

MÉTODOS DE SEGMENTAÇÃO PARA MODELAÇÃO 3D DO OUVIDO A PARTIR DE IMAGENS

**Elisa M. Barroso¹, Carolina Garbe², Fernanda Gentil², Marco Parente²,
R. M. Natal Jorge² e João Manuel R. S. Tavares¹**

1: Faculdade de Engenharia da Universidade do Porto (FEUP) /
Instituto de Engenharia Mecânica e Gestão Industrial (INEGI)
Rua Dr. Roberto Frias 400, 4200-465 Porto, Portugal
e-mail: {meb09020, tavares}@fe.up.pt

2: Faculdade de Engenharia da Universidade do Porto (FEUP) / IDMEC-Polo FEUP
Rua Dr. Roberto Frias 400, 4200-465 Porto, Portugal
e-mail: garbe@fe.up.pt, fernanda.fgnanda@gmail.com, {mparente, rnatal}@fe.up.pt

Palavras-chave: Análise de Imagem, Tomografia Computorizada, Biomecânica, Revisão

Resumo. *O objectivo principal deste artigo centra-se na apresentação de métodos de segmentação de imagem adequados para a construção de modelos geométricos 3D das estruturas do ouvido a partir de imagens médicas de Tomografia Computorizada (TC), sendo discutidas as vantagens e desvantagens de cada um. Os métodos são classificados de acordo com as técnicas utilizadas; nomeadamente, em métodos de thresholding, de clustering e de modelos deformáveis. Neste artigo, são também apresentados e discutidos resultados experimentais de segmentação das estruturas do ouvido em imagens de TC.*

1. INTRODUÇÃO

No homem, o sistema auditivo pertence ao grupo dos sentidos especiais, que se definem como sistemas que possuem receptores altamente localizados que proporcionam informação específica sobre o ambiente que o rodeia. Este sistema compreende os órgãos responsáveis pela função auditiva e pelo equilíbrio. O ouvido humano é usualmente dividido em ouvido externo, ouvido médio e ouvido interno [1, 2].

A reconstrução e a visualização de modelos 3D do ouvido humano têm elevada aplicabilidade no ensino [3, 4], na construção de modelos biomecânicos [5, 6] e no planeamento pré-cirúrgico [7, 8]. Para a realização dos modelos tridimensionais podem ser utilizadas imagens médicas obtidas a partir de diferentes técnicas de imagiologia, como por exemplo, Tomografia Computorizada (CT-standard, Micro-CT, Spiral-CT) [9-11], Ressonância Magnética (MR-standard, Micro-MR) [12-14] e Processamentos Histológicos [13]. Já em estudos experimentais sobre as propriedades anatómicas do ouvido têm sido utilizados ouvidos de gatos, de porquinhos-da-índia, de cadáveres humanos e de chinchilas [6, 13].

Desde a década de 80, têm havido vários desenvolvimentos que combinam a tecnologia do processamento de imagem à imagiologia médica e aos processos histológicos para a realização da modelação tridimensional das estruturas do ouvido interno. A modelação do ouvido médio tem provado estar já consideravelmente estudada e desenvolvida quando comparada com a morfologia real do ouvido médio [13]. A tecnologia de processamento de imagem é fundamental para aproximar os modelos geométricos às morfologias anatómicas das estruturas em questão. Assim, a segmentação das estruturas do ouvido é essencial para a criação de modelos computacionais eficientes. Os métodos de segmentação de imagem podem-se dividir em três tipos principais considerando as técnicas base usadas: *thresholding*, *clustering* e modelos deformáveis. Os métodos de segmentação podem também ser conjugados de forma a obter-se resultados de segmentação mais exactos.

A utilização de modelos geométricos permite a simulação do comportamento do ouvido, de forma a compreender as relações existentes entre as estruturas e a sua função. Desta forma, torna-se mais fácil a compreensão e a optimização de implantes/instrumentos protésicos. Por outro lado, também são melhoradas as metodologias de planeamento dos procedimentos cirúrgicos a serem utilizados no ouvido [15]. A modelação biomecânica do ouvido também apresenta um papel fundamental no diagnóstico e tratamento de doenças do ouvido médio e interno. Estes dois processos são dificultados pelo pequeno tamanho das estruturas e das posições recônditas em que se encontra o osso temporal [16]. A partir da modelação do ouvido interno podem ser identificados os pacientes que apresentem anomalias anatómicas do labirinto ósseo, contudo, apenas 15% dos pacientes com perda de audição apresentam configurações anormais. Desta forma, existe a facilidade em criar modelos com configurações anormais que efectivamente representem pacientes que apresentem perda de audição [17]. Sendo assim, o implantação coclear apresenta-se como uma aplicação directa da modelação geométrica, sobretudo nos dias de hoje que se tem tornado numa intervenção clínica padrão utilizada em todo o mundo para surdez severa e/ou profunda. A posição do *array* de eléctrodos implantados tem sido apresentada como uma das variáveis importantes no reconhecimento da fala e através da modelação geométrica é possível criar automação no

processo de inserção do eléctrodo. Este processo tem demonstrado um papel importante no que diz respeito à presença de traumas na cirurgia coclear. Assim, com a utilização de métodos automáticos, podem ser reduzidos os traumas cirúrgicos e minimizada a utilização de técnicas invasivas [7, 8]. Para além disso, as técnicas de pós-processamento, como a técnica de endoscopia virtual, têm sido muito desenvolvidas como uma forma de simulação da cirurgia do ouvido médio [13].

O objectivo principal deste artigo centra-se na apresentação e verificação das vantagens e desvantagens de métodos de segmentação de imagem adequados para a construção de modelos geométricos 3D das estruturas do ouvido, a partir de imagens médicas de Tomografia Computorizada e discussão dos seus resultados.

O artigo está organizado em 4 secções, sendo que, na secção 2 é efectuada uma revisão dos algoritmos de segmentação utilizados em imagens médicas e demonstrada a aplicação dos mesmos em imagens do ouvido com recurso a resultados experimentais. Na secção 3 são descritas as vantagens e desvantagens dos métodos experimentados. Por fim, na secção 4, são apresentadas as conclusões do estudo apresentado.

2. ALGORITMOS DE SEGMENTAÇÃO

Nesta secção apresentam-se os métodos de segmentação de imagem tendo em consideração as técnicas base. Os métodos foram divididos em 3 classes: métodos de segmentação que têm como base a técnica de *thresholding*, métodos baseados na técnica de *clustering* e métodos de segmentação que têm como base a técnica dos modelos deformáveis.

2.1. Métodos de segmentação baseados na técnica de *thresholding*

O *thresholding* é um dos métodos de segmentação mais utilizados em imagens digitais. Este método separa as estruturas de interesse tendo como base a intensidade dos pixels das imagens a segmentar e tenta determinar um valor de intensidade de classificação. A esse valor dá-se o nome de *threshold*. Este é o valor responsável pela separação das classes pretendidas. Muitas vezes podem ser utilizados mais do que um valor de *threshold*. O processo realizado para a determinação de vários valores de *threshold* tem o nome de *multi-thresholding*. O *thresholding* é um método simples e efectivo para obter a segmentação de diferentes estruturas que tenham intensidades distintas ou apresentem outras características facilmente quantificáveis. Contudo, este método é sobretudo utilizado em etapas de pré-processamento, podendo também ser usado na sequência das operações de processamento de imagem. As principais limitações deste método são que, na sua forma mais simples, apenas duas classes são geradas. Para além disso, o *thresholding* não tem em consideração as características espaciais. Os métodos que se baseiam nesta técnica são de difícil controlo no que diz respeito à eliminação de ruído e artefactos [18].

Existem várias técnicas de *thresholding*. Algumas delas são baseadas na análise do histograma da imagem, enquanto outras são baseadas em propriedades locais ou no gradiente local. Assim, pode-se dividir o *thresholding* tendo em consideração as

propriedades do histograma, *global thresholding*, e tendo como base propriedades locais, *local thresholding*. O método de *Otsu* é um dos métodos de segmentação mais conhecidos que usa a técnica de *global thresholding*, Figura 1, [19, 20].



Figura 1. Imagem do osso temporal realçada a partir da utilização de um filtro de difusão anisotrópica (200 iterações) (a); Resultado da aplicação do método de otsu (*global thresholding*) (b); Resultado do método de *thresholding* para o valor de *threshold* de 0.8 (c).

Os métodos baseados na técnica de *thresholding* podem ainda dividir-se em métodos que têm como base as orlas (*edges*), que caracterizam uma mudança abrupta da intensidade indicando fronteiras ou limites entre regiões na imagem, as regiões ou ainda em métodos híbridos.

Os métodos que têm como base as orlas tentam encontrar os pixéis que as representam e eliminam a influência do ruído. Estes métodos tanto podem ser usados para efectuar a segmentação como, também, para realizar o pré-processamento da imagem original. *Edges* são alterações bruscas na intensidade dos pixéis e tipicamente estão localizados na fronteira de diferentes regiões da imagem [18, 21]. Os principais objectivos na detecção de *edges* são dois: obter os contornos das regiões que estão presentes na imagem e, através destes contornos extrair informação da imagem (cantos, linhas, curvas). A transformada de *wavelet*, os operadores de *canny*, *sobel* e *laplacian* são usados tendo como base valores de *threshold* e utilizam a informação dos *edges* da imagem [22-26]. A representação usando *wavelets* corresponde à decomposição da imagem original em frequências independentes, ou seja, esta representação explora as orientações espaciais: horizontal, vertical e diagonal. A transformada de *wavelet* é caracterizada por 3 etapas: A primeira compreende o estado de decomposição, ou seja, a imagem é decomposta em 4 imagens com diferentes informações (informação referente à aproximação da imagem original à escala 1 e aos detalhes horizontais, verticais, diagonais). A segunda etapa é caracterizada pela recomposição dos detalhes horizontais e dos detalhes verticais. Por fim, na terceira e última etapa, a imagem que foi recomposta é novamente decomposta e assim, são obtidos os coeficientes da transformada de *wavelet*. No final da terceira etapa, as imagens que resultam da decomposição são fundidas. Desta forma, as três etapas da transformada

wavelet podem ser denominadas por detecção dos *edges*, ligação do *framework* utilizando *wavelets* e fusão de imagem. No domínio da transformada de *wavelet*, a detecção e a ligação dos *edges* encontrados é considerada uma operação muito natural e directa [25]. Outro detector de *edges* que tem como base o *thresholding* é o detector de *edges* de *Canny*, Figura 2. Este operador é implementado de acordo com as seguintes etapas: suavização da imagem original pela utilização de um filtro Gaussiano apropriado para a redução do ruído e dos detalhes não desejados, determinação da magnitude e da direcção do gradiente de cada pixel. De seguida, recorre-se à verificação da magnitude dos pixéis. Se a magnitude do gradiente de um pixel for maior do que a magnitude dos seus vizinhos na mesma direcção do gradiente, o pixel é assinalado como o *edge* de maior magnitude.




Figura 2. Resultado obtido pela aplicação do operador de Canny na imagem da Figura 1a.

Os pixéis vizinhos de menor intensidade e que possuem a mesma direcção do gradiente são removidos. Por fim, remove-se os *edges* resultantes que apresentam um valor de magnitude inferior ao valor de limiar de histerese (*hysteresis threshold*). O operador de *Canny* apresenta bons resultados na detecção e localização dos *edges* para uma resposta simples [23]. O operador *Sobel* também é baseado na detecção de *edges* e realiza a detecção a partir da convolução da imagem com 4 máscaras 3x3 com diferentes pesos. A partir destas convoluções observam-se as diferenças entre intensidades de acordo com as direcções horizontais, verticais e diagonais (esquerda e direita). De seguida, são analisadas as componentes de magnitude e direcção do gradiente considerando as informações obtidas pela convolução [22]. Ao contrário do operador de *Canny* e do operador *Sobel*, o operador Laplaciano não utiliza informação relacionada com a direcção do *edge*, sendo assim considerado, um operador isotrópico. Este operador realiza a segunda derivada e o *zero-crossing* sobre o resultado anterior. O *zero-crossing* evita a utilização de uma etapa de adelgaçamento do *edge*. Uma vez que, a presença de ruído ou artefactos apresenta grande influência no resultado do Laplaciano, Marr e Hidreth criaram

uma alteração neste método pela adição de um filtro Gaussiano que é utilizado como etapa inicial. Este novo operador foi denominado de Laplaciano do Gaussiano (LOG) e esta evolução permitiu a remoção de frequências não desejadas, observando-se assim a redução da sensibilidade ao ruído quando efectuado o *zero-crossing* [26].

Os métodos que se baseiam na análise de regiões homogêneas e têm como técnica de raiz o *thresholding* são, tipicamente, os métodos de *region growing* e *split and merge*. O método de *region growing* é caracterizado pela colocação de uma semente numa região homogênea e através da análise dos pixels vizinhos é realizada a adição ou a rejeição de novos pixels. Para tal, é considerado um valor de *threshold* que irá limitar o valor médio de intensidade da região e o crescimento da mesma. O resultado deste método depende sobretudo do local de selecção para o crescimento da semente e do ruído e artefactos presentes na imagem, Figure 3, [18, 19].




Figura 3. À esquerda, foi seleccionado o local da semente para a região a ser obtida; na imagem da direita, o resultado do método de *region growing* (labirinto ósseo).

Por outro lado, o método de *split and merge* não necessita da colocação da semente e apresenta como objectivo a segmentação automática de uma imagem considerando um número mínimo de regiões possíveis que representem áreas com uma uniformidade significativa. Como resultado da segmentação, verificam-se contornos que apresentam características directamente relacionadas com a resolução da imagem [27].

Os métodos híbridos são o último tipo de métodos que tem como base a técnica de *thresholding*. Estes métodos combinam a detecção de orlas com a detecção de regiões. Um exemplo deste método é o método de *watershed* que tem como principal objectivo a combinação de valores de intensidade de uma dada imagem com a informação do gradiente da mesma. Este método pode também utilizar operações matemáticas morfológicas para a realização da segmentação. Para além disto, o conhecimento das características de forma e aparência do objecto melhoram a performance do método,

Figura 4, [19, 21, 28].

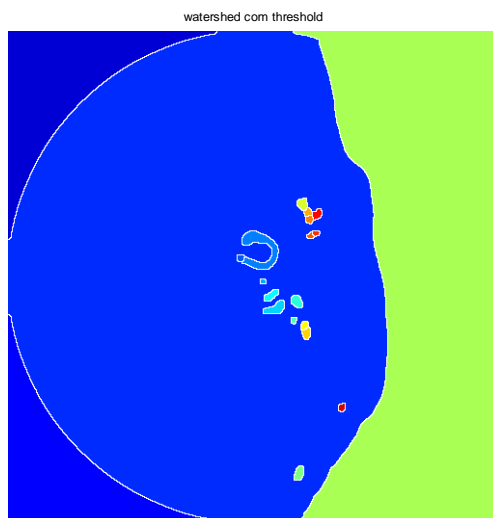


Figura 4. Resultado do método de *watershed* sobre a imagem Figura 1a, com pré-processamento para realçar os *edges* utilizando o operador de *sobel*. (O resultado apresentado foi obtido com um valor de *threshold* de 0.1).

O método de *global thresholding* é um dos métodos mais utilizados para a segmentação dos ossículos, presentes no ouvido médio, e do labirinto ósseo, localizado no ouvido interno [11, 17, 29, 30]. Este método é aplicado em imagens de Ressonância Magnética [17, 29], em imagens de Micro-CT [30] e ainda em imagens de Spiral-CT [11]. Apresenta resultados significativamente razoáveis no que diz respeito à diferenciação de tecidos que efectivamente apresentem uma grande divergência nos valores de intensidade dos seus pixels. Nestes casos, observa-se a diferenciação entre o tecido ósseo (pixels com elevada intensidade) e os outros tipos de tecido (pixels de intensidade inferior). Para além do método de *global thresholding*, os métodos de *region growing* e de *watershed* pertencem à classe dos métodos de *local thresholding* e também são usados para a segmentação de estruturas do ouvido, nomeadamente a cóclea [11, 28, 31]. Em [11] foi aplicado o método de *region growing* para efectuar a segmentação da cóclea em imagens de Spiral-CT. No mesmo tipo de imagens, [31] aplicou o método de *connected threshold region growing* para o mesmo efeito e em imagens de Ressonância Magnética [28] aplicou o método de *watershed*. O método de *connected threshold region growing* tem como objectivo encontrar os pixels vizinhos, de uma semente, que tenham valores de intensidade compreendidos entre um limite superior e inferior de *threshold* [31]. A segmentação da cóclea não depende apenas da utilização dos métodos referenciados anteriormente. Depois do processamento dos mesmos é, geralmente, necessária a segmentação manual, pois estes algoritmos efectuam uma incompleta segmentação automática [11]. Também para a segmentação da cóclea [11] utiliza-se filtragem morfológica, no entanto, este método apresenta baixa eficiência.

2.2. Algoritmos de segmentação baseados na técnica de *clustering*

Os métodos baseados na técnica de *clustering* realizam iterativamente de forma alternada a segmentação da imagem e caracterizam as propriedades de cada classe [18]. A técnica de *clustering* também pode ser expressa numa vasta variedade de algoritmos e pode ser dividida nas seguintes etapas: representação de dados, medição e execução de etapas de optimização. A representação de dados é caracterizada pela selecção de características e extracção das mesmas. A selecção de características refere-se ao agrupamento de todos os dados que possuem determinado atributo em comum. Por outro lado, a extracção de características é representada pela criação de uma nova propriedade que é gerada a partir de uma outra propriedade existente. A segunda fase, medição, é baseada na distância ou na similaridade das características. Por último, a terceira fase possibilita a obtenção de *clusterings* a partir de uma vasta variedade de algoritmos de optimização [32].

Os métodos de *clustering* podem ser divididos em três classes: métodos supervisionados, não supervisionados e semi-supervisionados. Os métodos supervisionados são muito utilizados e incluem: o classificador *k-nearest neighbor* (kNN), o algoritmo *maximum likelihood* (ML), *artificial neural networks* (ANN), *support vector machines* (SVM), *active shape models* (ASM) e *active appearance models* (AAM) (Ma, 2010). Para a realização da classificação supervisionada é necessário efectuar um conjunto de treinos para a extracção de informação estrutural [32]. As técnicas de *clustering* que não necessitam de supervisão compreendem o algoritmo *fuzzy C-means* (FCM), os algoritmos técnicos de análise de dados de auto-organização iterativa (ISODATA – *Iterative self-organising data analysis technique algorithms*) e as redes neuronais não supervisionadas [21].

Os algoritmos não supervisionados exploram a estrutura de dados para segmentar a imagem em diferentes regiões considerando diferenças estatísticas. Contudo, estes métodos têm dificuldade em atingir o resultado desejado, especialmente se a segmentação inclui regiões com características muito distintas. Por outro lado, a segmentação de imagens supervisionadas realiza a classificação de conjuntos de dados a partir da realização de um treino. Esta classificação apresenta melhores resultados; no entanto, a realização do treino faz com que estes algoritmos apresentem um demorado tempo de processamento. A segmentação de imagem semi-supervisionada, é o último tipo de *clustering*, e contorna os problemas das classes anteriores a partir da etiquetagem parcial das imagens. A principal diferença entre os algoritmos supervisionados e semi-supervisionados é a utilização da estrutura de pontos etiquetados e não etiquetados. Assim, a maior vantagem dos algoritmos semi-supervisionados é utilizar marcações para direccionar a segmentação. Desta forma, verifica-se a minimização da utilização de etiquetas obtidas pelo treino dos dados [33-35].

O sistema vestibular, presente no ouvido interno, é segmentado de acordo com [12] pela conjugação de técnicas de *clustering* com modelos deformáveis (descritos na próxima secção). A segmentação automática do sistema vestibular a partir de imagens de ressonância magnética compreende os seguintes procedimentos: extracção da região de interesse, reamostragem de forma a tornar a imagem isotrópica, filtragem para

preservação dos *edges*, aplicação do algoritmo *k-means clustering* ou *ISODATA* com $K=2$ e utilização do método dos modelos deformáveis. O algoritmo *k-means clustering* foi aplicado para categorizar os pixéis que se encontram em segundo plano dos que se encontram em primeiro plano, tendo como observação os valores de intensidade. O grupo que apresenta menos número de pixéis é considerado primeiro plano (objecto de interesse) [12]. A função principal do algoritmo *k-means clustering* é agrupar dados pela computação iterativa de uma intensidade média para cada classe e segmentar a imagem pela classificação do valor de intensidade do pixel comparativamente ao valor médio da classe mais próxima [18].

2.3. Métodos de segmentação baseados em modelos deformáveis

Os métodos baseados em modelos deformáveis são mais flexíveis quando comparados com os outros dois tipos de métodos. Os modelos deformáveis são sobretudo utilizados para a realização de segmentações de estruturas que apresentem elevada complexidade [21]. Estes modelos são baseados em técnicas para delimitação de regiões de fronteira e utilizam curvas ou superfícies paramétricas que se deformam de acordo com a influência causada pelas forças externa e interna. A principal vantagem dos modelos deformáveis está relacionada com a capacidade de produzir directamente curvas ou superfícies paramétricas fechadas. Para além da vantagem descrita anteriormente, este método também apresenta elevado interesse para a segmentação, pois apresenta-se robusto na presença de ruído. Contudo, o algoritmo necessita de interacção manual para a colocação do modelo inicial e para a escolha dos parâmetros de entrada [18]. Os métodos dos modelos deformáveis podem ser divididos em modelos deformáveis paramétricos e modelos deformáveis geométricos. Os modelos deformáveis paramétricos representam curvas e superfícies explicitamente paramétricas durante a deformação. Esta representação permite uma interacção directa com o modelo e pode levar a uma representação compacta de execução rápida e em tempo real. A separação ou a fusão de partes que ocorrem durante a deformação pode tornar difícil a utilização de modelos paramétricos. Por outro lado, os modelos deformáveis geométricos conseguem lidar naturalmente com mudanças topológicas. Estes modelos são baseados na teoria da evolução da curva e no método de *level set* [36, 37].

Os modelos deformáveis paramétricos baseiam-se basicamente na utilização de um contorno activo deformável, usualmente designado por *snake*. A este método pode ainda ser incorporada informação estatística (AAM e ASM algoritmo) ou informação do gradiente (*Generalised Gradient Vector Flow snake* – GGVF *snake*).

Como já foi referido anteriormente, sabe-se que o ouvido é dividido em 3 partes: ouvido externo, ouvido médio e ouvido interno. A estrutura que divide o ouvido externo do ouvido médio, a membrana timpânica, é observada externamente a partir de imagens de vídeo-otoscopia e de otoscopia [38, 39]. Através da análise destas imagens podem ser diagnosticadas diversas patologias, como por exemplo, otites médias e outras infecções. A segmentação desta estrutura é efectuada através da versão generalizada do GVF *snake*

(GGVF snake). O GVF é caracterizado por um campo vectorial denso proveniente das imagens pela minimização da energia funcional num *variational framework* [37]. O *variational framework* deriva da segmentação de um domínio que apresenta regiões com movimento homogêneo. A aplicação *variational* tem um papel fundamental para mover a linha de segmentação com um contorno explícito onde a estimação do movimento e a optimização do contorno são derivadas a partir da minimização de uma energia funcional. Este método é baseado num modelo probabilístico simples para a determinação do gradiente da imagem espaço-temporal a partir de duas imagens consecutivas de uma sequência. Os contornos activos ou *snakes* são muito utilizados em processamento de imagem e visão computadorizada devido à facilidade de manipulação das variações de forma e à independência durante a operação (apenas é dependente na fase inicial). Estes métodos são úteis quando se tratam de fronteiras que possuem aberturas ou intervalos de pequena dimensão [38]. Para além disso, o algoritmo *GVF snake* apresenta grande facilidade em movimentar-se entre limites côncavos e apresenta uma intensificação na inicialização do método. As inicializações do método podem-se dar no interior, exterior ou sobre os limites dos objectos de interesse. O algoritmo *GVF snake* também apresenta uma elevada gama de captura, o que significa que impede a interferência provocada por outros objectos e, desta forma, a inicialização pode dar-se longe da fronteira. Este aumento da gama de captura é verificado através do processo de difusão que não esbate os *edges* do objecto de interesse [37]. O objectivo da utilização deste método *GGVF snake* é realizar a delineação dos limites da membrana timpânica, assim como, detectar anormalidades de cor nas imagens da membrana timpânica [38]. O algoritmo de *snake* também é apropriado para a segmentação da cóclea devido ao elevado controlo da suavização e ao ajuste da propriedade de convergência. Usualmente, a modelação a partir deste algoritmo necessita da interacção humana, nomeadamente do ajustamento dos parâmetros de processamento e da especificação de um contorno inicial. A principal desvantagem deste algoritmo prende-se ao facto de não poder ser utilizado em diferentes regiões e, para além disso, este método é realizado em cada imagem. Contudo, em imagens de Tomografia Computorizada a cóclea apresenta-se como uma superfície bastante homogênea e lisa, por isso, este algoritmo é considerado apropriado [10, 40]. Segundo [12] outra estrutura do ouvido que pode ser segmentada a partir do algoritmo *snake* é o sistema vestibular. Também na observação de imagens de micro-CT pode ser realizada a segmentação aos canais semi-circulares pela utilização de contornos activos [41].

Os modelos deformáveis geométricos são caracterizados pelo algoritmo de *level set* e compreendem os seguintes modelos: *Mumford-Shah*, *Chan and Vese* e *Malladi*.

A membrana timpânica do ouvido médio pode ser segmentada através da utilização do método semi-automático de *Mumford-Shah*. Este método é amplamente utilizado em processamento e análise de imagem pois realiza simultaneamente a suavização e a segmentação da imagem. A suavização utilizada por este método não é idêntica à difusão anisotrópica (filtro bastante utilizado em processamento de imagens médicas), mas é linear e preserva os *edges* tendo em consideração a segmentação global e não o gradiente da imagem. O desenvolvimento deste modelo matemático é baseado em estimações teóricas e considerações geométricas [42]. Neste método pode ser verificada a utilização

da equação do fluxo do gradiente para envolver o contorno activo. No entanto, cada etapa do gradiente envolve a estimação da solução óptima para determinar as aproximações da suavização de conjuntos de dados existentes no interior e no exterior do contorno activo. O método de *Mumford-Shah* é baseado em regiões e tal facto leva a que apresente propriedades bastante atractivas, como por exemplo a elevada robustez na presença de ruído e na escolha do local de contorno inicial [42]. Este método também garante a ligação entre os segmentos e permite o conhecimento da informação quantitativa relativa às perfurações da membrana timpânica, ou seja, é direccionado para o diagnóstico clínico [39].

4. DISCUSSÃO

Na segmentação das estruturas do ouvido verifica-se a vasta utilização do método de *thresholding*. Contudo, este método apresenta várias desvantagens, pois é sensível a efeitos de volume parcial, não tem em consideração as características espaciais e não pode ser aplicado em imagens multicanal. Assim, é possível concluir que este método apresenta melhores resultados quando existe o objectivo de segmentar tecidos que efectivamente demonstrem uma grande diferença nos valores de intensidade dos pixéis, o que na maior parte das imagens médicas não é observado. Os tecidos moles, o tecido ósseo, os fluidos e o ar estão presentes em imagens multicanal e podem apresentar intensidades próximas não sendo fácil a decisão do valor de *threshold* [18, 20]. O método de *region growing* é uma solução de processamento de *thresholding* local que apresenta várias desvantagens. Este método necessita da selecção manual de um ponto e é muito sensível a artefactos, os quais podem provocar o aparecimento de buracos e descontinuidades [11, 18]. Outro método que utiliza o *region growing* é o método de *connected threshold region growing*. Este possibilita a extracção de várias estruturas anatómicas, possui um baixo tempo de processamento e detém uma elevada simplicidade. Porém, o operador necessita de definir o valor de *threshold* e, como descrito anteriormente, mudanças ligeiras no valor de *threshold* alteram significativamente os resultados. O operador também é responsável por escolher pixéis que se encontrem no interior da região de interesse. Outro dos métodos que se baseia na técnica de *thresholding* é o método de *watershed*. Este método torna possível a segmentação de objectos múltiplos a partir da definição de um valor de *threshold*. Contudo, diferentes tipos de imagem necessitam de diferentes valores de *threshold*, pois se o valor de *threshold* não for o mais indicado a segmentação não é eficiente. Para além disso, mudanças ligeiras no valor podem alterar significativamente os resultados, o que demonstra a subjectividade deste método [28].

A utilização de métodos que têm como base os contornos activos é observada para as três partes do ouvido. Observa-se a utilização de métodos que têm como base a modelação com contornos activos na membrana timpânica, nos ossículos, na cóclea, no sistema vestibular e ainda nos canais semi-circulares. Os métodos que são baseados em contornos activos apresentam várias vantagens, pois são representados por um modelo matemático preciso, simples e acessível, não dependem de parâmetros subjectivos como é o caso do

thresholding e são menos sensíveis a artefactos e a variações de intensidade no plano de fundo da imagem, quando é realizada a comparação com o algoritmo *thresholding*. Outras vantagens inerentes a métodos que têm como base a utilização de contornos activos são a facilidade de manipulação das variações de forma, a não observação da suavização dos *edges* do objecto de interesse e a independência durante a operação. A desvantagem que os contornos activos apresentam é a necessidade da interacção do operador na fase inicial. Este grande leque de vantagens providencia bons resultados na utilização de métodos que tenham como base esta técnica [37, 38].

Para além dos métodos anteriormente caracterizados é verificada a combinação de métodos de pré-processamento com métodos de segmentação e ainda, a combinação destes com métodos de reconstrução tridimensional. A agregação de métodos permite ultrapassar algumas desvantagens e a evidenciação da precisão e eficiência do resultado. Por outro lado, quando é observada a combinação de métodos de segmentação com métodos de reconstrução tridimensional está a possibilitar-se a observação pormenorizada da estrutura de interesse e torna-se desnecessária a remoção manual das restantes estruturas que não são de interesse.

5. CONCLUSÃO

Neste artigo, os métodos utilizados para a segmentação de imagens médicas foram classificados em 3 tipos e as principais características das diferentes classes foram descritas. Alguns dos métodos apresentados foram aplicados na segmentação de estruturas do ouvido em imagens de TC. Estes exemplos foram também utilizados para facilitar a distinção das suas diferentes características.

As classes de métodos mais utilizadas para segmentação de estruturas do ouvido são as baseadas nas técnicas de *thresholding* e dos modelos deformáveis. Contudo, pelo confronto das vantagens e desvantagens verificou-se que os métodos que têm como base os modelos deformáveis apresentam melhores características e mostram-se mais eficazes.

Para uma segmentação concreta e precisa, de imagens médicas, é necessário a consideração de uma elevada complexidade computacional e iterativa no desenvolvimento dos métodos de segmentação.

6. AGRADECIMENTOS

Este trabalho foi parcialmente desenvolvido no âmbito dos projectos “Estudo bio-computacional do zumbido” e “Metodologias para Análise de Órgãos a partir de Imagens Médicas Complexas – Aplicações à Cavidade Pélvica Feminina”, com as referências PTDC/SAU-BEB/104992/2008 e PTDC/EEA-CRO/103320/2008, respectivamente, financiados pela Fundação para a Ciência e a Tecnologia (FCT).

REFERÊNCIAS

- [1] Seeley, Stephens, and Tate, *The Special Senses. Anatomy and Physiology*, Sixth Edition, (2004).

- [2] A.R. Moller, *Hearing: Anatomy, Physiology, and Disorders of the Auditory System, Second Edition*, (2006).
- [3] B.-C. Jun, et al., "Three-dimensional reconstruction based on images from spiral high-resolution computed tomography of the temporal bone: anatomy and clinical application". *The Journal of Laryngology & Otology*, Vol: **119**: pp. 693-698,(2005)
- [4] Y. Wang, Y. Zhu, and Q. Guo, *Medical image segmentation based on deformable models and its applications*, in *Deformable Models Theory and Biomaterial Applications*, Springer New York. pp. 209-260, (2007).
- [5] W.F. Decraemer, J.J.J. Dirckx, and W.R.J. Funnell, "Three-Dimensional Modelling of the Middle-Ear Ossicular Chain Using a Commercial High-Resolution X-Ray CT Scanner". *Journal of the Association for Research in Otolaryngology*, Vol: **4**: pp. 250-263,(2003)
- [6] J.H. Sim and S. Puria, "Soft Tissue Morphometry of the Malleus-Incus Complex from Micro-CT Imaging". *Journal of the Association for Research in Otolaryngology*, Vol: **9**: pp. 5-21,(2008)
- [7] A. Hussong, et al., "An automated insertion tool for cochlear implants: another step towards atraumatic cochlear implant surgery". *Int Journal CARS*, Vol: **5**: pp. 163-171,(2009)
- [8] T.S. Rau, et al., "Automated insertion of performed cochlear implant electrodes: evaluation of curling behaviour and insertion forces on an artificial cochlear model". *Int Journal CARS*, Vol: **5**: pp. 173-181,(2010)
- [9] G.E. Christensen, et al., "Automatic Measurement of the Labyrinth Using Image Registration and a Deformable Inner Ear Atlas". *Academic Radiology Journal*, Vol: **10**: pp. 988-999,(2003)
- [10] A.A. Poznyakovskiy, et al., "The creation of geometric three-dimensional models of the inner ear based on micro computer tomography data". *Hearing Research*, Vol: **243**: pp. 95-104,(2008)
- [11] D. Xianfen, et al., *3D Semi-automatic Segmentation of the Cochlea and Inner Ear*, in *Engineering in Medicine and Biology 27th Annual Conference*, IEEE, Editor. 2005: Shangai, China.
- [12] L. Shi, et al., "Automatic MRI segmentation and morphoanatomy analysis of the vestibular system in adolescent idiopathic scoliosis". *NeuroImage*: pp. 9,(2010)
- [13] B. Liu, et al., "A detailed 3D model of the guinea pig cochlea". *Brain Struct Funct*, Vol: **212**: pp. 212-230,(2007)
- [14] J.I. Lane, et al., "Imaging Microscopy of the Middle and Inner Ear Part II: MR Microscopy". *Clinical Anatomy Wiley-Liss*, Vol: **18**: pp. 409-415,(2005)
- [15] J.P. Tuck-Lee, et al., "Finite element modeling of acoustical-mechanical coupling in the cat middle ear". *Journal Acoustical Society of America*, Vol: **124**: pp. 348-362,(2008)
- [16] M.D. Seemann, et al., "Evaluation of the middle and inner ear structures: comparison of hybrid rendering, virtual endoscopy and axial 2D source images". *European Radiology*, Vol: **9**: pp. 1851-1858,(1999)
- [17] E.R. Melhem, et al., "Inner Ear Volumetric Measurements Using High-Resolution

- 3D T2-Weighted Fast Spin-Echo MR Imaging: Initial Experience in Healthy Subjects". *American Journal Of Neuroradiol*, Vol: **19**: pp. 1819-1822,(1998)
- [18] D.L. Pham, C. Xu, and J.L. Prince, "Current Methods in Medical Image Segmentation". *Annu. Rev. Biomed. Eng.* , Vol: **2**: pp. 315-37,(2000)
- [19] I.N. Bankman, *Handbook of Medical Imaging Processing and Analysis*, (2000).
- [20] C. Xiao-Juan and L. Dan, *Medical image segmentation based on threshold SVM*, in *ICBECS2010 Conference Schedule*, IEEE, Editor. 2010: China.
- [21] Z. Ma, et al., "A review of algorithms for medical image segmentation and their applications to the female pelvic cavity". *Computer Methods in Biomechanics and Biomedical Engineering*, Vol: **13**: pp. 235-246,(2010)
- [22] N. Kanopoulos, N. Vasanthavada, and R.L. Baker, "Design of an Image Edge Detection Filter Using the Sobel Operator". *IEEE Journal of Solid-State Circuits*, Vol: **23**: pp. 358-367,(1988)
- [23] L. Ding and A. Goshtasby, "On the Canny edge detector". *Pattern Recognition*, Vol: **34**: pp. 721-725,(2001)
- [24] E.F. Glynn. *Mixture of Gaussian Distributions*. 2007 [cited 2011 12-01-2011]; Available from: <http://research.stowers-institute.org/efg/R/Statistics/MixturesOfDistributions/index.htm>.
- [25] P. Akhtar and T.J. Ali, *Edge detection and linking using wavelet representation and image fusion*, in *Image and Signal Processing, 2008. CISP '08. Congress 2008*: Sanya, Hainan. pp. 273 - 277.
- [26] P.A. Mlsna and J.J. Rodríguez, *Gradient and Laplacian Edge Detection*, in *The Essential Guide to Image Processing*, Elsevier, Editor: San Diego. pp. 495-524, (2009).
- [27] I.N. Manousakas, et al., "Split-and-Merge Segmentation of Magnetic Resonance Medical Images: Performance Evaluation and Extension to Three Dimensions". *Computers and Biomedical Research*, Vol: **31**: pp. 393-412,(1998)
- [28] Y.B. Chen and O.T.C. Chen, "Image Segmentation Method Using Thresholds AUTomatically Determined from Picture Contents". *EURASIP Journal on Image and Video Processing*, Vol: **2009**: pp. 15,(2009)
- [29] T. Rodt, et al., "3D visualisation of the middle ear and adjacent structures using reconstructed multi-slice CT datasets, correlating 3D images and virtual endoscopy images". *Neuroradiology*, Vol: **44**: pp. 783-790,(2002)
- [30] D.H. Lee, et al., "Reconstruction and exploration of virtual middle-ear models derived from micro-CT datasets". *Hearing Research*, Vol: **263**: pp. 198-203,(2010)
- [31] C. Todd, M. Tarabichi, and F. Naghdy, *A computer-based, Interactive Tool for Semi-Automatic Extraction, Visualization and Pre-operative Assessment of the Inner Ear*, in *Joint Conference on Medical Informatics*. 2009: Taiwan, Taipei.
- [32] Y. Zhu, *An Efficient Supervised Clustering Algorithm Based on Neural Networks*, in *3rd International Conference on Advanced Computer Theory and Engineering(ICACTE)*, IEEE, Editor. 2010. pp. 265-268.
- [33] M.A.T. Figueiredo, *Semi-Supervised Clustering: Application to Image Segmentation*, in *Advances in Data Analysis* R. Decker and H.-J. Lenz, Editors,

- Springer Berlin Heidelberg: Berlin. pp. 39-50, (2007).
- [34] B. Xiao-min, et al., *Textile Image Segmentation Based on Semi-supervised Clustering and Bayes Decision*, in *International Conference on Artificial Intelligence and Computational Intelligence*. 2009, IEEE. pp. 559-562.
 - [35] A.R.C. Paiva and T. Tasdizen, *Fast Semi-Supervised Image Segmentation by Novelty Selection*, in *Acoustics Speech and Signal Processing (ICASSP), 2010 IEEE International Conference 2010*, IEEE: Salt Lake City. pp. 1054 - 1057
 - [36] T. McInerney and D. Terzopoulos, "Deformable Models in Medical Image Analysis: A Survey". *Medical Image Analysis*, Vol: **2**: pp. 91-108,(1996)
 - [37] C. Xu and J.L. Prince, "Snakes, Shapes, and Gradient Vector Flow". *IEEE Transactions on Image Processing*, Vol: **7**: pp. 359-369,(1998)
 - [38] X. Xie, et al., "Detecting Abnormalities in Tympanic Membrane Images". *Medical Image Understanding and Analysis*: pp. 19–22,(2005)
 - [39] E. Comunello, et al., "A computational method for the semi-automated quantitative analysis of tympanic membrane perforations and tympanosclerosis". *Computers in Biology and Medicine*, Vol: **39**: pp. 889-895,(2009)
 - [40] S.K. Yoo, et al., "Semiautomatic Segmentation of the Cochlea Using Real-Time Volume Rendering and Regional Adaptive Snake Modeling". *Journal of Digital Imaging*, Vol: **14**: pp. 173-181,(2001)
 - [41] A.P. Bradshaw, et al., "A Mathematical Model of Human Semicircular Canal Geometry: A New Basis for Interpreting Vestibular Physiology". *Journal of the Association for Research in Otolaryngology*, Vol: **11**: pp. 145-159,(2010)
 - [42] A.Y.A. Tsai and A.S. Willsky, "Curve Evolution Implementation of the Mumford-Shah Functional for Image Segmentation, Denoising, Interpolation, and Magnification". *IEEE transactions on Image Processing*, Vol: **10**: pp. 1169-1186,(2001)