

DETECÇÃO E RASTREAMENTO DE VEÍCULOS EM MOVIMENTO PARA AUTOMÓVEIS ROBÓTICOS AUTÔNOMOS

EDUARDO M. A. AMARAL¹, CLAUDINE BADUE², THIAGO OLIVEIRA-SANTOS², ALBERTO F. DE SOUZA²

1. *Laboratório de Robótica e Sistemas Embarcados (LARSE), Instituto Federal do Espírito Santo Rodovia ES-010 Km 6,5, Manguiños, CEP 29173-087, Serra-ES, Brasil*
E-mail: eduardomax@ifes.edu.br

2. *Laboratório de Computação de Alto Desempenho (LCAD), Universidade Federal do Espírito Santo, Departamento de Informática*
Av. Fernando Ferrari 514, Goiabeiras, Prédio CT-VII, CEP 29075-910, Vitória-ES, Brasil
E-mails: claudine@lcad.inf.ufes.br, todsantos@lcad.inf.ufes.br, alberto@lcad.inf.ufes.br

Abstract— This work proposes a system for detection and tracking of multiple moving vehicles in the environment around an autonomous vehicle using a Light Detection and Ranging (LIDAR) 3D sensor. The proposed system operates in four steps: pre-processing, segmentation, association and tracking. At each sensor scan, the sensor data is converted into a 3D point cloud with global coordinates. In the segmentation step, the 3D points associated with the ground plane are removed; the point cloud is segmented into clusters of points using the Euclidean distance, wherein each cluster represents an object in the environment; and the clusters associated to curbs are removed. In the association step, the objects observed in the current scan sensor are associated with the same objects observed in previous scans using the nearest neighbor algorithm. Finally, in the tracking step, the states of the objects are estimated using a particle filter. Objects with velocity above a given threshold are considered moving vehicles. The experimental results showed that the proposed system was able to detect and track multiple moving vehicles on the environment around the autonomous vehicle with good performance.

Keywords— Robotics, intelligent systems, detection and tracking of moving objects, autonomous robotic vehicles.

Resumo— Este trabalho propõe um sistema para detecção e rastreamento de múltiplos veículos em movimento no ambiente ao redor de um veículo autônomo usando um sensor *Light Detection and Ranging* (LIDAR) 3D. O sistema proposto opera em quatro etapas: pré-processamento, segmentação, associação e rastreamento. A cada varredura do sensor, na etapa de pré-processamento, os dados do sensor são convertidos em uma nuvem de pontos 3D com coordenadas globais. Na etapa de segmentação, os pontos 3D associados ao plano do solo são removidos; a nuvem de pontos é segmentada em agrupamentos de pontos usando a distância Euclidiana, sendo que cada agrupamento representa um objeto no ambiente; e os agrupamentos associados a meios-fios são removidos. Na etapa de associação, os objetos observados na varredura atual do sensor são associados aos mesmos objetos observados em varreduras anteriores usando o algoritmo do vizinho mais próximo. Finalmente, na etapa de rastreamento, os estados dos objetos são estimados usando um filtro de partículas. Os objetos com velocidade acima de um determinado limiar são considerados veículos em movimento. Os resultados experimentais mostraram que o sistema proposto foi capaz de detectar e rastrear múltiplos veículos em movimento no ambiente ao redor do veículo autônomo com bom desempenho.

Palavras-chave— Robótica, sistemas inteligentes, detecção e rastreamento de objetos em movimento, veículos robóticos autônomos.

1 Introdução

A percepção confiável do ambiente é um passo muito importante para um veículo robótico autônomo. Ela é geralmente dividida em duas subtarefas: mapeamento e localização simultâneos (*simultaneous localization and mapping* - SLAM) e detecção e rastreamento de objetos em movimento (*detection and tracking of moving objects* - DATMO) (Azim and Aycard, 2012).

SLAM envolve a construção de um mapa do ambiente (e.g., lista de objetos no ambiente e suas posições) ao redor do veículo autônomo à medida que o veículo está navegando no ambiente e, simultaneamente, a estimativa do estado (e.g., posição e orientação) do veículo em relação ao mapa (Thrun et al., 2005). Para construir um mapa, o veículo autônomo requer a habilidade de detectar objetos estáticos, de forma que possa representá-los no mapa, bem como a capacidade de detectar e rastrear objetos em movimento, de forma que possa filtrá-los do mapa.

SLAM não foi investigado neste trabalho, visto que sistemas de mapeamento e localização já foram desenvolvidos para o veículo autônomo usado na avaliação experimental deste trabalho.

DATMO envolve a detecção de cada objeto em movimento no ambiente ao redor do veículo autônomo e o seu rastreamento, i.e., estimativa do seu estado (e.g., posição, orientação e velocidade) ao longo do tempo (Petrovskaya et al., 2012). O veículo autônomo precisa estimar os estados dos objetos ao longo do tempo, de forma que possa predizê-los alguns segundos mais tarde para fins de SLAM e navegação.

Diversas abordagens foram propostas para a solução do problema de DATMO (Wang et al., 2003; Almeida et al., 2005; Vu et al., 2007; Vu and Aycard, 2009; Al-Mutib et al., 2012; Azim and Aycard, 2012). Uma revisão bibliográfica de DATMO pode ser encontrada em Pancham et al. (2011) e Petrovskaya et al. (2012). Em sua maioria, estas abordagens foram implementadas com base nos dados obtidos por sensores 2D, principalmente sensores *Light Detection and Ranging* (LIDAR) 2D. Estes

sensores digitalizam o ambiente ao longo de um plano dentro de um ângulo de visão limitado e, assim, objetos acima ou abaixo deste plano não podem ser detectados.

Recentemente, sensores LIDAR 3D foram introduzidos comercialmente. Com vários lasers distribuídos sobre um campo vertical e com este campo girando 360 graus, estes sensores constroem uma nuvem de pontos detalhada do ambiente. Contudo, o problema de DATMO usando sensores LIDAR 3D ainda é pouco investigado (Petrovskaya et al., 2012). Uma razão é que sensores LIDAR 3D fornecem uma grande quantidade de dados, muitas vezes maior do que a de um LIDAR 2D, cuja manipulação requer estruturas de dados e algoritmos eficientes. Outra razão é que a extração e a interpretação de informação de dados de geometria em 3D são muito mais complexas do que a de geometria em 2D (Azim and Aycard, 2012).

Independente da tecnologia de sensoriamento adotada, a maioria das abordagens propostas para DATMO é baseada em um processamento clássico realizado em quatro etapas: pré-processamento dos dados do sensor, segmentação da nuvem de pontos 3D, associação dos segmentos e rastreamento dos objetos em movimento (Vu and Aycard, 2009; Al-Mutib et al., 2012; Azim and Aycard, 2012).

Este trabalho propõe um sistema de DATMO para detecção e rastreamento de múltiplos veículos em movimento no ambiente ao redor de um veículo autônomo usando um sensor LIDAR 3D. O sistema de DATMO proposto é baseado no processamento clássico realizado em quatro etapas mencionado acima. O desempenho do sistema de DATMO proposto foi avaliado usando dados de um sensor LIDAR 3D, além de dados de outros sensores, coletados por um veículo autônomo ao longo de uma volta pelo anel viário do campus da Universidade Federal do Espírito Santo (UFES). Os resultados experimentais mostraram que o sistema de DATMO proposto foi capaz de detectar e rastrear com bom desempenho múltiplos objetos em movimento no ambiente ao redor do veículo autônomo.

Até onde pudemos examinar na literatura, a combinação de técnicas que empregamos para resolver o problema de DATMO é única e os resultados que obtivemos são satisfatórios.

2 Sistema de Detecção e Rastreamento de Veículos em Movimento

A Figura 1 mostra o diagrama de fluxo do sistema de DATMO proposto que é descrito em detalhes seguir.

O sistema de DATMO proposto opera em quatro etapas: pré-processamento dos dados do sensor, segmentação da nuvem de pontos 3D, associação dos segmentos e rastreamento dos veículos em movimento.



Figura 1. Diagrama de fluxo do sistema de DATMO proposto

2.1 Pré-Processamento dos Dados do Sensor

Na etapa de pré-processamento, os dados do sensor LIDAR 3D são convertidos em uma nuvem de pontos 3D com coordenadas globais. Nesta etapa, os parâmetros de entrada são os dados do sensor LIDAR 3D, o estado (posição e orientação) do veículo autônomo e o estado (posição e orientação) do sensor LIDAR 3D em relação ao veículo; e o parâmetro de saída é uma nuvem de pontos com coordenadas globais. Na nuvem de pontos, cada ponto 3D p_i é representado por uma coordenada global (x_i, y_i, z_i) ; o componente z_i está em um eixo ortogonal ao plano xy e, portanto, representa a altura de p_i . Figura 2(a) mostra um exemplo de uma nuvem de pontos com coordenadas globais.

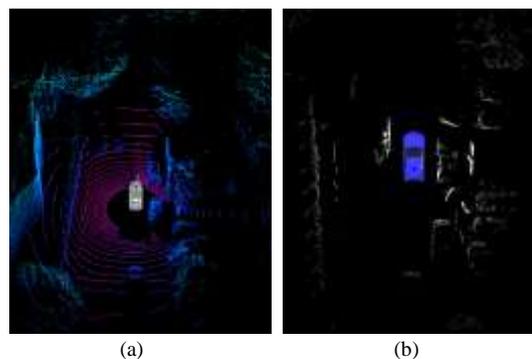


Figura 2. (a) Exemplo de uma nuvem de pontos 3D com coordenadas globais. Os pontos destacados em azul possuem $z_i > 0$ e aqueles destacados em vermelho possuem $z_i \leq 0$. (b) Nuvem de pontos após a remoção do plano do solo. Os pontos em branco são associados aos objetos considerados obstáculos

2.2 Segmentação da Nuvem de Pontos 3D

Na etapa de segmentação, no primeiro passo, os pontos do plano do solo são removidos. A remoção do plano do solo melhora significativamente a segmentação da nuvem de pontos em agrupamentos de pontos que representam objetos no ambiente (Douillard et al., 2011). Para detectar o plano do solo, usou-se uma abordagem baseada nas probabilidades de ocupação das regiões ao redor do veículo autônomo armazenadas em um mapa de *grid* de ocupação. Uma abordagem semelhante foi usada por Vu et al. (2007).

Um *grid* de ocupação representa o mapa do ambiente ao redor do veículo autônomo por um quadriculado composto por células associadas a regiões

igualmente espaçadas. Cada uma dessas células armazena a probabilidade de ocupação, i.e., a probabilidade de existir um obstáculo dentro dos limites de sua região. As células com probabilidade de ocupação maior ou igual a um determinado limiar são consideradas associadas a regiões pertencentes a obstáculos; as outras células são consideradas associadas a regiões pertencentes ao plano do solo e os pontos a elas associados são removidos da nuvem de pontos. A Figura 2(b) mostra um exemplo de uma nuvem de pontos após a remoção do plano do solo.

No segundo passo, a nuvem de pontos é segmentada em agrupamentos de pontos, sendo que cada agrupamento (ou segmento) representa um objeto no ambiente. Para agrupar os pontos, usou-se uma abordagem de agrupamento por distância Euclidiana denominada *Euclidean Cluster Extraction* implementada pela Biblioteca *Point Cloud Library* (PCL) (Rusu and Cousins, 2011).

Cada objeto o_j é descrito por um segmento c_j e um carimbo do tempo t_j da varredura do sensor na qual ele foi observado, e cada ponto $p_i \in c_j$ é representado por uma coordenada global (x_i, y_i, z_i) . Cada objeto o_j é inserido em uma lista de objetos $L_A = \{o_1, o_2, \dots, o_M\}$, onde M é o número de objetos observados. A Figura 3 mostra um exemplo de uma nuvem de pontos após sua segmentação.



Figura 3. Exemplo de uma nuvem de pontos 3D após sua segmentação. Os pontos associados a diferentes agrupamentos (ou segmentos), que representam diferentes objetos no ambiente, são destacados por cores diferentes

Finalmente, no terceiro passo, os segmentos associados a meios-fios são removidos. Meios-fios bem como muros, cercas e prédios longos podem ser frequentemente confundidos com objetos em movimento em decorrência do deslocamento do centro de massa do objeto estático na fase de associação dos segmentos (Seção 2.3). Para detectar os segmentos associados a meios-fios, usou-se uma abordagem de detecção de meios-fios baseada nas características geométricas dos objetos.

Geralmente, o objeto candidato a meio-fio possui uma geometria contínua e horizontalizada. Além disso, em objetos com geometria horizontalizada, a variância das alturas dos pontos pertencentes aos segmentos associados tende a ser menor. Por isso, usou-se a média μ e a variância σ^2 das alturas dos pontos dos segmentos como critérios para a escolha do segmento candidato a meio-fio. Se μ for inferior a um limiar μ_{limiar} e σ^2 for inferior a um limiar

σ_{limiar}^2 , onde μ_{limiar} e σ_{limiar}^2 são parâmetros do algoritmo, este segmento é removido da lista de segmentos identificados na fase de agrupamento dos pontos.

2.3 Associação dos Segmentos

Na etapa de associação, os segmentos (ou objetos) observados na varredura atual do sensor LIDAR 3D são associados aos mesmos objetos observados em varreduras anteriores. Para associar os objetos, usou-se uma abordagem baseada no centro de massa dos objetos e no algoritmo do vizinho mais próximo. Uma abordagem semelhante foi usada por Azim e Aycard (2012).

Inicialmente, para cada objeto $o_j \in L_A$, é computado o centro de massa $m_j = (x_j, y_j, z_j)$ da nuvem de pontos 3D do objeto, que passa a representar o_j , e m_j é projetado no plano xy , ou seja, $z_j = 0$. Com isso, cada objeto é representado por um simples ponto projetado no plano xy .

Em seguida, é definida uma nova lista de objetos L_B . Na primeira varredura do sensor, os objetos de L_A são inseridos em L_B , juntamente com seus centros de massa. Nas próximas varreduras do sensor, para cada objeto $o_j \in L_A$, procura-se o vizinho mais próximo $v_i \in L_B$ em um círculo com raio $r < a_{limiar}$, onde a_{limiar} é um parâmetro do algoritmo. Como medida de proximidade, usou-se a distância Euclidiana entre os centros de massa dos objetos.

Caso um vizinho mais próximo seja encontrado, a nuvem de pontos de v_i é substituída pela nuvem de pontos de o_j e o carimbo de tempo t_i de v_i é substituído pelo carimbo de tempo t_j de o_j . Além disso, um *flag* é desligado em v_i para indicar que ele já foi associado a um determinado objeto o_j , a fim de evitar que mais de um objeto em L_B seja associado a um mesmo objeto em L_A . Caso um vizinho mais próximo não seja encontrado, o_j é inserido em L_B como um novo objeto observado no ambiente.

Os objetos são eliminados de L_B quando atingem uma determinada distância Euclidiana do veículo autônomo. Para isso, a cada varredura do sensor, as distâncias entre os centros de massa de cada objeto e a posição global do veículo autônomo são calculadas e verificadas.

2.4 Rastreamento dos Veículos em Movimento

Na etapa de rastreamento, o estado (posição, orientação e velocidade) dos objetos é estimado usando um filtro de partículas. Para estimar o estado dos objetos, usou-se um filtro de partículas denominado *bootstrap* ou re-amostragem por importância da amostragem (*sampling importance resampling* – SIR) (Arulampalam et al., 2002). Um filtro de partículas representa a função de densidade de probabilidade do estado do objeto por um conjunto de amostras aleatórias (ou partículas), ao invés de por uma função sobre o espaço de estados. A cada iteração, o filtro *bootstrap* opera em três fases: predição, correção e re-

amostragem. Uma abordagem semelhante foi usada por Almeida et al. (2005).

Inicialmente, um filtro com um conjunto de M partículas é criado para cada um dos objetos pertencentes a L_B . Cada partícula é uma instanciação do estado do objeto no tempo t e é denotada por X_t^m . O estado da partícula é descrito pelo vetor $X_t^m = (x_t^m, y_t^m, \theta_t^m, v_t^m)$, onde (x_t^m, y_t^m) é a posição da partícula, θ_t^m é a orientação e v_t^m é a velocidade. A posição das partículas é inicializada com a posição do centro de massa da nuvem de pontos do objeto; a orientação é inicializada com um valor aleatório de uma distribuição uniforme no intervalo $[-\pi, \pi]$; e a velocidade é inicializada com um valor aleatório de uma distribuição uniforme no intervalo $[0, 25]$ m/s.

O filtro opera quando uma associação de um objeto observado no tempo atual $t = t_j$ é feita a um objeto observado em um tempo anterior $t - 1 = t_k$. Na fase de predição, para estimar o estado de cada partícula X_t^m no tempo $t = t_j$ com base no estado da partícula X_{t-1}^m em um tempo anterior $t - 1 = t_k$, usou-se um modelo de transição de estado baseado no modelo de movimento com velocidade constante, descrito pela Equação (1) e Equação (2):

$$x_t^m = x_{t-1}^m + x_{t-1}^m * v_{t-1}^m * \Delta t * \cos \theta_{t-1}^m \quad (1)$$

$$y_t^m = y_{t-1}^m + y_{t-1}^m * v_{t-1}^m * \Delta t * \sin \theta_{t-1}^m, \quad (2)$$

onde Δt é a diferença entre os carimbos de tempo $t = t_j$ e $t - 1 = t_k$. A cada predição, a orientação e a velocidade são perturbadas por um ruído gaussiano independente, de acordo com a Equação (3) e a Equação (4):

$$\theta_t^m = \theta_{t-1}^m + N(\mu, \sigma_1^2) \quad (3)$$

$$v_t^m = v_{t-1}^m + N(\mu, \sigma_2^2), \quad (4)$$

onde as funções $N(\mu, \sigma_1^2)$ e $N(\mu, \sigma_2^2)$ geram amostras aleatórias de uma distribuição normal centrada em zero (i.e., $\mu=0$) com variâncias σ_1^2 e σ_2^2 , respectivamente.

Na fase de correção, para gerar um peso w_t^m para cada partícula X_t^m com base na medida do sensor, usou-se um modelo de observação descrito pela Equação (5):

$$w_t^m = \exp(-dist_t^m), \quad (5)$$

onde $dist_t^m = \sqrt{(x_t^m - x_j)^2 + (y_t^m - y_j)^2}$ é a distância Euclidiana entre a posição da partícula e o centro de massa $m_j = (x_j, y_j)$ da nuvem de pontos do objeto projetado no plano xy . Uma abordagem semelhante foi usada por Al-Mutib et al. (2012). É importante observar que w_t^m é inversamente proporcional a $dist_t^m$ e que, para valores pequenos de $dist_t^m$, a função $\exp(-dist_t^m)$ forneceu valores suficientemente discriminativos. Após a execução da fase de correção, os pesos das partículas são normalizados.

Na fase de re-amostragem, para gerar um novo conjunto de M partículas ao re-amostrar com reposi-

ção M partículas do conjunto anterior de partículas, usou-se um algoritmo de amostragem de baixa variância (*low variance sampling*) semelhante àquele apresentado por Thrun et al. (2005). A probabilidade de amostrar uma partícula é igual ao seu peso. As partículas do novo conjunto são aquelas com maiores pesos. Sendo assim, a fase de re-amostragem reduz os efeitos do fenômeno da degeneração, pelo qual, depois de algumas iterações do filtro, as partículas recebem pesos insignificantes (Arulampalam et al., 2002).

Finalmente, o estado do objeto $\hat{X} = (\hat{x}, \hat{y}, \hat{\theta}, \hat{v})$ é estimado pela média dos estados das partículas $X_t^m = (x_t^m, y_t^m, \theta_t^m, v_t^m)$, $1 \leq m \leq M$, ponderada pelos pesos das partículas, segundo a Equação (6):

$$\hat{X} = \sum_{i=1}^M w_t^m X_t^m \quad (6)$$

Se o estado estimado para o objeto possuir uma velocidade acima de um limiar v_{limiar} , onde v_{limiar} é um parâmetro do algoritmo, então o objeto é considerado um veículo em movimento e uma caixa delimitadora é atribuída ao objeto, com formato de paralelepípedo retângulo, tamanho fixo semelhante a de um veículo de passeio, centro em (\hat{x}, \hat{y}) , orientação igual a $\hat{\theta}$ e velocidade igual a \hat{v} .

3 Metodologia Experimental

Para avaliar o desempenho do sistema de DATMO proposto, foram usados dados de um sensor LIDAR 3D, além de dados de outros sensores, coletados pelo *Intelligent and Autonomous Robotic Automobile – IARA* (Figura 4).



Figura 4. *Intelligent Autonomous Robotic Automobile (IARA)*

IARA é uma plataforma robótica experimental baseada no *Ford Escape Hybrid*. IARA tem vários sensores, incluindo: duas câmeras estéreo *Point Grey Bumblebee XB3* e duas câmeras estéreo *Bumblebee 2*; um *Light Detection and Ranging (LIDAR) 3D Velodyne HDL 32-E*; e um *GPS-aided Attitude and Heading Reference System (AHRS/GPS) Xsens MTiG*. Para processar os dados provenientes dos sensores, IARA tem quatro computadores *Dell Precision R5500*. Foram implementados diversos sistemas para IARA que permitem sua operação autônoma, tais como sistemas para mapeamento, localização, desvio de obstáculos, navegação, etc. (veja um vídeo da operação autônoma do IARA em

<http://youtu.be/4rFCjrFdR7o> e outros vídeos sobre sistemas do IARA em <http://www.youtube.com/user/lcadufes>).

Os dados dos sensores usados nos experimentos foram coletados por IARA ao longo do anel viário do campus da UFES. Estes dados foram armazenados em um arquivo de *log*. Para gerar o arquivo de *log*, um motorista guiou IARA pelo anel viário em um trajeto de aproximadamente 3.7 km. Durante a execução dos experimentos, uma ferramenta reproduziu o arquivo de *log*, enviando os dados dos sensores armazenados no arquivo de *log* para os sistemas de interesse do IARA. O mapa do ambiente ao redor do IARA e os estados do IARA em relação ao mapa foram computados pelo sistema de mapeamento e pelo sistema de localização do IARA, respectivamente.

O desempenho do sistema de DATMO proposto foi avaliado por meio da comparação visual entre a nuvem de pontos 3D com coordenadas globais gerada a partir dos dados do sensor LIDAR 3D e a saída do sistema de DATMO composta por caixas delimitadoras atribuídas aos objetos considerados veículos em movimento. Para melhor visualização dos resultados experimentais, a saída do sistema de DATMO é sobreposta à nuvem de pontos.

4 Resultados Experimentais

A Figura 5 mostra um exemplo de rastreamento de um carro se aproximando pela esquerda do IARA.

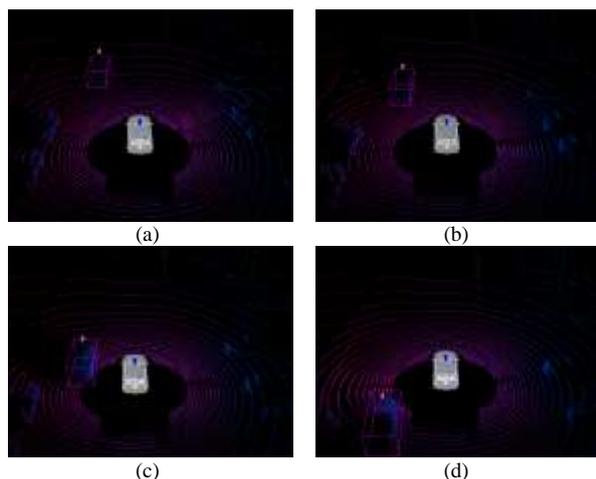


Figura 5. Exemplo de rastreamento de um carro se aproximando pela esquerda do IARA. Os números em branco sobre as caixas delimitadoras em rosa identificam o veículo que está sendo rastreado. (a) Rastreamento em um tempo t . (b) Rastreamento em um tempo $t+1$. (c) Rastreamento em um tempo $t+2$. (d) Rastreamento em um tempo $t+3$

A Figura 6 mostra um exemplo de rastreamento de dois carros que avançam pela esquerda em direção contrária ao IARA. Como observado na Figura 5 e na Figura 6, o sistema de DATMO proposto foi capaz de detectar e rastrear objetos com velocidade acima de $v_{limiar} = 3.0$ m/s. Entretanto, em alguns momentos, o sistema de DATMO detectou falsos positivos.

A Figura 7 mostra exemplos de detecções de falsos positivos. A Figura 7(a) mostra um exemplo de detecção de um objeto com contornos sinuosos; a Figura 7(b) um exemplo de detecção de um poste próximo ao meio-fio; a Figura 7(c) um exemplo de detecção de folhas de uma árvore; e a Figura 7(d) a detecção de um arbusto no canteiro central.

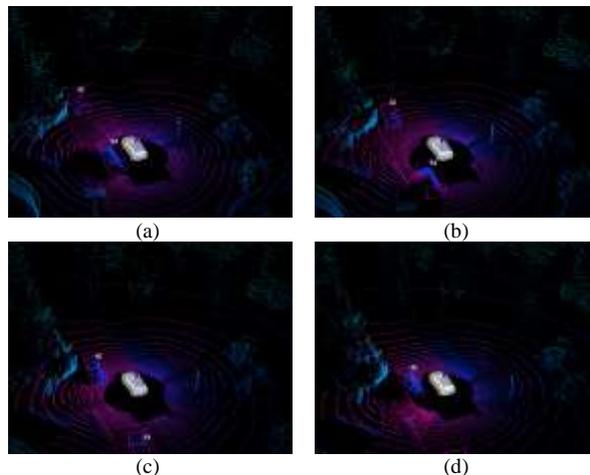


Figura 6. Exemplo de rastreamento de dois carros que avançam pela esquerda em direção contrária ao IARA. Os números em branco sobre as caixas delimitadoras em rosa identificam o veículo que está sendo rastreado. (a) Rastreamento em um tempo t . (b) Rastreamento em um tempo $t+1$. (c) Rastreamento em um tempo $t+2$. (d) Rastreamento em um tempo $t+3$

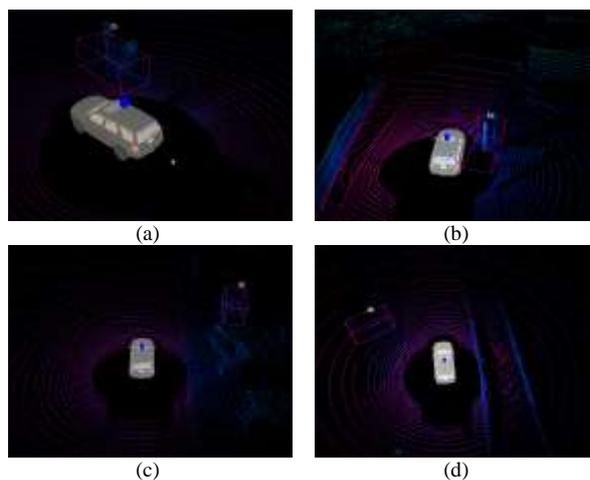


Figura 7. Exemplos de detecções de falsos positivos. Os números em branco sobre as caixas delimitadoras em rosa identificam o veículo que está sendo rastreado. (a) Exemplo de detecção de um objeto com contornos sinuosos. (b) Exemplo de detecção de um poste próximo ao meio-fio. (c) Exemplo de detecção de folhas de uma árvore. (d) Exemplo de detecção de um arbusto no canteiro central

As três causas da detecção de falsos positivos são: mudança do ângulo de observação dos objetos estáticos, a qual é provocada pela movimentação do sensor LIDAR 3D instalado no IARA; proximidade dos objetos estáticos observados; e movimentação rápida pelo vento de componentes dos objetos estáticos observados. Nestes cenários, o centro de massa do objeto estático pode se deslocar abruptamente. Isto pode gerar uma estimativa de velocidade acima

de v_{limiar} e levar o sistema de DATMO a detectar um objeto estático como um veículo em movimento.

Apesar do sistema de DATMO proposto detectar falsos positivos em decorrência do deslocamento abrupto do centro de massa do objeto estático, na maioria dos casos, o seu filtro de partículas foi eficiente para discriminar objetos estáticos e veículos em movimento ao longo do tempo, ou seja, após poucas iterações, o filtro foi capaz de corrigir velocidades estimadas erroneamente para objetos estáticos as quais os levaram a serem considerados objetos em movimento. Vale também mencionar que, no contexto de DATMO, falsos negativos são muito mais perigosos do que falsos positivos e o sistema de DATMO proposto detectou um número pequeno de falsos negativos.

Um vídeo que demonstra a operação do sistema de DATMO proposto está disponível em <https://youtu.be/9u4hl9pv2Zg>.

5 Conclusão e Trabalhos Futuros

Neste trabalho, foi proposto um sistema de DATMO para detecção e rastreamento de múltiplos veículos em movimento no ambiente ao redor de um veículo autônomo usando um sensor LIDAR 3D. O desempenho do sistema de DATMO proposto foi avaliado usando dados de um sensor LIDAR 3D, além de dados de outros sensores, coletados por um veículo autônomo ao longo de uma volta pelo anel viário do campus da UFES. Os resultados experimentais mostraram que o sistema de DATMO proposto foi capaz de detectar e rastrear com bom desempenho múltiplos objetos em movimento no ambiente ao redor do veículo autônomo.

Uma direção para trabalhos futuros seria a implementação de uma etapa de classificação dos objetos em classes de interesse, a qual poderia otimizar a fase de rastreamento. Outra vertente para pesquisas futuras seria a incorporação do tamanho do objeto em seu estado, o que permitiria a geração de caixas delimitadoras de tamanhos variados para os objetos e, conseqüentemente, o cômputo de estimativas mais precisas para os estados dos objetos. Outra sugestão para investigações futuras seria a melhoria da abordagem para o cálculo dos pesos das partículas dos objetos; uma alternativa seria calcular o peso de uma partícula com base na distância entre cada ponto do objeto e a caixa delimitadora da partícula. Finalmente, outra direção para trabalhos futuros seria a avaliação do sistema de DATMO proposto em ambientes com diversos níveis de dinamicidade.

Agradecimentos

Gostaríamos de agradecer o Instituto Federal do Espírito Santo (23158.001219/2013-61), o Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq (312786/2013-1, 552630/2011-0) e a Fundação de Amparo à Pesquisa do Espírito Santo – FAPES, Brasil (48511579/2009).

Referências Bibliográficas

- Almeida, A., Almeida, J. and Araujo, R. (2005). Real-time tracking of moving objects using particle filters, *IEEE International Symposium on Industrial Electronics*, Dubrovnik, Croatia, pp. 1327-1332.
- Al-Mutib, K., Emaduddin, M., Alsulaiman, M., Ramdane, H. and Mattar, E. (2012). Motion periodicity based pedestrian detection and particle filter based pedestrian tracking using stereo vision camera, *IEEE 19th International Conference on Mechatronics and Machine Vision in Practice (M2VIP)*, Auckland, New Zealand, pp. 32-37.
- Arulampalam, M. S., Maskell, S., Gordon, N. and Clapp, T. (2002). A tutorial on particle filters for online nonlinear/non-Gaussian bayesian tracking, *IEEE Transactions on Signal Processing*, vol. 50, no. 2, pp. 174-188.
- Azim, A. and Aycard, O. (2012). Detection, classification and tracking of moving objects in a 3D environment, *IEEE Intelligent Vehicles Symposium (IV)*, Madrid, Spain, pp. 802-807.
- Douillard, B., Underwood, J., Kuntz, N., Vlaskine, V., Quadros, A., Morton, P. and Frenkel, A. (2011). On the segmentation of 3d lidar point-clouds, *IEEE International Conference on Robotics and Automation (ICRA)*, Shanghai, China, pp. 2798-2805.
- Pancham, A., Tlale, N. and Bright, G. (2011). Literature review of SLAM and DATMO. *4th Robotics and Mechatronics Conference (RobMech)*, CSIR International Conference Centre, Pretoria, South Africa.
- Petrovskaya, A., Perrollaz, M., Oliveira, L., Spinello, L., Triebel, R., Makris, A., Yoder, J-D., Laugier, C., Nunes, U. and Bessiere, P. (2012). Awareness of road scene participants for autonomous driving, *Handbook of Intelligent Vehicles*, Springer-Verlag, London.
- Rusu, R. B. and Cousins, S. (2011). 3D is here: point cloud library (PCL), *IEEE International Conference on Robotics and Automation (ICRA)*, Shanghai, China, pp. 1-4.
- Thrun, S., Burgard, W. and Fox, D. (2005). *Probabilistic Robotics*, MIT Press, Cambridge, Massachusetts.
- Vu, T-D. and Aycard, O. (2009). Laser-based detection and tracking moving objects using data-driven Markov chain Monte Carlo, *IEEE International Conference on Robotics and Automation (ICRA)*, Kobe, Japan, pp. 3800-3806.
- Vu, T-D., Aycard, O. and Appenrodt, N. (2007). Online localization and mapping with moving object tracking in dynamic outdoor environments, *IEEE Intelligent Vehicles Symposium (IV)*, Istanbul, Turkey, pp. 190-195.
- Wang, C-C., Thorpe, C. and Thrun, S. (2003). Online simultaneous localization and mapping with detection and tracking of moving objects: theory and results from a ground vehicle in crowded urban areas, *IEEE International Conference on Robotics and Automation (ICRA)*, Taipei, Taiwan, pp. 842-849.