### CBA 2010 XVII Congresso Brasileiro de Automática

# DETECÇÃO DE MUDANÇAS E RECUPERAÇÃO DE FORMA EM MAPAS 3D BASEADOS EM NUVENS DE PONTOS

# Paulo Drews Jr\*, Rui Rocha $^\dagger,$ Mario Campos\*, Jorge Dias $^\dagger$

\*Departamento de Ciência da Computação - UFMG - Belo Horizonte - Brasil

<sup>†</sup>Instituto de Sistemas e Robótica - UC - Coimbra - Portugal

Emails: paulol@dcc.ufmg.br, rprocha@isr.uc.pt, mario@dcc.ufmg.br, jorge@isr.uc.pt

**Abstract**— There are several applications for which it is important to both detect and modelling changes. In the context of 3D point cloud, detecting changes constitutes a challenging task due to the large amounts of data that must be compared, as well as shape retrieval needs to deal with large kind of shape and with noise in the data. Thus, this paper proposes a framework to efficiently detect and represent changes through a compact model. Initially, the point cloud is simplified in order to preserve the geometric characteristics. Moreover, a combined approach using *Gaussian Mixture Models* (GMM) and the *Earth Mover's Distance* (EMD) is proposed, together with a greedy technique. It allows detect and segment changes, through an previous knowledge about the environment map. The 3D shape retrieval is achieved using two different approaches. The first approach is a new method that we developed which directly retrieves basic shapes the detected shape in the Gaussian space (planes, spheres and cylinders). The second approach uses superquadric models and the *split-and-merge* paradigm due to their good expressiveness in representing 3D shapes. Experimental results in various real scenarios were obtained to evaluate the approach's feasibility and robustness with large datasets.

Keywords— Novelty Detection, 3D Maps.

**Resumo**— Existem muitas aplicações onde é importante detectar e modelar mudanças. No contexto de nuvem de pontos 3D, detectar mudanças constitui um problema desafiador devido à grande quantidade de dados que precisa ser comparado. Além disso, para determinar a forma é preciso lidar com um grande número de possibilidades e com ruído nos dados. Assim, o presente trabalho propõe um arcabouço para determinação e representação de mudanças em modelos conhecidos de forma eficiente. Inicialmente, uma simplificação da nuvem de pontos é feita, buscando preservar as características geométricas. Além disso, é utilizada uma combinação de Modelos de Misturas Gaussianas (GMM) e da métrica de distância *Earth Mover's Distance* (EMD), por meio de uma técnica gulosa. Essa combinação permite detectar e segmentar mudanças a partir de um conhecimento prévio do mapa do ambiente. Dois métodos para a recuperação de formas 3D foram propostos. Primeiramente, um novo método é desenvolvido usando formas básicas no espaço das Gaussianas (planos, esferas e cilindros). Uma segunda abordagem utiliza superquádricas e o paradigma *split-and-merge*, visando dar uma maior expressividade à representação de forma 3D. Resultados experimentais foram obtidos em vários cenários reais, de forma a avaliar a robustez do método em grandes conjuntos de dados.

Palavras-chave— Detecção de Mudanças, Mapas 3D.

## 1 Introdução

Robôs móveis para trabalhar de forma independente em ambientes dinâmicos devem ser capazes de: (i) construir o mapa do ambiente baseado em suas percepções e simultaneamente localizarse com respeito ao mapa (SLAM) (Thrun et al., 2005); (ii) navegar e explorar o ambiente. Assim, a capacidade de navegar pode ser prejudicada pela presença de mudanças, de forma a afetar o caminho escolhido pelo robô. Deste modo, quando o robô visita novamente lugares no ambiente, pode ser de interesse comparar a percepção atual com a previamente adquirida, de modo a detectar mudanças. Bem como determinar algumas características da mudança como volume e área pode ser importante, de forma a replanejar a navegação. Assim, realizando a modelagem da mudança é um meio de determinar essas informações.

O problema de detectar mudanças não é restrito a robôs móveis durante a navegação (Markou and Singh, 2003). Porém, essa questão é de suma importância nesse contexto, principalmente, em sistemas de vigilância automática (Andreasson et al., 2007). Resolver o problema de detecção de mudanças eficientemente é desafiador e requer o desenvolvimento de técnicas específicas a fim de alcançar dois objetivos inter-relacionados: (i) detectar a existência de mudanças; (ii) realizar a segmentação e a modelagem das mudanças. Esses dois objetivos também facilitam uma posterior classificação e/ou identificação das mudanças.

Este trabalho propõe um arcabouço para detectar, segmentar e modelar mudanças. Inicialmente, os dados são simplificados de modo a reduzir o custo computacional dos próximos passos, por meio de uma abordagem multi-escala. Posteriormente, a detecção e segmentação de mudanças são feitas sobre uma representação dos dados usando o Modelo de Misturas Gaussianas (GMM). Por fim, a modelagem da mudança é realizada utilizando dois modelos. Uma primeira modelagem é feita utilizando formas básicas, diretamente no espaço de Gaussianas. Enquanto na segunda se faz por meio de superquádricas (Barr, 1981). A Figura 1 ilustra a ideia.

O trabalho está disposto com a Seção 2, a qual mostra uma revisão do estado da arte. Na Seção 3



Figura 1: Visão geral de proposta.

é apresentada a metodologia proposta para detecção de mudanças. Na Seção 4, os métodos para modelagem de mudanças são mostrados. Os resultados experimentais são mostrados na Seção 5. Por fim, na Seção 6, as conclusões e as direções futuras são apontadas.

#### 2 Trabalhos Relacionados

O uso de robôs móveis em ambientes dinâmicos tem sido intensamente estudado durante a última década. Uma estratégia típica é remover os objetos dinâmicos do modelo, de modo a melhorar a navegação e a localização do robô (Fox et al., 1999). Entretanto, essas mudanças podem ser importantes de serem reconhecidas, como no trabalho de Andreasson *et al.* (Andreasson et al., 2007), no qual é proposto um sistema de detecção de mudança utilizando a informação de um *laser scanner* 3D e de uma câmera colorida. Apesar dessa abordagem se mostrar eficiente, o método é dependente da dimensão do ambiente a ser mapeado e da presença de contraste de cor entre as mudanças e o ambiente.

Outro trabalho importante foi proposto por Vieira Neto *et al.* (Vieira Neto and Nehmzow, 2008), no qual um método para detecção de mudanças para vigilância é desenvolvido, baseado em modelo de saliência e algoritmos de clusterização. Os resultados mostraram que a abordagem detecta mudanças, principalmente quando existe grande contraste de cor entre as mudanças e o ambiente. Porém, em casos com pouco contraste, o método tem dificuldade de detecção. O presente trabalho por utilizar mapas 3D construídos com *laser scanners*, torna-se independente de variações de condições de iluminação e de contraste das mudanças.

A determinação de forma é uma tarefa comum em diversas áreas da Geometria e Ciência da Computação. O uso de formas básicas como esferas, planos, cilindros e outros tem sido foco de diversas propostas. Alguns autores usaram a Transformada de Hough para obtenção de formas básicas (Ballard, 1987), embora essa técnica tenha elevado custo computacional para computar formas tridimensionais. Outra técnica muito utilizada é o crescimento de regiões (Vieira and Shimada, 2005), na qual as regiões crescem em áreas vizinhas, a partir de "sementes" previamente determinadas. Recentemente, foi proposto o uso de RANSAC para determinação de formas básicas (Schnabel et al., 2007), este robusto à presença de ruído.

A superquádrica é um modelo para formas geométricas, representado por um conjunto simples de parâmetros com grande expressividade. Leonardis *et al.* (Leonardis et al., 1997) introduziram o padrão para segmentação e recuperação de forma usando superquádricas. Esse método foi aplicado em imagens de profundidade. Uma importante abordagem para nuvem de pontos 3D foi proposta em (Chevalier et al., 2003), onde o paradigma *split-and-merge* foi utilizado em nuvem de pontos 3D. Apesar do elevado custo computacional, o algoritmo produz resultados interessantes. Maiores detalhes sobre superquádricas podem ser encontrados em (Jaklič et al., 2000).

## 3 Detecção de Mudanças

No presente trabalho, a nuvem de pontos 3D é simplificada e transformada do espaço Euclidiano para o espaço matemático de Gaussianas. Isso permite compressão de dados e efetuar uma comparação de maneira eficiente, usando a métrica EMD (Rubner et al., 1998).

Um novo algoritmo foi proposto usando técnica gulosa e a métrica de distância *EMD*, de forma a permitir a segmentação das mudanças. As principais vantagens dessa abordagem são: (i) simples e eficaz, devido ao uso da simplificação da nuvem de pontos e ao novo algoritmo de segmentação; (ii) segmentação robusta, devido à remoção de *outliers* e ao uso do espaço de Gaussianas. A descrição detalhada do método é apresentada nas próximas subseções.

## 3.1 Pré Processamento

O pré processamento tem como parte central a simplificação da nuvem de pontos, a qual é utilizada para reduzir a alta densidade de pontos adquiridos por um *laser scanner* 3D, diminuindo o custo computacional da abordagem como um todo. A abordagem utilizada é baseada no trabalho proposto por Pauly *et al.* (Pauly et al., 2002).

A principal vantagem do método é a redução da densidade com pouca perda na informação geométrica da nuvem, com reduzido custo computacional. A abordagem permite gerar uma representação multi-escala da nuvem de pontos usando partição binária. Além disso, é feito uso da análise de covariância de modo a determinar uma métrica denominada de variação da superfície (Pauly et al., 2002) ( $\sigma$ ), baseada nos autovalores.

Inicialmente, o método de simplificação constrói uma árvore binária baseado na divisão de cada agrupamento, utilizando uma abordagem top-down. A nuvem de pontos é sempre dividida ao longo da direção de maior variação. Porém, o agrupamento P só é dividido quando o número de pontos |P| for menor do que um valor mínimo necessário para estimação da covariância; e o valor da variação da superfície for maior que um dado limiar máximo  $\sigma_{max}$ . O plano de corte é definido a partir do centróide do agrupamento e do autovetor associado ao maior autovalor. A representação em multi-escala é baseada nos níveis de restrições impostas à árvore, ou seja, escolhendo-se valores para o tamanho mínimo de |P| e para  $\sigma_{max}$ .

Em nuvem de pontos obtidas por *laser scan*ner, é comum a presença de plano do solo nos dados. Neste trabalho, um método usando RAN-SAC para ajustar o plano do solo é utilizado (Lai and Fox, 2009). Finalmente, a remoção da *outli*ers foi adicionada durante a construção da árvore de simplificação, baseado no trabalho de Rusu *et al.* (Rusu et al., 2008).

### 3.2 Modelos de Misturas Gaussianas (GMM)

O modelo de mistura Gaussiana é uma função densidade de probabilidade descrita por uma combinação linear de Gaussianas. Assim, a função é a uma mistura de Gaussianas quando tem a seguinte forma:

$$f(\mathbf{x}, \Theta) = \sum_{k=1}^{K} p_k g(\mathbf{x}; \mu_k, \mathbf{\Sigma}_k) \quad (\mathbf{x} \in \mathbb{R}^N), \quad (1)$$

onde a função g são Gaussianas definidas por  $\mu_k \in \mathbb{R}^N \in \Sigma_k$ , vetor média e matriz de covariância, respectivamente. O coeficiente  $p_k$ , peso da mistura, deve satisfazer:  $p_k \ge 0 \in \sum_{k=1}^{K} p_k = 1$ .

A GMM é um ótimo modelo para agrupamento de pontos. Dado um conjunto de pontos é possível encontrar uma GMM  $\Theta$  usando o conhecido método Expectation Maximization (EM). O número de Gaussianas da mistura(K) é selecionando usando um valor de  $K_{max}$  e uma função de penalidade baseado em Minimum DescriptionLength (MDL) (Rissanen, 1983).

### 3.3 Earth Mover's Distance (EMD)

O Earth Mover's Distance (EMD) (Rubner et al., 1998) é uma métrica que pode ser usada para computar a distância entre duas distribuições. Com  $\Theta = ((\theta_1, p_1), \dots, (\theta_n, p_n))$  e  $\Gamma = ((\gamma_1, q_1), \dots, (\gamma_m, q_m))$ , sendo duas GMM associadas a duas nuvem de pontos 3D, onde  $\theta_i \in \gamma_j$ são funções Gaussianas;  $p_i \in q_j$  são os pesos associados a cada Gaussiana, respectivamente. A distância entre duas GMM é definida por:

$$d_{GMM}(\Theta, \Gamma) = EMD(\Theta, \Gamma).$$
 (2)



Figura 2: Detecção e segmentação de mudança usando GMM: A) Corredor ideal sem mudança com modelo em GMM em C); B) Corredor ideal com mudança, modelado por uma GMM em D). A mudança detectada pelo algoritmo foi indicada pelo retângulo preto em D.

### 3.4 Segmentação de Mudanças usando GMM

A Equação (2) permite quantificar as mudanças no ambiente, porém, não permite segmentá-las diretamente. Tipicamente, o problema de detecção de mudanças pode ser definido como determinar um limiar  $U_{th}$ , que representa o maior valor a partir do qual é assumido a existência de mudança no mapa recentemente adquirido. Porém, limiares fixos são de difícil determinação e dependentes das características dos dados.

Um novo algoritmo baseado em técnica gulosa foi proposto objetivando ultrapassar essa restrição. A Figura 2 ilustra a idéia do algoritmo. A estrutura do método é mostrada em pseudo código no Algoritmo 1. O método busca mais do que detectar mudança, ele segmenta a mudança e determina os conjuntos de pontos associados a cada mudança, utilizando a probabilidade *a posteriori*.

O algoritmo tem como entrada duas GMMs  $\Gamma \in \Theta$ . Em cada iteração do algoritmo é selecionada uma Gaussiana de  $\Theta$ , que obtém a menor distância global com  $GMM \Gamma$ , utilizando a função  $Selecao_Gulosa(\Gamma, \Theta - \Theta_{new})$ . Essa função computa iterativamente a *EMD* entre  $\Gamma \in \Theta - \Theta_{new}$ , removendo uma Gaussiana por vez e adicionando à  $GMM \ \Theta_{new}$ . O resultado do algoritmo é uma lista de conjuntos de pontos C. Cada conjunto de C representa uma região da nuvem de pontos segmentada por uma única Gaussiana e computada pela função Seleciona\_Pontos. Essa função tem como argumento a nuvem de pontos P, utilizada para gerar aGMM  $\Theta$ e uma única Gaussiana  $\Theta_{new_i} = (\mu, \Sigma)$ . A probabilidade *a posteriori*, além de permitir segmentar os pontos relacionados a cada Gaussiana, ainda permite identificar a relação topológica entre as Gaussianas que representam a mudança. Essa relação será importante na modelagem por superquádricas na Seção 4.2.

Tabela 1: Algoritmo para Segmentação de Mudanças

1:  $d_{GMM} \leftarrow EMD(\Gamma, \Theta)$ 2:  $\Theta_{new} \leftarrow \{\emptyset\}$ 3:  $size \leftarrow 0$ 4: repeat  $d_{GMM_{old}} \leftarrow d_{GMM}$ 5:  $[\Theta_{new}, d_{GMM}] \leftarrow Selecao\_Gulosa(\Gamma, \Theta -$ 6:  $\Theta_{new}$ )  $size \gets size + 1$ 7: 8: until  $(d_{GMM_{old}} < d_{GMM})$ 9:  $\Theta_{new} \leftarrow \Theta_{new} - \Theta_{new_{size}}$ 10:  $C \leftarrow \{\emptyset\}$ 11: for all  $\Theta_{new_i}(\mu, \Sigma) \in \Theta_{new}$  do  $C \leftarrow C \cup Selectiona\_Pontos(P, \Theta_{new_i}(\mu, \Sigma))$ 12:

13: end for

#### 4 Recuperação de Forma 3D

Os algoritmos para recuperação de formas 3D das mudanças utilizam dois modelos distintos e são detalhados nesta secção. O primeiro é baseado em formas básicas (*e.g.* planos, esferas e cilindros) no espaço de Gaussianas. O segundo modelo utilizado são as superquádricas. Este último, especializado de forma a obter uma melhor representação por meio do paradigma *split-and-merge*. Esses métodos serão detalhados nos subseções a seguir.

#### 4.1 Formas Básicas no Espaço de Gaussianas

O algoritmo de recuperação de forma no espaço de Gaussianas é baseado no uso da matriz de covariância de cada Gaussiana, a qual fornece informação sobre a forma. Sendo  $\Theta_{new}$  uma mistura de Gaussianas associada às mudanças do ambiente, cada mudança k é caracterizada por uma função Gaussiana  $\Theta_{new_k} = (\mu_k, \Sigma_k)$ . Assim, é proposto um algoritmo que busca dentre as formas básicas, a que melhor modela a mudança, considerando uma transformação **T**. Para cada forma básica, é medida a similaridade com a Gaussiana apresentada. O modelo que obtiver a melhor representação é definido como formato da mudança.

Como medida de similaridade entre matrizes de covariância foi utilizada a métrica proposta no trabalho de Forstner e Moonen (Forstner and Moonen, 1999). Tal métrica é descrita na equação abaixo:

$$d(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2) = \sqrt{\sum_{i=1}^N ln^2 \lambda_i(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2)}, \qquad (3)$$

onde  $\Sigma_1$  e  $\Sigma_2$  são duas matrizes de covariância,  $\lambda$ são os autovalores generalizados das matrizes  $\Sigma_1$ e  $\Sigma_2$ , e N é a dimensionalidade das matrizes, no caso três. Neste trabalho, a matriz  $\Sigma_1$  representa a covariância da função Gaussiana referente a uma mudança identificada pelo algoritmo de detecção de mudança. A matriz  $\Sigma_2$  é a covariância associada à forma ideal (cada forma é representa por uma matriz no espaço de Gaussianas). Considerando as rotações e escalas possíveis para a forma da mudança, a Equação 4 foi utilizada.

$$\boldsymbol{\Sigma}_i = \mathbf{T} \boldsymbol{\Sigma}_j \mathbf{T}^T = (\mathbf{R} \cdot \mathbf{L}) \boldsymbol{\Sigma}_j (\mathbf{R} \cdot \mathbf{L})^T, \quad (4)$$

onde  $\mathbf{T}$  é a transformação rígida aplicada à forma ideal (sem escala nem rotação), sendo composta pela matriz de rotação  $\mathbf{R}$  e pela matriz  $\mathbf{L}$ , essa definida como uma matriz diagonal com os fatores de escala em cada eixo.

A Equação 3 é minimizada usando mínimos quadrados, baseado no algoritmo de Levenberg-Marquardt. Neste é modificada a rotação e escala a cada iteração. A inicialização dos parâmetros é feita por meio dos autovetores e autovalores da matriz de covariância da mudança.

#### 4.2 Superquádricas

A superquádrica é um modelo compacto de representação de formas. Ela é definida por dois parâmetros de forma  $(\epsilon_1, \epsilon_2)$  e três de escala  $(a_1, a_2, a_3)$ . A equação implícita das superquádricas é:

$$F(x,y,z) = \left( \left(\frac{x}{a_1}\right)^{\frac{2}{\epsilon_2}} + \left(\frac{y}{a_2}\right)^{\frac{2}{\epsilon_2}} \right)^{\frac{\epsilon_2}{\epsilon_1}} + \left(\frac{z}{a_3}\right)^{\frac{2}{\epsilon_1}}.$$
(5)

A informação sobre a posição de um dado ponto (x, y, z) em relação à superfície da superquádrica é dada por essa equação. Basicamente, se o valor for igual a um, o ponto encontrase na superfície. Caso contrário, se for maior que um, encontra-se fora da superquádrica, se for menor, está dentro da superquádrica. Isso permite efetuar a determinação da superquádrica de forma eficiente (Jaklič et al., 2000). Para representar superquádrica em um sistema de coordenadas global, como no caso da detecção de mudança, mais seis parâmetros para a pose são necessários. Logo, têm-se onze parâmetros no modelo final ( $\Lambda = \lambda_1, \ldots, \lambda_{11}$ ).

Para a estimação de um modelo a partir de um conjunto de pontos utiliza-se o método de minimização de quadrados, baseado no algoritmo de Levenberg-Marquardt (Jaklič et al., 2000). Embora outros método possam ser utilizados, esse é o mais rápido (Chevalier et al., 2003).

Neste trabalho, a partir de um modelo inicial utiliza-se o paradigma *split-and-merge* para buscar uma melhor representação em superquádricas da mudança, detalhada na subseção a seguir. Posteriormente, é realizado um refinamento no modelo baseado na abordagem multi-escala. Esse refinamento é realizado em apenas dois níveis, um nível inicial com dados simplificados e, um posterior, com os dados completos da nuvem de pontos.

# 4.3 Paradigma Split-and-Merge

A *GMM* é uma excelente *feature* para dados 3D, porém, o algoritmo utilizado para segmentação tem uma importante limitação: ele garante apenas mínimos locais. Para ultrapassar esse problema, uma abordagem utilizando o paradigma *split-andmerge* é proposta. Nessa, uma extensão ao trabalho de Chevalier *et al.* (Chevalier et al., 2003) que segmenta superquádricas é proposta: a abordagem é inicializada com segmentos dados pelo método de detecção de mudança, bem como a relação topológica é determinada a partir desse método (Seção 3.4). Essa abordagem permite uma simplificação do método, gerando redução do tempo de processamento.

O passo *split* divide o conjunto de dados, de modo que pontos de um objeto a ser reconhecido por uma superquádrica estarão em subconjuntos distintos ao fim desse passo. A divisão é efetuada utilizando um plano de corte baseado no momento de inércia (Chevalier et al., 2003), e confirmada caso a distância das duas superquádricas seja menor que a distância da superquádrica original (Equação 5). Esse método gera uma árvore binária que representa a relação topológica entre os subconjuntos. Essa relação é importante para evitar a recomputação no passo *merge*.

O passo *merge* gera um conjunto reduzido de formas, sem aumento da distância global do modelo, a partir dos subconjuntos do *split*. Ele computa uma matriz com os custos de unir as superquádricas vizinhas (com relação topológica). Iterativamente, escolhe-se um par que minimiza a distância e efetua a união, atualizando a matriz de custos.

Uma importante contribuição foi o uso de programação dinâmica por meio da matriz de custo, que permite atualizar apenas as distâncias da nova superquádrica gerada, evitando recomputar valores. Isso torna o método mais rápido que o método proposto por (Chevalier et al., 2003).

## 5 Resultados Experimentais

Neste artigo, a abordagem proposta foi avaliada utilizando dados reais de um robô móvel construindo mapas tridimensionais (montagem dinâmica), a partir de um *laser scanner* 2D; e de uma montagem estática de um *laser scanner* 2D e uma unidade de *pan-tilt*. O robô móvel utilizado foi um Pioneer 3 AT, equipado com odometria nas rodas e um laser SICK LMS 200 montado ortogonalmente ao movimento do robô. A montagem estática foi composta de uma unidade de Pan-tilt Directed Perception PTU-D46-17 e um *laser scanner* Hokuyo URG-04LX.

Em ambas as abordagens, mapas tridimensionais foram adquiridos a fim de se obter a representação do ambiente. Posteriormente, mudanças foram inseridas e uma nova leitura foi efetuada. O algoritmo para detecção e segmentação de mudança foi executado com resultados mostrados a seguir, bem como para a modelagem das mudanças.

# 5.1 Montagem Estática

A Figura 3 ilustra os resultados gerados a partir da montagem estática. Na Figura 3-A é mostrado o ambiente utilizado para gerar os mapas 3D, tratase de um ambiente de escritórios, com um corredor e portas. O mapa 3D obtido pela montagem é mostrado na Figura 3-B, onde a pessoa é destacada em vermelho no mapa, apenas de maneira ilustrativa. Pode-se notar que existe uma pequena inclinação no mapa gerado devido a um  $\mathit{offset}$  na medida de angulação da unidade de pan-tilt. As Gaussianas geradas a partir dos dois mapas 3D (sem e com mudança) são mostradas nas figuras 3-C e D. Pode-se notar que devido à presença de outliers na leitura do mapa sem mudanca, o algoritmo obtém uma Gaussiana maior (em verde) que não representa corretamente o ambiente. Porém, devido à robustez do algoritmo essa Gaussiana não foi considerada como uma mudança (mostrada em destaque na Figura 3-E).

Na Figura 3-F é mostrada a modelagem da mudança utilizando a abordagem de formas básicas. Em vermelho, é mostrado o resultado obtido pela abordagem do estado da arte de Schnabel *et al.* (Schnabel et al., 2007), enquanto em azul, é mostrado o resultado da abordagem proposta. Devido à segmentação utilizando o algoritmo EM, a forma humano foi segmentada por apenas uma Gaussiana e, consequentemente, por apenas uma forma básica. Apesar de uma pequena diferença de inclinação, ambas as abordagens obtiveram resultados semelhantes.

A Figura 3-G mostra o resultado do uso de superquádricas para a mudança da Figura 3-E. Enquanto na Figura 3-H é mostrado o resultado da abordagem proposta para segmentação de superquádricas usando o paradigma split-and-merge. Pode-se notar que a pessoa foi segmentada por um número bem maior de formas, que permite uma melhor representação. As partes do corpo são ilustradas na figura, com destaque para a segmentação do braço direito e do troco por apenas uma única superquádrica. Isso se deve ao fato de que durante a aquisição dos mapas, a pessoa está com o braço direito junto ao corpo, dificultando a segmentação. Apesar dessa dificuldade, a pessoa foi corretamente segmentada, gerando uma representação que pode permitir uma posterior classificação da forma.

# 5.2 Montagem Dinâmica

Para a obtenção de resultados experimentais da montagem dinâmica foram inseridas duas mudan-



Figura 3: Montagem Estática: A) Imagem do ambiente após inserção da mudança (pessoa ao centro do corredor); B) Mapa 3D com mudança destacada em vermelho; C) e D) mostram a representação em GMM do ambiente para o ambiente sem e com mudança, respectivamente; E) Ampliação da mudança detectada pelo algoritmo (Caixa preta em D; F) Resultado do algoritmo de modelagem de formas básicas para mudança em E; G) Representação em superquádrica da mudança em F; H) Representação em superquádricas usando abordagem proposta.

ças diferentes. Uma primeira mostrada na Figura 4-A na qual um cilindro vermelho de tamanho conhecido foi inserido ao ambiente (20 cm de raio por 47 cm altura) de forma a verificar a qualidade da abordagem. Foi inserida também uma pessoa como mudança, mostrada na Figura 4-B. O ambiente utilizado para obtenção de mapas foi de um corredor com portas, semelhante ao montagem estática. Nele, o robô percorreu cerca de 8 metros, apenas usando a informação de odometria, sujeita a erros. Pode-se notar um erro grande ao fim da leitura entre os mapas das figuras 4-C e E. Mesmo com a presença desses erros, a abordagem conseguiu detectar corretamente as mudanças (caixas em preto nas figuras 4-E e F).

Após a detecção das mudanças, elas foram modeladas por superquádricas, como mostram as figuras 4-G e H. Na Figura 4-G obteve-se uma forma com raio de aproximadamente 20cm e altura de 40cm. A diferença entre a medida de altura real do cilindro e a obtida pelo modelo se deve ao fato de que a leitura feita pelo *laser scanner* estar um pouco acima do início do cilindro, mesmo



Figura 4: Montagem Dinâmica: A) e B) Imagens do ambiente após inserção da mudança (cilindro vermelho e pessoa, respectivamente); C) e D) Representações 3D dos ambientes sem a presença de mudanças (Pontos e Gaussianas); E) e F) Representações 3D dos ambientes com mudança destacada por caixas em preta; G) e H) Representação em superquádricas usando abordagem proposta.

com a colocação de uma caixa branca para igualar as alturas de aquisição e do cilindro (mostrada na Figura 4-A). A pessoa representada na Figura 4-H, foi segmentada de uma maneira menos refinada do que na Figura 3-H, devido, principalmente, ao número de pontos obtido nas mudanças. Nesse resultado, o abdômen e os braços foram modelados pela mesma forma devido à posição dos braços da pessoa durante a aquisição dos mapas.

## 6 Conclusões

Este artigo apresentou um novo método para detectar e segmentar diretamente mudanças em um ambiente robótico, usando *laser scanner* 3D e, além disso, modelar a forma dessas mudanças usando dois modelos. Modelos de Misturas Gaussianas foram utilizados como *features* em mapas 3D, mostrando-se capaz de comprimir informação e representar adequadamente o ambiente. A métrica *EMD* associada a técnica gulosa proposta foi capaz de detectar e segmentar mudanças adequadamente. A nova técnica proposta para modelagem de formas básicas foi comparada com uma abordagem do estado da arte proposta por Schnabel *et al.* mostrando resultados semelhantes. O modelo de superquádricas associado ao paradigma *split-and-merge* deu maior expressividade a modelagem de forma de uma maneira eficiente. Os resultados experimentais em ambiente real mostram a capacidade da abordagem em detectar, segmentar e modelar as mudanças.

Trabalhos futuros vão ser focados em realizar mais experimentos validando a abordagem de uma maneira quantitativa, além de permitir o uso do método de maneira *online*. Uma possibilidade é o uso de *GMM* com aprendizado online. O objetivo final é obter um sistema completo capaz de detectar e representar objetos virtuais no ambiente do robô, com capacidade de identificar e classificar esses objetos. Outra importante melhoria proposta é a inclusão de um método de registro ao trabalho, de forma a impossibilitar o sistema de identificar regiões não escaneadas como mudanças, além de evitar a necessidade dos mapas estarem no mesmo sistema de coordenadas.

### Agradecimentos

Este trabalho contou com o apoio da CAPES, CNPQ, FAPEMIG e do projeto PROMETHEUS (EU-FP7-ICT-2007-1-214901). Os autores gostariam de agradecer também a colaboração do Prof. Pedro Nuñez e dos colegas do LRM-ISR e VerLab-UFMG.

# Referências

- Andreasson, H., Magnusson, M. and Lilienthal, A. J. (2007). Has something changed here? Autonomous difference detection for security patrol robots, *IEEE/RSJ International Conference on Intelligent Robots and Systems* (*IROS*), San Diego, EUA, pp. 3429–3435.
- Ballard, D. H. (1987). Generalizing the Hough transform to detect arbitrary shapes, Morgan Kaufmann Publishers Inc., San Francisco, EUA, pp. 714–725.
- Barr, A. H. (1981). Superquadrics and anglepreserving transformations, *IEEE Computer Graphics and Applications* 1(1): 11–23.
- Chevalier, L., Jaillet, F. and Baskurt, A. (2003). Segmentation and superquadric modeling of 3D objects, Journal of Winter School of Computer Graphics 11(1): 9–16.
- Forstner, W. and Moonen, B. (1999). A metric for covariance matrices, *Technical report*, Departament of Geodesy and Geoinformatics -Stuttgart University, Stuttgart, Alemanha.
- Fox, D., Burgard, W. and Thrun, S. (1999). Markov localization for mobile robots in dynamic environments, *Journal of Artificial Intelligence Research* 11: 391–427.

- Jaklič, A., Leonardis, A. and Solina, F. (2000). Segmentation and Recovery of Superquadrics, Kluwer Academic Publishers, Norwell, EUA.
- Lai, K. and Fox, D. (2009). 3D laser scan classification using web data and domain adaptation, *Robotics: Science and Systems (RSS)*, Seattle, EUA, pp. 1–8.
- Leonardis, A., Jaklič, A. and Solina, F. (1997). Superquadrics for segmenting and modeling range data, *IEEE Transactions on Pattern Analisys and Machine Intelligence* 19(11): 1289–1295.
- Markou, M. and Singh, S. (2003). Novelty detection: A review - part 1: Statistical approaches, Signal Processing 83(12): 2003.
- Pauly, M., Gross, M. and Kobbelt, L. P. (2002). Efficient simplification of point-sampled surfaces, *IEEE Visualization (VIS)*, IEEE Computer Society, Boston, EUA, pp. 163–170.
- Rissanen, J. (1983). A universal prior for integers and estimation by minimum description length, *The Annals of Statistics* **11**(2): 416– 431.
- Rubner, Y., Tomasi, C. and Guibas, L. J. (1998). A metric for distributions with applications to image databases, *International Conference* on Computer Vision (ICCV), IEEE Computer Society, Bombay, India, pp. 59–66.
- Rusu, R. B., Marton, Z. C., Blodow, N., Dolha, M. and Beetz, M. (2008). Towards 3D point cloud based object maps for household environments, *Robotics and Autonomous Systems* 56(11): 927–941.
- Schnabel, R., Wahl, R. and Klein, R. (2007). Efficient RANSAC for point-cloud shape detection, Computer Graphics Forum 26(2): 214– 226.
- Thrun, S., Burgard, W. and Fox, D. (2005). Probabilistic Robotics, primeira edn, The MIT Press, Cambridge, EUA.
- Vieira, M. and Shimada, K. (2005). Surface mesh segmentation and smooth surface extraction through region growing, *Computer Aided Geometric Design* 22(8): 771–792.
- Vieira Neto, H. and Nehmzow, U. (2008). Visual novelty detection for autonomous inspection robots, in Y. Takahashi (ed.), Service Robot Applications, I-Tech Education and Publishing, Vienna, Austria, pp. 309–330.