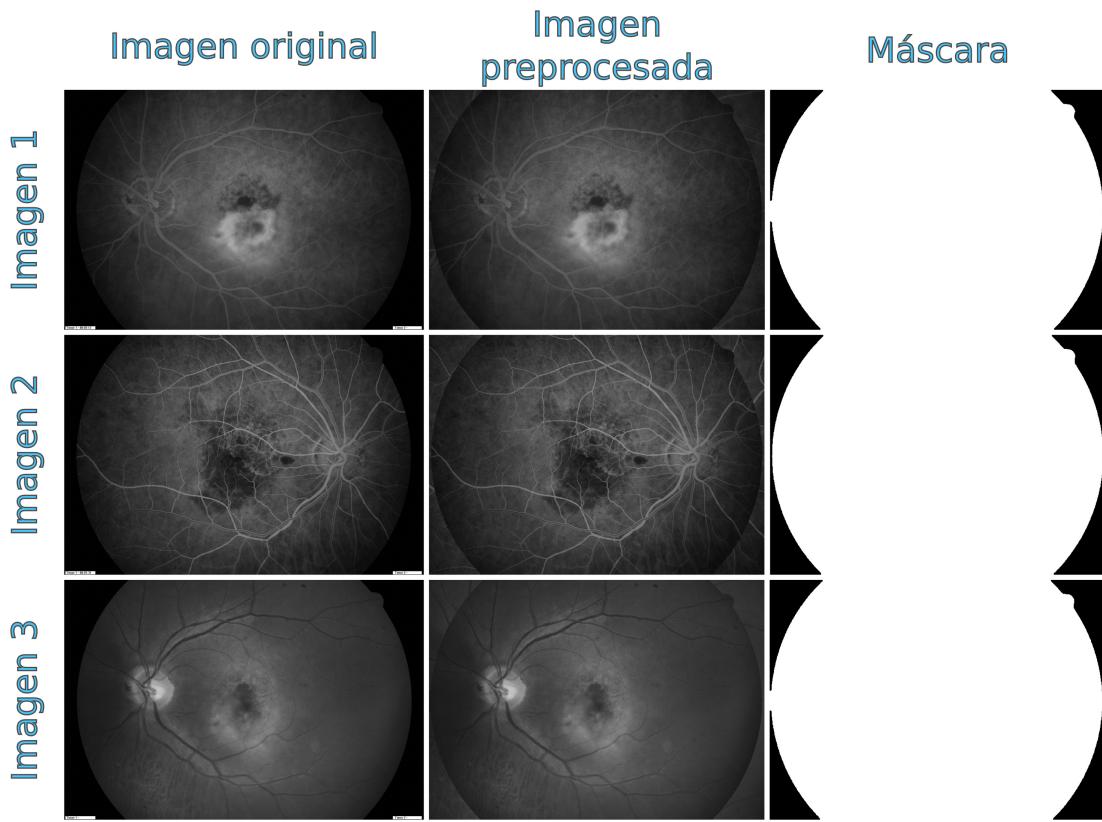


Figura 3.7: Prerocesado de tres imágenes retinianas. Se muestra la imagen resultado de las tres etapas de preprocesado y la máscara conseguida al segmentar la topografía retiniana.

3.4 Descomposición en modos

En esta sección se busca hacer la descomposición bidimensional de la imagen preprocesada que se obtuvo luego de la sección de extrapolación de zonas oscuras. Para ello hacemos uso de la función desarrollada por D'Errico y SasiKanth,

```
[imf_matrix] = bemd(input_image).
```

Esta función se encarga de hacer la descomposición de una imagen (`input_image`) usando los principios de una descomposición unidimensional planteada por Huang y col., 1998 y empleando funciones de cálculos bidimensionales. Sin embargo, esta función fue modificada en el desarrollo de este trabajo como

```
[imf_matrix, t_ejec] = bemd(input_image,N_modos),
```

Algoritmo 6: Algoritmo para descomposición bidimensional en modos empíricos de una imagen, usando funciones de Matlab.

Entrada: Imagen preprocessada : $I_{prep}(x, y)$
Salida: Modos intrínsecos $BIMFs$
 // Descomposición en modos
1: Definir el número de modos al cual se desea descomponer la imagen
2: $N_modos = 4;$
3: Reducir la imagen preprocessada en un factor a , con $0 < a < 1$
4: $I_reducida = imresize(I_{prep}, a);$
5: Descomponer la imagen usando bemd:
6: $BIMFs = bemd(I_reducida, N_modos);$
7: Reescalar los modos a la resolución de la imagen preprocessada:
8: $BIMFs = imresize(BIMFs, size(I_{prep}));$

agregándole como parámetro de entrada el número de modos¹ al cual se desea hacer la descomposición (N_modos), ya que la función original solo descomponía la imagen de entrada en 3 modos más un residuo, y como parámetro de salida se agregó el tiempo de ejecución de la función (t_ejec) .

En la Figura 3.8 se muestra los resultados de hacer la descomposición de la imagen mostrada en la figura 3.9a en 4 y 5 modos. Podemos notar que los primeros 3 BIMFs son iguales para ambas descomposiciones, y los dos últimos en la descomposición de 5 modos son el resultado de descomponer el BIMF4 de la descomposición de 4 modos. Los primeros dos primeros BIMF en la Figura 3.8 poseen el contenido frecuencial alto de la imagen original, lo cual hace referencia a los red de vasos sanguíneos, ruido en la imagen y otros bordes de la topografía de la retina. Los modos restantes contienen frecuencias mas bajas asociadas a la textura de la retina, la mácula y otras transiciones suaves en la superficie.

¹El número de Modos incluye el número de BIMFs y el Residuo

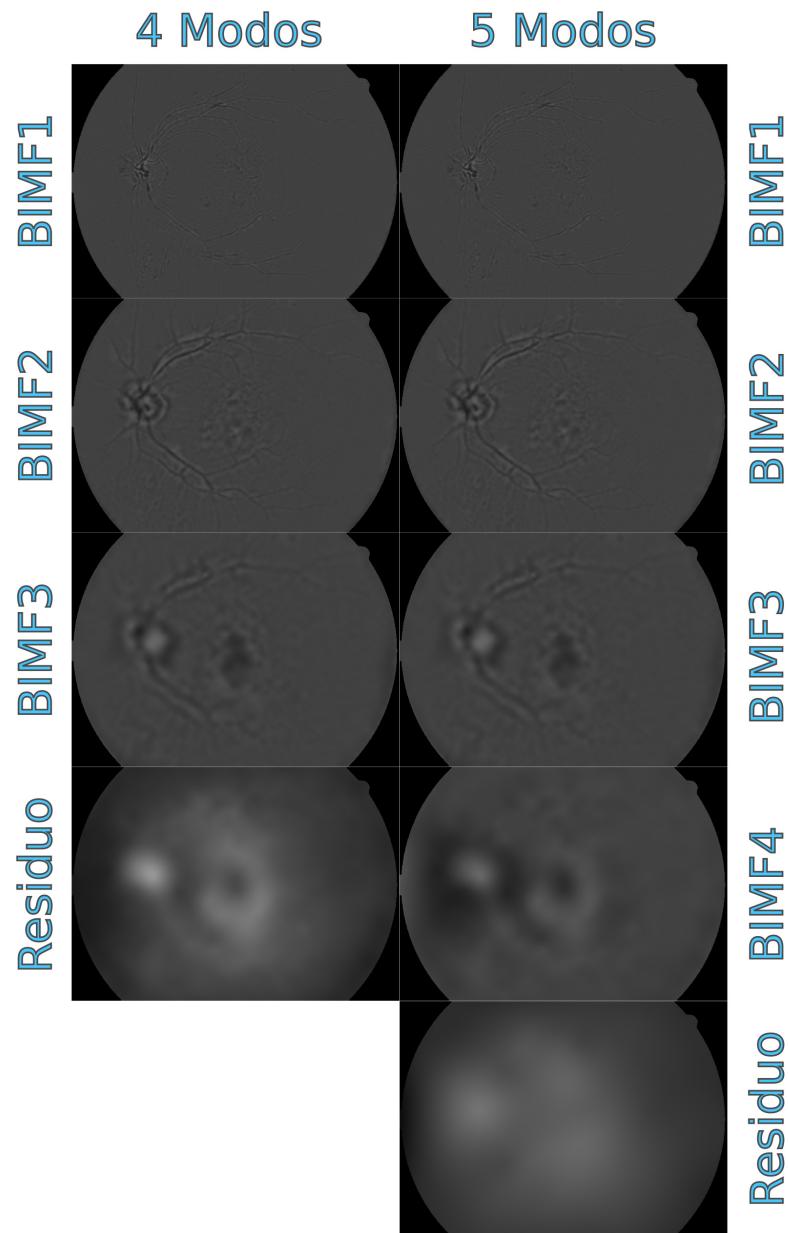


Figura 3.8: BIMFs obtenidos luego de hacer una descomposición a 4 y 5 modos a la imagen de la figura 3.9a.

3.4.1 Descomposición por reducción

En el Algoritmo 6 se muestra el procedimiento llevado a cabo para descomponer la imagen preprocesada en sus BIMFs. En este Algoritmo existen dos parámetros modificables los cuales son el número de modos (n_modos) y un factor de escala (a). El primero es necesario para caracterizar la función bemd en cuanto al número de descomposiciones

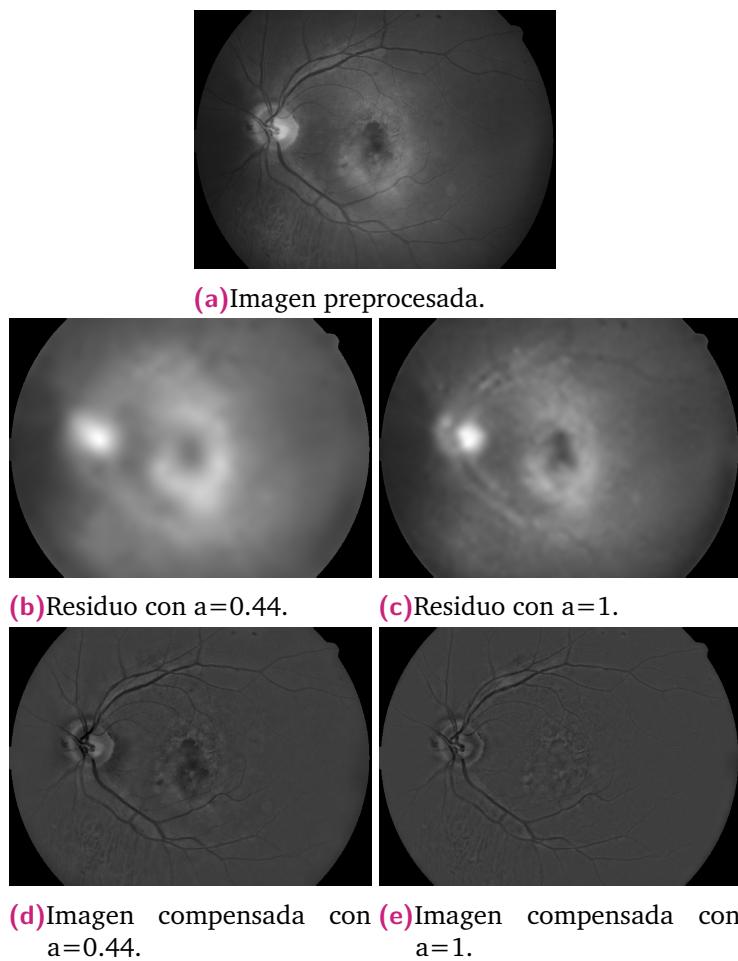


Figura 3.9: Se muestra la variación en la estimación y compensación de iluminación en base al factor de reducción a propuesto para el ahorro del tiempo de computo. El factor $a=0.44$ fue el resultado escalar la imagen a 512 píxeles en el tamaño de las filas.

que puede hacer y poder analizar la calidad de estimación de iluminación para diferentes números de modos. El segundo parámetro reduce el tamaño de la imagen para minimizar el tiempo de descomposición de ésta. El factor de escala a toma valores entre cero y uno; donde $a = 1$ significa resolución completa y $a = 0,5$ significa hacer una reducción a la mitad de filas y columnas. Cabe resaltar que el numero de píxeles no se reducen a la mitad, sino que se reducen en un factor a^2 . Por ejemplo, una imagen con resolución de 1000x1000 píxeles (100.000 píxeles en total) es reducida en un factor $a = 0,5$, el resultado es una imagen con resolución de 500x500 píxeles (25.000 píxeles en total), la cual ha reducido la cantidad de píxeles a un cuarto ($a^2 = 0,25$) del número de píxeles originales.

Una vez definido el número de modos y reducida la imagen preprocesada, procedemos a realizar la descomposición usando la función `bemd()` (Algoritmo 6, linea 6), estos

modos tienen la misma resolución de la imagen reducida por lo que procedemos a reescalarlos a la resolución original de la imagen preprocesada (Algoritmo 6, línea 8). La función utilizada para reducir y aumentar el tamaño de las imágenes fue

```
B = imresize(A,scale),
```

la cual retorna una imagen B que es scale-veces el tamaño de A. Si scale está entre 0 y 1; entonces, B es menor que A. Esta función emplea por defecto interpolaciones bicubicas.

En las Figuras 3.9b y 3.9c se muestran las estimaciones de iluminación (Residuos) de la imagen mostrada en la Figura 3.9a usando unos factores de escala de $a = 0.44$ y $a = 1$, respectivamente. Los tiempos de ejecución de la función `bemd()` fueron de 3.83 minutos para la descomposición de la imagen reducida y 35.81 minutos para la imagen a resolución completa usando con computador con procesador Intel CORE i5 con 8GB de RAM en Matlab R2016. La descomposición por reducción genera que el residuo obtenido tenga menor resolución que el obtenido a resolución completa; sin embargo, para ambos residuos se logra obtener una buena tendencia de la iluminación de imagen. No obstante, es importante que el residuo no contenga información de la vasos sanguíneos, arterias, nervio óptico o demás componentes estructurales de la retina, ya que esto provocaría artefactos al momento de hacer la compensación. Este problema se presenta para el residuo a resolución completa, donde la región de la fóvea es confundida como parte de la iluminación y cuando se hace la compensación (Figura 3.9e) esta región es eliminada de la imagen.

3.4.2 Tiempo de descomposición

El tiempo requerido para hacer la descomposición de una imagen depende del tamaño de misma (factor de reducción a) y el número de modos al que se desea descomponer. Para ilustrar, en la Figura 3.10 se muestra una gráfica que relaciona este factor de escala a con el tiempo que demanda descomponerla en 4 y 5 modos. La imagen usada en este análisis es la imagen preprocesada de la imagen 3, mostrada en la Figura 3.7, la cual cuenta con resolución de 1152x1612 píxeles y fue procesada en un computador con procesador Intel CORE i5 con 8GB de RAM en Matlab R2016a. Se observa que para ésta imagen, sin importar el número de modos en que se hizo la descomposición, la variación en el tiempo de computo incrementa conforme se aumenta el tamaño de la imagen a descomponer, o bien se acerca el factor de escala a uno. También se observa que una descomposición a cinco modos requiere más tiempo de procesamiento que

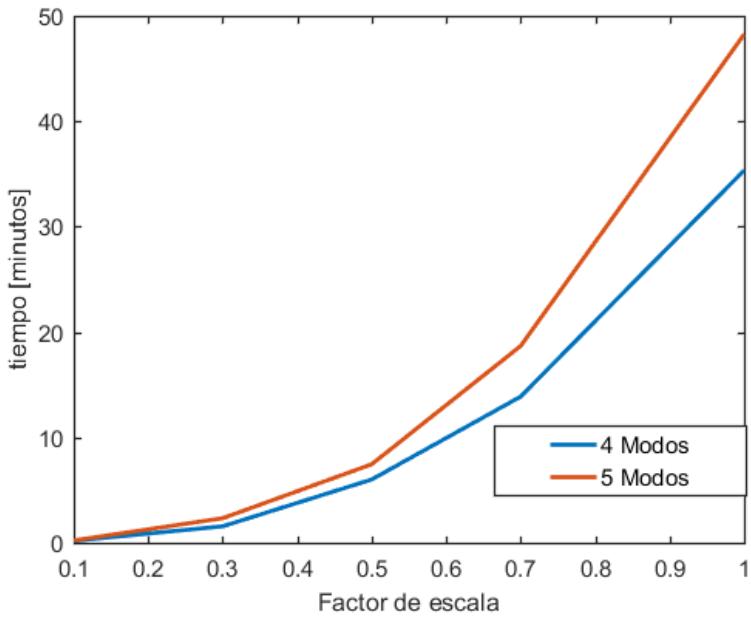


Figura 3.10: Relación entre el factor de escala (donde un factor de escala de '1' representa la resolución completa) y el tiempo de computo para la descomposición de la imagen 3 de la figura 3.7 (Resolución original: 1152x1612 píxeles) a 4 y 5 modos.

una descomposición a cuatro modos, debido a que se emplea un mayor número de iteraciones en el proceso.

En la Tabla 3.1 se observa que para cuatro imágenes retinianas con la misma resolución se obtuvieron tiempos de computo diferente. Por ejemplo, las imágenes 1 y 3 tienen la misma resolución (512x716 píxeles) pero no los mismos tiempos de computo, la imagen 1 necesitó 3.82 minutos para descomponerla en cuatro modos; por otro lado, la imagen 3 necesito 4.51 minutos para descomponerla en la misma cantidad de modos. Dado que las imágenes son distintas, también lo será sus distribuciones de iluminación (variación de los niveles de intensidad en la imagen); por tanto, los algoritmos de detección de extremos y *gridfit* se ejecutan en diferentes tiempos.

Imagen	Resolución	4 Modos tiempo [min]	5 Modos tiempo [min]
1	512x716	3.82	5.84
2	512x716	3.31	5.46
3	512x716	4.51	5.63
4	512x716	4.48	5.94

Tabla 3.1: Tiempo de cómputos para la descomposición en 4 y 5 modos para cuatro imágenes con igual resolución.

3.5 Compensación de iluminación

La compensación de iluminación en una imagen retiniana la estimamos a partir de la ecuación (2.4). La imagen compensada depende del número de modos en que se haga dicha descomposición. En esta sección contrastamos los resultados de estimar y compensar una imagen a 4 y 5 modos.

En la Figura 3.11 se aprecia la diferencia en la estimación y compensación de iluminación de 3 imágenes a 4 y 5 modos. Las imágenes compensadas con 4 modos tienen una iluminación mas plana. Sin embargo, hay regiones que hacen parte de la textura o topografía de la superficie que se confunden con la iluminación. Por ejemplo, después de compensar la imagen 2 a una descomposición a 4 modos, el área oscura central (encerrada por el círculo punteado) perteneciente a la fóvea desaparece, el algoritmo confunde esta zona como parte de la iluminación. Por tanto, es posible que al compensar las imágenes a 4 Modos pueda llegarse a eliminar información relevante.

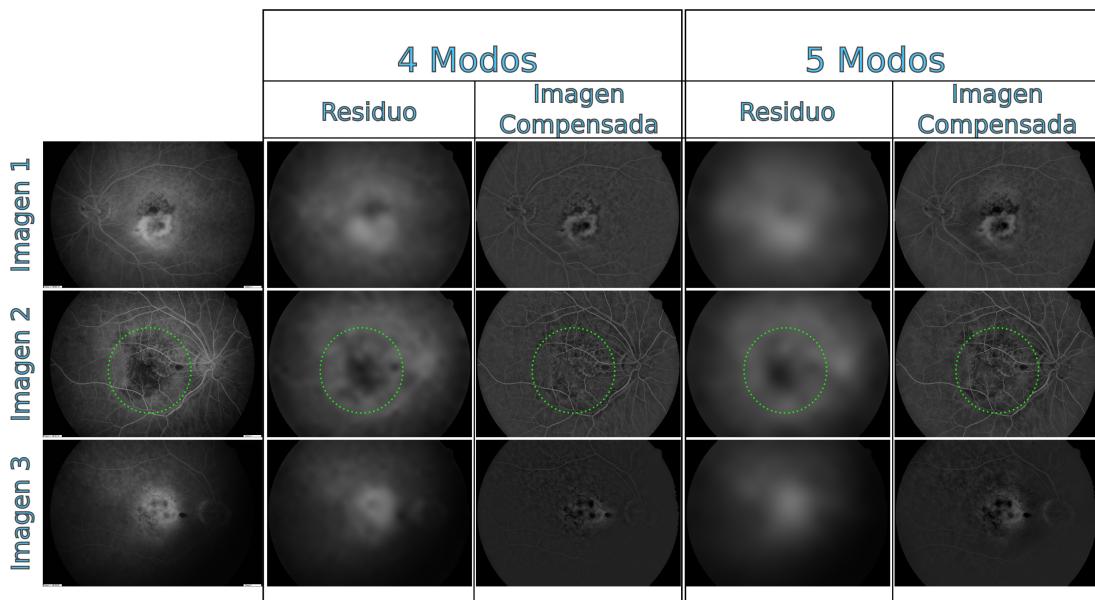


Figura 3.11: Estimación y compensación de iluminación de 3 imágenes retinianas en 4 y 5 modos.

Las compensaciones a 5 modos ofrecen una buena estimación de iluminación sin afectar en gran medida la topografía de la retina, aunque éstas requieren mayor costo computacional que una descomposición a 4 modos. Sin embargo, contamos con el factor de escala α el cual puede ser ajustado para minimizar los tiempos de ejecución y también nos ayuda a obtener una estimación suave global de la iluminación. De este modo, para

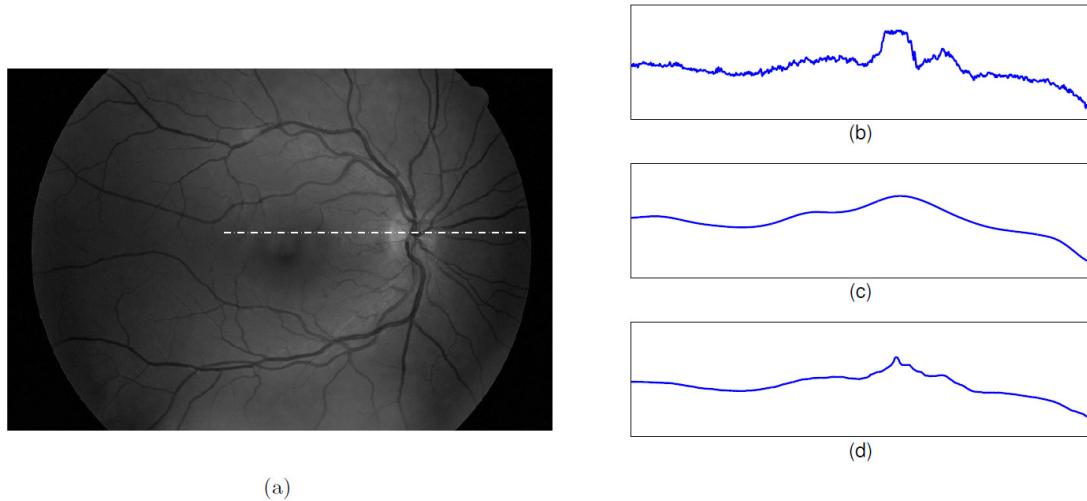


Figura 3.12: (a) Imagen retiniana original con iluminación no uniforme.(b) perfil de intensidad de la imagen (línea punteada). (c) Estimación de iluminación con EMD. (d) Estimación de iluminación por el método propuesto por Foracchia y col.

obtener un residuo más suave se recomienda disminuir el factor de reducción en la descomposición, en vez de realizar otra descomposición.

3.6 Comparación entre métodos

Los métodos para mejorar la calidad de imágenes retinianas suelen presentar inconvenientes a la hora de restaurarlas, ya que pueden cambiar la parte estructural de la retina y esto puede ser un gran inconveniente a la hora de dar un correcto diagnóstico. En ésta sección comparamos el método propuesto con el método de estimación de iluminación propuesto en Foracchia y col., 2005, el cual presenta problemas relacionados con la estimación de la iluminación cerca del nervio óptico. Para evitar la alteración del nervio óptico, en Marrugo y Millan, 2011 se segmenta en nervio óptico para no tenerlo en cuenta en la estimación de la iluminación.

En la figura 3.12 se muestra un imagen retiniana (figura 3.12a) y un perfil de intensidad (figura 3.12b) de la sección denotada por la linea blanca punteada sobre la imagen. Este perfil se toma sobre el nervio óptico con el objetivo de estudiar como afecta la estimación de iluminación por los métodos de Foracchia y col. y BEMD.

Las figuras 3.12c y 3.12d muestran la estimación de iluminación por EMD y por el método propuesto por Foracchia y col. para la señal mostrada en la figura 3.12b.

Podemos notar que ambas estimaciones siguen una tendencia igual hasta que se acercan alrededor del nervio óptico (el pico en el perfil), donde los niveles de intensidad son mas elevados. Debido a la presencia del nervio óptico la iluminación estimada en la figura 3.12d no es muy suave, lo que puede provocar que se cambie la topografía de la retina que se mostraba en la imagen original cuando se proceda a compensar la iluminación como se muestra en la figura 3.13; en la figura 3.13c se observa una variación significativa al compensar la iluminación con la técnica de Foracchia y col.

Analizando la figura 3.14 podemos notar que la iluminación estimada en la figura 3.14c va mas acorde a lo que se espera obtener de la imagen 3.12a y si analizamos las dos imágenes compensadas 3.14a y 3.14b observamos que el método propuesto por Foracchia y col., 2005 no genera una iluminación plana en toda imagen, incluso genera que se disminuya el contraste de los vasos sanguínos.

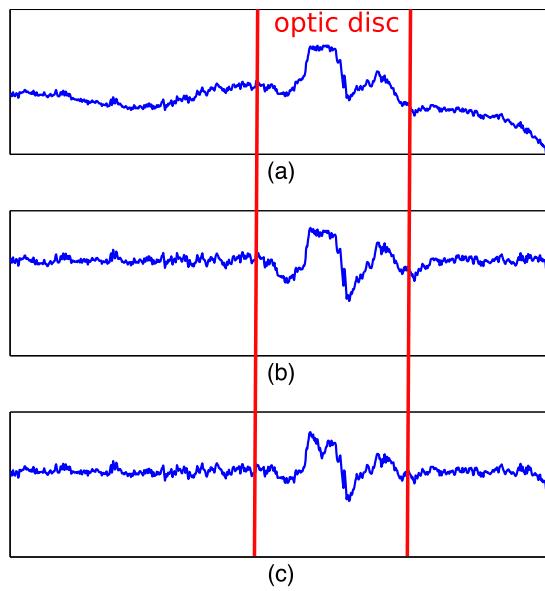


Figura 3.13: Compensación de iluminación en el nervio óptico. (a) Perfil de intensidad original
(b) Compensación por EMD y (C) compensación por el método de Foracchia y col.

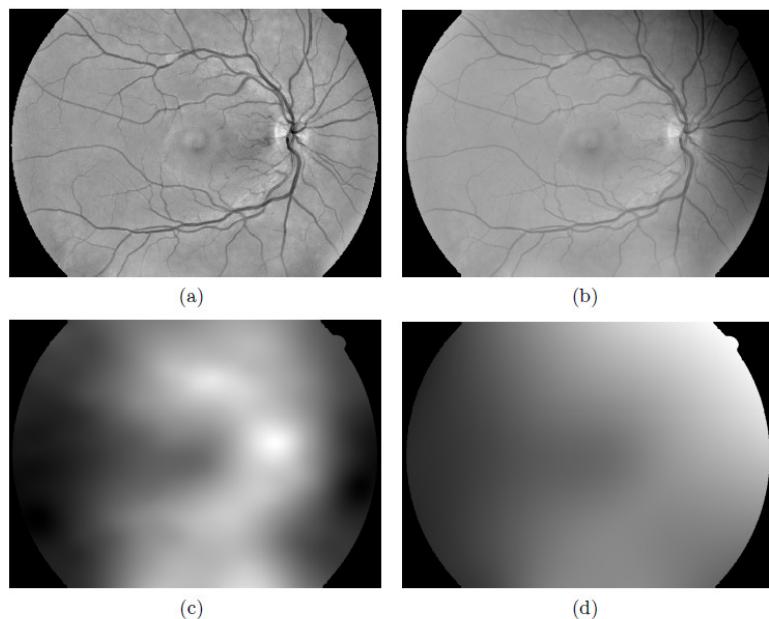


Figura 3.14: Estimación y compensación de iluminación de la imagen 3.12a por BEMD y el método de Foracchia y col.

Discusión y conclusiones

En este trabajo buscamos mejorar la calidad de las imágenes retinianas mejorando su iluminación, teniendo en cuenta no afectar otras características de la imagen que pueden ser importantes para el diagnóstico del paciente. La implementación de la técnica BEMD para hacer la compensación de iluminación ha permitido obtener resultados satisfactorios expuestos en las siguientes conclusiones:

1. Para la estimación y compensación de la iluminación en imágenes retinianas existe un compromiso entre el tiempo de cómputo y la calidad del residuo (que sea una variación suave que no contenga detalles de la imagen). Esto puede lograrse cambiando el número de modos en que se realiza la descomposición y ajustando el factor de escala en la descomposición por reducción.
2. La técnica presentó inconvenientes relacionados con un exceso en el tiempo de computo cuando la imagen que se deseaba procesar era demasiado grande, por ello se propuso en la sección 3.4.1 usar una descomposición por reducción para disminuir el tiempo de ejecución. La descomposición por reducción permitió también obtener una estimación de iluminación más suave, debido a que cuando se reduce la imagen se pierden detalles de la misma y el residuo contiene menos información topográfica de la retina.
3. Una descomposición a 5 modos (4 BIMFs y Residuo) brinda un residuo más suave comparado con una descomposición a 4 modos (3 BIMFs y Residuo); sin embargo, el tiempo de computo empleado para una descomposición a 5 modos es siempre mayor a una a 4 modos (sección 3.4.2). Se propone entonces, para no acarrear mas costo computacional, mantener la descomposición a 4 modos pero reducir el factor de escala en la descomposición por reducción.

Bibliografía

- Agurto, Carla, E Simon Barriga, Victor Murray y col. (2011). „Automatic detection of diabetic retinopathy and age-related macular degeneration in digital fundus images“. En: *Investigative ophthalmology & visual science* 52.8, págs. 5862-5871 (vid. pág. 11).
- Bouledjfane, B, L Bennacer y M S Kahli (2013). „BEMD-Unsharp Masking for retinal angiography image sharpening“. En: *Systems, Signal Processing and their Applications (WoSSPA), 2013 8th International Workshop on*, págs. 220-225 (vid. págs. 1, 16).
- D'Errico, John (2005). „Surface fitting using gridfit“. En: *MATLAB central file exchange* 643 (vid. pág. 15).
- D'Errico, John R (2006). „Understanding gridfit“. En: *Information available at: <http://www.mathworks.com/matlabcentral/fileexchange/loadFile.do>* (vid. pág. 15).
- Foracchia, Marco, Enrico Grisan y Alfredo Ruggeri (2005). „Luminosity and contrast normalization in retinal images“. En: *Medical Image Analysis* 9.3, págs. 179-190 (vid. págs. 32-34).
- Giancardo, Luca, F Meriaudeau y T Karnowski (2010). „Quality Assessment of Retinal Fundus Images using Elliptical Local Vessel Density“. En: *inspire.ornl.gov* (vid. pág. 19).
- Gonzalez, Rafael C y Richard E Woods (2008). „Digital image processing“. En: *Nueva Jersey* (vid. pág. 18).
- Huang, N E, Z Shen, S R Long y col. (1998). „The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis“. En: *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 454.1971, págs. 903-995 (vid. págs. 12, 25).
- Intajag, Sathit, Vittaya Tipsuwanporn y Rungrat Chatthai (2009). „Retinal image enhancement in multi-mode histogram“. En: *Computer Science and Information Engineering, 2009 WRI World Congress on*. Vol. 4. IEEE, págs. 745-749 (vid. pág. 10).
- José María Ruiz Moreno, Luis Arias Barquet (2013). *Manual de retina SERV*. 1era. Elsevier, págs. 1-7 (vid. pág. 7).
- Marrugo, Andrés G (2013). „Image Processing and Feature Extraction Techniques Oriented to the Clinical Task.“ Tesis doct. Barcelona: Universitat Politècnica de Catalunya (vid. págs. 10, 11).

- Marrugo, Andrés G y María S Millan (2011). „Retinal image analysis: preprocessing and feature extraction“. En: *Journal of Physics: Conference Series* 274.1, pág. 012039 (vid. pág. 32).
- Marrugo, Andrés G, Raúl Vargas, Melet Chirino y María S Millan (2015). „On the illumination compensation of retinal images by means of the bidimensional empirical mode decomposition“. En: *11th International Symposium on Medical Information Processing and Analysis (SIPAIM 2015)*. Ed. por Eduardo Romero, Natasha Lepore, Juan D García-Arteaga y Jorge Brieva. SPIE, pág. 96810D (vid. pág. 14).
- Miri, Mohammad Saleh y Ali Mahloojifar (2009). „A comparison study to evaluate retinal image enhancement techniques“. En: *Signal and Image Processing Applications (ICSIPA), 2009 IEEE International Conference on*. IEEE, págs. 90-94 (vid. pág. 10).
- Nayak, Jagadish, P Subbanna Bhat, Rajendra Acharya, CM Lim y Manjunath Kagathi (2008). „Automated identification of diabetic retinopathy stages using digital fundus images“. En: *Journal of medical systems* 32.2, págs. 107-115 (vid. pág. 11).
- Niemeijer, Meindert, Bram Van Ginneken, Michael J Cree y col. (2010). „Retinopathy online challenge: automatic detection of microaneurysms in digital color fundus photographs“. En: *IEEE transactions on medical imaging* 29.1, págs. 185-195 (vid. pág. 11).
- Nunes, J C, Y Bouaoune, E Delechelle, O Niang y Ph Bunel (2003). „Image analysis by bidimensional empirical mode decomposition“. En: *Image and Vision Computing* 21.12, págs. 1019-1026 (vid. págs. 14, 15).
- Sinhanayothin, Chanjira, JF Boyce, TH Williamson y col. (2002). „Automated detection of diabetic retinopathy on digital fundus images“. En: *Diabetic medicine* 19.2, págs. 105-112 (vid. pág. 11).
- Vázquez, SG, Noelia Barreira, Manuel G Penedo, Marc Saez y Antonio Pose-Reino (2010). „Using Retinex image enhancement to improve the artery/vein classification in retinal images“. En: *International Conference Image Analysis and Recognition*. Springer, págs. 50-59 (vid. pág. 10).
- Zhou, Xiang, Adrian Gh Podoleanu, Zhuangqun Yang, Tao Yang y Hong Zhao (2012). „Morphological operation-based bi-dimensional empirical mode decomposition for automatic background removal of fringe patterns.“ En: *Optics express* 20.22, págs. 24247-24262 (vid. pág. 15).

Páginas web

- American Academy of Ophthalmology (2013). *¿Qué Es la Retinopatía Diabética?* URL: <http://www.aao.org/salud-ocular/enfermedades/retinopatia-diabetica> (vid. pág. 11).
- National Eye Institute (2016). *La Retinopatía Diabética Lo que usted debe saber*. URL: <https://nei.nih.gov/health/espanol/retinopatia> (vid. pág. 9).

Declaración

Yo, Raúl Andrés Vargas Ramírez, con documento de identificación 1047470348 y estudiante del programa de Ingeniería Mecatrónica de la facultad de ingeniería de la Universidad Tecnológica de Bolívar, en relación con el Trabajo Fin de Grado presentando para su defensa y evaluación, declara que asume la originalidad de dicho trabajo, entendida en el sentido de que no ha utilizado fuentes sin citarlas debidamente.

Cartagena, Bolívar, 2016

Raúl Andrés Vargas Ramírez

5

Anexos

On the Illumination Compensation of Retinal Images by Means of the Bidimensional Empirical Mode Decomposition

Andrés G. Marrugo,^a Raúl Vargas,^a Melet Chirino,^a and María S. Millán^b

^aDept. of Mechanical and Mechatronics Engineering, Universidad Tecnológica de Bolívar
Km 1 vía Turbaco, 130011 Cartagena, Colombia.

^bDepartment of Optics and Optometry, Universitat Politècnica de Catalunya
Violinista Vellsolà 37, 08222 Terrassa, Spain.

ABSTRACT

Retinal images are used for diagnostic purposes by ophthalmologists. However, despite controlled conditions in acquisition retinal images often suffer from non-uniform illumination which hinder their clinical use. In this work we propose the compensation of the illumination by modeling the intensity as a sum of non-stationary signals using bidimensional empirical mode decomposition (BEMD). We compare the estimation and compensation of the background illumination with a widely used technique based retinal image pixel classification. The proposed method has shown to provide a better estimation of the background illumination, particularly in complicated areas such as the optic disk (usually bright) and the periphery of fundus images (usually dim).

Keywords: Medical image, retinal image, illumination compensation, empirical mode decomposition, fundus photography, ophthalmology, image enhancement.

1. INTRODUCTION

Eye fundus photography documents the retina and is central to the clinical care and management of patients with retinal diseases. It is widely used for population-based, large scale detection of diabetic retinopathy, glaucoma, age-related macular degeneration, and other eye-related diseases.¹ Retinal images, with typical angle of view of 30°, are acquired with a digital fundus camera which captures the illumination reflected from the retinal surface. Despite controlled conditions, many retinal images suffer from non-uniform illumination caused by several factors; e.g., the curved surface of the retina, pupil dilation (highly variable among patients), the presence of diseases, among others.² Generally, the curved retinal surface and the geometrical configuration of the light source and camera lead to a poorly illuminated peripheral part of the retina with respect to the central region. A retinal image with uneven illumination is shown in Figure 1(a). Note how the periphery is poorly illuminated.

Several techniques have been used to enhance retinal images. Histogram equalization has been shown to be inappropriate for retinal images.³ A local normalization of each pixel to zero mean and unit variance aims to compensate lighting variation and enhance local contrast but also introduces artifacts.³ Histogram matching between the red and green planes has been used as a preprocessing step for vessel segmentation.⁴ This improves the contrast of gross dark features like vessels but reduces the contrast of bright objects and tiny dark objects like micro-aneurysms. While most of the aforementioned methods are motivated by automated analysis as a preprocessing stage, they are all formulated without domain knowledge of the characteristics of the retinal image, and several despite increasing contrast and overall brightness introduce artifacts.

In order to compensate the non-uniform illumination of retinal images the illumination distribution has to be estimated properly. However, this is not straightforward since the retina has several elements like the blood vessels or the optic disc which have different luminosity properties. Thus, a proper illumination compensation approach should take this into account. Illumination compensation is important not only for visualization purposes, but also often included in the pipeline of algorithms for automated digital image analysis,^{6,7} for disease detection,⁸ for image restoration or deconvolution,⁹ and longitudinal change detection.¹⁰

Further author information: (Send correspondence to A.G. Marrugo)
A.G.M.: E-mail: agmarrugo@utbvirtual.edu.co, Telephone: +57 5 6535200 - 306.

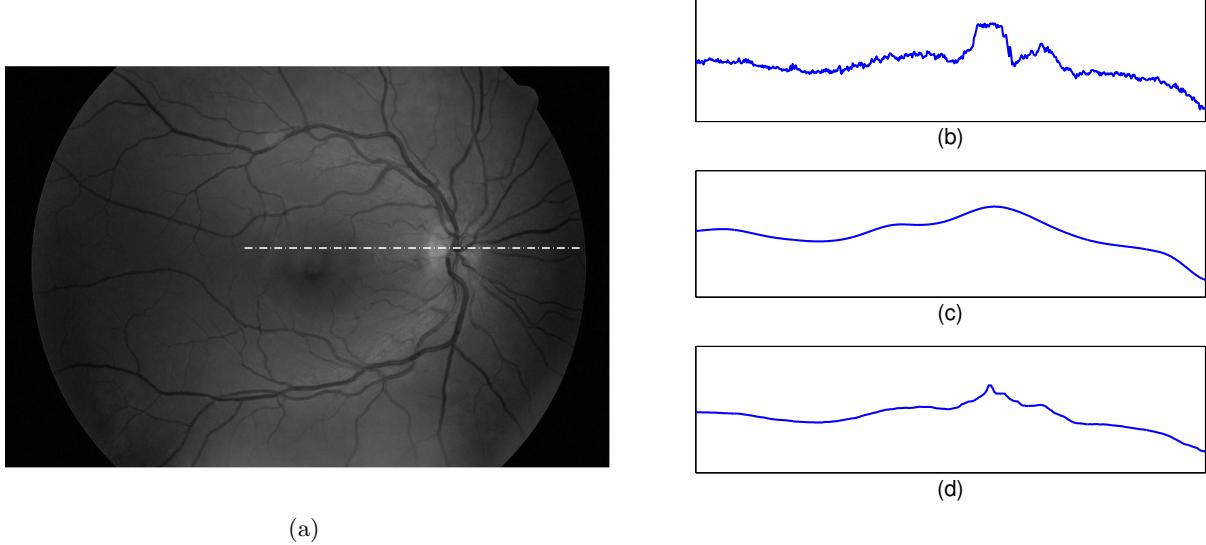


Figure 1. (a) Original retinal image with non-uniform illumination. Note that the illumination is worse toward the periphery of the image. (b) Intensity profile from image (dashed line in (a)) that goes across the optic disc. (c) Background illumination estimation with EMD. (d) Background illumination estimation from Ref. 5.

2. MOTIVATION AND RELATED WORKS

The work of Foracchia et al.⁵ was one of the first to propose a strategy that allowed the estimation of the background luminosity distribution solely from the *background pixels* of the retinal image. Their method separates the image into background and foreground planes using a windowing approach. The blood vessels and the optic disc belong to the foreground. This is a valid assumption as long as the classification of pixels is correct. If the pixels from the optic disc are classified as belonging to the background the illumination distribution is not estimated properly. This has been pointed out by Marrugo and Millán,¹¹ and recently in Ref. 8.

The work of Foracchia et al.⁵ introduced a strategy for luminosity and contrast enhancement on each color plane of the RGB color space, independently. This approach often produced hue-shifting related artifacts, given by the introduction of new colors to the image. Joshi et al.,¹² proposed a strategy that would avoid the color artifacts by performing the enhancement on single color plane to compensate equally every channel and ultimately perform linear color remapping. In this paper we work directly with the green channel of the RGB fundus image because it provides the best contrast.⁹ This is mainly due to the spectral absorption of the blood in this band, which yields the dark and well contrasted blood vessels.¹³ We also work with intensity fundus images like in the case of a retinal angiography as shown in Figure 5.

If we take an intensity profile along a row of the retinal image, like the one corresponding to the dashed line of Figure 1(a) and shown in Figure 1(b), we notice that the optic disc is a bright region that does not have the same properties or image statistics of the rest of the image. Moreover, the approach of Foracchia et al.⁵ uses the Mahalanobis distance to determine whether a pixel belongs to the background by using a fixed threshold. Akram et al.⁸ determined that a fixed threshold is not efficient due to the large variability of illumination and contrast in intra/inter image. This problem has been typically circumvented with additional stages of processing to better classify background pixels.^{14,15} In this paper we take a different approach by modeling the intensity profile as a sum of non-stationary signals using empirical mode decomposition (EMD).¹⁶

In Figure 1(d) we show the background estimation from the profile in Figure 1(b) following the method of Foracchia et al.⁵ On the one hand, note that while the profile follows the same general tendency of the original profile, the region surrounding the optic disc (the peak of the profile) is not smooth enough as it would be expected if only non-uniform illumination effects were involved. On the other hand, the profile in Figure 1(c) was obtained by EMD and it is much smoother around the optic disc.

3. BIDIMENSIONAL EMPIRICAL MODE DECOMPOSITION (BEMD)

BEMD is a two-dimensional (2-D) extension of the classical EMD.¹⁷ The EMD method is a sifting process that decomposes any complex signal into a finite, and often small, number of components called intrinsic mode functions (IMFs). An IMF represents a simple oscillatory mode with the same number of extrema and zero crossings, with its envelopes being symmetric with respect to zero.

In BEMD an image $I(x, y)$ is decomposed into multiple IMFs by the following sifting process:

1. Initialization: set $S(x, y) = I(x, y)$.
2. Identify all local maxima and local minima of $S(x, y)$.
3. Interpolate the local maxima (resp. minima) to obtain the upper envelope $e_{\max}(x, y)$ (resp. lower envelope $e_{\min}(x, y)$).
4. Compute the mean envelope $m(x, y) = [e_{\max} + e_{\min}] / 2$.
5. Compute $S'(x, y) = S(x, y) - m(x, y)$.
6. Update $S(x, y)$ by $S'(x, y)$.

Repeat steps 1 to 5 until the stopping criterion is met, in this case by limiting the size of the standard deviation (SD) computed from two consecutive sifting iteration results as

$$SD = \frac{\sum_x \sum_y [S'(x, y) - S(x, y)]^2}{\sum_x \sum_y [S(x, y)]^2} . \quad (1)$$

This sifting process stops if SD is less than a threshold. The resulting $S'(x, y)$, denoted by $c_1(x, y)$, is considered as the first IMF which represents the fast fluctuating component of the image. The residue $r_1(x, y) = I(x, y) - c_1(x, y)$ is a slower fluctuating signal, which is treated as the new input, i.e. $S(x, y) = r_1(x, y)$. The same sifting is then applied to the new input to extract the next IMF and produce the next residue. This iteration is carried out n times until no more IMFs can be extracted. Consequently, the original image can be obtained by:

$$I(x, y) = \sum_{j=1}^n c_j(x, y) + r_n(x, y) . \quad (2)$$

The decomposition by sifting process of an image provides a representation that is easy to interpret. In Figure 2 we show the EMD decomposition of the intensity profile from Figure 1(b). Note that the first IMF has all the local space-varying high frequency content from the original signal. The other IMFs contain smaller frequencies up to the residue which represents the smoothest variations in the image.

4. ILLUMINATION COMPENSATION BY BEMD

In this paper we propose the use of BEMD to accurately estimate the illumination distribution of retinal images. BEMD has the advantage that it decomposes the image in a nonlinear way into IMFs. The first IMS contains the highest spatial frequencies, the other IMFs contain frequencies progressively smaller and the residue represents low-frequency information in the source image.

After decomposing the image into IMFs, the residue contains the smoothest transitions in the image. We can model these as the changes in illumination. In this way, because the residue also has the dc content of the original image, we can proceed to compensate the illumination in the retinal image by subtracting the residue from the original image.

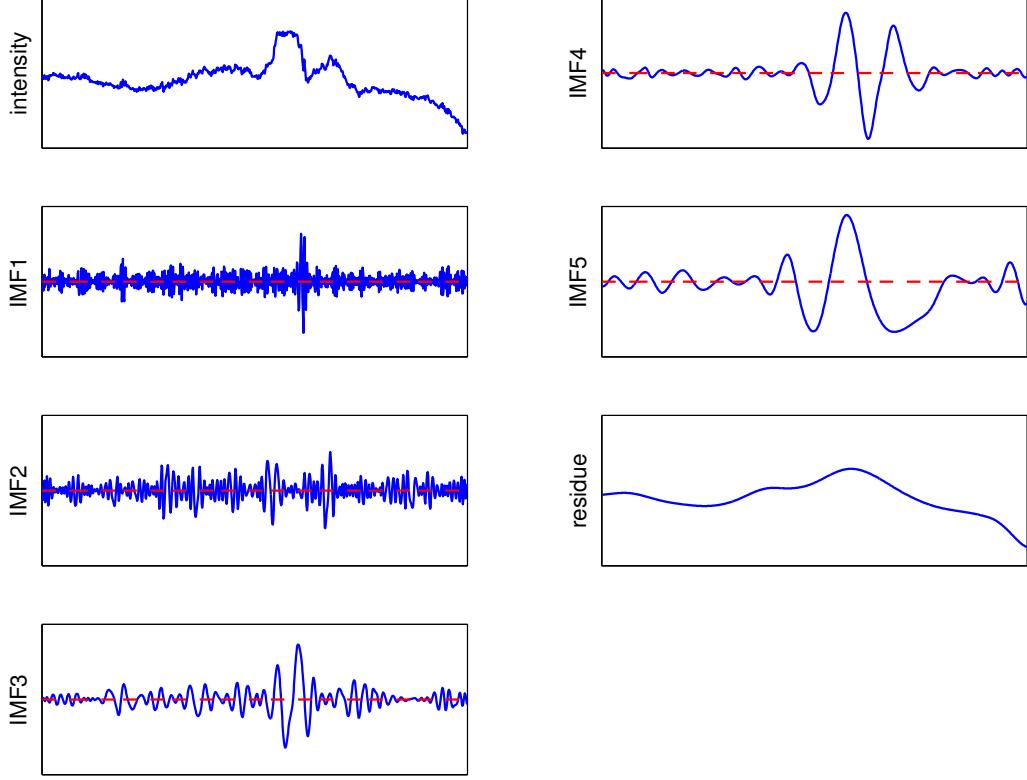


Figure 2. Empirical Mode Decomposition of the intensity profile plotted in Figure. 1(b).

4.1 Implementation

The BEMD algorithm was developed in MATLAB. To carry out a fast sifting procedure the algorithm searches for the maxima and minima by rows, columns, and diagonals. To compute the lower and upper envelopes it estimates a 2D surface on a 2D grid based on the scattered data from the local minima and maxima using the code from Ref. 18. The 2D surface estimation is not an interpolation, instead it is a regularized estimation in a least squares adjustment that smoothens the surface by keeping the surface gradients as small as possible. The stopping threshold for the sifting process was set at $SD \leq 0.2$.

Despite our fast maxima/minima search, the surface fitting algorithm takes considerable time to compute. To this end, we estimated the residue on a low-resolution version of the original image (512×512). This approximation does not introduce much error in the estimation because illumination variations are smooth and preserved through subsampling. We scaled back the residue to the original resolution and perform the compensation. The typical execution time for a retinal image of 2000×1500 pixels on MATLAB R2014 running on a PC with a core i5 processor and 8 GB of RAM is 3 minutes.

5. RESULTS

In Figure 3 we show the compensation of the non-uniform illumination in 1D from the intensity profile from Figure 1(b) using the compensation by BEMD (Figure 3(b)) and following the approach in Ref. 5 (Figure 3(c)). Note how the profile in the optic disc region is highly distorted in Figure 3(c) when compared to the original profile. However, the illumination distribution is indeed much more uniform. The compensation shown in Figure 3(b) distorts less the optic disc region and has a uniform illumination distribution, represented in a more flat profile.

In Figure 4(b) we show the compensated retinal image of Figure 1(a) using the method from Ref. 5. Note how the peripheral illumination has not been compensated properly. This is due to an incorrect pixel classification.

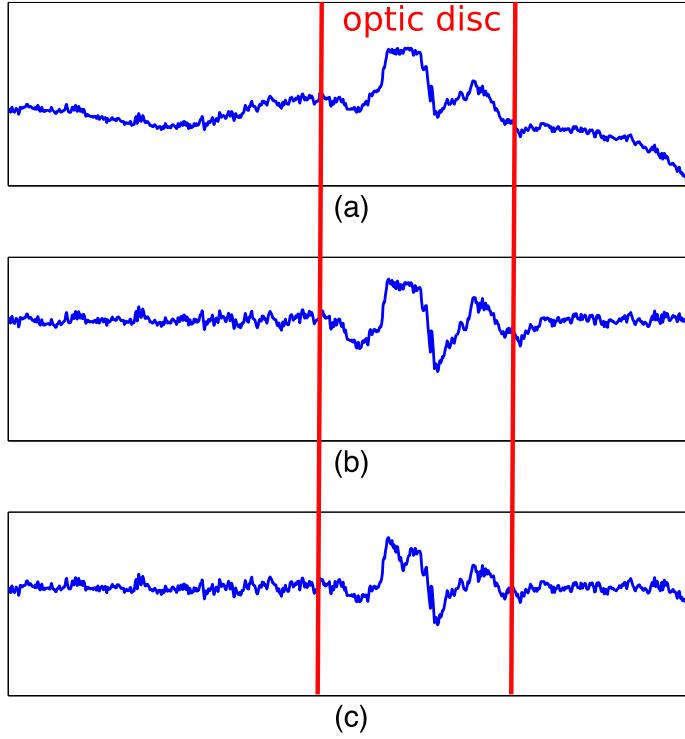


Figure 3. Compensation of non-uniform illumination. (a) Original intensity profile. (b) Compensation by EMD. (c) Compensation following Ref. 5

If the area surrounding the optic disc alters the classification, then the background illumination estimation fails. In contrast, the compensated image by BEMD shown in Figure 4(a) has been significantly enhanced with a uniform illumination distribution. In Figures 4(c)(d) we show the background illumination estimation from each corresponding method. In Figure 4(c) we note that it represents the smooth changes in the image while maintaining the local nature of the illumination distribution. The other estimation fails to reproduce the local variation.

A second example is given in Figure 5 where we show the compensation of a retinal angiography. The illumination is uniform and the blood vessels can be better appreciated in the compensated image along with other retinal features.

6. CONCLUSIONS

In this work we have presented a method for the estimation and compensation of the non-uniform illumination in retinal images by means of the bidimensional empirical mode decomposition. The method has shown to provide a better estimation of the background than related works, particularly in complicated areas such as the optic disk (usually bright) and the periphery of fundus images (usually dim). Two examples consisting of a fundus image and an angiography have been taken to design and illustrate the application of the method. Some improvement to speed up the computation is recommendable before its application to clinical studies.

ACKNOWLEDGMENT

This research has been partly funded by the Spanish Ministerio de Economía y Competitividad y Fondos FEDER (project No. DPI2013-43220-R). Financial support was also provided by the Universidad Tecnológica de Bolívar.

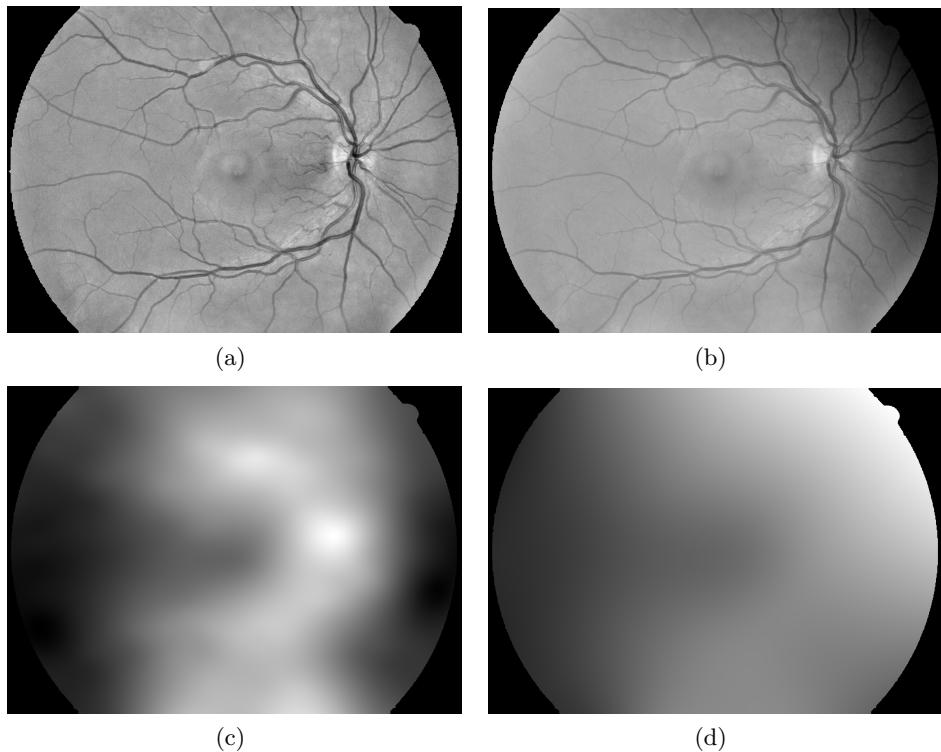


Figure 4. Illumination estimation and compensation for retinal image in Figure 1(a). Compensated retinal image by (a) BEMD and (b) following Ref. 5 (c) Background illumination estimation with BEMD. (d) Background illumination estimation from Ref. 5.

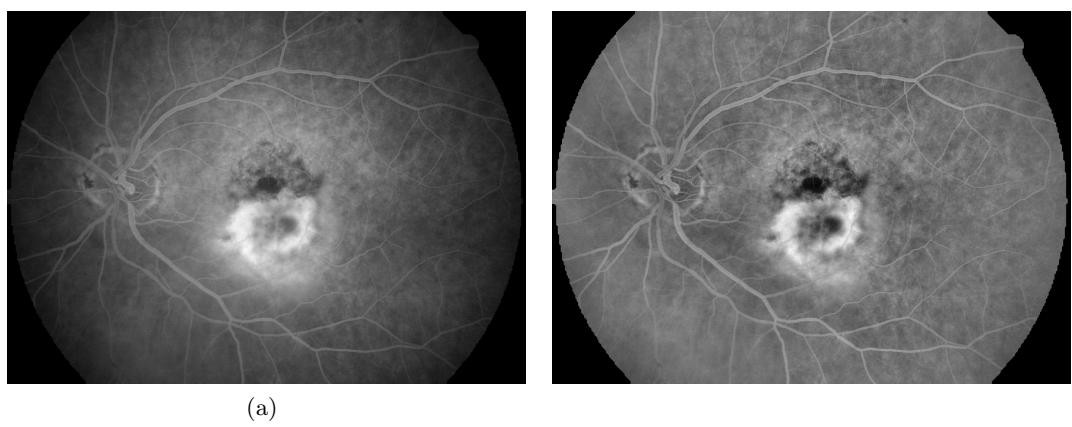


Figure 5. (a) A retinal angiography with non-uniform illumination. (b) Compensated image by BEMD.

REFERENCES

- [1] Abramoff, M. D., Garvin, M., and Sonka, M., "Retinal Imaging and Image Analysis," *Biomedical Engineering, IEEE Reviews in* **3**, 169–208 (2010).
- [2] Marrugo, A. G. and Millan, M. S., "Retinal Image Analysis Oriented to the Clinical Task," *Electronic Letters on Computer Vision and Image Analysis* **13**(2), 54–55 (2014).
- [3] Feng, P., Pan, Y., Wei, B., Jin, W., and Mi, D., "Enhancing retinal image by the Contourlet transform," *Pattern Recognition Letters* **28**(4), 516–522 (2007).
- [4] Salem, N. and Nandi, A., "Novel and adaptive contribution of the red channel in pre-processing of colour fundus images," *Journal of the Franklin Institute* **344**(3-4), 243–256 (2007).
- [5] Foracchia, M., Grisan, E., and Ruggeri, A., "Luminosity and contrast normalization in retinal images," *Medical Image Analysis* **9**(3), 179–190 (2005).
- [6] Newton, M. J., "The promise of telemedicine," *Survey of Ophthalmology* **59**, 559–567 (Sept. 2014).
- [7] Lu, Y., Xie, F., Wu, Y., Jiang, Z., and Meng, R., "No Reference Uneven Illumination Assessment for Dermoscopy Images," *IEEE Signal Processing Letters* **22**(5), 534–538 (2015).
- [8] Akram, M. U., Khitran, S., Usman, A., and Yasin, U., "Detection of Hemorrhages in Colored Fundus Images Using Non Uniform Illumination Estimation," in [*Lecture Notes in Computer Science*], Campilho, A. and Kamel, M., eds., **8815**, 329–336, Springer International Publishing (2014).
- [9] Marrugo, A. G., Millan, M. S., Sorel, M., and Sroubek, F., "Restoration of retinal images with space-variant blur," *Journal of Biomedical Optics* **19**, 016023 (Jan. 2014).
- [10] Marrugo, A. G., Sorel, M., Sroubek, F., and Millan, M. S., "Retinal image restoration by means of blind deconvolution," *Journal of Biomedical Optics* **16**(11), 116016 (2011).
- [11] Marrugo, A. G. and Millan, M. S., "Retinal image analysis: preprocessing and feature extraction," *Journal of Physics: Conference Series* **274**(1), 012039 (2011).
- [12] Joshi, G. and Sivaswamy, J., "Colour Retinal Image Enhancement Based on Domain Knowledge," in [*Computer Vision, Graphics & Image Processing, 2008. ICVGIP '08. Sixth Indian Conference on*], 591–598 (2008).
- [13] Gao, L., Smith, R. T., and Tkaczyk, T. S., "Snapshot hyperspectral retinal camera with the Image Mapping Spectrometer (IMS).," *Biomedical Optics Express* **3**, 48–54 (Jan. 2012).
- [14] Grisan, E., Giani, A., Ceseracciu, E., and Ruggeri, A., "Model-based illumination correction in retinal images," in [*Biomedical Imaging: Nano to Macro, 2006. 3rd IEEE International Symposium on*], 984–987 (2006).
- [15] Zheng, Y., Vanderbeek, B., Xiao, R., Daniel, E., Stambolian, D., Maguire, M., O'Brien, J., and Gee, J., "Retrospective illumination correction of retinal fundus images from gradient distribution sparsity," in [*2012 9th IEEE International Symposium on Biomedical Imaging (ISBI)*], (2012).
- [16] Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Yen, N. C., Tung, C. C., and Liu, H. H., "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* **454**, 903–995 (Mar. 1998).
- [17] Nunes, J. C., Bouaoune, Y., Delechelle, E., Niang, O., and Bunel, P., "Image analysis by bidimensional empirical mode decomposition," *Image and Vision Computing* **21**, 1019–1026 (Nov. 2003).
- [18] D'Errico, J., "Surface fitting using gridfit," *MATLAB central file exchange* **643** (2005).

On the Compensation of Uneven Illumination in Retinal Images for Restoration by Means of Blind Deconvolution

Andrés G. Marrugo, Raúl Vargas, and Sonia Contreras

Facultad de Ingeniería
Universidad Tecnológica de Bolívar
Cartagena, Colombia

agmarrugo@unitecnologica.edu.co

María S. Millán

Department of Optics and Optometry
Universitat Politècnica de Catalunya
Terrassa (Barcelona), Spain

millan@oo.upc.edu

Abstract

Retinal eye fundus images are used for diagnostic purposes, but despite controlled conditions in acquisition they often suffer from uneven illumination and blur. In this work, we propose the use of multi-channel blind deconvolution for the restoration of blurred retinal images. The estimation of an adequate point-spread function (PSF) is highly dependent on the registration of at least two images from the same retina, which undergo illumination compensation. We use the bi-dimensional empirical mode decomposition (BEMD) approach to model the illumination distribution as a sum of non-stationary signals. The BEMD approach enables an artifact-free compensation of the illumination in order to estimate an adequate PSF and carry out the best restoration possible. Encouraging experimental results show significant enhancement in the retinal images with increased contrast and visibility of subtle details like small blood vessels.

1. Introduction

Blur is one of main image quality degradations in eye fundus images. Its main causes are: inherent optical aberrations in the eye, relative camera-eye motion, and improper focusing. The optics of the eye is part of the optical imaging system and as such, eye aberrations are a common source of image degradation. The technique for recovering an original or unblurred image from a single or a set of blurred images in the presence of a poorly determined or unknown point spread function (PSF) is called blind deconvolution. For the restoration of retinal images, we have proposed [4] a blind deconvolution method to restore blurred retinal images acquired several months apart, even when structural changes had occurred in the retina.

Our restoration approach is based on multi-channel blind deconvolution (MBD) [7]. MBD requires at least two

images of the same scene in order to recover the PSFs and carry out the restoration. We consider as input two retinal images acquired with a conventional fundus camera within a time lapse that can span from several minutes to months given by routine patient checkups. The images correspond to the same retina but can differ with respect to illumination distribution, blur, and local structural changes given by pathological developments. These differences cannot solely be accounted for by the convolutional model. For that reason, the images must be preprocessed before the blind deconvolution stage can take place. We register the images and compensate for uneven illumination variation. Our work builds upon [4], the illumination distribution is compensated by making the illumination of one image as close as possible to the other image. This has a clear advantage of being easier to compute, but it does not guarantee a uniform illumination that provides better definition and contrast of the retinal image, despite improving PSF estimation.

In order to compensate the non-uniform illumination of retinal images the illumination distribution has to be estimated properly. However, this is not straight-forward since the retina has several elements like the blood vessels or the optic disc, which have different luminosity properties. Thus, a proper illumination compensation approach should take this into account. Illumination compensation is important not only for visualization purposes, but also often included in the pipeline of algorithms for automated digital image analysis [5, 2], for disease detection [1], for image restoration or deconvolution [3], and longitudinal change detection

2. Mathematical Model of Image Degradation

The unregistered input images, as shown in Figure 1, are \hat{I}_1 and \hat{I}_2 . After registration, we obtain two degraded registered images I_1 and I_2 , which we model as originating from an ideal sharp image. Mathematically, the degradation

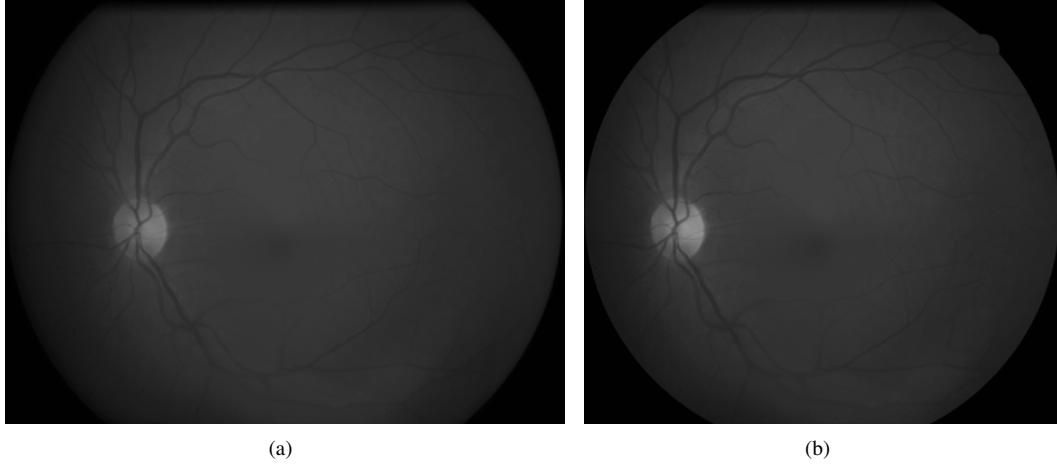


Figure 1. Two fundus images from the same retina. Both are degraded with blur and uneven illumination.

model is stated as

$$\begin{aligned} I_1 &= U * h_1 + n_1 \\ I_2 &= U * h_2 + n_2 , \end{aligned} \quad (1)$$

where $*$ is the standard convolution, h_i are called convolution kernels or PSFs, and n_i are Gaussian zero-mean noise.

3. Bidimensional Empirical Mode Decomposition (BEMD)

BEMD is a two-dimensional (2-D) extension of the classical EMD [6]. The EMD method is a sifting process that decomposes any complex signal into a finite, and often small, number of components called intrinsic mode functions (IMFs). An IMF represents a simple oscillatory mode with the same number of extrema and zero crossings, with its envelopes being symmetric with respect to zero.

In BEMD an image $I(x, y)$ is decomposed into multiple IMFs by the following sifting process:

1. Initialization: set $S(x, y) = I(x, y)$.
2. Identify all local maxima and local minima of $S(x, y)$.
3. Interpolate the local maxima (resp. minima) to obtain the upper envelope $e_{\max}(x, y)$ (resp. lower envelope $e_{\min}(x, y)$).
4. Compute the mean envelope $m(x, y) = [e_{\max} + e_{\min}] / 2$.
5. Compute $S'(x, y) = S(x, y) - m(x, y)$.
6. Update $S(x, y)$ by $S'(x, y)$.

Repeat steps 1 to 5 until the stopping criterion is met, in this case by limiting the size of the standard deviation (SD)

computed from two consecutive sifting iteration results as:

$$SD = \frac{\sum_x \sum_y [S'(x, y) - S(x, y)]^2}{\sum_x \sum_y [S(x, y)]^2} . \quad (2)$$

This sifting process stops if SD is less than a threshold. The resulting $S'(x, y)$, denoted by $c_1(x, y)$, is considered as the first IMF which represents the fast fluctuating component of the image. The residue $r_1(x, y) = I(x, y) - c_1(x, y)$ is a slower fluctuating signal, which is treated as the new input, i.e. $S(x, y) = r_1(x, y)$. The same sifting is then applied to the new input to extract the next IMF and produce the next residue. This iteration is carried out n times until no more IMFs can be extracted. Consequently, the original image can be obtained by:

$$I(x, y) = \sum_{j=1}^n c_j(x, y) + r_n(x, y) . \quad (3)$$

4. Illumination Compensation by BEMD

In this paper we propose the use of BEMD to accurately estimate the illumination distribution of retinal images. BEMD has the advantage that it decomposes the image in a nonlinear way into IMFs. The first IMF contains the highest spatial frequencies, the other IMFs contain frequencies progressively smaller and the residue represents low-frequency information in the source image.

After decomposing the image into IMFs, the residue contains the smoothest transitions in the image. We can model these as the changes in illumination. In this way, because the residue also has the dc content of the original image, we can proceed to compensate the illumination in the retinal image by subtracting the residue from the original image. From Eq. (3) the compensated image is

$$I'(x, y) = I(x, y) - r_n(x, y) . \quad (4)$$

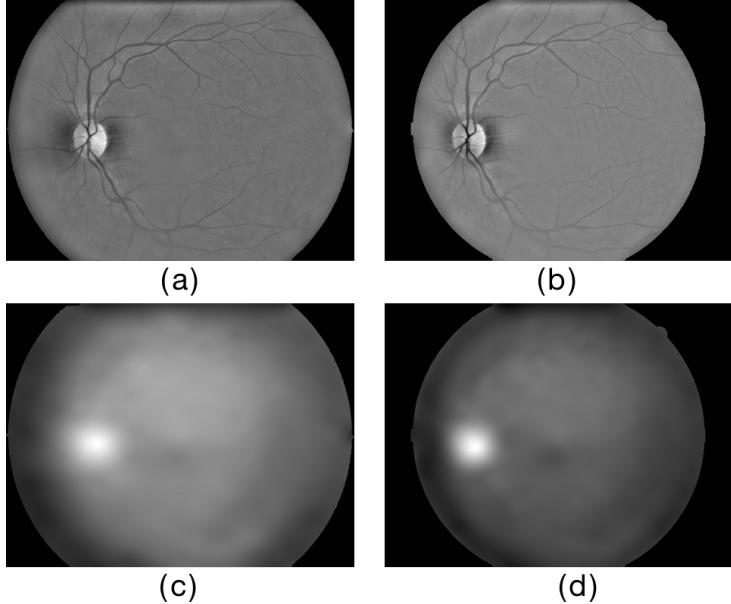


Figure 2. Illumination compensation by means of BEMD. (a)-(b) Are the compensated images from Figure 1. (c)-(d) are the residue (illumination component). Notice the increase in contrast and the uniform illumination.

5. Image restoration

The PSF estimation and image deconvolution algorithm can be viewed as a Bayesian maximum a posteriori estimation of the most probable sharp image and blur kernels. The algorithm is basically the minimization of the functional

$$\begin{aligned} \arg \min_{U, h_1, h_2} & \frac{1}{2} \|U * h_1 - I'_1\|^2 + \frac{1}{2} \|U * h_2 - I'_2\|^2 \\ & + \lambda_u \int |\nabla U| + \lambda_h \|I'_1 * h_2 - I'_2 * h_1\|^2, \quad (5) \\ & h_1, h_2 \geq 0, \end{aligned}$$

with respect to the latent image U and blur kernels h_1 and h_2 . The first and second terms measure the difference between the input blurred images and the searched image U blurred by kernels h_1 and h_2 . The size of this difference is measured by L_2 norm $\|\cdot\|$ and should be small for the correct solution. Ideally, it should correspond to the noise variance in the given image. I'_i are the illumination compensated images. The two remaining terms are regularization terms with positive weighting constants λ_u and λ_h . The third term is the total variation of U . It improves stability of the minimization and from the statistical viewpoint incorporates prior knowledge about the solution. The last term is a condition linking the PSFs of both images, which also improves the numerical stability of the minimization. For this procedure we set $\lambda_u = 1000$ and $\lambda_h = 10$.

The functional is alternately minimized in the subspaces corresponding to the image and the PSFs. The minimization in the PSF subspace is equivalent to the solution of a system of linear equations in the least squares sense with the non-

negativity constraint. In the same minimization procedure both the PSFs and the restored image are estimated.

6. Experiments and Results

We performed several experiments on naturally degraded images coming from the clinical practice to illustrate the appropriateness of the method. The proposed method has been tested on a dataset of 20 images with reliable results. In this section we show two typical examples of retinal images degraded with uneven illumination, their compensation, and the restoration by means of MBD.

In Figure 2 we show the same retinal images from Figure 1 with the illumination compensation by BEMD. It is important to highlight the increase in contrast and the homogeneous illumination. Figure 2(c)-(d) show the estimated illumination distribution.

In Figure 3 we show a detail of the restored retinal image by deconvolution and the estimated PSFs. There is a notable increase in visibility of subtle details like small blood vessels.

7. Conclusions

In this work we have proposed the use of the bidimensional empirical mode decomposition as a means of compensation of uneven illumination prior to restoration by multichannel blind deconvolution. The compensation of the illumination provided an improvement in contrast and a homogeneous illumination. In addition, the restoration by deconvolution improves visibility of subtle details like small blood vessels.

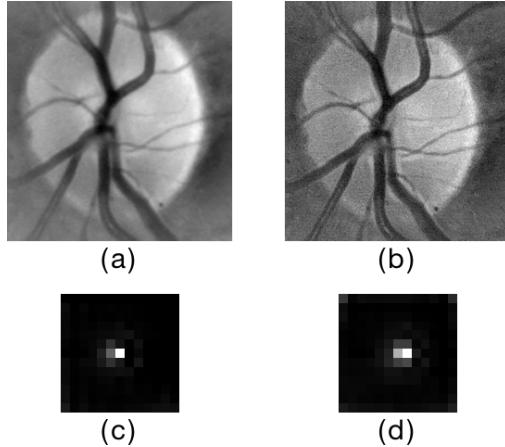


Figure 3. Image restoration by MBD. (a) original image with illumination compensation by BEMD. (b) Restored image. (c)-(d) Estimated PSFs for images in Fig. 2 (a)-(b). Note at the increase in visibility of small blood vessels.

8. Acknowledgments

This research has been partly funded by the Spanish Ministerio de Economía y Competitividad y Fondos FEDER (project No. DPI2013-43220-R). Financial support was also provided by the Universidad Tecnológica de Bolívar.

References

- [1] M. U. Akram, S. Khitran, A. Usman, and U. Yasin. Detection of Hemorrhages in Colored Fundus Images Using Non Uniform Illumination Estimation. In A. Campilho and M. Kamel, editors, *Lecture Notes in Computer Science*, volume 8815, pages 329–336. Springer International Publishing, 2014.
- [2] Y. Lu, F. Xie, Y. Wu, Z. Jiang, and R. Meng. No Reference Uneven Illumination Assessment for Dermoscopy Images. *IEEE Signal Processing Letters*, 22(5):534–538, 2015.
- [3] A. G. Marrugo and M. S. Millan. Retinal Image Analysis Oriented to the Clinical Task. *Electronic Letters on Computer Vision and Image Analysis*, 13(2):54–55, 2014.
- [4] A. G. Marrugo, M. Sorel, F. Sroubek, and M. S. Millan. Retinal image restoration by means of blind deconvolution. *Journal of Biomedical Optics*, 16(11):116016, 2011.
- [5] M. J. Newton. The promise of telemedicine. *Survey of Ophthalmology*, 59(5):559–567, Sept. 2014.
- [6] J. C. Nunes, Y. Bouaoune, E. Delechelle, O. Niang, and P. Bunel. Image analysis by bidimensional empirical mode decomposition. *Image and Vision Computing*, 21(12):1019–1026, Nov. 2003.
- [7] F. Sroubek and J. Flusser. Multichannel blind deconvolution of spatially misaligned images. *IEEE transactions on image processing : a publication of the IEEE Signal Processing Society*, 14(7):874–883, July 2005.

Background Intensity Removal in Structured Light Three-Dimensional Reconstruction

Raúl Vargas, Jesus Pineda, and Andrés G. Marrugo

Facultad de Ingeniería
Universidad Tecnológica de Bolívar
Cartagena, Colombia.

agmarrugo@unitecnologica.edu.co

Lenny A. Romero

Facultad de Ciencias Básicas
Universidad Tecnológica de Bolívar
Cartagena, Colombia.

lromero@unitecnologica.edu.co

Abstract

In Fourier Transform Profilometry, a filtering procedure is performed to separate the desired information (first order spectrum) from other unwanted contributions such as the background component (zero-order spectrum). However, if the zero-order spectrum and the high order spectra component interfere the fundamental spectra, the 3D reconstruction precision decreases. In this paper, we test two recently proposed methods for removing the background intensity so as to improve Fourier Transform Profilometry reconstruction precision. The first method is based on the twice piecewise Hilbert transform. The second is based on Bidimensional Empirical Mode Decomposition, but the decomposition is carried out by morphological operations. In this work, we present as a novel contribution, the sequential combination of these two methods for removing the background intensity and other unwanted frequencies close to the first order spectrum, thus obtaining the 3D topography of the object. Encouraging experimental results show the advantage of the proposed method.

1. Introduction

Fringe projection is a widely used technique based on structured illumination for optical three dimensional (3D) shape measurement. It provides a 3D topography of objects in a non-contact manner, with high resolution, and fast data processing. 3D shape measurement is commonly applied in production automation, robot vision, medical image diagnosis, industrial and scientific applications, cultural heritage and preservation and other fields. Among the existing techniques, Fourier transform profilometry (FTP) is one of the most used techniques [11]. In FTP a filtering procedure is performed to obtain the fundamental frequency spectrum in the frequency domain. This means that frequency aliasing between the zero-order spectrum and the fundamental spec-

trum has great influence on the measurement accuracy and measurable slope of height variation. If the zero frequency component and the high order spectra component interfere the useful fundamental spectra, the reconstruction precision of FTP will decrease greatly.

To overcome this difficulty various time-space-frequency analysis techniques based on Fourier analysis are often used to filter out background intensity from a single pattern. These techniques include windowed Fourier [6] or Gabor transform [13], wavelet transform [14], and smoothed space-frequency distribution [1]. A major restriction of these methods is their non-adaptive nature. A priori knowledge of parameters like filter window width and basis function is necessary for generating desirable outputs. Other authors have proposed quasi-sinusoidal projection and π -phase shifting for suppressing the zero frequency component and high-order spectra component [9] and composite stripe projection technology for eliminating zero frequency component [3] for improving the accuracy and measurement range of FTP. These techniques have their own applications according to the property of the measured objects. For instance, the π -shifting technique needs to capture two fringe pattern images with π -phase difference to eliminate the background intensity by a subtracting operation. This improves the accuracy and measurement range but is a clear drawback when measuring dynamic objects and scenes.

In this paper we test two recently proposed methods, Morphological-Based Bidimensional Empirical Mode Decomposition (MOBEMD) [15] and the Hilbert Transform [7], for removing the background intensity so as to improve FTP reconstruction precision. In identifying the shortcomings of these two methods we propose the use of both methods sequentially in order to obtain the most accurate 3D reconstruction.

2. Fourier Transform Profilometry

A sinusoidal grating image is projected onto the object surface (Figure 1). The deformed fringe pattern captured by the CCD can be expressed as

$$g(x, y) = a(x, y) + b(x, y) \cos[2\pi f_0 x + \varphi(x, y)] , \quad (1)$$

where $a(x, y)$ represents the background illumination, $b(x, y)$ is the amplitude of the cosine function and relates to the contrast of the fringes, f_0 is the carrier frequency, and $\varphi(x, y)$ is the phase that contains the shape information of the tested object. Equation (1) can be rewritten as

$$g(x, y) = a(x, y) + c(x, y)e^{i2\pi f_0 x} + c^*(x, y)e^{-i2\pi f_0 x}, \quad (2)$$

where

$$c(x, y) = \frac{1}{2}b(x, y)e^{i(\varphi(x, y))} , \quad (3)$$

and superscript * is the complex conjugate of $c(x, y)$. The phase of the fringe system is calculated using the Fourier transform method. Using one-dimensional notation for simplicity, we can express the Fourier transform with respect to x as

$$G(f_x, y) = A(f_x, y) + C(f_x - f_0, y) + C^*(f_x + f_0, y) , \quad (4)$$

where $A(f_x, y)$ and $C(f_x - f_0, y)$ are the 1-D Fourier transforms of $a(x, y)$ and $c(x, y)$. $A(f_x, y)$ represents the zero spectra corresponding to the background component and $C(f_x - f_0, y)$ contains the shape information from the measured object. $\varphi(x, y)$, $a(x, y)$, and $b(x, y)$ vary slowly compared to the carrier frequency f_0 . A properly designed filter is applied to select $C(f_x - f_0, y)$. Equation (5) shows the complex signal obtained by calculating the inverse Fourier transform of $C(f_x - f_0, y)$ [4, 7] as

$$c(x, y) = \frac{1}{2}b(x, y) \exp^{i(\varphi(x, y)+2\pi f_0 x)} . \quad (5)$$

The phase $\varphi(x, y)$ can be extracted by computing the logarithm of $c(x, y)$, and then isolating the imaginary part as

$$\varphi(x, y) = \text{Im} \left[\log \left(\frac{1}{2}b(x, y) \right) + i(\varphi(x, y)) \right] . \quad (6)$$

The obtained phase is wrapped in the range of π to $-\pi$. A phase unwrapping process is applied to remove the 2π discontinuity. This process is carried out by comparing the wrapped phase at neighboring pixels and adding or subtracting multiples of 2π thus obtaining the continuous phase. This obtained phase can be affected by local shadows, irregular surface brightness, fringe discontinuities and under sampling [10]. In order to overcome these problems, pre-processing strategies are carried out such as binary masks, interpolation techniques and filtering to remove noise, among other.

3. Background Intensity Removal Methods

Frequency aliasing between the zero spectrum and the fundamental spectrum has a great influence on the measurement accuracy and measurable slope of height variation. If the zero frequency component and the high order spectra component interfere the useful fundamental spectra, the reconstruction precision of FTP will decrease greatly. To overcome this problem, we test two methods and propose a variant, based on these two methods, for removing the background intensity so as to improve FTP reconstruction precision.

3.1. Hilbert transform

The Hilbert transform $H(\cdot)$ of a 1D signal $f(x)$ is defined as

$$H(f(x)) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{f(\tau)}{x - \tau} = \frac{1}{\pi x} * f(x) , \quad (7)$$

and the Fourier spectra of $H(f(x))$ is defined as [7]

$$\mathcal{F}\{H(f(x))\} = -j\text{sgn}(w)F(w) , \quad (8)$$

where $\text{sgn}(\cdot)$ is the signum function.

The Hilbert transform can carry out 90 degree phase shifting for the positive frequency and 90 degree phase shifting for the negative frequency. In addition, the DC component is removed.

Luo et al. [7] proposed a piece-wise Hilbert transform to suppress the background intensity of the deformed fringe pattern using only one fringe pattern according to the approximation that the background of the fringes is a slowly varying function and its distribution in each half period of the fringe can be considered as a constant.

The algorithm used to calculate the piece-wise Hilbert transform is the follow:

1. Detect ridges and troughs of the fringes.
2. Calculate the segments of fringe $f_i(x)$ between an adjacent local maximum and local minimum.
3. Calculate twice Hilbert transform (TPHT) to each fringe segment as:
 $D1=H(f_i(x));$
 $D11=-\text{imag}(D1);$
 $D2=H(D11);$
 $D22=-\text{imag}(D2);$

3.2. Morphological-based BEMD

The deformed fringe pattern is not periodic stationary because the projected sinusoidal pattern is modulated by the tested object. For analyzing non-stationary signals, Bidimensional Empirical Mode Decomposition (BEMD) can

decompose the deformed fringe pattern into Intrinsic Mode Functions (IMF) [5, 8] varying from high frequency to low frequency. Thus, removing the background is a simple operation. However, the decomposition is time consuming. To overcome this problem Zhou et al., [15] proposed a fast algorithm for empirical mode decomposition based on morphological operations and 2D convolution.

After finding the ridges (troughs) by morphological operations the envelopes are estimated by a weighted moving average algorithm and calculated by 2D convolutions to increase the speed of the estimation. The sifting procedure concludes when two modes are extracted, namely, a single IMF and a residue. The IMF corresponds to the fringe pattern without the background.

3.3. MO-BEMD and Hilbert transform

The previous two methods often fail to completely remove the background intensity. MOBEMD estimates the illumination by regions to obtain a global illumination distribution, but it fails to remove all local low frequency components associated with the DC level of each Fringe. In contrast, the Hilbert transform can eliminate these local DC components, but is susceptible to errors when there are global illumination variations, which does not allow a successful maxima and minima detection in the signal.

We propose to use both methods to suppress the background intensity of the fringe pattern. First, with MOBEMD, we obtain a global compensation illumination and then with twice piecewise Hilbert transform a local illumination compensation.

4. Experimental Details

The experimental setup consisted in two parts: a projection system and an observation system (Figure 1). The projection system used was an LED pattern projector (Opto-engineering LTPR36-W) that contains a stripe pattern of 400 lines with line thickness 0.01mm. A objective lens of 75-mm focal length was used to project the fringe pattern onto the tested object. The observation system consists of a CMOS camera (Basler Ace with 1280×1024 pixels) that captures the distorted pattern. The captured pattern was analyzed to extract the topographical information of the object. A calibration process was executed to convert the resulting phase map to (x, y, z) -coordinates [2, 12]. The tested object is a dented steel pipe. A dent is a permanent plastic deformation of the circular cross section of the pipe. The dent was produced by means of a Rockwell hardness test, penetrating the pipe with a diamond cone indenter.

In Figure 2 we show the acquired image of the tested object. This image presents a non-uniform illumination distribution and poor contrast of the fringes. Figure 3(a) shows the area of interest for 3D reconstruction. The projected fringes on the edges of the pipe dent exhibit discontinuity

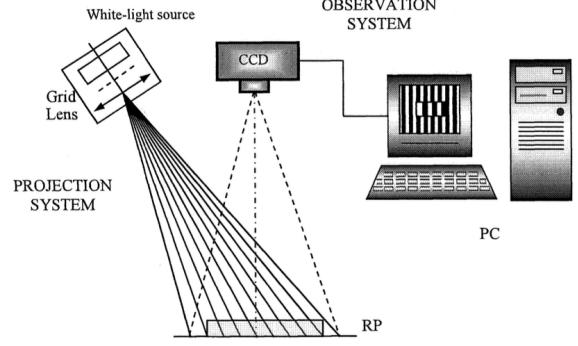


Figure 1. FTP measuring system arrangement.

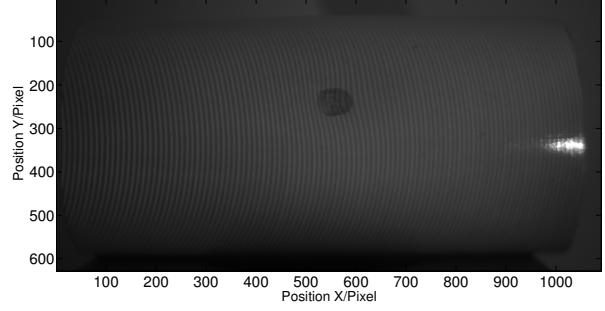


Figure 2. Acquired image of the dented pipe.

problems in some regions that impede an accurate 3D reconstruction.

5. Results and Discussion

5.1. Background Removal

The spectrum in Figure 3(e) was obtained using the FTP method. The unwanted background intensity is mainly represented by the central peak, i.e, the zero-order or DC component. The desired shape information is represented as two peaks centered at the carrier frequency value and its conjugate. A Hanning filter is applied to perform the filtering procedure. The size of the filter was designed to cover most of the frequencies associated with the object, however often leakage frequencies related to illumination or discontinuities in the image lead to incorrect phase information. To overcome this problem, we processed the images for background intensity removal. The results of applying TPHT, MOBEMD and the proposed method (TPHT+MOBEMD) to remove the background intensity are shown in Figures 3(b)-(d). In the second line of Figure 3 we show a profile of the Fourier spectra of the corresponding figures. Figure 3(f) shows the resulting spectrum after applying the TPHT method. This method removes the background intensity variation, however it has problems on compensating illumination in the pipe dent and in addition to generating irregularities at the edges as is shown in Figure 3(b).

Processing the image with MOBEMD provides a more

accurate estimation of the illumination distribution, especially inside the dent, but the overall background is not adequately removed as can be seen in the corresponding Fourier spectrum (Figure 3(g)). Our proposal, of processing the image with MOBEMD+TPHT, leads to an overall uniform intensity with hardly any artifacts in the dent. Figure 3(h) shows the spectrum of TPHT+MOBEMD in which the background is not completely removed but it is negligible.

5.2. Phase Maps and 3D Reconstruction

Accurately retrieving the phase map from the dent is most likely a problem due to the poor contrast and discontinuities of the fringes in the border. The 3D reconstruction is obtained subtracting the estimated linear phase from the reference plane from the continuous experimental phase map. In Figure 4 we show the four 3D reconstructions of the pipe dent. Notice the artifacts in the first three reconstructions (Figures 4(a)-(c)), whereas the reconstruction from the image processed by MOBEMD+TPHT is artifact-free.

To overcome this difficulty, often a binary mask is used, as the one shown in Figure 5(a). The phase unwrapping procedure is carried out without considering the pixels inside the mask. After the continuous phase has been obtained, the phase values of the pixels inside the mask are obtained by interpolation. In Figure 5(b) we show the 3D reconstruction using FTP plus the masking procedure. While this is always a possibility, this leads to inaccuracy in the 3D reconstruction and may altogether fail if the mask is too large relative to the image size.

In Figure 6(a) we show the profiles from the 3D reconstructions along the y-axis passing through the dent. There is a minor offset from the profiles because the reference linear phase is estimated from the experimental image. The preprocessing produces this offset, but it has no influence on the relative z values and the topography. Due to the phase unwrapping problems the profiles from FTP, MOBEMD, and TPHT have reconstruction errors that manifest as spikes. For the sake of comparison, in Figure 6(b) we show the profiles from the 3D reconstruction by FTP, FPT+Mask, and the proposed method. Notice that because of the masking and interpolation, the relatively high slope at the right-side of the spike is much more smooth. This topographical characteristic is preserved with the proposed method.

6. Conclusions

In this work we have presented a typical problem that arises in Fourier Transform Profilometry dealing with uneven illumination and poor contrast of the fringes. This leads to problems in the phase unwrapping stage that produce artifacts in the 3D surface reconstruction. We presented results on real images from a dented pipe using

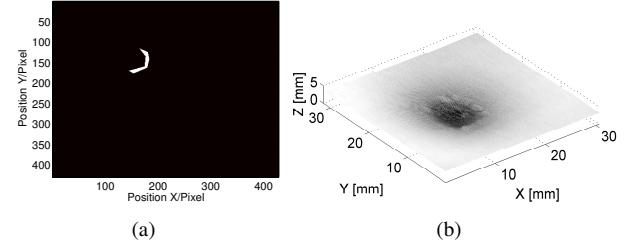


Figure 5. (a) Binary mask used to avoid phase unwrapping artifact. (b) 3D reconstruction after masking and interpolation.

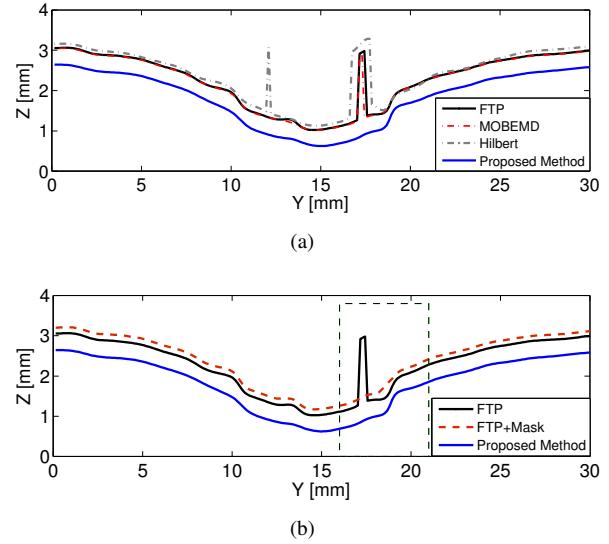


Figure 6. Profiles from the 3D reconstructions along the y-axis passing through the pipe dent.

three methods for removing the background intensity and improving fringe visibility. The methods MOBEMD and TPHT showed a significant enhancement of the input image, but fail either to adequately compensate the local or overall intensity distribution. For this reason, we proposed to use both techniques, first MOBEMD and followed by TPHT to enhance the images. The proposed method clearly improves the phase unwrapping stage and avoids the use of masks and interpolation which lead to inaccurate 3D reconstruction.

Acknowledgement

This work has been partly funded by Colciencias (Fondo Nacional de Financiamiento para la Ciencia, la Tecnología y la Innovación "Francisco José de Caldas") project 538871552485, and by Universidad Tecnológica de Bolívar project FI1607T2001. The authors thank the support from Dirección de Investigaciones Universidad Tecnológica de Bolívar.

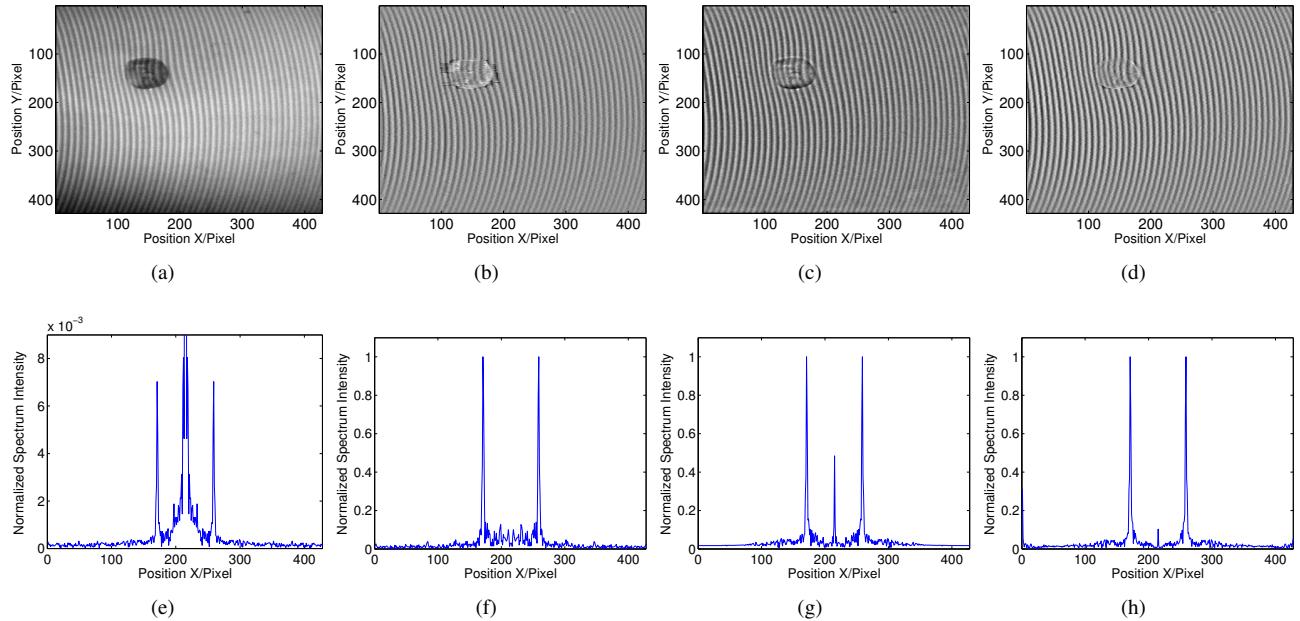


Figure 3. (a) Original image. Background removal with (b) TPHT, (c) MOBEMD, and (d) MOBEMD+TPHT. (e)-(h) A profile of the corresponding Fourier spectra. In (e) the DC component has been truncated for display purposes.

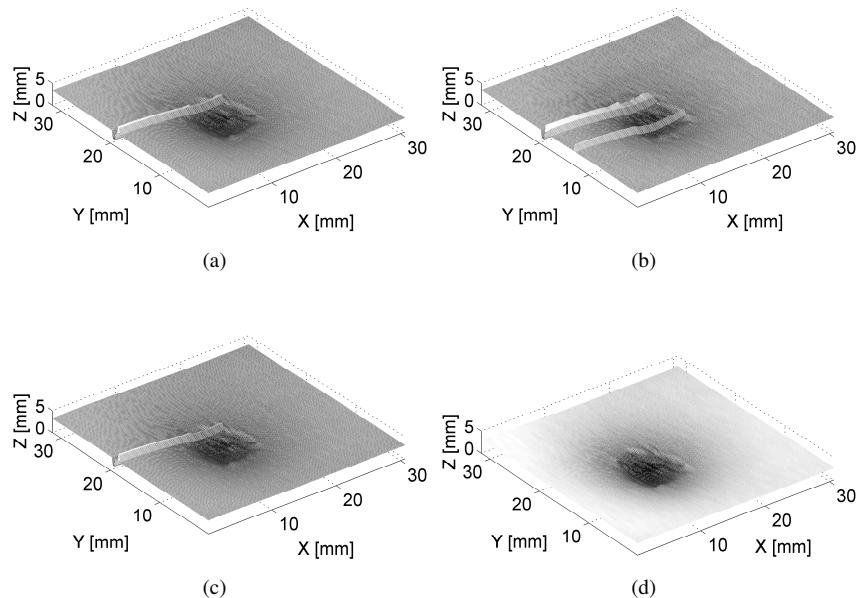


Figure 4. 3D surface reconstruction with (a) FTP, (b) TPHT, (c) MOBEMD, (d) MOBEMD+TPHT.

References

- [1] A. Federico and G. H. Kaufmann. Phase retrieval in digital speckle pattern interferometry by use of a smoothed space-frequency distribution. *Applied optics*, 42(35):7066–7071, 2003.
- [2] A. L. G. Gómez, J. E. M. Fonseca, and J. L. Téllez. Proyección de franjas en metrología óptica facial. *INGE CUC*, 8(1):191–206, 2012.
- [3] C. Guan, L. Hassebrook, and D. Lau. Composite structured light pattern for three-dimensional video. *Optics Express*, 11(5):406–417, 2003.
- [4] H. Guo. *3-D shape measurement based on Fourier transform and phase shifting method*. PhD thesis, STATE UNIVERSITY OF NEW YORK AT STONY BROOK, 2009.
- [5] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih,

- Q. Zheng, N. C. Yen, C. C. Tung, and H. H. Liu. The empirical mode decomposition and the Hilbert spectrum for non-linear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 454(1971):903–995, Mar. 1998.
- [6] Q. Kemao. Windowed fourier transform for fringe pattern analysis. *Applied Optics*, 43(13):2695–2702, 2004.
 - [7] F. Luo, W. Chen, and X. Su. Eliminating zero spectra in fourier transform profilometry by application of hilbert transform. *Optics Communications*, 365:76–85, 2016.
 - [8] J. C. Nunes, Y. Bouaoune, E. Delechelle, O. Niang, and P. Bunel. Image analysis by bidimensional empirical mode decomposition. *Image and vision computing*, 21(12):1019–1026, 2003.
 - [9] X. Su and W. Chen. Fourier transform profilometry:: a review. *Optics and Lasers in Engineering*, 2001.
 - [10] X. Su and W. Chen. Reliability-guided phase unwrapping algorithm: a review. *Optics and Lasers in Engineering*, 42(3):245–261, 2004.
 - [11] M. Takeda and K. Mutoh. Fourier transform profilometry for the automatic measurement of 3-d object shapes. *Applied optics*, 22(24):3977–3982, 1983.
 - [12] J. Villa, M. Araiza, D. Alaniz, R. Ivanov, and M. Ortiz. Transformation of phase to (x, y, z)-coordinates for the calibration of a fringe projection profilometer. *Optics and Lasers in Engineering*, 50(2):256–261, 2012.
 - [13] J. Zhong and J. Weng. Dilating gabor transform for the fringe analysis of 3-d shape measurement. *Optical Engineering*, 43(4):895–899, 2004.
 - [14] J. Zhong and J. Weng. Spatial carrier-fringe pattern analysis by means of wavelet transform: wavelet transform profilometry. *Applied optics*, 43(26):4993–4998, 2004.
 - [15] X. Zhou, A. G. Podoleanu, Z. Yang, T. Yang, and H. Zhao. Morphological operation-based bi-dimensional empirical mode decomposition for automatic background removal of fringe patterns. *Optics express*, 20(22):24247–24262, 2012.

Background Intensity Removal in Fourier Transform Profilometry: A Comparative Study

Raúl Vargas,¹ Jesús Pineda,¹ Lenny A. Romero,² and Andrés G. Marrugo¹

¹Facultad de Ingeniería, Universidad Tecnológica de Bolívar
Km 1 vía Turbaco, 130011 Cartagena, Colombia.

²Facultad de Ciencias Básicas, Universidad Tecnológica de Bolívar
Km 1 vía Turbaco, 130011 Cartagena, Colombia.

lromero@unitecnologica.edu.co

Abstract: We study the removal of the background intensity of fringe patterns via Empirical Mode Decomposition and the Hilbert Transform. Simulation results show that the latter provides a suitable background compensation with minimal error 3D-reconstruction.

OCIS codes: 070.0070, 100.0100, 120.0120.

1. Introduction

In Fourier Transform Profilometry (FTP) [1], a filtering procedure is performed to obtain the fundamental frequency spectrum in the frequency domain. This means frequency aliasing between the zero spectrum and the fundamental spectrum has a great influence on the measurement accuracy and measurable slope of height variation. If the zero frequency component and the high order spectra component interfere the useful fundamental spectra, the reconstruction precision of FTP will decrease greatly. To avoid this disadvantage, we test two recently proposed methods for removing the background intensity so as to improve FTP reconstruction precision. The first method is based on the piece-wise Hilbert transform [2]. The second method is based on Bi-dimensional Empirical Mode Decomposition (BEMD) [3], but the decomposition is carried out by morphological operations taking advantage of fringe images [4].

2. Background Removal

2.1. Morphological-based BEMD

The deformed fringe pattern is not periodic stationary, because the projected sinusoidal pattern is modulated by the tested object. For analyzing non-stationary signals, BEMD can decompose the deformed fringe pattern into Intrinsic Mode Functions (IMF) varying from high frequency to low frequency. Thus, removing the background is a simple operation. However, the decomposition is time consuming. To overcome this problem Zhou et al., [4] proposed a fast algorithm for empirical mode decomposition based on morphological operations and 2D convolution. In their work, extrema are not local maxima (minima), but are the pixels on the ridges (troughs) of a fringe pattern. After finding the ridges (troughs) by morphological operations the envelopes are estimated by a weighted moving average algorithm. The sifting procedure concludes when two modes are extracted, namely, a single IMF and a residue. The IMF corresponds to the fringe pattern without the background.

2.2. Piece-wise Hilbert Transform

The Hilbert transform can be seen as a 90-degree phase-shifter. Because the background intensity and contrast of the deformed fringe vary slowly throughout the image, they can be regarded as locally constant in a small region. Applying twice the Hilbert transform removes the DC component from a signal. However, because the background intensity varies, Luo et al. [2] proposed a piece-wise Hilbert transform per each half-period of the deformed fringe patterns.

3. Experiments and Results

In order to test realistically the considered background removal techniques we introduced three background modulation functions: (i) a negative slope from the bottom-left corner to the top-right corner of the image. This attempts to reproduce uneven illumination commonly found in fringe projection when the projector is tilted. (ii) A centered

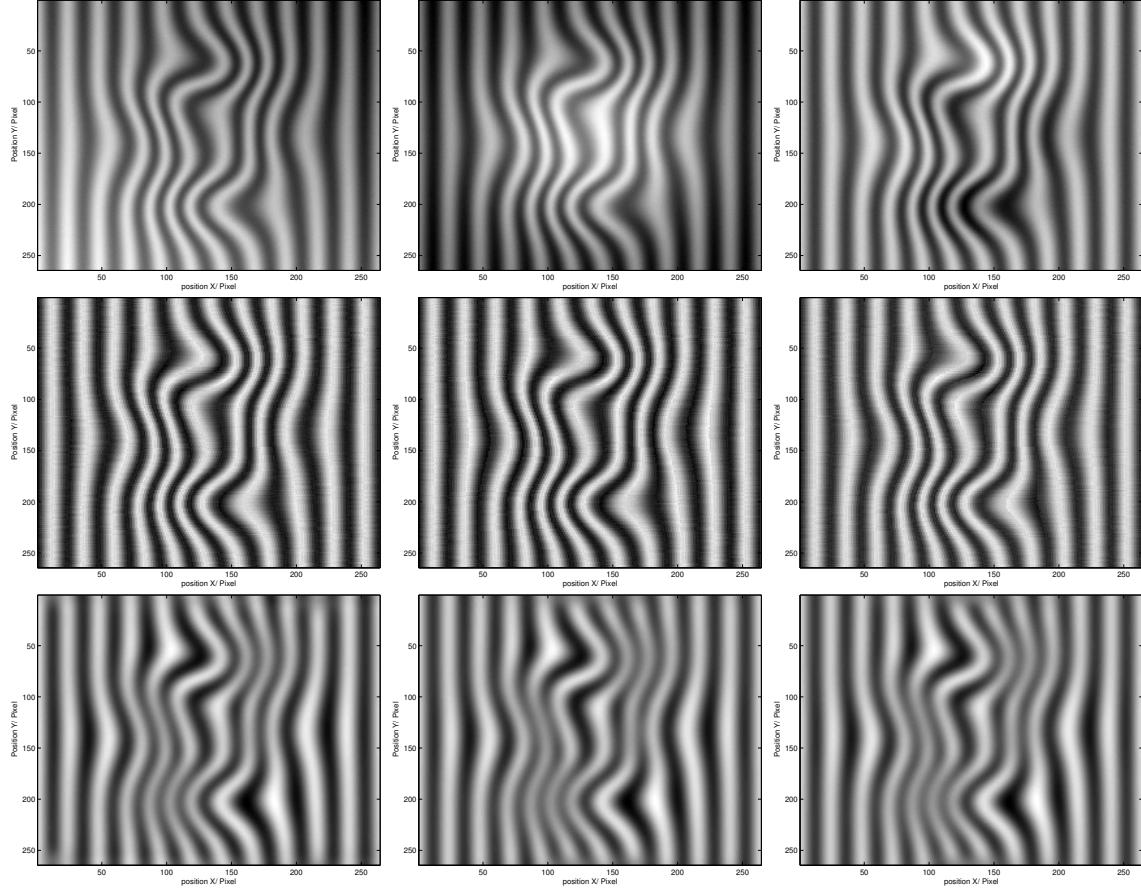


Fig. 1. (From left to right) Top-row: Deformed fringe patterns with different background modulation. Middle-row: the images after twice piece-wise Hilbert Transform. Bottom-row: After MOBEMD processing.

Gaussian function. This is also an approximation to commonly found uneven illumination. (iii) A more complex illumination modulation given by $-0.4 \times \frac{\text{peaks}(\cdot)}{\max \text{peaks}}$, where `peaks(.)` is the MATLAB function as suggested in Ref. [2]. The object for reconstruction is `0.95peaks(.)`.

In the top row of Fig. 1 the deformed fringe patterns with different background modulation are shown. In the middle and bottom row, the processed images with twice piece-wise Hilbert transform and MOBEMD are shown. The images processed with the Hilbert Transform are inverted because of the 90-degree phase shift. However, the background intensity has been successfully removed. Despite the fact that MOBEMD also removes the background, it also reduces the contrast of the fringes which may introduce errors in the 3D reconstruction.

The 3D reconstructions and the error maps for the case in which the background intensity is modulated by a linear function are shown in Fig. 2. The rms reconstruction errors are 0.65 mm, 0.069 mm, and 0.38 mm. For the Gaussian distribution the rms errors are 0.046 mm, 0.070 mm, and 0.122 mm. And for the modulation with $-0.4 \times \frac{\text{peaks}(\cdot)}{\max \text{peaks}}$ the rms errors are 0.061 mm, 0.056 mm, and 0.120 mm, respectively. Despite the errors, conventional FTP is significantly robust, mainly due to the filtering that is carried out. However, the piece-wise Hilbert Transform reduces the reconstruction errors by properly removing the slowly changing background. MOBEMD, while still removing the background intensity, its negative effect on lowering fringe contrast prevents it from being particularly useful.

4. Conclusions

In this work we have presented a comparative study with two recent techniques for removing the background intensity on fringe images for 3D Fourier Transform Profilometry. From our preliminary results, we have determined that the Piece-wise Hilbert Transform provides a suitable approach for removing the background and maintaining fringe

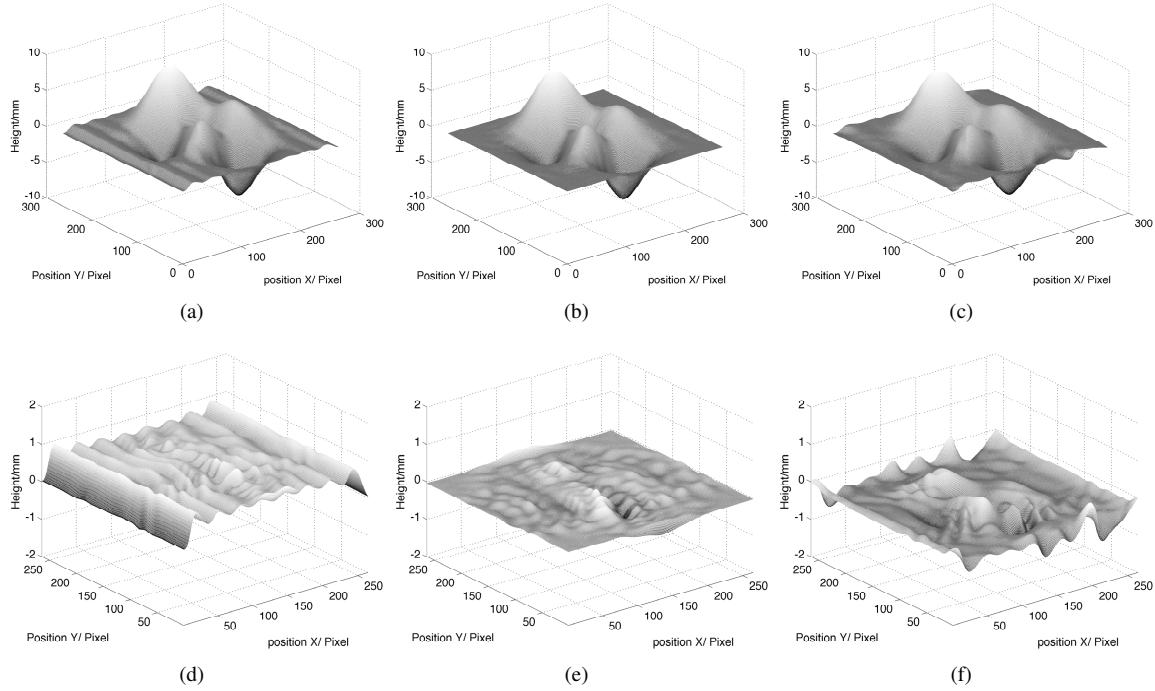


Fig. 2. 3D Reconstruction from deformed fringe pattern with background illumination modulated with a linear function by (a) conventional 2D FTP, (b) after PHT, and (c) MOBEMD. (d)-(f) The corresponding error maps.

fidelity.

References

1. M. Takeda and K. Mutoh, “Fourier transform profilometry for the automatic measurement of 3-D object shapes.” *Applied Optics* **22**, 3977 (1983).
2. F. Luo, W. Chen, and X. Su, “Eliminating zero spectra in Fourier transform profilometry by application of Hilbert transform,” *Optics Communications* **365**, 76–85 (2016).
3. J. C. Nunes, Y. Bouaoune, E. Delechelle, O. Niang, and P. Bunel, “Image analysis by bidimensional empirical mode decomposition,” *Image and Vision Computing* **21**, 1019–1026 (2003).
4. X. Zhou, A. G. Podoleanu, Z. Yang, T. Yang, and H. Zhao, “Morphological operation-based bi-dimensional empirical mode decomposition for automatic background removal of fringe patterns.” *Optics express* **20**, 24,247–24,262 (2012).