

Detecção de Mudanças e Recuperação de Forma em Mapas 3D Baseados em Nuvens de Pontos

Paulo Drews Jr¹ *, Mario Campos¹

¹Programa de Pós-Graduação em Ciência da Computação (PPGCC)
Universidade Federal do Minas Gerais (UFMG)

Resumo. *Este trabalho aborda o problema de se determinar a ocorrência de alterações em ambientes não necessariamente estruturados, representados por nuvens de pontos 3D. Apresenta-se, aqui, um arcabouço computacional baseado em modelos matemáticos que permitem a detecção e a consequente representação de mudanças em ambientes reais de maneira eficiente. A modelagem é obtida com o Modelo de Misturas de Gaussianas (GMM) sob pontos simplificados e a mudança é segmentada com o algoritmo Earth Mover's Distance (EMD), por meio de uma técnica gulosa. Essa combinação permite detectar e segmentar mudanças entre duas nuvens de pontos obtidas do ambiente em momentos distintos. Dois métodos para a recuperação de formas 3D foram desenvolvidos e analisados. O primeiro método, inovador, modela a mudança por meio de primitivas geométricas básicas (planos, esferas e cilindros) aplicadas diretamente no espaço das Gaussianas. O segundo modela as mudanças por meio de superquádricas e do paradigma split-and-merge, visando dar uma maior expressividade à representação de forma 3D. As técnicas foram validadas por meio de experimentos realizados em ambiente de simulação e em ambientes reais, onde as nuvens de pontos 3D foram obtidas por sensores laser embarcados em robôs móveis.*

1. Introdução

O problema de se detectar mudanças em ambientes é de grande relevância para aplicações como a monitoração e segurança, determinação de alterações morfológicas em membros e órgãos do corpo humano, bem como de discrepâncias em estruturas de dimensões nanométricas como estruturas moleculares e proteicas. Em particular, em robótica, resolver esse problema é de grande importância para permitir que robôs móveis possam operar de forma autônoma em ambientes dinâmicos. Para tanto, eles devem ser capazes de: (i) construir o mapa do ambiente baseado em suas percepções e simultaneamente localizar-se com respeito a esse mapa (técnica conhecida como SLAM – *Simultaneous Localization and Mapping*); (ii) navegar e explorar o ambiente com base nessa representação. Assim, a capacidade de navegar pode ser dificultada pela presença de mudanças em mapas previamente obtidos, 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, para verificar a existência de alterações. Além

*Este trabalho de mestrado foi orientado pelo professor Prof. Mario Fernando Montenegro Campos do Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Minas Gerais (PPGCC-UFMG) e co-orientado pelo Prof. Jorge Manuel Miranda Dias do Instituto de Sistemas e Robótica da Universidade de Coimbra (ISR-UC). O trabalho contou ainda com a colaboração do Prof. Rui Rocha (ISR-UC) e do Prof. Pedro Nuñez (Universidad de Extremadura). Este trabalho foi financiado parcialmente pela CAPES e pela FP6 da Comissão Européia (Projeto IRPS). O texto, na íntegra, encontra-se disponível em: <http://paloma.isr.uc.pt/~pdrews/dissertacaoFinal.pdf>

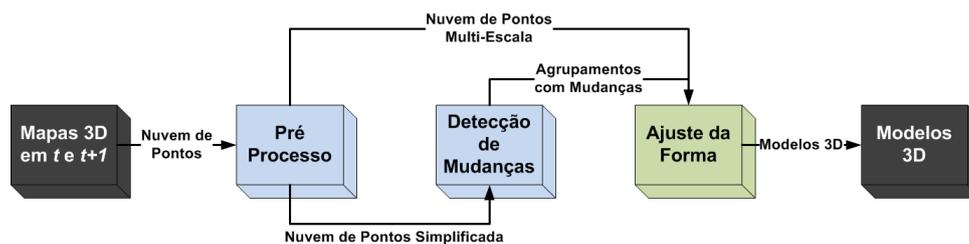


Figura 1. Visão geral da abordagem para detecção e modelagem de mudanças em ambientes.

da simples detecção, para muitas aplicações é fundamental que se obtenha determinadas características da mudança como volume e área.

O problema de detectar mudanças não é restrito a robôs móveis durante a navegação. 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 dessas mudanças. Esses dois objetivos facilitam uma posterior classificação e/ou identificação das mudanças.

Este trabalho descreve um arcabouço para detectar, segmentar e modelar mudanças. Inicialmente, os dados são pré-processados de modo a reduzir o custo computacional dos próximos passos, por meio de uma abordagem multi-escalas. Posteriormente, a detecção e segmentação de mudanças são realizadas sobre uma representação dos dados usando o *Modelo de Misturas de Gaussianas* (GMM). Por fim, a modelagem da mudança é realizada utilizando dois modelos: a primeira é baseada em formas básicas, diretamente no espaço de Gaussianas, e a segunda faz uso de superquádricas. A Figura 1 ilustra esse arcabouço.

O desenvolvimento deste trabalho trouxe contribuições relevantes para a área. A primeira delas é a simplificação de pontos em mapas 3D aplicados à robótica. Esse tipo de técnica é extensivamente utilizada em computação gráfica para possibilitar visualização rápida. Porém, poucos trabalhos na área de mapeamento 3D em robótica fazem uso deste tipo de técnica e, quando o fazem, restringem-se a reamostrar a nuvem de pontos, sem garantir as características geométricas [Andreasson et al. 2007]. O uso de GMMs para se obter características relevantes (*features*) em conjuntos de dados demonstrou ser uma abordagem robusta e descritiva, a qual, utilizando métrica *Earth Mover's Distance* (EMD), em uma implementação gulosa, possibilita a detecção e segmentação eficiente de mudanças, o que é uma abordagem inovadora e promissora.

Na área de recuperação de formas, foi proposto um novo método utilizando o espaço das Gaussianas, buscando otimizar as informações fornecidas pelo processo de detecção de mudanças, de modo a obter uma recuperação robusta e eficiente. Uma análise comparativa com um método do estado da arte foi realizada, mostrando as vantagens do método proposto.

Finalmente, para a modelagem de superquádricas, utilizou-se o paradigma *split-and-merge*, que busca contornar restrições devido ao uso do algoritmo *EM* para cálculo do *GMM*. Adaptações foram feitas buscando maximizar a eficiência considerando o uso do algoritmo *GMM* e do processo de simplificação. Foi proposta uma nova metodologia que utiliza, como inicialização, a segmentação obtida da mudança, além de recuperar a

informação topológica utilizando os dados fornecidos pela *GMM*. Um refinamento utilizando múltiplas escalas foi proposto, com objetivo de tornar a recuperação ainda mais eficiente.

2. Trabalhos Relacionados

O uso de robôs móveis em ambientes dinâmicos tem sido intensamente estudado nas duas últimas décadas. Uma das abordagens tipicamente utilizadas é remover os objetos dinâmicos do modelo, de modo a simplificar 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. 2007], no qual é proposto um sistema de detecção de mudança utilizando a informação de um sensor laser 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 existência de informação colorimétrica suficiente para se segmentar mudanças.

Em [Vieira Neto and Nehmzow 2008] foi proposto um método para detecção de mudanças para aplicações em vigilância o qual é baseado em modelo de saliência e algoritmos de clusterização. Os resultados mostraram que a abordagem detecta mudanças, principalmente quando há diferença expressiva de cor entre as alterações detectadas e o ambiente. Porém, em casos onde essa diferença de cor é pequena, o método apresenta dificuldade de detecção. Em contraste, o presente trabalho, por utilizar mapas 3D construídos com sensor laser, torna-se fundamentalmente independente de variações de condições de iluminação no ambiente e de cor das mudanças.

A determinação de forma é uma tarefa característica de diversas áreas da Geometria e da Ciência da Computação. O uso de primitivas geométricas como esferas, planos e cilindros para expressar formas mais genéricas tem sido foco de diversos trabalhos nessas áreas. Dentre as muitas abordagens, destaca-se aqui o trabalho de [Schnabel et al. 2007] para determinação de formas básicas, que utiliza RANSAC para maximizar a robustez do método à presença de ruído.

A superquádrica é um modelo para formas geométricas fechadas, que utiliza um conjunto conciso de parâmetros, mas com grande poder de expressão [Solina and Bajcsy 1990]. [Jaklič et al. 2000] consolidaram o padrão para segmentação e recuperação de forma usando superquádricas 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 bons resultados.

3. Detecção de Mudanças

No presente trabalho, uma nuvem de pontos 3D é simplificada e transformada do espaço Euclidiano para o espaço matemático de Gaussianas. Isso permite uma redução expressiva de dados e bem como permite efetuar comparações usando a métrica *EMD* de modo eficiente. Um novo algoritmo foi desenvolvido usando uma técnica gulosa, o qual realiza a segmentação das mudanças com eficiência. As principais vantagens da abordagem proposta neste trabalho são: (i) ser simples e eficaz, devido ao uso da simplificação da nuvem de pontos e ao novo algoritmo de segmentação; (ii) realizar segmentação robusta, devido à remoção de *outliers* e ao uso do espaço de Gaussianas. A descrição detalhada do método é apresentada a seguir.

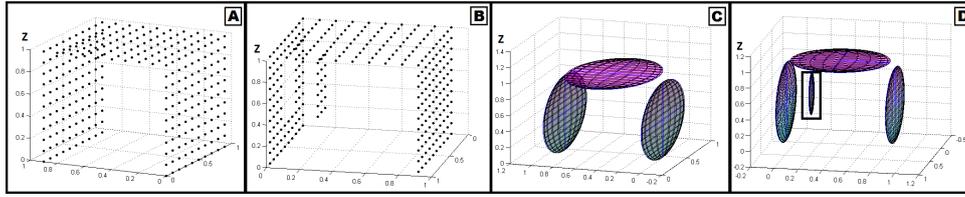


Figura 2. Detecção e segmentação de mudança usando GMM: A) Corredor ideal sem mudança com modelo em GMM em C); B) Corredor ideal com mudança, modelado por um GMM em D). A mudança detectada pelo algoritmo foi indicada pelo retângulo preto em D.

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 sensor laser 3D, diminuindo o custo computacional da abordagem como um todo. A abordagem utilizada é baseada no trabalho proposto por [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 (σ), baseada nos autovalores. A remoção de *outliers* baseado no trabalho de [Rusu et al. 2008], foi adaptada ao processo de construção da árvore.

3.2. Modelos de Misturas Gaussianas (GMM) e Earth Mover's Distance (EMD)

O Modelo de Mistura de Gaussianas é uma função de densidade de probabilidade descrita por uma combinação linear de Gaussianas, sendo um ótimo modelo para agrupamento de pontos. Assim, dado um conjunto de pontos é possível encontrar um *GMM* Θ usando o algoritmo *Expectation Maximization (EM)*. O número de Gaussianas em uma mistura (K) é selecionado a partir de um valor de K_{max} e uma função de penalidade baseado em *Minimum Description Length (MDL)*. 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 θ_i e γ_j são funções Gaussianas; p_i e q_j são os pesos associados a cada Gaussiana, respectivamente. A distância entre duas *GMM* é definida diretamente pela equação: $d_{GMM}(\Theta, \Gamma) = EMD(\Theta, \Gamma)$.

3.3. Algoritmo de Detecção e Segmentação de Mudanças

A *EMD* permite quantificar as mudanças no ambiente, mas não permite segmentá-las diretamente. Tipicamente, o problema de detecção de mudanças pode ser definido como determinar um limiar, que representa o maior valor a partir do qual é assumido uma existência de mudança. Porém, limiares fixos são de difícil determinação e dependentes das características dos dados.

Um novo algoritmo baseado em técnica gulosa foi proposto neste trabalho objetivando ultrapassar essa restrição. A Figura 2 ilustra a idéia básica do algoritmo. Além de detectar mudança, o método ainda permite a segmentação da mudança sem o uso de limiares. Enquanto a d_{GMM} for minimizada, o algoritmo remove, iterativamente, uma Gaussiana de um *GMM* associada ao mapa atual. Além disso, o algoritmo determina os conjuntos de pontos associados a cada mudança utilizando a probabilidade *a posteriori*.

Ela permite, também, identificar a relação topológica entre as Gaussianas. Essa relação será importante na modelagem por superquádricas na Seção 4.2.

4. Recuperação de Forma 3D

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. Assim, foi proposto um algoritmo que busca dentre as formas básicas conhecidas, a que melhor modela a mudança, considerando uma transformação. Para cada forma, é medida a similaridade com a Gaussiana apresentada. A medida de similaridade entre matrizes de covariância adotada neste trabalho foi proposta por [Forstner and Moonen 1999]. Tal métrica é minimizada usando mínimos quadrados, baseado no algoritmo de Levenberg-Marquardt. A cada passo do algoritmo são modificadas a rotação e a escala.

4.2. Superquádricas

A superquádrica é um modelo compacto de representação de formas, definida por dois parâmetros de forma e três de escala [Solina and Bajcsy 1990]. Para a representação em um sistema de coordenadas global, mais seis parâmetros para a pose são necessários. Logo, têm-se onze parâmetros no modelo final. A informação sobre a distância de um dado ponto em relação à superfície da superquádrica é dada pela equação implícita. Isso permite efetuar a determinação da superquádrica de forma eficiente com minimização de quadrados [Jaklič et al. 2000].

Neste trabalho, a partir de um modelo inicial utiliza-se o paradigma *split-and-merge* para buscar a superquádrica que melhor represente a forma. O passo *split* divide o conjunto de dados por meio de um plano de corte baseado no momento de inércia, obtendo uma árvore binária que representa a relação topológica entre os subconjuntos. O passo *merge* obtém um conjunto reduzido de formas, sem aumento da distorção do modelo. Ele computa uma matriz MC com os custos de unir as superquádricas vizinhas. Iterativamente, é escolhido o melhor par a ser unido com base na distância, atualizando a MC. Uma importante contribuição deste trabalho foi o uso de programação dinâmica no cálculo da MC, melhorando a eficiência em relação ao trabalho de [Chevalier et al. 2003]. Um refinamento final no modelo é realizado em dois níveis baseado na abordagem multi-escalar.

5. Resultados Experimentais

A abordagem proposta foi validada utilizando dados simulados e reais. Dois resultados obtidos em ambientes reais são mostrados a seguir. O mapa 3D (nuvem de pontos) foi obtido com o uso de um robô móvel equipado sensor laser e de uma montagem estática de uma unidade de *pan-tilt* e de um sensor laser. O robô móvel utilizado foi um Pioneer 3 AT, equipado com odometria e um laser SICK LMS 200 montado ortogonalmente ao deslocamento do robô. A montagem estática foi composta de uma unidade de Pan-tilt Directed Perception PTU-D46-17 e um sensor laser Hokuyo URG-04LX.

5.1. Montagem Estática

A Figura 3 ilustra os resultados. Na Figura 3-A é mostrado o ambiente (um ambiente de escritório) utilizado para gerar os mapas 3D após inserção da mudança (uma pessoa). O mapa 3D obtido para essa cena é mostrado na Figura 3-B, onde a mudança é destacada em

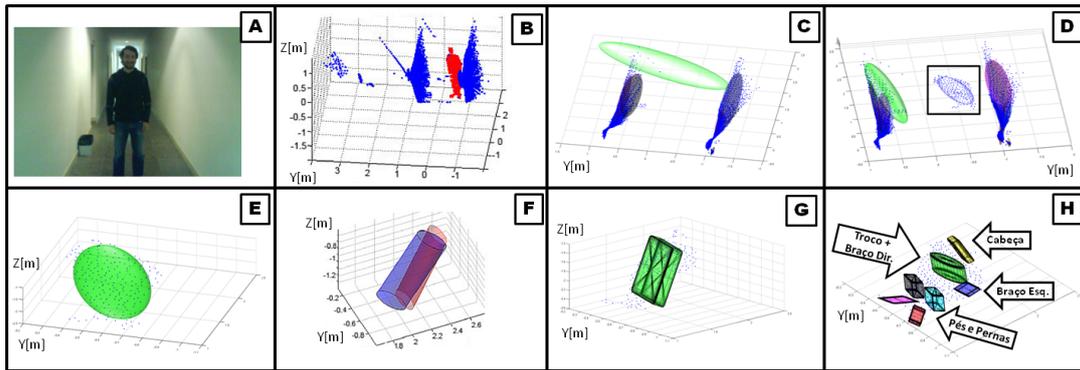


Figura 3. Montagem Estática: A) Imagem do ambiente após inserção da mudança (pessoa ao centro do corredor); B) Mapa 3D com mudança destacada em vermelho; C) e D) mostram a representação em *GMM* do ambiente para o ambiente sem e com mudança, respectivamente; E) Ampliação da mudança detectada pelo algoritmo (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.

vermelho. Pode-se notar que existe uma pequena inclinação no mapa gerado devido à um *offset* montagem 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, respectivamente. Pode-se notar que, devido à presença de *outliers* na leitura do mapa sem mudança, 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. 2007], enquanto em azul, é mostrado o resultado da abordagem proposta. Devido à segmentação utilizando o algoritmo *EM*, a forma humana foi segmentada com uma Gaussiana e, conseqüentemente, por apenas uma forma básica. Apesar de uma pequena diferença de inclinação, ambas abordagens obtiveram resultados semelhantes. A Figura 3-G mostra o modelo de superquádrica para a mudança da Figura 3-E. Na Figura 3-H é mostrado o resultado final usando o paradigma *split-and-merge* e o refinamento. 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

Dois resultados experimentais obtidos pela montagem dinâmica são mostrados. Uma primeira, na Figura 4-A, na qual um cilindro vermelho de tamanho conhecido foi inserido ao ambiente (20 cm de raio \times 47 cm altura) de forma a verificar a qualidade da abordagem. Foi inserida também uma pessoa como mudança, mostrada na Figura 4-C. Um corredor foi utilizado para obtenção de mapas, semelhante ao da montagem estática. Nele, o robô percorreu cerca de 8 metros, apenas usando a informação de odometria, fortemente sujeita a erros. Pode-se notar um erro grande ao fim da leitura entre os mapas das figuras 4-B e

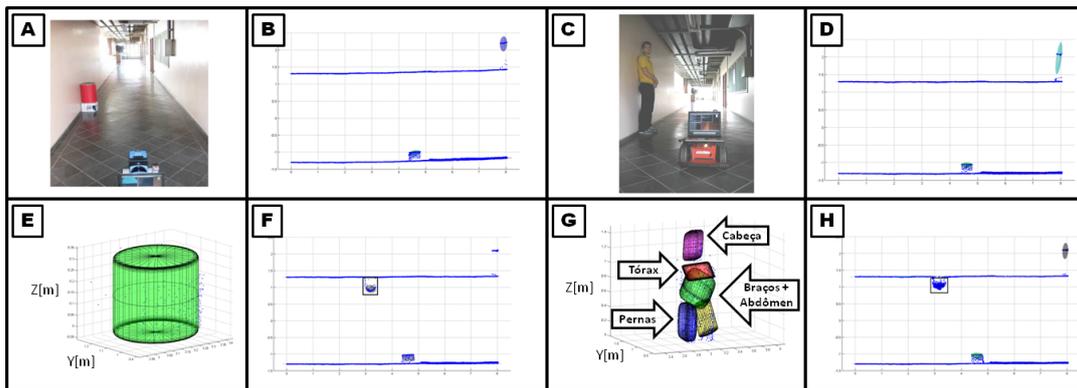


Figura 4. Montagem Dinâmica: A) e C) Imagens do ambiente após inserção da mudança (cilindro vermelho e pessoa, respectivamente); B) e D) Representações 3D dos ambientes sem a presença de mudanças; F) e H) Representações 3D dos ambientes com mudança destacada por caixas em preto; E) e G) Representação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

F. Mesmo com a presença desses erros, a abordagem conseguiu detectar corretamente as mudanças (caixas em preto nas figuras 4-F e H).

Após a detecção das mudanças, elas foram modeladas por superquádricas, como mostram as figuras 4-E e G. Na Figura 4-E obteve-se a 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 do scanner estar posicionado acima da base do cilindro, mesmo com a colocação de uma caixa branca para reduzir a diferença entre alturas (mostrada na Figura 4-A). A pessoa representada na Figura 4-G, foi segmentada de uma maneira menos refinada do que na Figura 3-H, devido, principalmente, à menor densidade de pontos do mapa.

6. Conclusões

O trabalho apresentou um novo método para detectar e segmentar diretamente mudanças, além de modelar a forma dessas mudanças usando dois modelos. Modelos de Misturas Gaussianas foram utilizados como *features*, mostrando-se capazes de comprimir informação e representar adequadamente os dados. A métrica *EMD* associada a técnica gulosa proposta foi capaz de detectar e segmentar mudanças. A nova técnica proposta para modelagem de formas básicas foi comparada com uma abordagem do estado da arte proposta por Schnabel *et al.* [Schnabel et al. 2007], mostrando resultados semelhantes. O modelo de superquádricas associado ao paradigma *split-and-merge* obteve maior expressividade, além de permitir a modelagem de uma maneira eficiente. Os resultados experimentais mostraram a capacidade da abordagem mesmo em condições reais.

Trabalhos futuros versarão sobre o objetivo final de se obter um sistema completo capaz não somente de detectar e representar objetos em ambientes, mas também de identificar e classificar.

7. Publicações Resultantes da Dissertação

Até o momento, três trabalhos em conferências internacionais foram publicados, sendo duas classificadas no extrato A do Qualis-CC. Além desses, um artigo foi submetido para o IROS 2010 (A2 – Qualis-CC) e um outro encontra-se em preparação para submissão ao periódico *Autonomous Robots* (A2 – Qualis-CC).

P. Drews Jr, P. Núñez, R. Rocha, M. Campos and J. Dias. "Novelty Detection and 3D Shape Retrieval using Superquadrics and Multi-Scale Sampling for Autonomous Mobile Robots". In *IEEE Int. Conf. on Robotics and Automation (ICRA'2010)*, Anchorage, EUA, 2010. – A1 no Qualis-CC.

P. Núñez, P. Drews Jr, R. Rocha, M. Campos and J. Dias. "Novelty Detection and 3D Shape Retrieval based on Gaussian Mixture Models for Autonomous Surveillance Robotics". In *IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS'2009)*, St. Louis, EUA, 2009. – A2 no Qualis-CC.

Diego R. Faria, José Prado, Paulo Drews Jr. and Jorge Dias. "Object Shape Retrieval through Grasping Exploration". In *European Conference on Mobile Robots (ECMR'09)*, Dubrovnik, Croácia, 2009.

Referências

- [Andreasson et al. 2007] Andreasson, H., Magnusson, M., and Lilienthal, A. J. (2007). Has something changed here? Autonomous difference detection for security patrol robots. In *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3429–3435, San Diego, EUA.
- [Chevalier et al. 2003] 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 and Moonen 1999] Forstner, W. and Moonen, B. (1999). A metric for covariance matrices. Technical report, Stuttgart University.
- [Fox et al. 1999] 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 et al. 2000] Jaklič, A., Leonardis, A., and Solina, F. (2000). *Segmentation and Recovery of Superquadrics*. Kluwer Academic Publishers, Norwell, EUA.
- [Pauly et al. 2002] Pauly, M., Gross, M., and Kobbelt, L. P. (2002). Efficient simplification of point-sampled surfaces. In *IEEE Visualization (VIS)*, pages 163–170, Boston, EUA.
- [Rubner et al. 1998] Rubner, Y., Tomasi, C., and Guibas, L. J. (1998). A metric for distributions with applications to image databases. In *International Conference on Computer Vision (ICCV)*, pages 59–66, Bombay, India.
- [Rusu et al. 2008] Rusu, R. B., Marton, Z. C., Blodow, N., Dolha, M., and Betsch, M. (2008). Towards 3D point cloud based object maps for household environments. *Robotics and Autonomous Systems*, 56(11):927–941.
- [Schnabel et al. 2007] Schnabel, R., Wahl, R., and Klein, R. (2007). Efficient RANSAC for point-cloud shape detection. *Computer Graphics Forum*, 26(2):214–226.
- [Solina and Bajcsy 1990] Solina, F. and Bajcsy, R. (1990). Recovery of parametric models from range images: The case for superquadrics with global deformations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(2):131–147.
- [Vieira Neto and Nehmzow 2008] Vieira Neto, H. and Nehmzow, U. (2008). Visual novelty detection for autonomous inspection robots. In Takahashi, Y., editor, *Service Robot Applications*, pages 309–330. I-Tech Education and Publishing, Vienna, Austria.