

Segmentación automática de estructuras nerviosas en imágenes de ultrasonido: una comparación entre técnicas de procesamiento de imágenes y modelos Bayesianos no paramétricos.

Estudiante investigador: Juan José Giraldo Gutiérrez

Director: Mauricio Alexander Álvarez



Universidad Tecnológica de Pereira
Facultad de Ingenierías Eléctrica, Electrónica, Física y Ciencias de la
Computación
Maestría en Ingeniería Eléctrica - Línea de automática
Grupo de Investigación en Control e Instrumentación
Pereira-Risaralda
2015

Índice general

Agradecimientos	2
Resumen	3
Abstract	4
Introducción	5
1. Planteamiento del problema	6
1.1. Bloqueo de Nervios Periféricos	6
1.2. Limitaciones del Ultrasonido	6
1.3. Segmentación de Imágenes de Ultrasonido	7
2. Justificación	9
2.1. La Segmentación Automática de Imágenes de Ultrasonido como asistencia a la Anestesiología	9
2.2. Pertinencia	9
2.3. Viabilidad	9
2.4. Impacto	10
3. Objetivos	11
3.1. General	11
3.2. Específicos	11
4. Revisión del estado del arte	12
4.1. Bloqueo Regional Asistido	12
4.2. Técnicas del Procesamiento de Imágenes	13
4.3. Modelos Bayesianos No Paramétricos	15
5. Materiales y Métodos	16
5.1. Base de Datos	16
5.2. Filtrado Speckle basado en Non Local Means	17
5.3. Modelos Estadísticos de forma	17
5.3.1. Modelamiento de la variación en la forma	18
5.3.2. Elección del número de modos	19
5.3.3. Generación de posibles formas	20
5.3.4. Encontrando la forma más cercana posible	20
5.3.5. Ajuste del modelo a nuevos puntos	21
5.4. Modelo de forma activa	22

5.5. Modelo Bayesiano No paramétrico	22
5.6. Clustering Jerárquico	24
5.7. Modelo Bayesiano No Paramétrico de Clustering Jerárquico	24
5.8. Validación	25
6. Resultados y Discusión	26
6.1. Filtro Non Local Means	26
6.2. Segmentación de Estructuras nerviosas: Comparación entre <i>ASM</i> y <i>Non Parametric Bayesian HC</i>	27
6.2.1. Resultados Modelo ASM	27
6.2.2. Resultados Modelo NPBHC	27
6.2.3. Resultados Modelo ASM vs. Modelo NPBHC	28
7. Conclusiones y Trabajos Futuros	34
7.1. Conclusiones	34
7.2. Trabajos Futuros	35
8. Publicaciones	36
Bibliografía	37

Agradecimientos

Quiero agradecer especialmente a Dios, quien me ha regalado la vida y la oportunidad de conocerle a través de la creación que manifiesta Su grandesa. “Porque el Señor da la sabiduría; conocimiento y ciencia brotan de sus labios.”¹.

Así mismo quiero agradecer a mi Director Ph.D Mauricio A. Álvarez quién constantemente me asesoró en el desarrollo de este trabajo hasta su culminación. Gracias al Ph.D Álvaro A. Orózco quien me brindó su apoyo y vinculación al proyecto de investigación CIE 6-13-6, financiado por la Universidad Tecnológica de Pereira, bajo el cual se desarrolló esta tesis de Maestría.

Gracias al Dr. Diego Salazar especialista en anestesiología quien amablemente dedicó gran parte de su tiempo a la construcción de la base de datos, el etiquetado de las imágenes de ultrasonido y asesoramiento para la segmentación de las mismas.

Gracias a mis compañeros MsC. Hernán Felipe García y MsC. Cristian Alejandro Torres quienes constantemente me asesoraron en mis estudios de Maestría y me enseñaron el uso de diversas herramientas algorítmicas y ofimáticas.

Gracias a mi amada esposa Liza María González quien siempre me ha animado a seguir adelante haciendo las cosas con excelencia y es abnegada con nuestros tiempos de pareja.

Gracias a mis papás Hernando Giraldo y Luz Nidia Gutiérrez, hermanos, familiares y amigos quienes a diario me manifiestan su amor y se preocupan por el progreso de mi vida tanto física, emocional y espiritual.

¹Proverbios 2:6

Resumen

Un gran número de casos relacionados con el dolor crónico, debido a accidentes, enfermedades o intervenciones quirúrgicas dependen de prácticas anestesiológicas. Estas prácticas son asistidas mediante imágenes de ultrasonido. Aunque, las imágenes de ultrasonido son una herramienta útil que tiene como propósito guiar al especialista en anestesiología, la falta de inteligibilidad debido a un ruido multiplicativo acústico conocido como speckle, hace de este tipo de intervención quirúrgica una tarea difícil. De la misma manera, algunos artefactos son introducidos en el proceso de captura, desafiando al experto en anestesiología de no confundir las verdaderas estructuras nerviosas. En consecuencia, una metodología de asistencia usando procesamiento de señales podría mejorar la precisión en la práctica de anestesiología. Este trabajo propone dos métodos para la segmentación de nervios periféricos en imágenes médicas de ultrasonido, el primero con base en un Modelo de Forma Activa y el segundo con base en un Modelo Bayesiano no paramétrico de Clustering Jerárquico. La comparación de los resultados experimentales muestra un mejor desempeño de segmentación para el modelo no paramétrico, con un error cuadrático medio $1,026 \pm 0,379$ píxeles para el nervio cubital, $0,704 \pm 0,233$ píxeles para el nervio mediano y $1,698 \pm 0,564$ píxeles para el nervio peroneal. Así mismo, este modelo permite enfatizar otras estructuras blandas como músculos y tejidos acuosos. Por otra parte, el Modelo de Forma Activa segmenta con un desempeño de error cuadrático medio de $2,610 \pm 0,486$ píxeles para el nervio cubital, $2,047 \pm 0,399$ píxeles para el nervio mediano y $2,808 \pm 0,369$ píxeles para el nervio peroneal, con un mejor tiempo de ejecución que el modelo Bayesiano no paramétrico. Todos los resultados se validaron con etiquetas reales suministradas por un anestesiólogo.

Abstract

Several cases related to chronic pain, due to accidents, illness or surgical interventions, depend on anesthesiology procedures. These procedures are assisted with ultrasound images. Although, the ultrasound images are a useful instrument in order to guide the specialist in anesthesiology, the lack of intelligibility due to speckle noise, makes the clinical intervention a difficult task. In a similar manner, some artifacts are introduced in the image capturing process, challenging the expertise of anesthesiologists for not confusing the true nerve structures. Accordingly, an assistance methodology using image processing can improve the accuracy in the anesthesia practice. This work proposes two peripheral nerve segmentation methods in medical ultrasound images, one based on Active Shape Models and the other on Nonparametric Bayesian Hierarchical Clustering. The comparison of experimental results show a better segmentation performances for Nonparametric model, with a Mean Squared Error of $1,026 \pm 0,379$ pixels for ulnar nerve, $0,704 \pm 0,233$ pixels for median nerve and $1,698 \pm 0,564$ pixels for peroneal nerve. Likewise, this model allows to emphasize other soft structures like muscles and aqueous tissues. In the other hand, the Active Shape Model segments with a Mean Squared Error performance of $2,610 \pm 0,486$ pixels for ulnar nerve, $2,047 \pm 0,399$ pixels for median nerve and $2,808 \pm 0,369$ pixels for peroneal nerve, with a better run time than the Nonparametric Bayesian Model. All results were validated with segmentations manually labeled by an anesthesiologist.

Introducción

El bloqueo de nervios periféricos (PNB) es un procedimiento que juega un papel importante en el tratamiento del dolor crónico y la práctica anestesiológica actual, gracias a que permite interrumpir la conducción nerviosa de zonas corporales sometidas a intervenciones quirúrgicas o afectadas por dolor crónico de origen neuropático. El enfoque general del PNB consiste en la administración de un anestésico local en la proximidad de estas estructuras nerviosas, la difusión del anestésico a través del nervio impide su conducción eléctrica por bloqueo de canales de sodio y de esta manera la transmisión de información nociceptiva que viaja hasta el sistema nervioso central [1].

La localización de las estructuras nerviosas en la realización de un PNB se lleva a cabo mediante técnicas de marcas anatómicas, inducción de parestesias, estimulación eléctrica y ultrasonido. Las tres primeras técnicas presentan ciertas desventajas debido a su poca efectividad o al tratarse de procedimientos invasivos, es por esto que el uso de la ultrasonografía se ha posicionado como la técnica más utilizada en la realización de PNB, permitiendo la captura de imágenes de las estructuras anatómicas y nerviosas en tiempo real. A pesar de la alta cantidad de ruido y poca inteligibilidad de éste tipo de imágenes, permiten dar una orientación a los especialistas en anestesiología para realizar los procedimientos de bloqueos regionales, claro está, previa preparación exhaustiva por parte del especialista acerca de las falencias en las imágenes ultrasónicas. A pesar de las ventajas del ultrasonido como técnica no invasiva, existen además ciertos factores asociados con esta técnica de captura, que dificultan la práctica de anestesia. Se les conoce como artefactos, o sea objetos que se visualizan en una imagen ecográfica, pero que en realidad no existen o pérdida de ecos por estructuras óseas o líquidas como vasos [2].

Así mismo, debido a las características propias del ultrasonido, existe un ruido conocido como multiplicativo acústico (speckle), que degrada la calidad de las imágenes dificultando la precisión en el proceso de anestesiología, debido a la pérdida de bordes y apariencia de las formas. En la actualidad, estos problemas relacionados con las imágenes de ultrasonido resultan ser desafiantes y de interés en el campo de investigación a nivel mundial [3, 4].

Sistemas automáticos que logren realzar y segmentar las estructuras presentes en este tipo de imágenes son motivo de estudio latente, no obstante el enfoque de la segmentación automática se ha volcado en dirección a las imágenes intravasculares, tumores, reconstrucciones trans-craneales e imágenes fetales [5, 6]. En la literatura, se encuentran pocas publicaciones en relación a la segmentación automática de imágenes con el propósito de asistir la práctica de anestesiología [7, 8]. Por lo tanto, la carencia de resultados en el estado del arte relacionados con la segmentación de imágenes de ultrasonido procedentes de la práctica de anestesiología, motiva al desarrollo de una metodología de segmentación de las imágenes mencionadas y la exploración de resultados asociados a técnicas algorítmicas expuestas en el estado del arte para el tratamiento de imágenes y/o datos multidimensionales [9].

1. Planteamiento del problema

1.1. Bloqueo de Nervios Periféricos

El bloqueo de nervios periféricos (PNB) es un procedimiento que juega un papel importante en el tratamiento del dolor crónico y la práctica anestesiológica actual, gracias a que permite interrumpir la conducción nerviosa de las zonas corporales sometidas a intervenciones quirúrgicas o afectadas por dolor crónico de origen neuropático [1, 2]. El enfoque general del PNB consiste en la administración de un anestésico local en la proximidad de estas estructuras nerviosas, la difusión del anestésico a través del nervio impide su conducción eléctrica por bloqueo de canales de sodio y de esta manera la transmisión de información nociceptiva que viaja hasta el sistema nervioso central. Para suministrar la dosis correcta de droga en el punto exacto, la localización del nervio periférico es de vital importancia en las técnicas anestésicas regionales [1, 2, 7]. Existen cuatro métodos que se han utilizado para la realización de PNB: utilización de referencias anatómicas, provocación de parestesias, estimulación eléctrica y ultrasonido. La utilización de referencias anatómicas ayuda a encontrar puntos de inserción de la aguja para realizar el bloqueo, sin embargo este método no es muy utilizado debido a la presencia de múltiples variantes anatómicas. La provocación de parestesia durante la exploración con una aguja indica que ésta se encuentra ubicada en la proximidad del nervio. Este método no es muy utilizado debido a que es incómodo para el paciente y se asocia con lesión nerviosa. La estimulación eléctrica de los nervios periféricos se ha establecido como el estándar durante muchos años: usando un impulso eléctrico aplicado a una aguja de neuro-estimulación en la proximidad de un nervio periférico, se producirá una contracción muscular en el territorio inervado por el nervio estimulado [10, 11]. A diferencia de las técnicas anteriores, la ultrasonografía es una técnica no invasiva que permite una visualización directa de los nervios periféricos, de los tejidos en su proximidad, de la aguja para la realización del bloqueo y del anestésico inyectado para asegurar su óptima distribución. El haz de ultrasonido penetra el tejido del cuerpo y es reflejado, refractado y dispersado después de encontrarse con estructuras de diferentes impedancias acústicas. El transductor de ultrasonido funciona tanto como transmisor y receptor del haz y una imagen clara del objetivo se obtiene únicamente cuando una señal fuerte regresa al transductor, por lo cual la calidad de la imagen y la ecogeneidad estructural dependen altamente del ángulo de incidencia del mismo [1, 2].

1.2. Limitaciones del Ultrasonido

La tecnología de ultrasonido y sus recientes avances han permitido que la práctica de la anestesia regional con esta tecnología, no requiera que los anestesiólogos tengan un conocimiento profundo de los detalles técnicos del equipamiento de ultrasonido [2, 7]. Sin embargo para realizar satisfactoriamente un bloqueo nervioso se requiere una detección apropiada de las estructuras nerviosas en la imagen, eficiencia en el rastreo del avance de la aguja en tiempo real y una valoración de la propagación del anestésico local alrededor del nervio periférico [12].

El uso de imágenes de ultrasonido como asistencia en la práctica de la anestesia regional tiene ciertas limi-

taciones dadas por la presencia de diversos tipos de artefactos. Los artefactos asociados a la ultrasonografía generan imágenes de estructuras percibidas falsamente o estructuras anatómicas no nerviosas que asemejan nervios periféricos [2]. La generación de imágenes falsamente percibidas se debe a factores del equipo como ganancia y resolución, o a factores relacionados con la interpretación del operador como la sombra acústica, el reforzamiento ecogénico y los fenómenos de degradación de las imágenes. Las estructuras anatómicas que ecográficamente pueden ser confundidas con nervios periféricos son los tendones, los músculos, los nódulos linfáticos, los vasos sanguíneos y condiciones patológicas como la presencia de edema tisular dificultan la visualización de estructuras nerviosas [2, 7]. Otro aspecto que dificulta la captura de imágenes ultrasonográficas de nervios periféricos son sus propiedades anatómicas. Los nervios periféricos no son estructuras estáticas y su ubicación varía con referencia a la posición del cuerpo, la gravedad, el movimiento y las fuerzas de presión externas. Los nervios periféricos pueden tener diferentes formas y un mismo nervio varía en su morfología a lo largo de su recorrido y en relación a sus estructuras adyacentes. La ubicación de nervios periféricos en estructuras profundas y que además se encuentren rodeados de tejidos vasculares, linfáticos y óseos adyacentes añaden otro factor de dificultad [13].

Desde el punto de vista del procesamiento de imágenes, el trabajo con ultrasonido tiene ciertos aspectos desafiantes a partir de las características propias de esta tecnología de adquisición [14]. Las tecnologías de adquisición de imágenes médicas introducen ruido y artefactos en las imágenes que deben ser atenuados, sin eliminar o destruir los detalles anatómicos relevantes para el punto de vista clínico [3]. En la reducción de ruido en imágenes médicas, se debe realizar un equilibrio entre la reducción del ruido y la preservación de las actuales características que son relevantes para la intervención o el diagnóstico [13, 4]. Este aspecto de la remoción de ruido en imágenes médicas no puede ser llevado a cabo utilizando técnicas convencionales de eliminación de ruido en imágenes ya que se encuentran afectadas por ruidos no aditivos como en el caso del ultrasonido, donde las imágenes se ven afectadas por un ruido denominado ruido multiplicativo acústico (speckle), que en algunos casos contiene información relevante desde el punto de vista clínico.

1.3. Segmentación de Imágenes de Ultrasonido

La segmentación de imágenes es un paso inicial antes de realizar cualquier tarea de alto nivel como el reconocimiento de objetos. La segmentación de imágenes ultrasónicas se ve influenciada fuertemente por la calidad de los datos y existen artefactos característicos que hacen que la tarea de segmentación sea complicada debido a la atenuación, el speckle, las sombras acústicas y el decaimiento de la señal, al igual que la pérdida de bordes debido a la dependencia de la orientación en la etapa de adquisición y las complicaciones debido al pobre contraste en las regiones de interés [15, 16]. En las imágenes médicas la segmentación es importante para la extracción de características y medidas de la imagen, las aproximaciones más comúnmente usadas son de bordes y de regiones. El problema de la detección de bordes es la presencia de ruido que resulta en una variación aleatoria en el nivel de pixel a pixel, lo cual hace que los bordes ideales nunca sean encontrados en imágenes reales. Las aproximaciones basadas en regiones están enfocadas en la similitud de los datos de la imagen y sus vecindades, algunas de las técnicas más comunes del enfoque basado en regiones son el umbralizado, agrupamiento, crecimiento de regiones, separación y fusión, sin embargo el desempeño de las técnicas de segmentación aún es un problema latente. No obstante, técnicas del procesamiento de imágenes conocidas como modelos de forma y apariencia han tenido resultados relevantes en el ajuste, segmentación y tracking de imágenes de rostros, objetos articulados e inclusive imágenes de ultrasonido [17]. Sin embargo, no han sido probadas en imágenes relacionadas con la práctica de anestesiología.

Por otra parte, el tratamiento de datos multidimensionales asociado a métodos Bayesianos no paramétricos ha generado aportes significativos en la expresión y relación de datos genéticos, construcción de árboles

de relación evolutiva entre organismos vivos, estructuración de bases de datos con grandes cantidades de documentos y particularmente la segmentación de estructuras en imágenes [18, 19]. Teniendo un enfoque no supervisado de entrenamiento que motiva al clustering jerárquico, basándose en medidas de disimilaridades entre los datos (píxeles en el caso de imágenes) y no necesariamente en las formas y apariencias [20, 21]. Por lo cuál, resulta ser de gran interés la exploración de resultados mediante éstos modelos en imágenes de ultrasonido, procedentes de la práctica de anestesiología.

Con la intención de realizar un proceso investigativo que aporte al desarrollo de nuevas tecnologías que optimicen los procedimientos de anestesia regional en tratamientos de dolor crónico e intervenciones quirúrgicas, se propone el desarrollo de una metodología de segmentación de las imágenes mencionadas y la exploración comparativa de resultados asociados a técnicas algorítmicas expuestas en el estado del arte, con un enfoque del tratamiendo de las formas en imágenes, y por otra parte, un enfoque Bayesiano no paramétrico.

2. Justificación

2.1. La Segmentación Automática de Imágenes de Ultrasonido como asistencia a la Anestesiología

2.2. Pertinencia

El requerimiento clave para llevar a cabo un PNB exitoso es la administración del anestésico local alrededor de las estructuras nerviosas. Este objetivo es alcanzado de manera efectiva con la utilización de técnicas ultrasonográficas las cuales permiten una visualización y caracterización anatómica de estructuras nerviosas, vasculares y osteotendinosas [7]. El ultrasonido permite verificar la distribución perineural del anestésico local durante su administración, igualmente permite la reubicación de la aguja del bloqueo si la distribución del anestésico local no es óptima, disminuye la posibilidad de inyección intravascular e intraneural, favorece la utilización de dosis menores de anestésico local y evita las contracciones musculares ocasionadas por la neuroestimulación [2]. La anestesia regional eco guiada requiere del apoyo de la ciencia computacional para el desarrollo de técnicas automáticas que faciliten el proceso de aprendizaje y la adquisición de habilidades sicomotrices en anesthesiólogos que laboran en este campo del conocimiento. Hoy en día el uso del ultrasonido en la práctica clínica requiere un alto nivel de entrenamiento así como un equipamiento especializado [7]. Los anesthesiólogos deben adquirir un conocimiento profundo en sonoanatomía, al igual que una base sólida en la utilización de la tecnología del ultrasonido para visualizar estructuras nerviosas, aún así la realización exitosa de un bloqueo nervioso eco guiado no está asegurada, pues continua siendo un procedimiento operador dependiente. Se deben desarrollar metodologías médicas apoyadas por técnicas sistematizadas que auxilien al anesthesiólogo en la práctica de la anestesia regional eco guiada, aumentando la precisión en la realización de este tipo de procedimientos [22, 23].

2.3. Viabilidad

El uso de la imagenología en diversas aplicaciones médicas, permite la realización de procedimientos terapéuticos y de diagnóstico más efectivos. Así mismo, el procesamiento de las imágenes asociado a la ultrasonografía ha ido evolucionando a medida que avanzan las tecnologías de captura. Las etapas de pre-procesamiento, como la eliminación de ruido, han sido estudiadas para el desarrollo de trabajos como los presentados en [24] y [25], donde se parte de la transformación del ruido característico de las imágenes ultrasónicas (speckle) en ruido aditivo, en combinación con filtros wavelet. Varias técnicas también se han propuesto, tales como el filtrado de Wiener [26], en las últimas décadas, métodos de filtrado no lineal como el filtro de mediana ponderado (WMF) propuesto en [27] y el uso de wavelets en el proceso de eliminación de ruido para luego utilizar operadores no lineales Bayesianos [3].

Por otra parte, en las imágenes médicas la segmentación de estructuras anatómicas es una tarea desafiante en el área. Diversas técnicas han sido desarrolladas para la segmentación de imágenes de ultrasonido, tales

como métodos de campos aleatorios de Markov [28], métodos de clustering, difusos y no supervisados [27]. El problema principal de éstos métodos consiste en que la información de textura es modelada sin tener ninguna consideración acerca de la variabilidad de las formas de las estructuras anatómicas. Esto ha conllevado a un desarrollo de técnicas del procesamiento de imágenes asociadas no solo a la apariencia, sino también a las formas, obteniendo resultados significativos en el modelado de rostros humanos y en el tracking de objetos en movimiento, incluyendo el caso de estructuras anatómicas en imágenes de ultrasonido [17, 29, 30]. No obstante, algunas técnicas probabilísticas de tratamiento de datos multidimensionales conocidas como métodos Bayesianos no paramétricos suscitan también en la actualidad diversas investigaciones en el ámbito de la Bio-electrónica y Electro-medicina [31]. Obteniendo resultados que logran expresar los datos en estructuras jerárquicas que incrementan la inteligibilidad de la información.

Dado el gran número de trabajos desarrollados en cuanto al procesamiento de imágenes ultrasónicas y la constante evolución de esta técnica de adquisición de imágenes médicas, se puede pensar en el desarrollo de una metodología que permita segmentar las estructuras nerviosas relevantes en la práctica de bloqueos de ramas nerviosas en intervenciones quirúrgicas. Así mismo, establecer comparaciones de resultados entre técnicas supervisadas supeditadas al procesamiento de imágenes y métodos Bayesianos no paramétricos sujetos a modelos probabilísticos no supervisados.

2.4. Impacto

La asistencia por ultrasonido en la realización de bloqueos nerviosos ha demostrado en varios estudios una mejora considerable en el procedimiento anestesiológico, brindando una mayor certeza sobre la localización de la estructura nerviosa alrededor de la cual se quiere aplicar el anestésico [1]. No obstante, es constante la imprecisión en los procesos anestesiológicos, los cuales pueden conllevar a diversas problemáticas en los pacientes. La punción con la aguja puede generar lesión vascular; arterial, venosa o linfática, trayendo como posibles consecuencias hematomas, desgarros arteriales y problemas isquémicos. De la misma manera, la punción con la aguja epidural puede generar lesión neurológica en la médula, plexos o nervios, y traer como graves consecuencias paraplejia, parálisis, paresia y dolores neuropáticos. Otro tipo de complicaciones por punción en tejidos como la pleura, esófago, intestinos, riñón y vejiga, puede desembocar en neumotórax, mediastinitis, peritonitis y hematuria. Así mismo, existen complicaciones en el proceso de anestesiología de PNB asociadas a la inyección del anestésico, como bloqueo de las estructuras nerviosas adyacentes al nervio o al tronco que se pretende bloquear, ocasionando toxicidad local; parálisis del diafragma o de las cuerdas vocales, síndrome de Horner y retención urinaria [32, 33].

Con el desarrollo de este proyecto, se busca mejorar la inteligibilidad en las imágenes de ultrasonido, con el propósito de incrementar la precisión en la administración del anestésico en la realización de bloqueos nerviosos, mediante la identificación de las estructuras nerviosas que son objetivo en los diferentes bloqueos. Se busca entonces, realizar bloqueos nerviosos más efectivos, que tomen menor tiempo en su realización, sin utilizar métodos invasivos para la localización de las estructuras, lo cual genera un grado de confianza mayor en un paciente sobre la intervención que se le va a realizar y disminución en las complicaciones previamente mencionadas.

3. Objetivos

3.1. General

Desarrollar una metodología para la segmentación automática de estructuras nerviosas en 3 tipos de imágenes comunes en la práctica de anestesiología; Estructura Cubital (brazo), Peroneal (detrás de la rodilla) y del Mediano (antebrazo), basada en los resultados obtenidos a partir de dos enfoques del tratamiento de señales: Procesamiento de Imágenes y Modelos Bayesianos no paramétricos.

3.2. Específicos

- Desarrollar algoritmos para la segmentación de imágenes de ultrasonido, basados en modelos de forma y apariencia.
- Desarrollar algoritmos para la segmentación de imágenes de ultrasonido, basados en modelos Bayesianos No Paramétricos.
- Validar el desempeño de los algoritmos desarrollados en relación a una segmentación manual de las estructuras nerviosas, suministrada por un especialista en anestesiología.

4. Revisión del estado del arte

4.1. Bloqueo Regional Asistido

El ultrasonido de alta resolución puede proveer imágenes en tiempo real directa de nervios periféricos e identificar tejidos planos que permiten una distribución favorable de la anestesia local. Para hacer efectivamente un bloqueo nervioso guiado por ultrasonido, se debe estar familiarizado con la anatomía relevante y la coordinación de la sonda y el plano de imagen con la aguja del bloqueo. En [11], se realiza un estudio sobre los diferentes bloqueos y las características necesarias para realizar una captura eficiente de las estructuras mediante el ultrasonido en cada una de las diferentes locaciones para cada uno de los bloqueos, discusiones sobre la frecuencia que se debe usar y el ángulo de la sonda se especifican para obtener una imagen adecuada para realizar la aplicación de la anestesia local. Se discuten algunas limitaciones de la anestesia local guiada por ultrasonido como son la resolución y calidad de la imagen, la cual varía inversamente con la profundidad de la penetración, donde la frecuencia utilizada debe ser tenida en cuenta en regiones más gruesas de la anatomía humana como por ejemplo la localización del nervio ciático en la región de los glúteos. También la localización de la aguja con la aproximación In-Plane (IP) se dificulta cuando la sonda y la aguja están alineadas a 45° la una de la otra y la señal de retorno es débil. Del mismo modo ciertas estructuras anatómicas se ven opacadas por los huesos y su accesibilidad puede ser muy restringida. La localización de pequeños nervios en locaciones profundas es un aspecto desafiante y ciertos artefactos acústicos posteriores a los vasos pueden ser interpretados erróneamente como nervios. Se concluye en este estudio que medidas plausibles de la mejoría de las técnicas de anestesia guiada por ultrasonido, son el tiempo de realización del bloqueo, la intensidad y duración del bloqueo sensorial y motriz, complicaciones asociadas al bloqueo, costo y satisfacción del paciente.

Por otra parte, con respecto al seguimiento de la aguja en la realización de bloqueos, en [7] se realiza una discusión similar sobre las aproximaciones Out-Of-Plane (OOP) e IP para la asistencia por ultrasonido en la aplicación de anestesia local. Se tratan problemas tal como la pobre visibilidad de la punta de la aguja y de las diversas estructuras nerviosas especialmente en la aproximación OOP, al igual que el difícil alineamiento de la aguja con el plano de la imagen, el cual solo puede ser llevado a cabo con mucha experiencia. En el desarrollo de este trabajo se propone una metodología para dar solución a estos problemas mencionados mediante el uso de una cámara estéreo para el posicionamiento y seguimiento de la sonda ultrasónica con un rastreador (UST) al igual que el seguimiento de una aguja de bloque con un rastreador (BNT). Mediante este sistema se busca alinear los sistemas coordenados del plano de la imagen ultrasónica y de la aguja, al igual que establecer la distancia de la punta de la aguja con el haz ultrasónico. Toda esta información se presenta en la imagen ultrasónica para asistir al anestesiólogo antes y durante la inserción de la aguja. Los experimentos son realizados con 10 personas sin experiencia en el uso de ultrasonido en la aplicación de anestesia local, utilizando una simulación de un hígado con 3 tubos de metal que simulan un nervio y dos vasos sanguíneos, la aguja se inserta utilizando la aproximación OOP y cada persona tiene la tarea de hacer la inserción de la aguja con y sin el sistema de asistencia con ultrasonido, evaluando métricas como el número de inserciones de la aguja, el número de veces que se hacía contacto con un vaso, el tiempo

de ejecución, la distancia de la punta de la aguja con el objetivo y una evaluación del manejo por parte de las persona. Con este sistema de asistencia se notó claramente una mejoría en cada una de las métricas evaluadas, con lo que se concluye el verdadero impacto del uso del ultrasonido en la aplicación de anestesia local, al igual que un sistema de asistencia para realizar este procedimiento.

Las imágenes ultrasónicas son preferidas en el ámbito médico antes que otras técnicas de imagenología en las que el paciente se expone a altos niveles de radiación nuclear o de rayos X, con el plus de tener ciertas ventajas como el bajo costo, ausencia de daños en los tejidos y procesamiento en tiempo real. Sin embargo estas imágenes presentan baja calidad por la adición de ruido de alta frecuencia, distorsión de la información espacial perpendicular a la dirección de la propagación de la onda sónica, al igual que distorsiones en la región cercana al transductor [14, 34].

4.2. Técnicas del Procesamiento de Imágenes

En el ámbito del procesamiento de imágenes existen diversas aproximaciones para modelar el speckle y realizar segmentación en las imágenes ultrasónicas a partir de éste ruido. Una distribución de Rayleigh se utilizó en el método de detección anisotrópico de borde en [35] y métodos de segmentación estadístico en [8], y [5]. Más recientemente, la distribución de Rayleigh fue incorporada en el método de ajuste de nivel de Sarti et al. [36]. Una modificación de la distribución de Rayleigh se utilizó en el enfoque de contorno activo de [37] y en el algoritmo de segmentación de nivel ajustado en [38]. Otros modelos de distribución de niveles de gris también se han utilizado en la literatura de segmentación en ultrasonido, por ejemplo, distribuciones como la de Gauss [9], exponencial [39], gamma [40], y Beta [41].

Otro enfoque utilizado en la segmentación es el uso del gradiente de la intensidad. La motivación para el uso de gradiente de intensidad como una característica proviene de la literatura basada en un modelo fotométrico, los gradientes de alta intensidad o de intensidad equivalente a cambios de paso o discontinuidades en la intensidad, son con frecuencia asociados con bordes de los objetos. En la segmentación de ultrasonido, conviene utilizar el gradiente de intensidad como una restricción de segmentación si el objetivo es encontrar discontinuidades acústicas [6, 42]. Para reducir el efecto de speckle antes de la estimación del gradiente, aplicando suavizado morfológico [43], reducción de punto [42], optimización gruesa a fina [9] y otras técnicas de pre-filtrado [44] se han utilizado. La fase local proporciona una forma alternativa de caracterizar estructuras en una imagen y se ha utilizado en trabajos como [45]. La medición de la fase local, o de la congruencia de la fase en las escalas espaciales, proporciona una manera de caracterizar las diferentes características de intensidad en términos de la forma del perfil de intensidad en lugar de la magnitud de la intensidad derivada, por lo cual la fase ha sido sugerida como una característica robusta para la detección de bordes acústicos. El speckle también tiene una fase por lo cual ciertas escalas espaciales deben ser seleccionadas. Generalmente, la fase se estima utilizando bancos de filtros. Así, existe una relación entre los métodos basados en fase con los métodos basados en wavelets. Dentro de la discusión actual del modo de segmentación de ultrasonido, medidas de similitud se han utilizado para proporcionar una estimación del desplazamiento como una limitación en el análisis espacio-temporal en lugar de una característica de segmentación de forma independiente. La diferencia de suma de cuadrados (SSD) se utiliza por ejemplo, en [45]. Cohen y Dinstein desarrollaron una medida de similitud por ultrasonido específico basado en el supuesto de que ambos bloques de la imagen contienen speckle que puede ser modelado por una distribución de Rayleigh multiplicativo [46]. Este método se muestra a ser mejor que el SSD o de correlación cruzada normalizada en [47]. Una variante de la información mutua que utiliza información local, la geometría de la información mutua de la imagen (MIIG) se propuso en [48]. La similitud MIIG Se utilizó para la estimación de una intensidad media de un conjunto de entrenamiento y fue tomada en cuenta en la segmentación por medio de la misma medida de similitud.

Si bien, los patrones de textura de ultrasonido son intrínsecamente dependientes del sistema de imagen, estos caracterizan la microestructura de los tejidos que son capturados. La distribución de estructuras y sus tamaños relativos a la longitud de onda del pulso de ultrasonido incidente, produce patrones de texturas diferentes. En general los métodos estadísticos de análisis de texturas han sido utilizados con cierto éxito en este campo. Un potencial ventaja del análisis de texturas es que la mayoría de medidas de la textura se basan en modelos estadísticos de las intensidades y por lo tanto esto es independiente de la física del sistema de imagen. Así pues, en la segmentación donde el objetivo es a menudo caracterizar el objeto fotografiado en lugar de necesariamente caracterizar sus propiedades físicas reales, los métodos de análisis de textura han tenido éxito. La caracterización de textura se ha utilizado por ejemplo, en la clasificación y los estudios de discriminación de los tejidos del hígado [49], masas de mama [50], placas carotídeas [1, 10] y placas coronarias [51], los tejidos del miocardio, la glándula tiroidea, las masas ováricas, y tejidos de la próstata. En general, los buenos índices de clasificación han sido obtenidos cuando grandes regiones de interés son utilizadas, pero su rendimiento decae un poco cuando se trabaja con pequeños tamaños de muestra, es decir, cuando el área patológica es muy pequeña. Basados en algoritmos de segmentación de texturas, es posible utilizar ultrasonido en diversos ámbitos de aplicación clínica.

Los bordes y la información de regiones a menudo no son suficientes para una segmentación fiable y precisa. En este caso, las restricciones de las formas a menudo sirven para mejorar la eficacia de los resultados. Debido a la atenuación, sombras y manchas del artefacto, las restricciones de forma han demostrado dar buenos resultados recientemente en la segmentación de imágenes ultrasónicas [48, 52]. La información de la forma está incrustada en los métodos de segmentación de varias maneras. Probablemente la forma más clásica de restricción implica la regularización de los límites, como en la elección de los términos internos en un contorno activo. Una segunda manera de imponer una restricción de la forma es mediante el uso de una forma paramétrica y una forma preferida puede ser impuesta, por ejemplo, en un marco probabilístico, utilizando las distribuciones aprendidas del parámetro de forma sobre un conjunto de ejemplos de entrenamiento. Un ejemplo de una restricción de forma en la segmentación de la imagen ultrasónica se presenta en el trabajo de Gong et al. [53]. Una variante cercana es la de imponer una condición de forma, restringiendo el espacio de formas posibles a un modelo de forma predefinido con un conjunto de transformaciones (global y/o local). Esta representación no impone una parametrización de la forma y no requiere entrenamiento. En este caso, la restricción se impone sobre el conjunto de transformaciones y las transformaciones globales y locales son penalizadas de manera diferente. Una amplia y reconocida forma alternativa de emplear una restricción de forma es mediante el uso de un modelo de punto de distribución (PDM) [29]. Un PDM describe la forma normal y sus variaciones más características a partir de un conjunto de muestras de entrenamiento obtenidas usando análisis de componente principal (PCA). El uso de un PDM en segmentación se conoce como un modelo de forma activa (ASM) y al igual que en el modelo anterior, sin parametrización de la forma que se necesita, sin embargo, el conjunto de formas posibles se define por los principales modos de variación de la forma en el conjunto de entrenamiento. En general, el conocimiento de forma previa es modelada en un marco probabilístico, por ejemplo, una distribución gaussiana [29] o un modelo de mezcla [30]. A pesar que los ASM son adecuados para describir deformaciones de forma libre, una correspondencia punto a punto de la forma es necesaria para la estimación de la forma promedio y sus modos de variación. Una extensión para incluir la información a priori de intensidad, es denominada el modelo de apariencia activa (AAM) en [54]. Otra de las posibilidades es incluir la información de movimiento como en [46] y el modelo de movimiento de apariencia activa (AAMM) en [55]. Una ventaja del enfoque AAM es que se trata de aprender tanto la geometría de la forma como el modelo de los bordes de un objeto, una limitación es que asume las imágenes clínicas de diferentes sujetos con una apariencia similar.

4.3. Modelos Bayesianos No Paramétricos

En la actualidad, los modelos Bayesianos no paramétricos motivan al ámbito científico a una creciente ola de investigaciones en el Aprendizaje de Máquina, Clasificación de Documentos, Ecología y particularmente la segmentación de imágenes [18,31]. La inferencia Bayesiana no paramétrica se remonta a los años 70's y 80's tiempo en el cual una gran cantidad de artículos científicos fueron publicados en torno a éste problema. El catalizador de éstas publicaciones fue: la publicación [56] en "Annals of Statistics" por Thomas S. Ferguson en 1973 y posteriormente en 1974 Kjell Doksum publicó su artículo [57] en "Annals of Probability". El gran aporte asociado a estas publicaciones era la conveniencia y facilidad para el cálculo de las distribuciones posteriores, en base a los procesos de Dirichlet [58,59].

Estos modelos, como el de Asignación de Dirichlet Latente (LDA) han logrado tratar problemas de organización de grandes cantidades de información, aunque es sensible a cambios en las bases de datos. Con base en éste, se deriva una variación como Asignación de Dirichlet Latente Jerárquica (hLDA) el cual se logra ajustarse fácilmente ante el crecimiento de la información en las bases de datos [60]. Otras variaciones de los modelos sugieren la asociación de información de datos puros con información de imágenes, documentos, etiquetas y palabras claves, a éstos modelos se les conoce como Proceso del Restaurante Chino (CRP), El Buffet indio (IB), y variaciones dependientes de distancias (DD-CRP) [61,62]. Los resultados muestran un agrupamiento de la información con jerarquías que logran explicar y asociar más fácilmente los múltiples datos [63]. Por otra parte, su utilidad ha dado un aporte al cálculo inteligente de rutas de tránsito ante escenarios congestionados [64]. La necesidad de asociación de la información en el ámbito biológico-genético ha llevado al desarrollo de metodologías para la estructuración de los datos de expresión de genes de levadura de una forma jerárquica [18].

En el caso particular de datos multidimensionales como imágenes y video, la tesis Doctoral [19] de Erik B. Sudderth es la más representativa en torno a la detección visual efectiva, el tracking de objetos en escenarios complejos y la categorización de éstos. Ésta tesis propone modelos Bayesianos no paramétricos en base a los procesos de Dirichlet con el propósito de aprender automáticamente el número de objetos que componen cada escena en videos. Así mismo, en [65] se propone un método de segmentación de imágenes de radar de apertura sintética (SAR) en base a un modelo de mezcla infinito no paramétrico logrando resultados de alto desempeño en comparación a técnicas tradicionales de segmentación. En [66] se proponen dos algoritmos de super-resolución Bayesianos no paramétricos que logran incrementar el desempeño en el reconocimiento automático de objetivos en imágenes, a través del estándar de super-resolución.

Otros aportes en torno al procesamiento de imágenes mediante los modelos citados son: el trabajo en [67] donde se propone un "clustering" del histograma de la imagen logrando segmentaciones precisas en imágenes SAR y resonancias magnéticas. Teniendo también en cuenta las características medias del histograma en [68] se propone la segmentación en imágenes de entornos naturales, logrando un desempeño significativo dado el aprendizaje no supervisado y el no conocimiento a priori de colores y texturas del entorno. Otro aporte asociado a imágenes en entornos naturales se presenta en [69] donde no solo se logra segmentar objetos en un único video, sino en múltiples videos de la misma escena logrando co-segmentaciones del mismo objeto. En el caso particular de las imágenes de ultrasonido, el aporte en [70] es el más reciente. En este artículo se logra realizar un seguimiento de las deformaciones de arterias en imágenes de ultrasonido intravasculares. Se logra estimar conjuntamente el movimiento rígido del catéter, es decir, el desplazamiento y la rotación dentro de la arteria y las deformaciones a lo largo de sus contornos.

5. Materiales y Métodos

La dinámica del proyecto se fundamenta en el aporte interdisciplinario y la cooperación entre el Hospital Santa Mónica en Pereira y sus especialistas, junto con el grupo de investigación en Automática de la Universidad Tecnológica de Pereira en su componente investigativa.

La metodología para el desarrollo del proyecto se encuentra enmarcada dentro del cumplimiento de cada uno de los objetivos específicos teniendo en cuenta los siguientes aspectos.

5.1. Base de Datos

La base de datos utilizada en este trabajo proviene de la Universidad Tecnológica de Pereira (UltraDB-UTP) y el Hospital de Santa Mónica de Pereira-Colombia. Esta base de datos contiene grabaciones de imágenes de ultrasonido de diez pacientes, las cuales están relacionadas con el bloqueo de nervios periféricos. La base de datos fue etiquetada por un especialista en anestesiología del Hospital Santa Mónica utilizando un dispositivo de ultrasonografía Sonosite NanoMaxx.¹ La ubicación de las estructuras nerviosas en los pacientes corresponde al antebrazo (nervios cubital y mediano), y la parte trasera de la rodilla (nervio peroneal). La base de datos fue construida con 30 imágenes correspondientes al nervio cubital, 15 imágenes del nervio peroneal, y 30 imágenes del nervio mediano, respectivamente. Todas las imágenes de la base de datos se capturaron mediante conexión AV (Audio/video) entre el Sonosite NanoMaxx y un Core i3 con 2.1GHz y 4GB RAM, con un tamaño máximo de las imágenes de 640x480 píxeles. La Figura 5.1 muestra los tipos de imágenes pertenecientes a la base de datos.

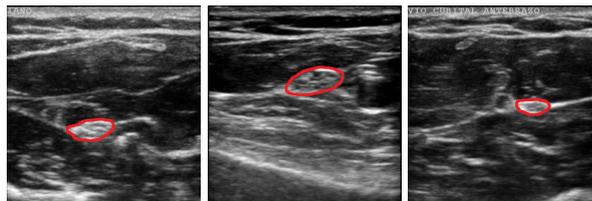


Figura 5.1: Un ejemplo de las imágenes de ultrasonido del nervio mediano (izquierda), nervio peroneal (medio) y nervio cubital (derecha) con una segmentación manual de la región de interés (ROI).

Posteriormente, se implementa un algoritmo de ajuste de una forma y apariencia inicial, hasta obtener una forma y apariencia convergente en relación a los modos de variación previamente analizados [29].

¹<http://www.sonosite.com/products/nanomaxx>

5.2. Filtrado Speckle basado en Non Local Means

En la segmentación de imágenes de ultrasonido, se espera una restauración con la intención de mejorar la inspección cualitativa de la imágenes y el desempeño de las técnicas de análisis cuantitativo de las mismas. En los modelos implementados se utilizó una adaptación del filtro Non Local (NL) means propuesto por Coupé *et. al.* en [71] para la reducción del ruido speckle en imágenes de ultrasonido. Se utilizó una estructura Bayesian para derivar un filtro NL-means adaptado a un modelo de reducción de ruido de ultrasonido [72]. Considérese una imagen ruidosa en escala de grises $u = (u(x_i))$, $x_i \in \Omega^{\text{dim}}$ definida alrededor de un dominio delimitado por $\Omega^{\text{dim}} \subset \mathbb{R}^{\text{dim}}$ y $u(x_i) \in \mathbb{R}_+$ es la intensidad ruidosa observada en un pixel $x_i \in \Omega^{\text{dim}}$.² Equivalente al estimador de media condicional propuesto en [72], el estimador $\hat{v}(B_{i_k})$ de un bloque B_{i_k} puede ser definido como

$$\hat{v}(B_{i_k}) = \frac{\sum_{j=1}^{|\Delta_{i_k}|} \mathbf{u}(B_j) p(\mathbf{u}(B_{i_k})|\mathbf{u}(B_j))}{\sum_{j=1}^{|\Delta_{i_k}|} p(\mathbf{u}(B_{i_k})|\mathbf{u}(B_j))},$$

donde $p(\mathbf{u}(B_{i_k})|\mathbf{u}(B_j))$ denota la función de densidad de probabilidad de $\mathbf{u}(B_{i_k})$ dado el ruido y los parches desconocidos $\mathbf{u}(B_j)$ con B_i como un bloque cuadrado centrado en x_i de tamaño $|B_i| = (2\alpha + 1)^{\text{dim}}$ y Δ_i como un volumen cuadrado de búsqueda centrado en el pixel x_i de tamaño $|\Delta_i| = (2M + 1)^{\text{dim}}$ (M es el tamaño del área de búsqueda y α es el tamaño del parche). En el caso de un ruido aditivo blanco Gaussiano, la verosimilitud $p(\mathbf{u}(B_{i_k})|\mathbf{u}(B_j))$ será proporcional a $e^{-\|\mathbf{u}(B_{i_k}) - \mathbf{u}(B_j)\|^2/h^2}$ y el modelo del ruido speckle está dado por

$$u(x) = v(x) + v^\gamma(x)\eta(x),$$

donde $v(x)$ es la imagen original, $u(x)$ es la imagen observada y $\eta(x) \sim \mathcal{N}(0, \sigma^2)$ es un ruido Gaussiano de media cero. Este modelo es capaz de capturar estadísticos confiables de la imagen dado que el factor γ depende de los dispositivos de ultrasonido relacionados con la formación de la imagen [73].

5.3. Modelos Estadísticos de forma

La forma³ de un objeto está representada por un conjunto de n puntos, en cualquier dimensión (comúnmente en 2-D o 3-D). Para construir modelos de forma en un espacio d -dimensional es necesario definir una transformación adecuada al número de dimensiones, en 2D y 3D usualmente se utiliza la Transformación de similitud, denotada por T_θ , donde θ son los parámetros de la transformación, debido a su fácil representación y a que son ampliamente estudiados se tienen en cuenta los parámetros de traslación, rotación y escalamiento.

El objetivo principal es obtener un modelo de forma activa (ASM) que permita analizar nuevas formas y sintetizar formas similares a las del conjunto de entrenamiento [74], en el cuál se puede analizar las variaciones y de esta manera construir un modelo que imite estas variaciones.

Una vez obtenidos los puntos de referencia del rostro, los cuales se deben poder localizar consistentemente de una imagen a otra, se puede representar la forma por un vector de nd elementos formado por la concatenación de los vectores individuales de la posición de los puntos.

²dim denota la dimensión de la cuadrícula de la imagen. En este trabajo se utilizó $\text{dim} = 2$ para imágenes 2D.

³La forma está definida como la cualidad de una configuración de puntos que es invariante a alguna transformación.

Por ejemplo, si se tiene una imagen 2-D se puede representar n puntos de referencia como (x_i, y_i) , el vector x estará compuesto por $2n$ elementos de la forma

$$\mathbf{x} = (x_1, \dots, x_n, y_1, \dots, y_n)^T.$$

De manera que dado s muestras de entrenamiento, se generan s número de vectores \mathbf{x}_j . Es importante que antes de comenzar el análisis estadístico de estos vectores, se tenga en cuenta que las formas representadas estén en el mismo sistema de coordenadas, para eliminar cualquier variación que pueda ser atribuida al tipo de transformación T utilizada. El análisis estadístico de la forma más utilizado para alinear el conjunto de entrenamiento, en un sistema de coordenadas común, es el análisis Procrustes [75].

5.3.1. Modelamiento de la variación en la forma

Se supone un conjunto s de puntos \mathbf{x}_i , alineados en un sistema de coordenadas común, los cuales forman una distribución en el espacio nd dimensional en el que se encuentran, de manera que una vez modelada esta distribución es posible generar nuevas muestras similares a las del conjunto de entrenamiento y examinar nuevas formas para determinar si son posibles ejemplos del modelo [76, 30]. En particular, se busca un modelo M parametrizado de la forma

$$\mathbf{x} = M(\mathbf{b}),$$

donde \mathbf{b} es el vector de parámetros del modelo, este modelo puede ser usado para generar nuevos vectores \mathbf{x} , los cuales son similares a los del conjunto de entrenamiento.

Inicialmente se reduce la dimensionalidad de los datos de nd a alguna más manejable, para esto se utiliza el análisis de componentes principales (PCA), que se describe a continuación

1. Se calcula la media de los datos

$$\bar{\mathbf{x}} = \frac{1}{s} \sum_{i=1}^s \mathbf{x}_i.$$

2. Se calcula la covarianza de los datos

$$\mathbf{S} = \frac{1}{s-1} \sum_{i=1}^s (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T.$$

3. Se calculan los vectores propios ϕ_i y los correspondientes valores propios λ_i de \mathbf{S} , clasificados de modo que $\lambda_i \geq \lambda_{i+1}$.

Como Φ contiene los t vectores propios correspondientes a los mayores valores propios, de manera que es posible aproximar cualquier vector del conjunto de entrenamiento, usando

$$\mathbf{x} \approx \bar{\mathbf{x}} + \Phi \mathbf{b}, \tag{5.1}$$

donde $\Phi = (\phi_1 | \phi_2 | \dots | \phi_t)$ y \mathbf{b} es un vector t dimensional, que define un conjunto de parámetros de un modelo deformable, dado por

$$\mathbf{b} = \Phi^T (\mathbf{x} - \bar{\mathbf{x}}).$$

Variando los elementos de \mathbf{b} por medio de la ecuación (5.1) es posible variar la forma \mathbf{x} . La variación del parámetro b_i , a través del conjunto de entrenamiento está dada por λ_i . Para asegurar que la forma generada sea similar a las del conjunto de entrenamiento original, se limita el parámetro b_i a $\pm 3\sqrt{\lambda_i}$.

5.3.2. Elección del número de modos

El número de vectores propios o modos t para conservar, puede ser escogido de la manera más simple de manera que el modelo represente alguna proporción del total de la varianza de los datos, exhibida en el conjunto de entrenamiento [74].

Si λ_i representa los autovalores de la matriz de covarianza de los datos de entrenamiento, cada autovalor es la covarianza de los datos alrededor de la media en la dirección del autovector correspondiente. La varianza total en los datos de entrenamiento es la suma de todos los autovalores, dada por

$$V_T = \sum \lambda_i.$$

Ahora se escoge el autovalor t mas grande, tal que:

$$\sum_{i=1}^t \lambda_i \geq f_v V_T,$$

donde f_v determina el valor de la proporción de la variación total que se desea.

Si el ruido en las medidas de las posiciones de los puntos tiene una varianza de σ_n^2 , entonces el autovalor más grande se puede escoger, tal que

$$\lambda_t > \sigma_n^2,$$

dado que los autovalores estén ordenados en orden descendiente.

En las imágenes que contienen rostros es posible obtener un amplio grado de variación, tanto en la forma, como en la textura, debido a las diferencias en los rostros de los individuos, en los cambios en las expresiones y en las variaciones en la iluminación. A continuación se presenta un ejemplo (Figura 5.2) de las formas de un conjunto de entrenamiento de 300 imágenes de rostros etiquetadas, en el cual cada imagen fué marcada con 133 puntos de referencia, tomado de [74].



Figura 5.2: Muestras de la forma del rostro de un conjunto de entrenamiento.

Aplicando el criterio descrito anteriormente para encontrar el número de modos, se obtiene un modelo de la forma con 36 modos, que corresponden al 98 % de la varianza en las posiciones marcadas del conjunto de

entrenamiento. Los modos del modelo de variación en la forma del rostro son mostrados en la figura 5.3. En este ejemplo se variaron los tres primeros parámetros de forma entre ± 3 desviaciones estándar del valor medio, dejando los otros parámetros en cero.

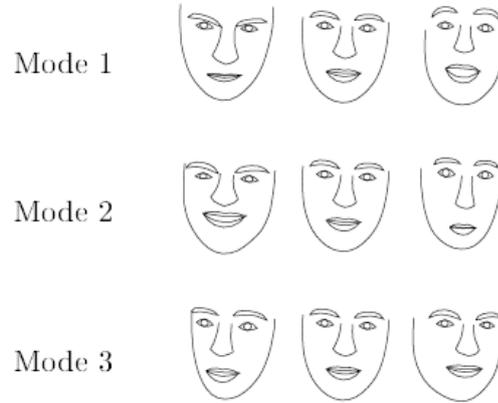


Figura 5.3: Modos de un modelo de la variación en la forma del rostro.

5.3.3. Generación de posibles formas

Para generar muestras similares al conjunto de entrenamiento a partir del modelo $\mathbf{x} = \bar{\mathbf{x}} + \Phi \mathbf{b}$, se deben escoger los parámetros \mathbf{b} de una distribución entrenada del conjunto de entrenamiento, entonces, a partir de este se debe estimar la distribución $p(\mathbf{b})$. De manera que se define un conjunto de parámetros posibles si $p(\mathbf{b}) \geq p_t$, donde p_t corresponde al umbral adecuado, el cual es elegido de manera que cierta proporción del conjunto de entrenamiento sobrepase el umbral [76]. Se asume que los b_i son independientes y con distribución gaussiana, entonces

$$\log p(\mathbf{b}) = -0,5 \sum_{i=1}^t \frac{b_i^2}{\lambda_i} + const.$$

Para limitar \mathbf{b} a posibles valores se aplican límites a cada elemento b_i o también se puede limitar \mathbf{b} para que este dentro de un hiperelipsoide

$$\left(\sum_{i=1}^t \frac{b_i^2}{\lambda_i} \right) \leq M_t, \quad (5.2)$$

donde el umbral, M_t es escogido usando la distribución χ^2 .

5.3.4. Encontrando la forma más cercana posible

El problema de encontrar la forma más cercana posible \mathbf{x} a una forma objetivo \mathbf{x}' surge cuando se desea ajustar el modelo a un nuevo conjunto de puntos [76]. El primer estimado es proyectarla en el espacio de parámetros, de manera que

$$\mathbf{b} = \Phi^\top (\mathbf{x}' - \bar{\mathbf{x}}).$$

Ahora se define un conjunto posible de parámetros si $p(\mathbf{b}) \geq p_t$. Si $p(\mathbf{b}) < p_t$ se desea mover \mathbf{x} al punto más cercano en el cual se considere posible. Si el modelo de $p(\mathbf{b})$ es únicamente gaussiano, es posible truncar los elementos b_i de manera que

$$|b_i| \leq 3\sqrt{\lambda_i},$$

alternativamente se puede escalar \mathbf{b} hasta un umbral M_t .

$$\left(\sum_{i=1}^t \frac{b_i^2}{\lambda_i}\right) \leq M_t.$$

Si se usa un modelo mixto para representar $p(\mathbf{b})$ y $p(\mathbf{b}') < p_t$, se debe encontrar el \mathbf{b} más cercano tal que $p(\mathbf{b}) \geq p_t$. Esto es algo difícil de lograr en la práctica, pero aplicando el gradiente ascendente se puede obtener una buena aproximación [76].

5.3.5. Ajuste del modelo a nuevos puntos

El modelo de una imagen puede ser descrito por los parámetros de forma \mathbf{b} , que al ser combinados con una transformación, se obtiene una transformación de similaridad, definida por la posición X_t, Y_t , orientación dada por θ y escala s , del modelo en la imagen. Las posiciones de los puntos del modelo en la imagen \mathbf{x} , están dados por

$$\mathbf{x} = T_{X_t, Y_t, s, \theta}(\bar{\mathbf{x}} + \Phi\mathbf{b}),$$

donde la función $T_{X_t, Y_t, s, \theta}$ realiza una rotación θ , un escalamiento s y traslación X_t, Y_t .

Ahora, si se desea determinar la mejor pose y los mejores parámetros de forma, de tal manera que el modelo \mathbf{x} coincida con un nuevo conjunto de puntos de una imagen \mathbf{Y} . El Minimizar la suma de cuadrados de las distancias entre el modelo y los puntos de la imagen es equivalente a minimizar la siguiente expresión

$$|\mathbf{Y} - T_{X_t, Y_t, s, \theta}(\bar{\mathbf{x}} + \Phi\mathbf{b})|^2.$$

Para lograr esto a continuación se describe una simple aproximación iterativa, tomada de [76]:

1. Inicializar los parámetros de forma \mathbf{b} a cero.
2. Generar una instancia del modelo $\mathbf{x} = \bar{\mathbf{x}} + \Phi\mathbf{b}$.
3. Encontrar los parámetros de la pose (X_t, Y_t, s, θ) con los que se puede construir un mejor mapeo de \mathbf{x} a \mathbf{Y} .
4. Invertir los parámetros de la pose y usarlos para proyectar \mathbf{Y} en el sistema coordenado del modelo.

$$\mathbf{y} = T_{X_t, Y_t, s, \theta}^{-1}(\mathbf{Y})$$

5. Proyectar y en el plano tangente a $\bar{\mathbf{x}}$ escalando por $\frac{1}{\mathbf{y} \cdot \bar{\mathbf{x}}}$
6. Actualizar los parámetros del modelo para que coincidan con \mathbf{y}

$$\mathbf{b} = \Phi^T(\mathbf{y} - \bar{\mathbf{x}})$$

7. Aplicar límites a b (ecuación (5.2)).
8. Si no converge, es decir si no produce ningún cambio significativo en la pose o en los parámetros de forma, regresar al paso número 2.

5.4. Modelo de forma activa

Debido a la pérdida de homogeneidad en las imágenes de ultrasonido producida por el ruido speckle, se propone un paso inicial de preprocesamiento antes de ejecutar un ASM. Con el fin de reducir la cantidad de ruido speckle, sin deteriorar la información de las estructuras nerviosas en las imágenes de ultrasonido, se utilizó el filtro NL-means implementado y propuesto por Coupé et.al. en [71].

Después de la remoción de ruido speckle, se implementó un modelo de forma activa para segmentar el contorno de una estructura nerviosa presente en la imagen de ultrasonido. El modelo fue entrenado con un conjunto de formas etiquetadas manualmente por un anestesiólogo (58 puntos para cada nervio) y las estructuras nerviosas periféricas etiquetadas corresponden a los nervios cubital, peroneal y mediano pertenecientes a UltraDB-UTP expuesta previamente. Para la implementación del ASM, se utilizó el Toolbox *Active Shape Model (ASM) and Active Appearance Model (AAM)*⁴ desarrollado en MATLAB sobre un Core i5 de 2,1GHz y con 6GB de RAM. La Figura 5.4 muestra el diagrama de flujo del método propuesto para la segmentación de nervios periféricos. Se entrenaron tres modelos, uno para cada tipo de estructura nerviosa a segmentar.

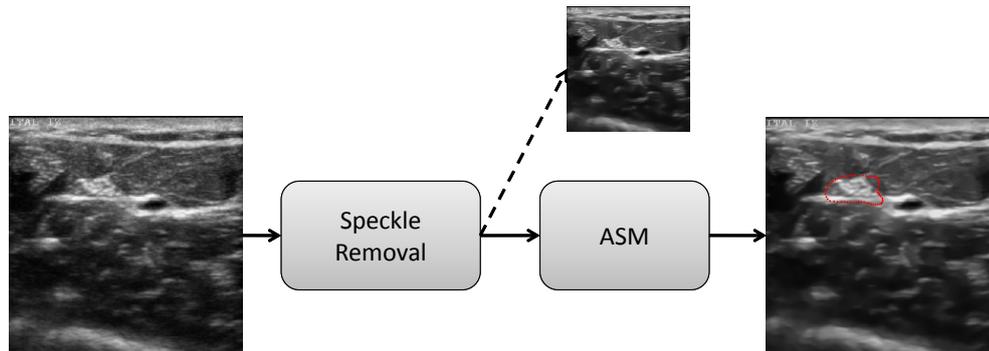


Figura 5.4: Diagrama de flujo para la segmentación del nervio periférico. Primero el ruido speckle es removido de las imágenes de la base de datos y en consecuencia el ASM deforma su contorno para ajustar la estructura nerviosa dada. En color rojo: puntos ajustados a la estructura nerviosa cubital.

5.5. Modelo Bayesiano No paramétrico

El análisis matemático del modelo no paramétrico, Modelo infinito de Mezclas Gaussianas (iGMM) se deriva del modelo clásico de Mezclas de Gaussianas (GMM) [18], en el cual el número de mezclas es una constante conocida. Se puede expresar matemáticamente el GMM como:

⁴Se utilizó la implementación ASM disponible en <http://www.mathworks.com/matlabcentral/fileexchange/26706-active-shape-model--asm--and-active-appearance-model--aam->

$$p(y, \mu_1, \dots, \mu_k, s_1, \dots, s_k, \pi_1, \dots, \pi_k) = \sum_{j=1}^k \pi_j \mathcal{N}(\mu_j, s_j^{-1}),$$

donde k es el número de mezclas, s_j son las precisiones, π_j las proporciones de mezcla y μ_j las medias. Por lo tanto, el análisis sugiere explorar el límite en el cual $k \rightarrow \infty$. Se asume un conjunto de entrenamiento $\mathbf{y} = \{y_1, \dots, y_n\}$ con n observaciones. Las medias μ_j son muestreadas de priors Gaussianos y las precisiones s_j son muestreadas de priors con distribución Gamma:

$$\begin{aligned} p(\mu_j | \lambda, r) &\sim \mathcal{N}(\lambda, r^{-1}), \\ p(\lambda) &\sim \mathcal{N}(\mu_y, \sigma_y^2), \\ p(r) &\sim \mathcal{G}(1, \sigma_y^{-2}) \propto r^{-1/2} \exp(-r\sigma_y^2/2), \\ \\ p(s_j | \beta, w) &\sim \mathcal{G}(\beta, w^{-1}), \\ p(\beta^{-1}) &\sim \mathcal{G}(1, 1) \Rightarrow p(\beta) \propto \beta^{-3/2} \exp(-1/(2\beta)), \\ p(w) &\sim \mathcal{G}(1, \sigma_y^2), \end{aligned}$$

donde λ y r son hiperparámetros, media y precisión muestreados de priors con distribución Normal y Gamma respectivamente, μ_y and σ_y^2 son la media y varianza de las observaciones [31]. El parámetro de forma en el prior Gamma se ajusta en uno dado que se considera como una distribución amplia. Así mismo, β y w corresponden a los hiperparámetros forma y media comunes a todas las componentes, y muestreados de una distribución Gamma inversa y Gamma respectivamente.

Las proporciones de mezcla, π_j (positivas y suman uno) son muestreadas de un prior Dirichlet con parámetro de concentración α/k :

$$\begin{aligned} p(\pi_1, \dots, \pi_k | \alpha) &\sim \text{Dirichlet}(\alpha/k, \dots, \alpha/k) = \frac{\Gamma(\alpha)}{\Gamma(\alpha/k)^k} \prod_{j=1}^k \pi_j^{\alpha/k-1}, \\ p(c_1, \dots, c_k | \pi_1, \dots, \pi_k) &= \prod_{j=1}^k \pi_j^{n_j}, \\ n_j &= \sum_{i=1}^n \delta(c_i, j), \end{aligned} \tag{5.3}$$

donde c_i son variables estocásticas indicadoras, una para cada observación. Estas variables c_i codifican cual de las clases generó una observación. También, n_j es el número de observaciones que pertenecen a la clase j . Se puede integrar respecto a las proporciones de mezcla y reescribir el prior de (5.1) en términos de los indicadores como:

$$p(c_1, \dots, c_k | \alpha) = \frac{\Gamma(\alpha)}{\Gamma(n + \alpha)} \prod_{j=1}^k \frac{\Gamma(n_j + \alpha/k)}{\Gamma(\alpha/k)}.$$

Finalmente, si se tiene en cuenta el proceso de inferencia, es necesario escribir el prior condicional para un simple indicador dados todos los demás [77].

$$p(c_i = j | \mathbf{c}_{-i}, \alpha) = \frac{n_{-i,j} + \alpha/k}{n - 1 + \alpha},$$

donde $-i$ indica todos los índices excepto i . Cuando $k \rightarrow \infty$, el prior condicional alcanza los siguientes límites [78],

$$\text{cuando } n_{-i,j} > 0 : \quad p(c_i = j | \mathbf{c}_{-i}, \alpha) = \frac{n_{-i,j}}{n-1+\alpha},$$

$$\text{otros : } p(c_i \neq c_{i'} \text{ for all } i' \neq i | \mathbf{c}_{-i}, \alpha) = \frac{\alpha}{n-1+\alpha},$$

donde $n_{-i,j}$ es el número de observaciones, excluyendo y_i , los cuales están asociados con la componente j , y “otros” se refiere a todas las demás componentes combinadas. Los priors finalmente obtenidos se refieren a un caso particular de un proceso de Dirichlet conocido como el Proceso del Restaurante Chino [31]. Otros detalles acerca de los distribuciones posteriores para los hiperparámetros se pueden revisar en [78]. Sin embargo, las distribuciones posteriores condicionales para las medias y las precisiones están dadas como

$$p(\mu_j | \mathbf{c}, \mathbf{y}, s_j, \lambda, r) \sim N\left(\frac{\bar{y}_j n_j s_j + \lambda r}{n_j s_j + r}, \frac{1}{n_j s_j + r}\right),$$

$$p(s_j | \mathbf{c}, \mathbf{y}, \mu_j, \beta, w) \sim \gamma\left(\beta + n_j, \left(\frac{1}{\beta + n_j} (w\beta + \sum_{i:c_i=j} (y_i - \mu_j)^2)\right)^{-1}\right).$$

5.6. Clustering Jerárquico

El Clustering Jerárquico (HC) es un método que permite anidar clusters dentro de otro, creando una estructura ordenada de jerarquías [18]. El HC puede ser desarrollado a través de dos enfoques: clustering aglomerativo o clustering divisivo. El primero, también conocido como “De abajo hacia arriba”, inicia expresando cada observación de una base de datos como clusters independientes y sucesivamente mezclando pares de datos, dependiendo de la información de la disimilaridad entre los objetos de la base de datos. El segundo, también conocido como “De arriba hacia abajo”, inicia expresando todas las observaciones de la base de datos como un único cluster principal y sucesivamente va dividiendo todo la base de datos en pares de dos en dos [79]. Se utilizó la metodología “De abajo hacia arriba”, definiendo una matriz de disimilaridades con medidas de las distancias promedio entre pares de datos como:

$$d_{avg}(G, H) = \frac{1}{N_G N_H} \sum_{i \in G} \sum_{i' \in H} d_{i,i'},$$

donde N_G es el número de elementos en el grupo G , N_H el número de elementos en el grupo H y $d_{i,i'}$ la distancia entre un dato i y un dato i' .

5.7. Modelo Bayesiano No Paramétrico de Clustering Jerárquico

Debido a la distorsión introducida por el ruido speckle y los artefactos inherentes al proceso de captura de las imágenes, se propuso un paso de pre-procesamiento antes de la ejecución del iGMM. Se implementó el filtro NL-means propuesto por Coupé et.al. en [72]. En consecuencia, el iGMM efectúa la segmentación de la imagen de ultrasonido teniendo en cuenta la información de intensidad de los píxeles. El proceso de inferencia del iGMM se realizó mediante un método de Cadenas de Markov Monte Carlo (MCMC) conocido como *Slice Sampling* [77, 31]. Todos los parámetros e hiperparámetros se actualizaron muestreando de las distribuciones condicionales expuestas en las secciones previas, haciendo uso de la función `mb_iGMM1D.m`⁵.

⁵Se utilizó la implementación del iGMM disponible en http://www.mathworks.com/matlabcentral/fileexchange/34839-1d-infinite-gaussian-mixture-model/content/mb_iGMM1D.m

Entonces, cada cluster (segmento) obtenido por el iGMM fue utilizado por el HC para generar una estructura ordenada de jerarquías. El modelo jerárquico es obtenido como resultado de medir la distancia promedio entre todos los pares de píxeles de la imagen de ultrasonido. Cada algoritmo fue ejecutado en MATLAB con un Core *i5* con *2.5GHz* y *6GB* de RAM. La Figura 5.5 muestra el diagrama de flujo propuesto para la segmentación de la imagen de ultrasonido.

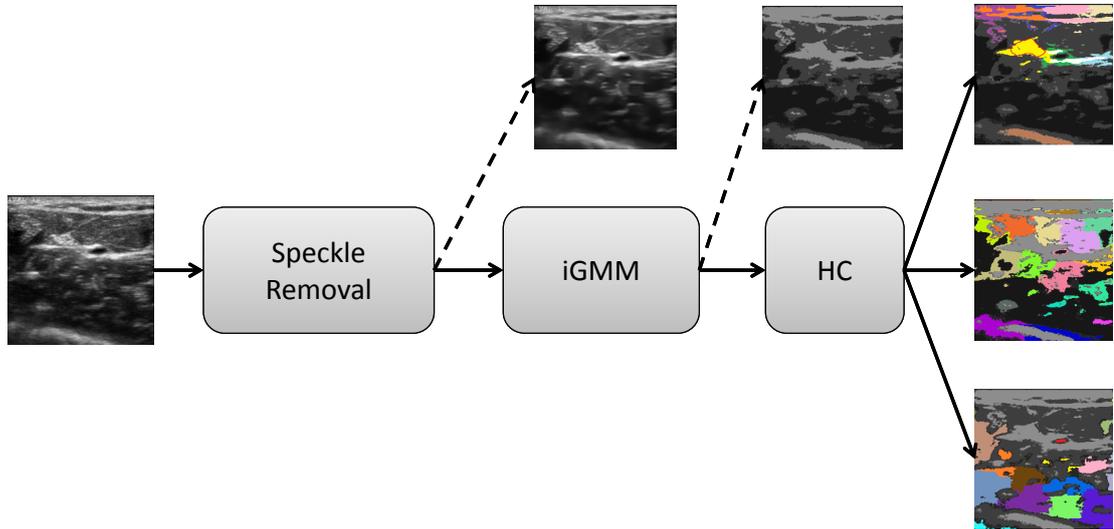


Figura 5.5: Diagrama de flujo del modelo Bayesiano no Paramétrico de Clustering Jerárquico (NPBHC). Primero el ruido speckle es removido de la imagen y en consecuencia el iGMM es usado para segmentar la información de las intensidades de la imagen. Finalmente, los clusters obtenidos por el iGMM son usados para generar una estructura ordenada de jerarquías mediante el HC teniendo en cuenta la información de la ubicación espacial y la intensidad de los píxeles.

5.8. Validación

Con la intención de tener una medida cuantitativa de la precisión en los modelos de segmentación, se computó el error cuadrático medio (MSE) de la distancia Euclidiana entre la forma (contorno) ajustado por los modelos y las etiquetas manuales suministradas por un especialista en anestesiología, la métrica usada se define como

$$\text{Error} = \frac{1}{N_I N_{pts}} \sum_{i=1}^{N_{pts}} \|\mathbf{p}_i - \hat{\mathbf{p}}_i\|,$$

donde \mathbf{p}_i son los puntos etiquetados manualmente y $\hat{\mathbf{p}}_i$ son los puntos estimados por los modelos propuestos. De la misma manera, N_I es el número de imágenes etiquetadas manualmente y N_{pts} es el número de puntos que fueron estimados [80].

6. Resultados y Discusión

6.1. Filtro Non Local Means

Los resultados experimentales consisten en la segmentación de las estructuras nerviosas periféricas pertenecientes a la base de datos UltraDB-UTP. Este proceso se realizó para cada uno de los tres nervios de la base de datos. No obstante, como paso inicial y con el fin de realzar el proceso de segmentación, se filtraron todas las imágenes de la base de datos mediante Non Local means para reducir el ruido speckle. Los parámetros de ajuste utilizados fueron de tamaño $M = 7$ para el área de búsqueda, $\alpha = 3$ para el tamaño del filtro de parche y $h = 0,7$ como parámetro de suavizado [71]. Los resultados mostrados en la Figura 6.1, indican que el filtro eficientemente remueve las componentes del ruido multiplicativo acústico, en la medida que realza los bordes y preseva las estructuras nerviosas.

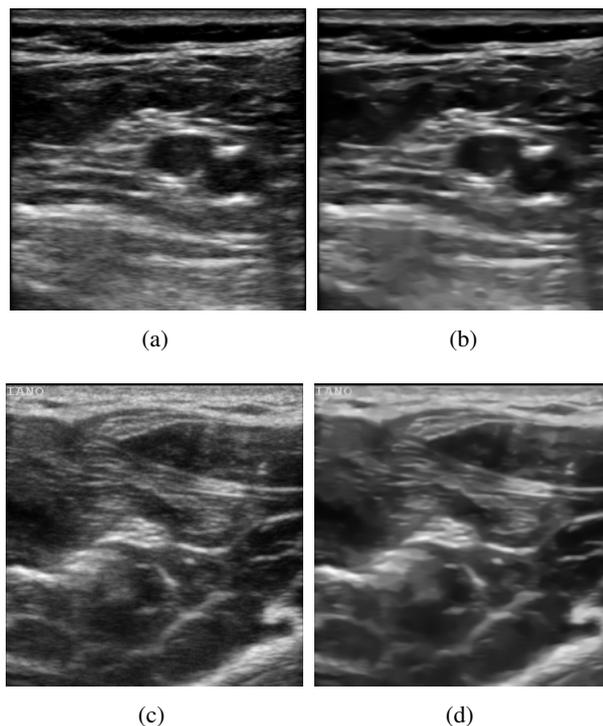


Figura 6.1: Resultados obtenidos con el filtro NL-means. Las Figuras (a) y (b) muestran el proceso de filtrado para el nervio peroneal (imagen no filtrada a la izquierda e imagen filtrada a la derecha respectivamente). Las Figuras (c) y (d) muestran el proceso de filtrado para el nervio mediano (imagen no filtrada a la izquierda e imagen filtrada a la derecha respectivamente).

6.2. Segmentación de Estructuras nerviosas: Comparación entre ASM y Non Parametric Bayesian HC

En esta sección se exponen los resultados de la segmentación de las estructuras nerviosas pertenecientes a la base de datos UltraDB-UTP, obtenidos mediante la técnica del procesamiento de imágenes conocida como ASM y el modelo Bayesiano no paramétrico de Clustering Jerárquico (NPBHC). Se muestran los resultados obtenidos mediante cada uno de los modelos y se compara el desempeño de las segmentaciones de las estructuras nerviosas.

Con la intención de validar cuantitativamente la precisión de la segmentación, se computó el error cuadrático medio (MSE) de la distancia Euclidiana entre las formas ajustadas por cada modelo y las etiquetas manuales (Plano Verdadero) suministradas por el anesthesiólogo.

6.2.1. Resultados Modelo ASM

El ASM logra un MSE de desempeño de $2,610 \pm 0,486$ píxeles en 30 imágenes del nervio cubital, $2,047 \pm 0,399$ píxeles en 30 imágenes del nervio mediano y $2,808 \pm 0,369$ píxeles en 15 imágenes del nervio peroneal. La Figura 6.2 muestra algunas imágenes de la base de datos referentes a los tres tipos de estructuras nerviosas, se muestra el proceso iterativo del algoritmo cuando inicia con un contorno (puntos en color rojo) elipsoidal alrededor de la estructura nerviosa, y cómo luego de 5, 50 y 150 iteraciones se deforma el contorno hasta ajustar la estructura nerviosa [81].

La ejecución del modelo toma alrededor de 150 iteraciones mientras se deforma el contorno inicial y se ajusta a la estructura nerviosa y alrededor de 8 segundos de tiempo en la CPU por imagen. La Figura 6.3 muestra una gráfica del desempeño del MSE para los tres tipos de nervios cubital, mediano y peroneal, con relación al número de iteraciones del algoritmo, se puede notar que el modelo ASM presenta una mayor precisión en el ajuste del contorno de la estructura nerviosa del mediano.

6.2.2. Resultados Modelo NPBHC

El NPBHC logra un MSE de desempeño de $1,026 \pm 0,379$ píxeles en 30 imágenes del nervio cubital, $0,704 \pm 0,233$ píxeles en 30 imágenes del nervio mediano y $1,698 \pm 0,564$ píxeles en 15 imágenes del nervio peroneal. La Figura 6.4 muestra tres nervios de la UltraDB-UTP y la segmentación obtenida por el iGMM y los nervios periféricos encontrados por el HC. La Figura 6.5 muestra un caso particular de una imagen del nervio cubital donde el modelo logra segmentar la ROI y otros tejidos blandos. La ejecución del modelo toma alrededor de 250 iteraciones en el proceso de inferencia. Este proceso de inferencia consiste en encontrar el número adecuado de Gaussianas (clusters o segmentos) que logren ajustar mediante un modelo de mezcla el histograma que identifica a cada imagen de ultrasonido [82].

La Figura 6.6 muestra el histograma de tres imágenes de ultrasonido, correspondiente a cada estructura nerviosa cubital, mediano y peroneal, además muestra el traslape del modelo de mezcla de Gaussianas obtenido sobre el histograma de la imagen y el gráfico de la inferencia del número de clusters (Gaussianas de la mezcla) reajustado en cada iteración del algoritmo iGMM. La ejecución de todo el modelo en general toma alrededor de 1,5 minutos del tiempo de la CPU por imagen. El número de clusters ajustados por el iGMM estuvo concentrado alrededor de 3 – 10 clusters (segmentos) para todas las imágenes de la base de datos UltraDB-UTP.

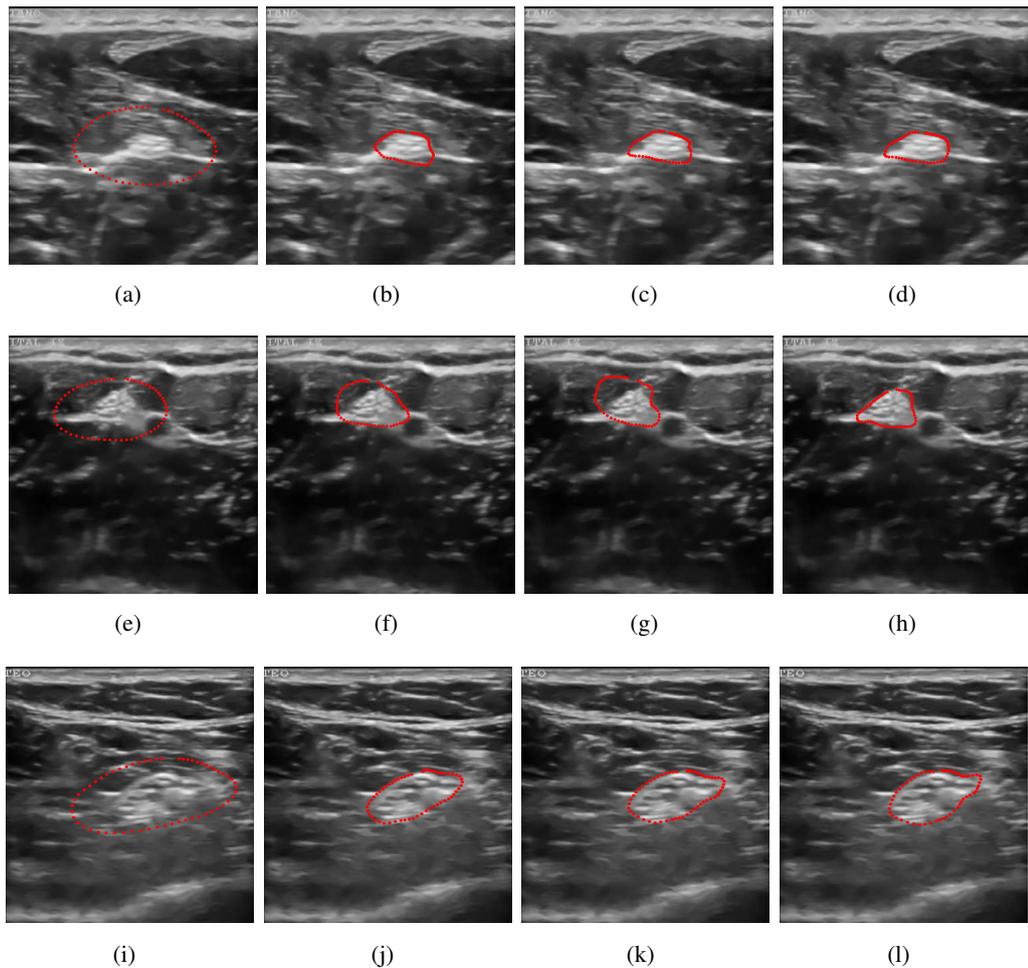


Figura 6.2: Resultados obtenidos con el ASM. De izquierda a derecha: ajuste del algoritmo con 1, 5, 50 y 150 iteraciones. Nervio Mediano (Primera fila), Nervio Cubital (Segunda fila), Nervio Peroneal (última fila). Puntos en color rojo: el contorno que se deforma a medida que transcurren las iteraciones para ajustar la estructura nerviosa.

6.2.3. Resultados Modelo ASM vs. Modelo NPBHC

El modelo ASM logra ajustar los contornos de las estructuras nerviosas con una precisión alrededor de 2,5 píxeles de error, su bajo tiempo de ejecución hace de éste una herramienta útil en los procesos de análisis de imágenes asociadas a la práctica de anestesiología, por su bajo costo computacional. Sin embargo, el ASM tiene una tendencia al ajuste erróneo de las estructuras nerviosas cuando el contorno inicial que será deformado en el proceso de ajuste está muy alejado de la estructura.

Por otra parte, el modelo NPBHC tiene la capacidad de aglomerar la información de la imagen de ultrasonido, mejorando la inteligibilidad de la misma y no solo dando claridad en las estructuras nerviosas, sino también realzando las estructuras acuosas, piel y músculos. El NPBHC segmenta las estructuras nerviosas con una precisión alrededor de 1,5 píxeles de error superior al ASM, aunque su tiempo de ejecución se incrementa considerablemente por el proceso de inferencia del iGMM.

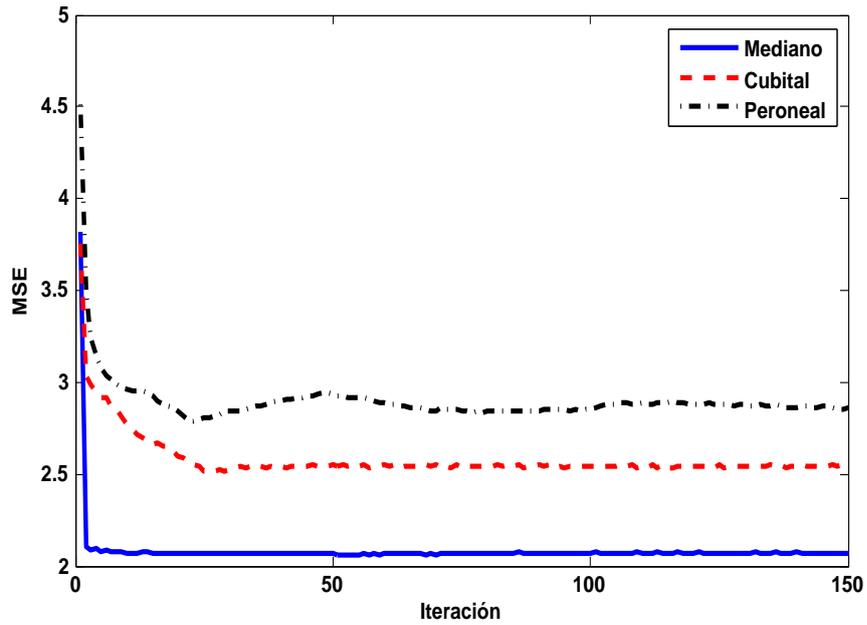


Figura 6.3: Error promedio del modelo ASM para los nervios cubital (rojo), mediano (azul) y peroneal (negro), con relación al número de iteraciones del algoritmo.

Ambos modelos implementados en MATLAB muestran resultados relevantes en la precisión de la segmentación, sin embargo su utilidad en procesos de anestesiología en tiempo real están supeditados a la exploración de un mejor tiempo de ejecución sobre otros lenguajes de programación. La Figura 6.7 muestra el desempeño obtenido en el proceso de validación de cada uno de los modelos utilizados, para la segmentación de los nervios cubital, mediano y peroneal.

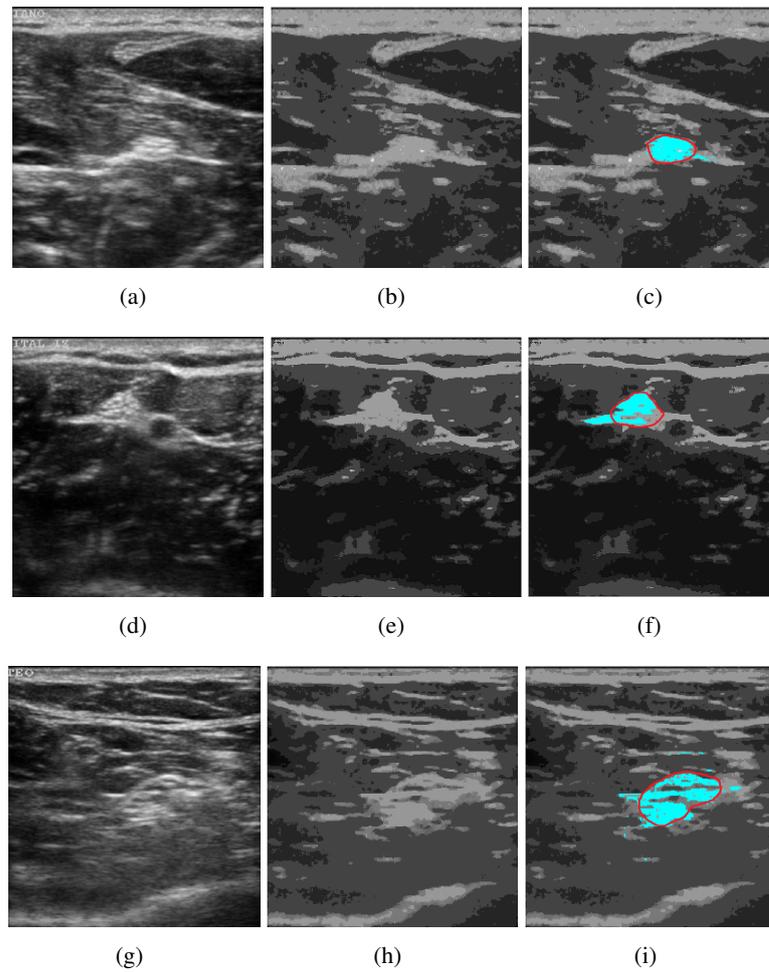


Figura 6.4: Resultados obtenidos por el NPBHC. Primera columna de arriba hacia abajo: imagen original de los nervios Mediano, Cubital y Peroneal. Segunda Columna: Segmentación por el iGMM. Tercera Columna: Segmentación por iGMM and HC. Color cyan: ROI encontrada por el modelo. Línea roja: ROI etiquetada manualmente por el anestesiólogo.

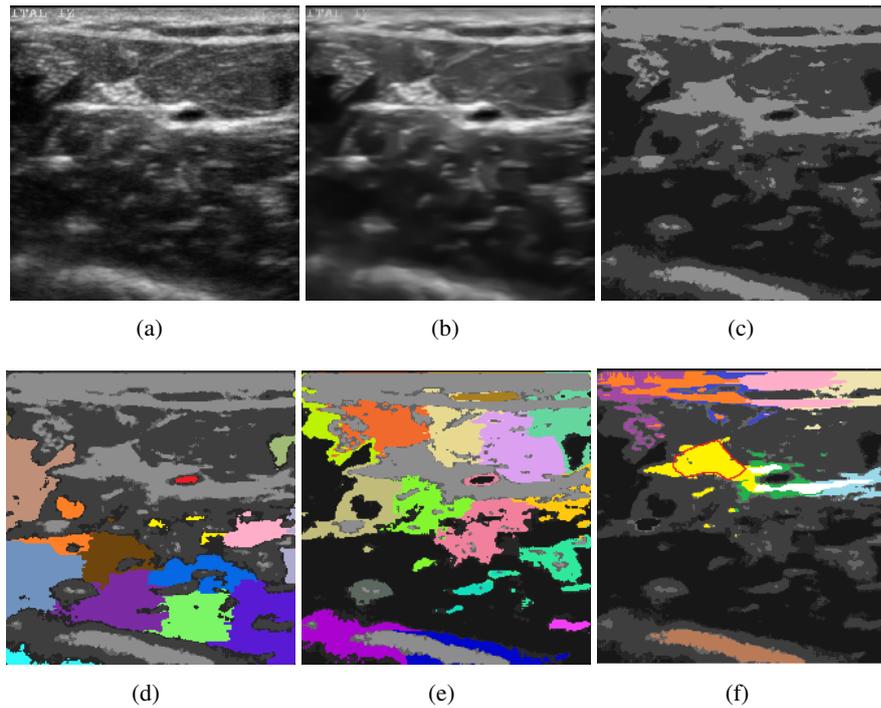


Figura 6.5: Resultados obtenidos por el modelo NPBHC. Primera fila: imagen cubital original (a), después del filtro NL-Means (b) y la segmentación obtenida por iGMM (c). Segunda fila: arteria (rojo) y estructuras musculares mezcladas con tejidos acuosos (los demás colores) (d), sombra acústica (púrpura y azul) y estructuras musculares mezcladas con tejidos acuosos (los demás colores) (e), piel y grasa (púrpura, naranja, rosado, azul y habano), estructura nerviosa (amarillo), contorno de arteria (verde, blanco y azul claro) y sombra acústica (café) (f). La línea roja es la ROI etiquetada manualmente.

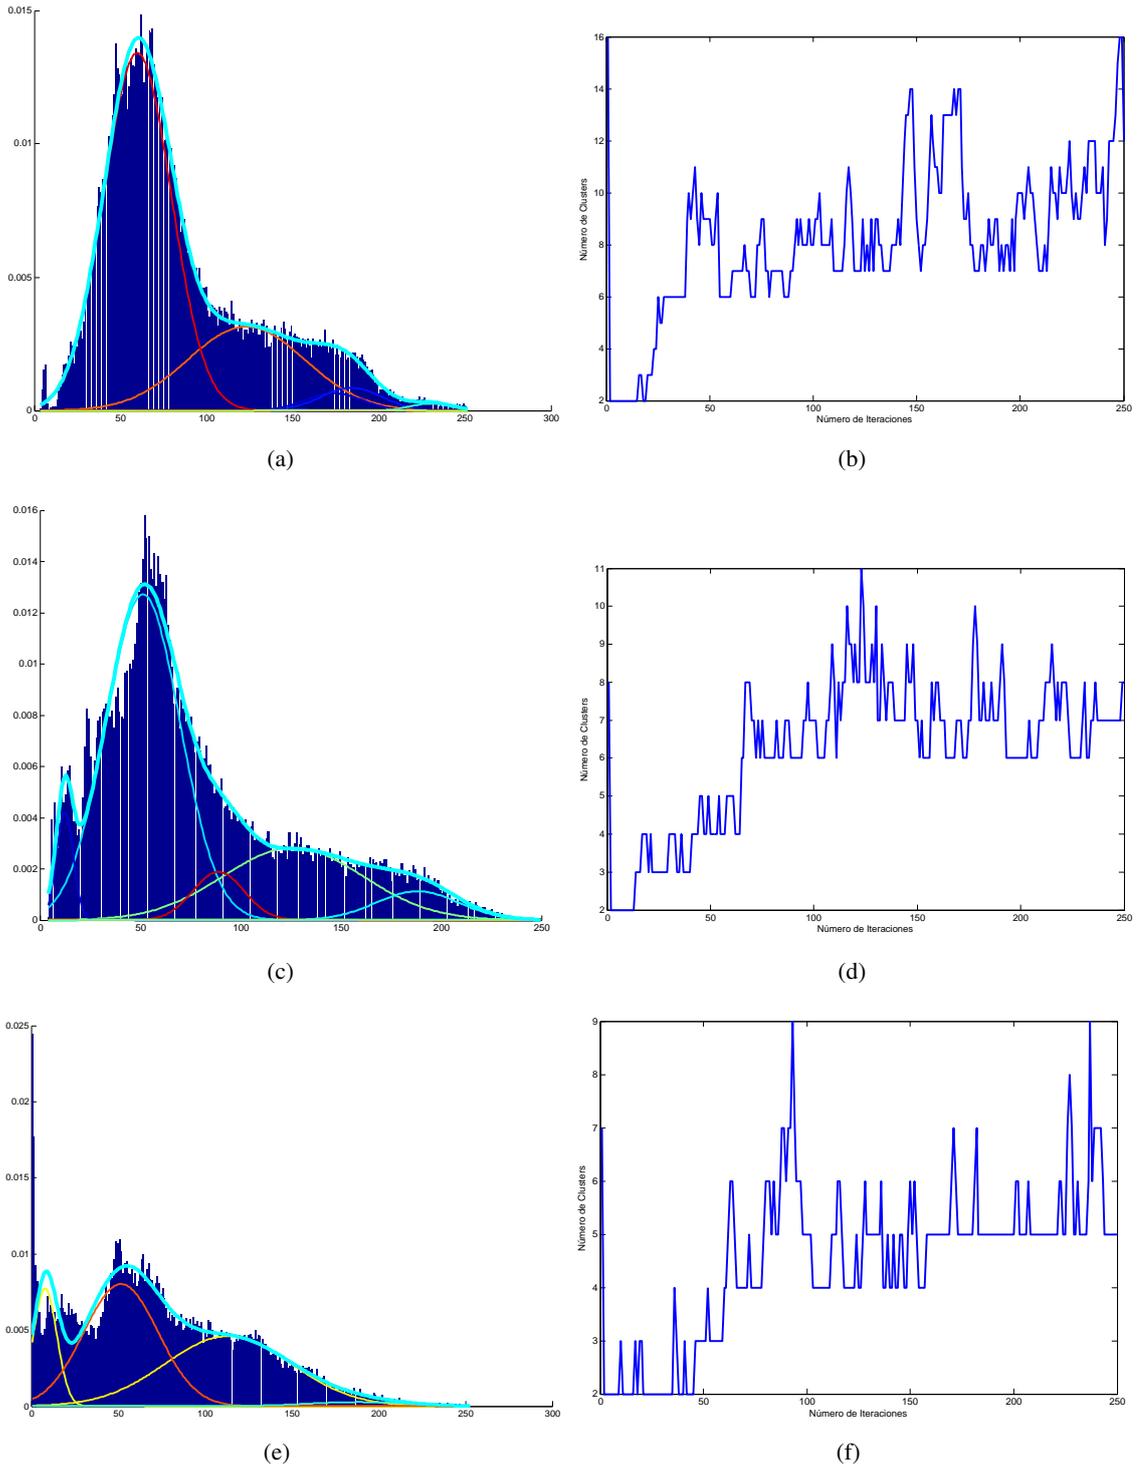


Figura 6.6: Resultados obtenidos por el modelo iGMM. La primera columna muestra de arriba hacia abajo el histograma de la imagen de un nervio mediano, cubital y peroneal, además se muestra en color cian el modelo de mezcla ajustado al histograma y en colores rojo, azul, amarillo y verde se muestran las Gaussianas de forma independiente que conforman la mezcla. Al frente de cada histograma se muestra el ajuste del número de clusters (Gaussianas) con relación al número de iteraciones del algoritmo, que modelan la distribución del histograma.

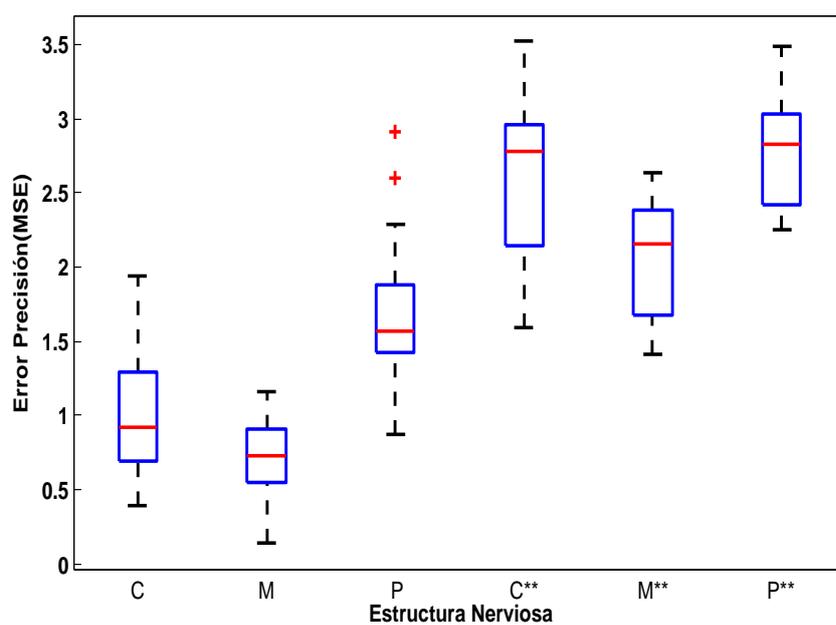


Figura 6.7: Error de precisión en la segmentación para los tres nervios Cubital (C), Mediano (M) y Peroneal (P). La figura muestra el esquema de segmentación usando los modelos NPBHC y ASM. El símbolo ** en el vértice x quiere decir que el esquema de segmentación usado corresponde al ASM y los demás al NPBHC. Las cruces rojas indican errores atípicos.

7. Conclusiones y Trabajos Futuros

7.1. Conclusiones

En este trabajo se desarrollaron dos metodologías para la segmentación de imágenes de ultrasonido asociadas a la práctica de anestesiología, utilizando un modelo del procesamiento de imágenes conocido como ASM y un modelo denominado NPBHC que es el complemento entre iGMM y HC. Se construyó una base de datos denominada UltraDB-UTP con un etiquetado del contorno de las estructuras nerviosas cubital, peroneal y mediano por un especialista en el área.

El modelo ASM se entrenó mediante el aprendizaje de los modos de variación de las formas de las estructuras nerviosas presentes en la base de datos, de tal manera que al ubicar un contorno elipsoidal sobre una región que contenga la estructura nerviosa, un algoritmo deforme el contorno hasta ajustar la estructura nerviosa presente.

El modelo NPBHC con un enfoque no supervisado, ajusta el número de segmentos (clusters) presentes en la imagen en escala de grises mediante iGMM y con base en estos segmentos se ejecuta un HC que aglomera la información de la imagen de forma tal que se segmentan estructuras acuosas, piel, grasa y particularmente la estructura nerviosa de interés.

Los resultados de la precisión en la segmentación de los modelos, indican que ambos modelos son promisorios dadas las necesidades de precisión en las prácticas de anestesiología, no obstante, el modelo NPBHC supera no por un gran margen al modelo ASM.

Es necesario optimizar los tiempos de ejecución de los modelos ASM y NPBHC, particularmente en éste último, el cual resulta ser costoso computacionalmente dado los procesos de inferencia que son inherentes al mismo. De tal manera, su implementación en un sistema en tiempo real sería una herramienta útil para la asistencia en la práctica de anestesiología.

El modelo ASM depende de un contorno de inicialización cercano a la estructura nerviosa, de esta manera el contorno se deforma hasta lograr converger con la forma del contorno de la estructura nerviosa, sin embargo, una inicialización alejada de la estructura nerviosa no garantiza un ajuste correcto de la misma.

El modelo NPBHC logra segmentar no solo las estructuras nerviosas presentes en las imágenes, sino también segmentar estructuras acuosas, piel, grasa y músculo, que son del interés de un anestesiólogo en su práctica, no obstante, es necesario que el anestesiólogo identifique los subsegmentos descubiertos por el modelo dado que carece de una etapa final de clasificación.

Ambos modelos ASM y NPBHC son herramientas que tienen el propósito de asistir y dar mayor inteligibi-

lidad de la información de las imágenes de ultrasonido, con el fin de incrementar la precisión en la práctica de anestesiología y llegar a reducir los factores de riesgo en pacientes con dificultades físicas asociadas al dolor crónico e intervenciones quirúrgicas. Así mismo, su utilidad se ve enmarcada en facilitar los procesos de enseñanza-aprendizaje de futuros anestesiólogos y la disminución en el tiempo de capacitación de los mismos.

7.2. Trabajos Futuros

Adquisición de un equipo de ultrasonido que permita capturar estructuras nerviosas con más profundidad en el cuerpo humano, y de tal manera construir una base de datos con una mayor cantidad de imágenes de distintos nervios, lo que conllevaría a una tarea desafiante para la segmentación de muchas otras estructuras nerviosas.

Implementación de los algoritmos en otras plataformas y lenguajes de programación para disminuir el tiempo de cómputo en el procesamiento, con miras a la implementación en tiempo real de un sistema de asistencia en la práctica de anestesiología.

Seguimiento o *tracking* de las estructuras nerviosas en videos de intervenciones quirúrgicas, en especial ante la acción de movimiento de la sonda sobre una región del cuerpo, por parte del anestesiólogo.

Un sistema de ubicación espacial de la estructura nerviosa, con relación a la ubicación espacial de la aguja hipodérmica, que pueda asistir y/o guiar al anestesiólogo hacia la proximidad de la estructura nerviosa para aplicación del anestésico.

8. Publicaciones

El desarrollo de éste trabajo condujo a la publicación de:

- *Peripheral Nerve Segmentation Using Speckle Removal and Bayesian Shape Models*. Hernán F. García, Juan J. Giraldo, Mauricio A. Álvarez, Álvaro Orozco, y Diego Salazar. Publicación de un artículo en Lecture Notes in Computer Science Series, volume 9117, pages 387–394. Springer International Publishing, 2015. IbPRIA 2015: 7th Iberian Conference on Pattern Recognition and Image Analysis.
- *Peripheral Nerve Segmentation using Nonparametric Bayesian Hierarchical Clustering*. Juan J. Giraldo, Mauricio A. Álvarez y Álvaro A. Orozco. Publicación de un artículo en la 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society IEEE EMBC 2015 en Milán, Italia.

Bibliografía

- [1] S.A. Grant and D.B. Auyoung. *Ultrasound Guided Regional Anesthesia*. OUP USA, 2012. 5, 6, 10, 14
- [2] Admir Hadzic. *Section 7. Atlas of Ultrasound-Guided Anatomy*. The McGraw-Hill Companies, New York, NY, 2012. 5, 6, 7, 9
- [3] A. Pizurica, W. Philips, I. Lemahieu, and M. Acheroy. A versatile wavelet domain noise filtration technique for medical imaging. *Medical Imaging, IEEE Transactions on*, 22(3):323–331, March 2003. 5, 7, 9
- [4] J.M. Sanches, J.C. Nascimento, and J.S. Marques. *Medical Image Noise Reduction Using the Sylvester-Lyapunov Equation*. *Image Processing, IEEE Transactions on*, 17(9):1522–1539, Sept 2008. 5, 7
- [5] S. Rueda, S. Fathima, C.L. Knight, M. Yaqub, A.T. Papageorghiou, B. Rahmatullah, A. Foi, M. Maggioni, A. Pepe, J. Tohka, R.V. Stebbing, J.E. McManigle, A. Ciurte, X. Bresson, M.B. Cuadra, Changming Sun, G.V. Ponomarev, M.S. Gelfand, M.D. Kazanov, Ching-Wei Wang, Hsiang-Chou Chen, Chun-Wei Peng, Chu-Mei Hung, and J.A. Noble. Evaluation and comparison of current fetal ultrasound image segmentation methods for biometric measurements: A grand challenge. *Medical Imaging, IEEE Transactions on*, 33(4):797–813, April 2014. 5, 13
- [6] M.I. Daoud, M.M. Baba, F. Awwad, M. Al-Najjar, and E.S. Tarawneh. Accurate segmentation of breast tumors in ultrasound images using a custom-made active contour model and signal-to-noise ratio variations. In *Signal Image Technology and Internet Based Systems (SITIS), 2012 Eighth International Conference on*, pages 137–141, Nov 2012. 5, 13
- [7] Jiayi Shi, Johannes Schwaiger, and Tim C. Lueth. Nerve block using a navigation system and ultrasound imaging for regional anesthesia. In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, pages 1153–1156, Aug 2011. 5, 6, 7, 9, 12
- [8] Qi Xing, Jim X. Chen, Wenzhen Yang, Lin Yang, Qiang Peng, and Keqiang Wang. A fully automated lumen contour detection of intravascular ultrasound images based on gabor texture analysis. In *Proceedings of the 9th ACM SIGGRAPH Conference on Virtual-Reality Continuum and Its Applications in Industry, VRCAI '10*, pages 39–46, New York, NY, USA, 2010. ACM. 5, 13
- [9] Djamal Boukerroui, Atilla Baskurt, J.Alison Noble, and Olivier Basset. Segmentation of ultrasound images—multiresolution 2d and 3d algorithm based on global and local statistics. *Pattern Recognition Letters*, 24(4-5):779 – 790, 2003. 5, 13
- [10] M.I. Gonzalez M.P. Benavides R. Duque, G. Vásquez. *Ultrasonido: la nueva ventana hacia la anestesia regional y los accesos vasculares*. Corporación Integral de Servicios Scare, 2011. 6, 14

- [11] O. John Ma and James R. Mateer. *Ma and Mateers Emergency Ultrasound*. McGraw-Hill Medical; Edición: 3, 2013. 6, 12
- [12] Schüpfer G. Wipfli M. Greif R. Luginbühl M. Luyet, C. and U. Eichenberger. Different learning curves for axillary brachial plexus block: Ultrasound guidance versus nerve stimulation. In *Anesthesiology Research and Practice*, 2010. 6
- [13] N. M. Denny and W. Harrop-Griffiths. Editorial i: Location, location, location! ultrasound imaging in regional anaesthesia. *British Journal of Anaesthesia*, 94(1):1–3, 2005. 7
- [14] N. Friedland and D. Adam. Automatic ventricular cavity boundary detection from sequential ultrasound images using simulated annealing. *Medical Imaging, IEEE Transactions on*, 8(4):344–353, Dec 1989. 7, 13
- [15] C.I. Christodoulou, C.S. Pattichis, M. Pantziaris, and A. Nicolaides. Texture-based classification of atherosclerotic carotid plaques. *Medical Imaging, IEEE Transactions on*, 22(7):902–912, July 2003. 7
- [16] Jun Xie, Yifeng Jiang, and Hung-Tat Tsui. Segmentation of kidney from ultrasound images based on texture and shape priors. *Medical Imaging, IEEE Transactions on*, 24(1):45–57, Jan 2005. 7
- [17] S. Ghose, A. Oliver, R. Marti, X. Llado, J. Freixenet, J.C. Vilanova, and F. Meriaudeau. A probabilistic framework for automatic prostate segmentation with a statistical model of shape and appearance. In *Image Processing (ICIP), 2011 18th IEEE International Conference on*, pages 713–716, Sept 2011. 7, 10
- [18] Kevin P Murphy. *Machine learning: a probabilistic perspective*. Cambridge, MA, 2012. 8, 15, 22, 24
- [19] Erik B. Sudderth. Graphical models for visual object recognition and tracking. Massachusetts Institute of Technology, 2006. 8, 15
- [20] Michael I. Jordan. Hierarchical models, nested models and completely random measures. Technical report, University of California, Berkeley, 2010. 8
- [21] Brian Kulis and Michael I. Jordan. *Revisiting k-means: New Algorithms via Bayesian Nonparametrics*. *ICML*, 2012. 8
- [22] Chan V.W. Neal J.M. Weller R. Grau T. Koscielniak-Nielsen Z.J. Ivani G. Sites, B.D. The american society of regional anesthesia and pain medicine and the european society of regional anaesthesia and pain therapy joint committee recommendations for education and training in ultrasound-guided regional anesthesia. *Regional Anesthesia and Pain Medicine*, 2009. 9
- [23] Joseph M. Neal, Dan J. Kopacz, Gregory A. Liguori, James D. Beckman, and Mary J. Hargett. The training and careers of regional anesthesia fellows-1983-2002. *Regional Anesthesia and Pain Medicine*, 30(3):226 – 232, 2005. 9
- [24] J. Guerrero, S.E. Salcudean, J.A. McEwen, B.A. Masri, and S. Nicolaou. Real-time vessel segmentation and tracking for ultrasound imaging applications. *Medical Imaging, IEEE Transactions on*, 26(8):1079–1090, Aug 2007. 9
- [25] P. Mohana Shankar. A general statistical model for ultrasonic backscattering from tissues. *Ultrasonics, Ferroelectrics, and Frequency Control, IEEE Transactions on*, 47(3):727–736, May 2000. 9

-
- [26] C.J. Solomon and T.P. Breckon. *Fundamentals of Digital Image Processing: A Practical Approach with Examples in Matlab*. Wiley-Blackwell, 2010. 9
- [27] J.A. Noble and D. Boukerroui. Ultrasound image segmentation: a survey. *Medical Imaging, IEEE Transactions on*, 25(8):987–1010, Aug 2006. 9, 10
- [28] Zhigang Peng, W. Wee, and Jing-Huei Lee. *Automatic Segmentation of MR Brain Images Using Spatial-Varying Gaussian Mixture and Markov Random Field Approach*. In *Computer Vision and Pattern Recognition Workshop, 2006. CVPRW '06. Conference on*, pages 80–80, June 2006. 10
- [29] T.F. Cootes, C.J. Taylor, D.H. Cooper, and J. Graham. Active shape models-their training and application. *Computer Vision and Image Understanding*, 61(1):38 – 59, 1995. 10, 14, 16
- [30] T.F. Cootes and C.J. Taylor. A mixture model for representing shape variation. *Image and Vision Computing*, 17(8):567 – 573, 1999. 10, 14, 18
- [31] E.G. Phadia. *Prior Processes and Their Applications: Nonparametric Bayesian Estimation*. Springer Berlin Heidelberg, 2013. 10, 15, 23, 24
- [32] J.C. Tornero Tornero, M. Gómez Gómez, G. Fabregat Cid, L. Aliaga Font, V. Roqués Escolar, B. Escamilla Ca nete, and A. Guerrí Cebollada. Complicaciones tras técnicas de anestesia regional. *Revista Española de Anestesiología y Reanimación*, 55(9):552 – 562, 2008. 10
- [33] Jaime Rodríguez, María Bárcena, Manuel Taboada-Muñiz, and Julián Álvarez. Horner syndrome after unintended subdural block. a report of 2 cases. *Journal of Clinical Anesthesia*, 17(6):473 – 477, 2005. 10
- [34] O.T. von Ramm, S.W. Smith, and Jr. Pavy, H.G. High-speed ultrasound volumetric imaging system. ii. parallel processing and image display. *Ultrasonics, Ferroelectrics, and Frequency Control, IEEE Transactions on*, 38(2):109–115, March 1991. 13
- [35] P. Perona and J. Malik. Scale-space and edge detection using anisotropic diffusion. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(7):629–639, Jul 1990. 13
- [36] A. Sarti, C. Corsi, E. Mazzini, and C. Lamberti. *Maximum likelihood segmentation with Rayleigh distribution of ultrasound images*. In *Computers in Cardiology, 2004*, pages 329–332, Sept 2004. 13
- [37] M. Mignotte and J. Meunier. A multiscale optimization approach for the dynamic contour-based boundary detection issue. *Computerized Medical Imaging and Graphics*, 25(3):265 – 275, 2001. 13
- [38] Marie-H. Roy Cardinal, Jean Meunier, and Soulez. Intravascular ultrasound image segmentation: A fast-marching method. In RandyE. Ellis and TerryM. Peters, editors, *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2003*, volume 2879 of *Lecture Notes in Computer Science*, pages 432–439. Springer Berlin Heidelberg, 2003. 13
- [39] Nikos Paragios, Marie-Pierre Jolly, Maxime Taron, and Rama Ramaraj. Active shape models and segmentation of the left ventricle in echocardiography. In Ron Kimmel, NirA. Sochen, and Joachim Weickert, editors, *Scale Space and PDE Methods in Computer Vision*, volume 3459 of *Lecture Notes in Computer Science*, pages 131–142. Springer Berlin Heidelberg, 2005. 13

-
- [40] Zhong Tao, C. Carl Jaffe, and Hemant D. Tagare. Tunnelling descent: A new algorithm for active contour segmentation of ultrasound images. In Chris Taylor and J. Alison Noble, editors, *Information Processing in Medical Imaging*, volume 2732 of *Lecture Notes in Computer Science*, pages 246–257. Springer Berlin Heidelberg, 2003. 13
- [41] Marcos Martín-Fernández and Carlos Alberola-López. *An approach for contour detection of human kidneys from ultrasound images using Markov random fields and active contours*. *Medical Image Analysis*, 9:1–23, 2005. 13
- [42] S.D. Pathak, D.R. Haynor, and Y. Kim. Edge-guided boundary delineation in prostate ultrasound images. *Medical Imaging, IEEE Transactions on*, 19(12):1211–1219, Dec 2000. 13
- [43] A. Mishra, P.K. Dutta, and M.K. Ghosh. *A GA based approach for boundary detection of left ventricle with echocardiographic image sequences*. *Image and Vision Computing*, 21(11):967 – 976, 2003. 13
- [44] Atsushi Takagi, Kiyoshi Hibi, Xiangmin Zhang, Tat Jin Teo, Heidi N. Bonneau, Paul G. Yock, and Peter J. Fitzgerald. Automated contour detection for high-frequency intravascular ultrasound imaging: a technique with blood noise reduction for edge enhancement. *Ultrasound in Medicine and Biology*, 26(6):1033 – 1041, 2000. 13
- [45] I. Mikic, S. Krucinski, and J.D. Thomas. Segmentation and tracking in echocardiographic sequences: active contours guided by optical flow estimates. *Medical Imaging, IEEE Transactions on*, 17(2):274–284, April 1998. 13
- [46] Boaz Cohen and ItsTMhak Dinstein. New maximum likelihood motion estimation schemes for noisy ultrasound images. *Pattern Recognition*, 35(2):455 – 463, 2002. 13, 14
- [47] Djamel Boukerroui, J. Alison Noble, and Michael Brady. Velocity estimation in ultrasound images: A block matching approach. In Chris Taylor and J. Alison Noble, editors, *Information Processing in Medical Imaging*, volume 2732 of *Lecture Notes in Computer Science*, pages 586–598. Springer Berlin Heidelberg, 2003. 13
- [48] Yunmei Chen, Feng Huang, H.D. Tagare, M. Rao, D. Wilson, and Edward A. Geiser. Using prior shape and intensity profile in medical image segmentation. In *Computer Vision, 2003. Proceedings. Ninth IEEE International Conference on*, pages 1117–1124 vol.2, Oct 2003. 13, 14
- [49] Y.M. Kadah, A.A. Farag, J.M. Zurada, A.M. Badawi, and A.-B.M. Youssef. Classification algorithms for quantitative tissue characterization of diffuse liver disease from ultrasound images. *Medical Imaging, IEEE Transactions on*, 15(4):466–478, Aug 1996. 14
- [50] Xu Liu, Zhimin Huo, and Jiwu Zhang. Automated segmentation of breast lesions in ultrasound images. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, pages 7433–7435, Jan 2005. 14
- [51] D.G Vince, K.J Dixon, R.M Cothren, and J.F Cornhill. Comparison of texture analysis methods for the characterization of coronary plaques in intravascular ultrasound images. *Computerized Medical Imaging and Graphics*, 24(4):221 – 229, 2000. 14
- [52] Yunmei Chen, Feng Huang, Hemant D. Tagare, and Murali Rao. A coupled minimization problem for medical image segmentation with priors. *International Journal of Computer Vision*, 71(3):259–272, 2007. 14
-

-
- [53] Lixin Gong, S.D. Pathak, D.R. Haynor, P.S. Cho, and Yongmin Kim. Parametric shape modeling using deformable superellipses for prostate segmentation. *Medical Imaging, IEEE Transactions on*, 23(3):340–349, March 2004. 14
- [54] Timothy F. Cootes, Gareth J. Edwards, and Christopher J. Taylor. Active appearance models. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 484–498. Springer, 1998. 14
- [55] S.C. Mitchell, J.G. Bosch, B.P.F. Lelieveldt, R.J. van der Geest, J.H.C. Reiber, and M. Sonka. 3-d active appearance models: segmentation of cardiac mr and ultrasound images. *Medical Imaging, IEEE Transactions on*, 21(9):1167–1178, Sept 2002. 14
- [56] Thomas S. Ferguson. *A Bayesian Analysis of Some Nonparametric Problems*. *Ann. Statist.*, 1(2):209–230, 03 1973. 15
- [57] Kjell Doksum. Tailfree and neutral random probabilities and their posterior distributions. *Ann. Probab.*, 2(2):183–201, 04 1974. 15
- [58] Bela A. Frigyik, Amol Kapila, and Maya R. Gupta. *Introduction to the Dirichlet distribution and related processes*. *Department of Electrical Engineering, University of Washington, UWEETR-2010-0006*, 2010. 15
- [59] Yee-Whye Teh. Dirichlet processes. In *Encyclopedia of Machine Learning*. Springer, 2010. 15
- [60] Pingan Liu, Lei Li, Wei Heng, and Boyuan Wang. *HLDA based text clustering*. In *Cloud Computing and Intelligent Systems (CCIS), 2012 IEEE 2nd International Conference on*, volume 03, pages 1465–1469, Oct 2012. 15
- [61] Finale Doshi-Velez and Zoubin Ghahramani. Accelerated sampling for the indian buffet process. pages 273–280. ACM, 2009. 15
- [62] Cheng Li, Dinh Phung, S. Rana, and S. Venkatesh. Exploiting side information in distance dependent chinese restaurant processes for data clustering. In *Multimedia and Expo (ICME), 2013 IEEE International Conference on*, pages 1–6, July 2013. 15
- [63] Yee-Whye Teh and Michael I. Jordan. *Hierarchical Bayesian nonparametric models with applications*. In N. Hjort, C. Holmes, P. Muller, and S. Walker, editors, *Bayesian Nonparametrics: Principles and Practice*. Cambridge University Press, 2010. 15
- [64] Jiangbo Yu, Kian Hsiang Low, Ali Oran, and Patrick Jaillet. *Hierarchical Bayesian Nonparametric Approach to Modeling and Learning the Wisdom of Crowds of Urban Traffic Route Planning Agents*. In *Proceedings of the The 2012 IEEE/WIC/ACM International Joint Conferences on Web Intelligence and Intelligent Agent Technology - Volume 02, WI-IAT '12*, pages 478–485, Washington, DC, USA, 2012. IEEE Computer Society. 15
- [65] Sun Li, Zhang Yanning, Ma Miao, and Tian Guangjian. *SAR Image Segmentation Method Using DP Mixture Models*. In *Computer Science and Computational Technology, 2008. ISCSCT '08. International Symposium on*, volume 2, pages 598–601, Dec 2008. 15
- [66] R.O. Lane. *Non-parametric Bayesian super-resolution*. *Radar, Sonar Navigation, IET*, 4(4):639–648, August 2010. 15

-
- [67] Peter Orbanz and JoachimM. Buhmann. *Smooth Image Segmentation by Nonparametric Bayesian Inference*. In Ales Leonardis, Horst Bischof, and Axel Pinz, editors, *Computer Vision - ECCV 2006*, volume 3951 of *Lecture Notes in Computer Science*, pages 444–457. Springer Berlin Heidelberg, 2006. 15
- [68] M.M. Rahman. An unsupervised natural image segmentation algorithm using mean histogram features. In *Computer and Information Technology (ICCIT), 2011 14th International Conference on*, pages 577–582, Dec 2011. 15
- [69] Wei-Chen Chiu and M. Fritz. Multi-class video co-segmentation with a generative multi-video model. In *Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on*, pages 321–328, June 2013. 15
- [70] N. Widynski, J. Poree, M.-H.R. Cardinal, J. Ohayon, G. Cloutier, and D. Garcia. *A sequential Bayesian based method for tracking and strain palpography estimation of arteries in intravascular ultrasound images*. In *Ultrasonics Symposium (IUS), 2014 IEEE International*, pages 515–518, Sept 2014. 15
- [71] P. Coupe, P. Hellier, C. Kervrann, and C. Barillot. Nonlocal means-based speckle filtering for ultrasound images. *Image Processing, IEEE Transactions on*, 18(10):2221–2229, Oct 2009. 17, 22, 26
- [72] Charles Kervrann, Jérôme Boulanger, and Pierrick Coupé. Bayesian non-local means filter, image redundancy and adaptive dictionaries for noise removal. In *Proceedings of the 1st International Conference on Scale Space and Variational Methods in Computer Vision, SSVM'07*, pages 520–532, Berlin, Heidelberg, 2007. Springer-Verlag. 17, 24
- [73] Zhong Tao, Hemant D. Tagare, and J. D. Beaty. Evaluation of four probability distribution models for speckle in clinical cardiac ultrasound images. *IEEE Trans. Med. Imaging*, 25(11):1483–1491, 2006. 17
- [74] Manchester M. Pt. Cootes T. F., Taylor C.J. Statistical models of appearance for computer vision, 2004. 17, 19
- [75] Goodall and Colin. Procrustes methods in the statistical analysis of shape. *Journal of the Royal Statistical Society, Series B Methodological*, 53:285–339, 1991. 18
- [76] T.F. Cootes and C.J. Taylor. Statistical models of appearance for computer vision, 2000. 18, 20, 21
- [77] David J. C. MacKay. *Information Theory, Inference & Learning Algorithms*. Cambridge University Press, New York, NY, USA, 2002. 23, 24
- [78] Carl Edward Rasmussen. *The Infinite Gaussian Mixture Model*. MIT Press, 2000. 24
- [79] A. N. Selvan. *Highlighting Dissimilarity in Medical Images Using Hierarchical Clustering Based Segmentation (HCS)*. PhD thesis, Sheffield Hallam University, Sheffield, UK, 2006. 24
- [80] Hernán García, Augusto Salazar, Damián Alvarez, and Álvaro Orozco. Driving fatigue detection using active shape models. In *Advances in Visual Computing*, volume 6455 of *Lecture Notes in Computer Science*, pages 171–180. Springer Berlin Heidelberg, 2010. 25
- [81] HernánF. García, JuanJ. Giraldo, MauricioA. Álvarez, ÁlvaroA. Orozco, and Diego Salazar. *Peripheral Nerve Segmentation Using Speckle Removal and Bayesian Shape Models*. In Roberto Paredes, Jaime S. Cardoso, and Xosé M. Pardo, editors, *Pattern Recognition and Image Analysis*, volume 9117 of *Lecture Notes in Computer Science*, pages 387–394. Springer International Publishing, 2015. 27

- [82] Juan J. Giraldo Mauricio A. Álvarez and Álvaro A. Orozco. *Peripheral Nerve Segmentation Using Nonparametric Bayesian Hierarchical Clustering*. *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society IEEE EMBC 2015, Milán, Italia*, 2015. 27