

Registro de imagens aplicado à estimação do ângulo de acoplamento entre veículos tratores e semirreboques

Bruno Mussoi, Jonatas Lemuel Bispo Zottis,
Guilherme Garbossa Pastre e Maicon Molon
Vertical de Mobilidade
Instituto Hercílio Randon
Caxias do Sul - RS, Brasil, 95070-560
Email: {jonatas.zottis ; bruno.mussoi
guilherme.pastre ; maicon.molon}@ihr.tec.br

Gabriela Machado Dallalba
e Guilherme Holsbach Costa
Programa de Pós-graduação em Computação Aplicada
Universidade de Caxias do Sul, Brasil, 95070-560
Email: {gmdallalba ; ghcosta}@ucs.br

Abstract—Accurate estimation of the coupling angle between a tractor and a semitrailer is crucial for the control of autonomous and semi-autonomous articulated vehicles. In freight transport scenarios, it is particularly important to estimate this angle without instrumenting the semitrailer. Existing methods in the literature often suffer from limitations such as dependence on trailer geometry, the need for recalibration at each coupling, sensitivity to weather conditions, or proprietary constraints. This paper proposes an image registration-based method for coupling angle estimation that addresses these issues and can be extended to support trailer approach maneuvers.

Resumo—A estimativa precisa do ângulo de engate entre um veículo trator e um semirreboque é crucial para o controle de veículos articulados autônomos e semiautônomos. Em cenários de transporte de cargas, é particularmente importante estimar esse ângulo sem instrumentar o semirreboque. Os métodos existentes na literatura frequentemente apresentam limitações, como dependência da geometria do reboque, necessidade de recalibração a cada engate, sensibilidade às condições climáticas ou restrições de propriedade. Este artigo propõe um método baseado em registro de imagens para a estimativa do ângulo de engate que aborda essas questões e pode ser estendido para auxiliar manobras de aproximação de reboques.

I. INTRODUÇÃO

Na área automotiva, os veículos articulados são comumente tratados como uma composição dividida em um veículo trator e um implemento. O veículo trator é popularmente chamado de *cavalo mecânico*, ou *truck*. Os implementos podem ser do tipo reboque, que se mantêm em equilíbrio ao se apoiarem apenas sobre suas próprias rodas, ou do tipo semirreboque, que precisam de um ponto de apoio para se manterem estáveis quando desacoplados do veículo trator. Os implementos podem ser classificados como rodoviários ou agrícolas.

A estimação da posição relativa (ângulo) entre implementos e veículos tratores é um tema de interesse para o controle de veículos articulados autônomos e semi-autônomos [1], [2], bem como para sistemas de apoio a motoristas durante manobras [3]. Aparentemente, até 2015 não era possível encontrar sistemas comerciais de assistência de direção para veículos articulados, e a literatura que endereçava esse tipo

de problema e o de planejamento de rotas assumia como conhecida a posição do implemento [4]. Em aplicações de transporte de cargas, principalmente, é comum o veículo trator interagir com diferentes semirreboques, sendo fortemente desejáveis as soluções que demandem pouca ou nenhuma instrumentação do implemento. Em vista disso, atualmente a literatura traz soluções baseadas em diferentes sensores, explorando principalmente o uso de câmeras [3], [4], sensores LiDAR [5]–[7], ultrassom [1] ou radar [8], dispostos exclusivamente no veículo trator.

Como será contextualizado na próxima seção, a maior parte dos métodos existentes na literatura oferece um equilíbrio entre a instrumentação do implemento e a consideração de uma geometria específica. Isto é, para que um determinado método se aplique a qualquer geometria de implemento, ele geralmente acaba por requerer algum nível de instrumentação no reboque ou semirreboque [4]. No outro extremo, abrir mão dessa instrumentação geralmente implica imputar algum tipo de restrição à geometria do implemento [6]. Quando na aplicação de interesse o acoplamento se dá por Quinta-rodas em vez de engate esférico (popularmente chamado de *bola de reboque* ou *bola de engate*) [1], [3], [8], o único método [2] da literatura, no conhecimento dos autores, que dispensa a instrumentação de implementos acoplados e aplica-se a qualquer geometria de semirreboques, como será discutido na próxima seção, tem sua aplicação comercial protegida por patente [9]. O uso dessa solução, portanto, coloca a indústria nacional em desvantagem. Além disso, o método limita-se a condições em que o veículo e o semirreboque estão acoplados, não abrangendo situações em que se deseja determinar o ângulo do semirreboque para realizar manobras de acoplamento autônomo. Por fim, baseia-se no método de *Parallel Tracking And Mapping* (PTAM) [10] que, embora paralelize as tarefas de rastreamento e mapeamento, ainda exige uma quantidade significativa de recursos computacionais para processar imagens em tempo real, o que pode prejudicar ou até mesmo inviabilizar soluções comerciais.

Neste trabalho é proposto um método alternativo a [2], com melhores características de aplicação, uma vez que dispensa calibração a cada novo acoplamento, com potencial de obter desempenho competitivo em termos de acurácia e potencialmente expansível para manobras de acoplamento. O método proposto se baseia no registro de imagens por Correlação de Fase. Considerando os requisitos de segurança da aplicação, para fins de ganho de robustez, as imagens são mapas de profundidade construídos a partir de sensores LiDAR.

Nas seções II e III é apresentada e discutida a revisão do estado-da-arte sobre estimação de posição entre veículo e reboque e sobre registro de nuvens de pontos. Na Seção IV são apresentados os fundamentos da estimação de rotação por Correlação de Fase. Na Seção V é apresentado o método proposto. Na Seção VI são apresentados e discutidos os resultados obtidos. Por fim, na Seção VII o trabalho é concluído e as principais contribuições são destacadas.

II. ESTIMAÇÃO DO ÂNGULO DO SEMIRREBOQUE

Diversos trabalhos atacam o problema, usando diferentes abordagens, sensores e condições de aplicação. A seguir é apresentada uma discussão sobre o estado-da-arte, cujos trabalhos de estimação da posição de reboques e semirreboques podem ser classificados conforme ilustrado na Figura 1. Dada a aplicação de interesse, essa revisão é focada predominantemente em implementos acoplados ou em acoplamento, sendo eles veículos de carga e, portanto, com engate por Quinta-roda. Dentre as abordagens de interesse, o foco está nas abordagens estatísticas, buscando-se com isso métodos que sejam passíveis de análise teórica e modelos analíticos que forneçam garantias de desempenho. Busca-se também, através dessas abordagens, evitar a tradicional dependência dos conjuntos de treinamento impostas pelas técnicas baseadas em redes neurais profundas. Essa revisão é resumida e esquematizada na Tabela I.

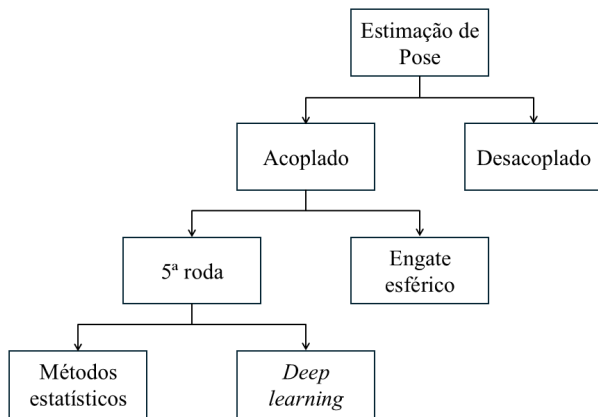


Fig. 1. Classificação de trabalhos na área.

Em [1] é proposta uma solução baseada em quatro sensores ultrassônicos. O ângulo do reboque é estimado por relações trigonométricas e refinado por filtragem de Kalman, considerando a dinâmica do veículo. O método proposto assume engates do tipo esférico, mas aparentemente pode ser

adaptado a acoplamento por Quinta-roda. Entretanto, limita-se a implementos com face plana ou em “V” (*V-nose*), o que é uma restrição substancial para a aplicação no mercado de transporte de cargas.

Em [4] é proposta uma solução baseada em câmera. Cada imagem adquirida é usada individualmente de forma a gerar uma estimação da posição desejada, e as estimações anteriores são utilizadas para refinar as estimativas atuais, através de um filtro de Kalman, melhorando substancialmente o desempenho da solução. Todavia, esse método depende de marcadores fixados no reboque, o que não é desejável em aplicações de transporte de cargas. Em tais casos, é comum que o veículo trator e o semirreboque tenham proprietários distintos e, portanto, é desejável que a solução não dependa de instrumentação ou de alterações no implemento.

Em [5] e em [6] o problema de controle do conjunto veicular é abordado. Neles, o método de estimação de ângulo proposto em [7], baseado em sensores LiDAR, é considerado. Note-se que, ainda que [5] não tenha passado por revisão por pares, é consideravelmente citado na literatura, incluindo [11]–[13]. Em [7] o método de estimação de ângulo proposto se baseia em um sensor do tipo LiDAR e assume implementos com face plana (retangular). O algoritmo de RANSAC [14] é utilizado para detectar a face (segmento de reta) do implemento por meio da vista superior da nuvem de pontos obtida com o sensor. Os pontos referentes às faces laterais do implemento, quando presentes na nuvem, são tratados de forma empírica. Esse método foi utilizado em [6], em razão de ter alcançado melhores resultados que técnicas de *Deep Learning* [15].

Em [8] os autores propõem uma solução baseada em radar, que assume implementos de face plana. O ângulo é estimado usando Análise de Componentes Principais, Mínimos Quadrados Ordinários e Estimação por Máxima Verossimilhança. O método assume acoplamento por engate esférico, mas é aplicável a acoplamento por Quinta-roda. Apesar dos radares agregarem robustez em relação à operação em ambientes adversos, a característica de baixa resolução parece se refletir nos resultados apresentados, com erros substancialmente grandes para ambiente controlado, se comparados com os resultados obtidos em outros trabalhos desta revisão.

Finalmente, em [2] é proposto um método baseado em câmera, dedicado a veículos de carga com reboques ou semirreboques, que estima o ângulo do implemento usando o método PTAM. Esse método é uma adaptação do método vSLAM (*Visual Simultaneous Localization and Mapping*) [16] para câmeras monocromáticas. A solução independe da geometria do implemento, e os resultados, validados em condições reais de aplicação, atingem erros quadráticos médios inferiores a $1,2^\circ$ para semirreboques. O PTAM se baseia em pontos característicos (chamados de *pontos de controle*) extraídos automaticamente das imagens. Quando as imagens possuem poucas informações de alta frequência, como no caso de contêineres lisos e com pintura homogênea, a acurácia da estimação tende a ser prejudicada. Ainda que os autores tragam resultados bastante expressivos, como o método se baseia em sinais de câmeras, é razoável prever perda de desempenho em

condições climáticas adversas, como no tráfego sob neblina. O método demanda uma inicialização para identificação do ângulo zero, que pode ser feita com o motorista dirigindo à frente por alguns metros. Outro ponto importante é o fato de a solução estar protegida por patente [9].

III. REGISTRO DE NUVENS DE PONTOS

O uso de sensores LiDAR sugere a aplicação de métodos de registro de nuvens de pontos [17]. Esses métodos podem ser classificados em 5 categorias [18]:

- I) Métodos baseados em *Iterative Closest Point* (ICP) — Possui garantia de convergência mas o estado-da-arte ainda busca contornar problemas de velocidade e de soluções baseadas em mínimos locais;
- II) Métodos baseados em extração de características — Método em que se baseia a proposta em [2]. Tende a perder desempenho com sinais de baixas frequências, conforme discutido no final da Seção II. O custo computacional da etapa de extração de características costuma ser similar ao do registro, penalizando essa classe de algoritmos para sinais de alta resolução;
- III) Métodos baseados em mídias intermediárias — em vez realizar o registro diretamente sobre a nuvem de pontos, transformam os dados para um outro domínio, tipicamente uma imagem representando um mapa de profundidade ou de intensidades de retorno do LASER emitido pelo sensor. Esses métodos geram perda de resolução, em relação às coordenadas tridimensionais entregues pelos sensores rotativos, mas tendem a melhorar consideravelmente o custo computacional e requisitos de memória, em relação às demais classes;
- IV) Métodos baseados em *Deep Learning* — Nuvens de pontos são dados em grande volume, esparsos e cuja estrutura é espacialmente desordenada. Por essa razão, as redes atuais possuem problemas de tempo de treinamento para esse tipo de dado. Esses métodos são fortemente dependentes do conjunto de treinamento, necessitando cobrir a ampla variedade de geometrias dos implementos;
- V) Métodos baseados em domínio da frequência — Métodos de baixo custo computacional, que permitem avaliações de desempenho analíticas. São restritivos em relação ao modelo de movimento, aplicando-se idealmente a movimentos globais, de translação, rotação e reescala.

O método proposto neste trabalho se trata das classes III e V, realizando o registro de Correlação de Fase de imagens construídas a partir de nuvens de pontos geradas por um LiDAR rotativo.

IV. REGISTRO POR CORRELAÇÃO DE FASE

Um movimento translacional e global entre duas imagens pode ser estimado usando-se a Propriedade do Deslocamento da Transformada de Fourier (TF) [19]. Para isso, considere-se duas imagens \mathbf{F}_1 (chamada de *imagem de referência*) e \mathbf{F}_2 (chamada de *imagem de entrada*), com *pixels* representados por $f_1(x, y)$ e $f_2(x, y)$, respectivamente, em que x e y são as

coordenadas de cada *pixel* nas imagens. Considere-se também que \mathbf{F}_2 é uma versão transladada de \mathbf{F}_1 , sendo

$$f_2(x, y) = f_1(x - x_0, y - y_0), \quad (1)$$

em que x_0 e y_0 são respectivamente os deslocamentos relativos entre \mathbf{F}_1 e \mathbf{F}_2 na direção das colunas e das linhas. Os elementos das respectivas transformadas de Fourier, $\tilde{\mathbf{F}}_1$ e $\tilde{\mathbf{F}}_2$, podem ser relacionados pela Propriedade do Deslocamento conforme [20]:

$$\tilde{f}_2(\xi, \eta) = e^{-j2\pi(\xi x_0 + \eta y_0)} \tilde{f}_1(\xi, \eta), \quad (2)$$

em que ξ e η são variáveis que denotam os componentes de frequência nas duas direções do domínio transformado. A fração resultante de se isolar a exponencial em (2) resulta em um problema de desconvolução. Entretanto, modelando-se as imagens como sinais aleatórios, faz mais sentido abordar esse problema de um ponto de vista estatístico. Portanto, as variáveis a serem estimadas, x_0 e y_0 , podem ser determinadas a partir do Espectro de Potência Cruzado, que consiste na Transformada Fourier de Tempo Discreto (TFTD) da sequência de correlação cruzada entre os sinais. Dada a similaridade entre as definições de convolução e de correlação (para sinais ergódicos), o Espectro de Potência Cruzada Normalizado pode ser definido diretamente de (2) como

$$\frac{\tilde{f}_2(\xi, \eta) \tilde{f}_1^*(\xi, \eta)}{|\tilde{f}_2(\xi, \eta) \tilde{f}_1^*(\xi, \eta)|} = e^{-j2\pi(\xi x_0 + \eta y_0)}, \quad (3)$$

em que $\tilde{f}_1^*(\xi, \eta)$ é o conjugado de $\tilde{f}_1(\xi, \eta)$. Sabendo-se que a TFTD inversa da exponencial complexa no lado direito de (3) corresponde a um impulso deslocado, tem-se que

$$r(x, y) = \mathcal{F}^{-1} \left\{ \frac{\tilde{f}_2(\xi, \eta) \tilde{f}_1^*(\xi, \eta)}{|\tilde{f}_2(\xi, \eta) \tilde{f}_1^*(\xi, \eta)|} \right\} = \delta(x - x_0, y - y_0), \quad (4)$$

de onde as variáveis desejadas x_0 e y_0 podem ser obtidas.

A partir disso, um movimento de rotação, objeto de interesse deste trabalho, pode ser estimado de forma similar. Considere-se agora uma imagem \mathbf{F}_1 como sendo uma versão rotacionada \mathbf{F}_2 . Segue direto de uma transformação de coordenadas que

$$f_2(x, y) = f_1(x \cos \theta_0 + y \sin \theta_0 - x_0, -x \sin \theta_0 + y \cos \theta_0 - y_0). \quad (5)$$

Aplicando-se a TFTD a (5), chega-se em [19]

$$\tilde{f}_2(\xi, \eta) = e^{-j2\pi(\xi x_0 + \eta y_0)} \times \tilde{f}_1(\xi \cos \theta_0 + \eta \sin \theta_0, -\xi \sin \theta_0 + \eta \cos \theta_0). \quad (6)$$

Como pode ser observado em (2), o efeito de um deslocamento no domínio da imagem implica unicamente em uma alteração na fase, no domínio da frequência. A partir disso, conclui-se que mudanças na magnitude, entre $\tilde{\mathbf{F}}_1$ e $\tilde{\mathbf{F}}_2$, em (6), resultam exclusivamente de uma rotação no domínio da imagem (assumindo-se a situação ideal descrita na equação). Note-se então que a aplicação da TFTD isola a informação de rotação na magnitude do espectro.

TABLE I
RESUMO ESQUEMÁTICO DOS PRINCIPAIS MÉTODOS DISPONÍVEIS NA LITERATURA

Ref.	Sensor	Abordagem	Resultados	Observações
[1]	Ultrassom	Estimação do ângulo por relações trigonométricas apoiada por métodos estatísticos.	Em pista.	Avalia a dinâmica por filtragem de Kalman. Reboques planos e <i>V-nose</i> . Acoplamento por bola de engate, mas aparentemente pode ser adaptado para acoplamento por Quinta-rodas.
[2]	Câmera	PTAM [10].	Em pista.	Aplicável a qualquer geometria de implemento. Requer calibração na inicialização.
[4]	Câmera e marcadores no semirreboque	Uso de marcadores.	Em protótipo.	Avalia a dinâmica por filtragem de Kalman.
[5]	LiDAR	Proposta em [6].	Em pista.	Não passou por revisão por pares.
[6]	LiDAR	Proposta em [7].	Em pista.	Assume implemento com face retangular.
[7]	LiDAR	Deteção de retas usando RANSAC aplicada a uma vista de topo.	Em pista.	Assume implemento com face retangular.
[8]	Radar	PCA, OLS e MLE.	Em protótipo.	Não se aplica a acoplamento por Quinta-rodas. Assume implemento com face retangular.
[15]	LiDAR	<i>Deep Learning</i> .	Em pista.	Obtém resultados melhores com o RANSAC [7] do que com <i>Deep Learning</i> .

Os parâmetros de rotação são estimados a partir da magnitude de (6):

$$|\tilde{f}_2(\xi, \eta)| = |\tilde{f}_1(\xi \cos \theta_0 + \eta \sin \theta_0, -\xi \sin \theta_0 + \eta \cos \theta_0)|. \quad (7)$$

Assumindo-se essas magnitudes como sinais de entrada de um novo problema de registro de imagens, tem-se um problema de estimação de um movimento puramente rotacional. Esse problema pode ser transformado em um problema de estimação de movimento de translação através de uma transformação do sistema de referência, em coordenadas cartesianas, para coordenadas polares, como se segue:

$$\tilde{m}_2(\rho, \theta) = \tilde{m}_1(\rho, \theta - \theta_0) \quad (8)$$

em que $\tilde{m}_1(\cdot, \cdot) = |\tilde{f}_1(\cdot, \cdot)|$, $\tilde{m}_2(\cdot, \cdot) = |\tilde{f}_2(\cdot, \cdot)|$, ρ e θ correspondem às coordenadas de módulo e de ângulo, respectivamente, no sistema de coordenadas polares que mapeiam os sinais de entrada (“imagens”) do novo problema de registro. Esse problema de estimação, sendo agora translacional, pode ser resolvido via (4).

V. MÉTODO PROPOSTO

Neste trabalho é proposto o sensoreamento do implemento a partir de um LiDAR rotativo de múltiplas linhas fixado no veículo trator, em direção à ré, conforme ilustrado na Figura 2. Os múltiplos feixes permitem um maior campo de visão, possibilitando a aplicação em diferentes geometrias de implementos, a exemplo de baús, tanques e de plataformas. De forma geral, é proposto que a nuvem de pontos adquirida seja convertida em um mapa de profundidade, caracterizando uma vista superior do implemento. O mapa de profundidade resulta, então, predominantemente no destaque da face frontal do implemento, conforme os pontos ilustrados em vermelho na Figura 3a, para o exemplo de um semirreboque de face plana. A estimativa do ângulo de acoplamento é realizada por Correlação de Fase, estimando-se o ângulo entre esse mapa de profundidade e uma versão espelhada dele em relação ao eixo central do sensor, conforme proposto em [21]. A imagem de referência usada para o registro é ilustrada na Figura 3b.

Em face do espelhamento, o ângulo de acoplamento corresponde à metade do ângulo estimado pelo método de Correlação de Fase. Além disso, uma vez que a estimação de rotação se dá com base no espectro de magnitude, que possui simetria conjugada, ela se limita a ângulos máximos de 180° ou, nesta aplicação, $\pm 90^\circ$. Usando-se o espelhamento da imagem de entrada como imagem de referência, a faixa de ângulos que se pode estimar para o ângulo proposto se reduz a $\pm 45^\circ$. Para faixas angulares maiores, é possível pós-processar as estimativas usando-se um preditor, como em [22], ou aplicar pós-processamento em domínio não transformado [19].

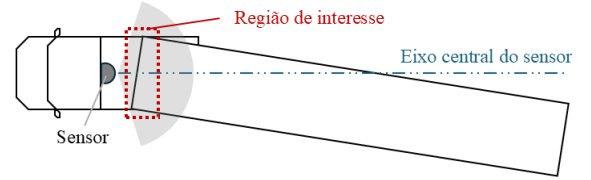


Fig. 2. Ilustração da instalação do sensor.

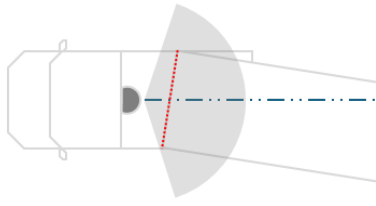
A região de interesse (RoI – *Region of Interest*) a ser submetida ao registro de imagens pode ser definida de acordo com a conveniência.

VI. RESULTADOS

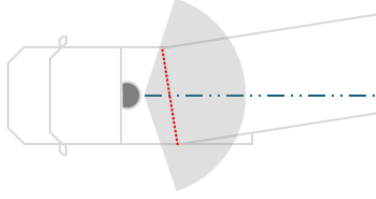
Nesta seção são apresentados resultados preliminares do método proposto aplicado ao AT4T, veículo autônomo desenvolvido pelo grupo, ilustrado na Figura 4, acoplado em um semirreboque graneleiro. O sensor utilizado é um LiDAR Velodyne modelo VLP-32C, com 32 feixes. Os mapas de profundidade foram montados com resolução de 201×201 elementos. O eixo de rotação do sensor corresponde à origem do sistema de coordenadas, o eixo x corresponde à dimensão longitudinal do veículo trator (eixo central do sensor na Figura 2) e o eixo y à direção transversal.

A. Simulações

Os resultados de simulação foram obtidos a partir do Simcenter Prescan, da Siemens, onde foram considerados modelos



(a) Imagem de entrada



(b) Imagem de referência

Fig. 3. Construção da imagem de referência.



Fig. 4. Protótipo do AT4T — veículo autônomo utilizado.

industriais do veículo e do semirreboque, desenvolvidos em CAD-3D. Foram consideradas apenas as aleatoriedades do sensor, no modelo fornecido pelo fabricante, que contemplam apenas ruído eletrônico, não gerando impacto em diferentes realizações das simulações. Foram considerados ângulos de 0° , $\pm 3^\circ$, $\pm 10^\circ$, $\pm 15^\circ$, $\pm 20^\circ$, $\pm 25^\circ$, $\pm 30^\circ$ e $\pm 35^\circ$. O erro absoluto médio resultante das simulações foi de $0,27^\circ$, com erro absoluto máximo de $1,0^\circ$.

B. Condições reais de aplicação

Não tendo sido possível, até o momento, implementar um sistema de navegação inercial (INS) no semirreboque, tem-se como *ground truth* apenas os dados inerciais do veículo trator. Preliminarmente, duas avaliações sobre o desempenho do método proposto são realizadas, com base nos dados obtidos. Na primeira delas, observa-se que os mapas de profundidade obtidos através do simulador (Figura 5) apresentam, visualmente, uma similaridade considerável com os mapas de profundidade obtidos em condições reais de aplicação (ver Figura 6). Com isso, é razoável esperar que o algoritmo

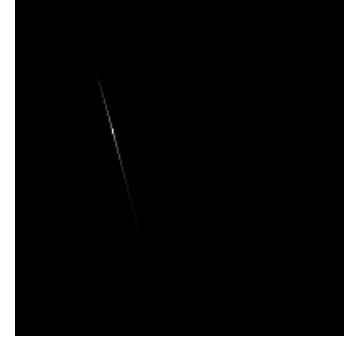


Fig. 5. Exemplo de mapa de profundidade obtido por sinais sintéticos.

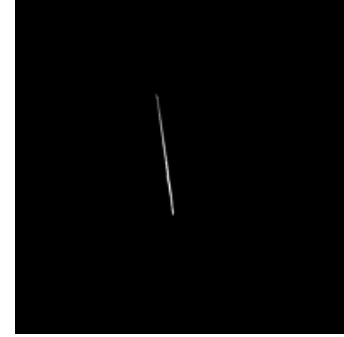


Fig. 6. Exemplo de mapa de profundidade obtido por sinais reais.

seja capaz de alcançar, em condições reais de aplicação, desempenho compatível com o obtido no simulador. Como uma segunda avaliação, os dados de azimuth do veículo trator foram processados por um modelo autorregressivo de ordem 1, do tipo

$$a_s[n] = \alpha a_s[n-1] - (1 - \alpha) \Delta a_t[n], \quad (9)$$

em que a_s é uma aproximação do azimuth do semirreboque, Δa_t é uma aproximação de primeira ordem da derivada do azimuth do trator, $\alpha = 0,999$ e n é a variável de tempo discreto. Foram negligenciados os demais parâmetros advindos da INS, incluindo velocidade e período de amostragem. A Figura 7 ilustra o comportamento do ângulo estimado pelo método proposto e o comportamento do ângulo aproximado por (9). O coeficiente de correlação obtido dessas curvas foi de aproximadamente $\rho = 0,89$.

C. Discussão

O custo computacional do método proposto está majoritariamente vinculado ao método de Correlação de Fase, que se destaca justamente pela velocidade de processamento. Esse método é tipicamente usado em aplicações de geoprocessamento, que consideram imagens de alta resolução, enquanto a solução proposta tem obtido bom desempenho usando-se mapas de profundidade com resolução de 201×201 .

A solução ainda não foi testada em condições climáticas adversas, mas a aplicação impõe uma pequena distância entre o LiDAR e o semirreboque, o que compensa a falta de desempenho desse tipo de sensor em condições de neblina,

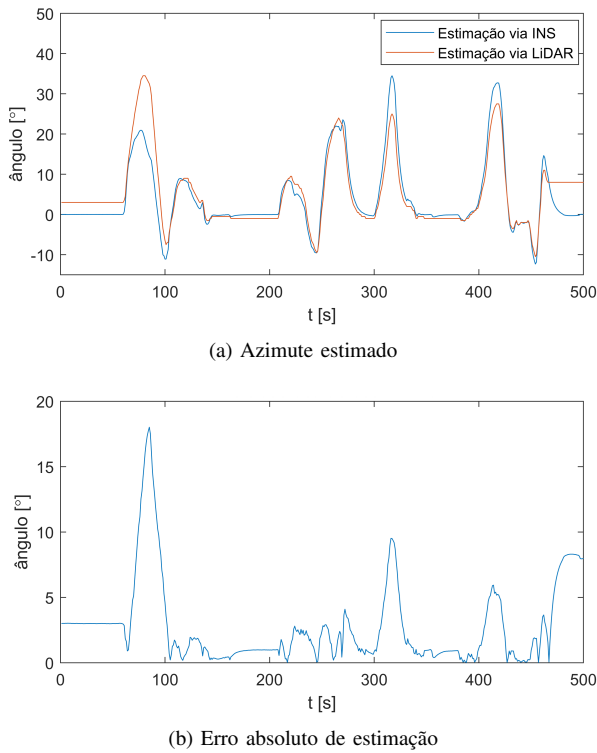


Fig. 7. Resultados das estimações do azimuth via Correlação de Fase (LiDAR) e via modelo em (9).

chuva e neve. Mesmo ante tais condições, o uso de LiDAR sugere uma maior robustez do que o registro por imagens do espectro visível [2], tipicamente mais afetadas por condições climáticas e de iluminação. Por fim, o desempenho obtido foi superior ao das técnicas revisadas, sob condições similares de avaliação.

VII. CONCLUSÕES

Neste trabalho foi apresentada uma prova de conceito acerca do sensoriamento do ângulo de acoplamento entre veículos tratores e semirreboques, baseada no registro de imagens. Como principal contribuição, o método proposto é o único dentre os trabalhos revisados na literatura que, por hipótese, reúne as seguintes características: (i) sensoriamento sem instrumentação do implemento; (ii) aplicável a qualquer geometria de semirreboque e de reboque; (iii) aplicável a qualquer tipo de engate; (iv) expansível a veículos não acoplados (em manobra de acoplamento); (v) não necessita de calibração a cada acoplamento; (vi) pode ser aplicado a sinais de LiDAR (via mapas de profundidade) e a sinais de imagens (via algoritmos de *birds eye view*). Como próximos passos, os autores estão trabalhando na expansão das simulações para condições dinâmicas e com diferentes modelos de semirreboques, bem como implementando uma unidade de navegação inercial no semirreboque, para obtenção do *ground truth*.

AGRADECIMENTOS

Os autores agradecem o Instituto Hercílio Randon (IHR) pelo financiamento desta pesquisa, bem como ao CNPq, pelo

apoio financeiro concedido sob o processo 302828/2023-0.

REFERENCES

- [1] A. Habibnejad Korayem, A. Pazooki, L. Durali, A. Khajepour, B. Fidan, A. V. Ponnuswami, and S. P. Khaligh, "Hitch angle estimation of a towing vehicle with arbitrary configuration," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 7, pp. 7535–7546, 2022.
- [2] C. d. Saxe and D. Cebon, "Camera-based articulation angle sensing for heavy goods vehicles," *IEEE Transactions on Vehicular Technology*, vol. 70, no. 8, pp. 7522–7535, 2021.
- [3] L. Caup, J. Salmen, I. Muharemovic, and S. Houben, "Video-based trailer detection and articulation estimation," in *2013 IEEE Intelligent Vehicles Symposium (IV)*, 2013, pp. 1179–1184.
- [4] C. Fuchs, F. Neuhaus, and D. Paulus, "Advanced 3-d trailer pose estimation for articulated vehicles," in *2015 IEEE Intelligent Vehicles Symposium (IV)*, 2015, pp. 211–216.
- [5] O. Ljungqvist, D. Axehill, H. Pettersson, and J. Löfberg, "Estimation-aware model predictive path-following control for a general 2-trailer with a car-like tractor," 2020. [Online]. Available: <https://arxiv.org/abs/2002.10291>
- [6] O. Ljungqvist, N. Evstedt, D. Axehill, M. Cirillo, and H. Pettersson, "A path planning and path-following control framework for a general 2-trailer with a car-like tractor," *Journal of Field Robotics*, vol. 36, no. 8, p. 1345–1377, Oct. 2019. [Online]. Available: <http://dx.doi.org/10.1002/rob.21908>
- [7] P. Nyberg, "Stabilization, sensor fusion and path following for autonomous reversing of a full-scale truck and trailer system," Master's thesis, Linköping University, 2016.
- [8] K. Olutomilayo and D. R. Fuhrmann, "Estimation of trailer-vehicle articulation angle using 2d point-cloud data," in *2019 IEEE Radar Conference (RadarConf)*, 2019, pp. 1–6.
- [9] D. Cebon and C. De Saxe, "Method and system of articulation angle measurement," WIPO Patent WO 2019/202317 A1, Oct. 2019.
- [10] G. Klein and D. Murray, "Parallel tracking and mapping for small ar workspaces," in *2007 6th IEEE and ACM International Symposium on Mixed and Augmented Reality*, 2007, pp. 225–234.
- [11] A. Habibnejad Korayem, A. Khajepour, and B. Fidan, "A review on vehicle-trailer state and parameter estimation," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 7, pp. 5993–6010, 2022.
- [12] M. Kumar, A. Haas, P. Strauss, S. Kraus, Taş, and C. Stiller, "Conception and experimental validation of a model predictive control (mpc) for lateral control of a truck-trailer," in *2022 IEEE Intelligent Vehicles Symposium (IV)*, 2022, pp. 1550–1557.
- [13] G. Xu, M. Chen, X. He, Y. Liu, J. Wu, and P. Diao, "Research on state-parameter estimation of unmanned tractor—a hybrid method of dekf and arbfnn," *Engineering Applications of Artificial Intelligence*, vol. 127, p. 107402, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0952197623015865>
- [14] M. A. Fischler and R. C. Bolles, "Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography," *Commun. ACM*, vol. 24, no. 6, p. 381–395, Jun. 1981. [Online]. Available: <https://doi.org/10.1145/358669.358692>
- [15] D. Arnström, "State estimation for truck and trailer systems using deep learning," Master's thesis, Linköping University, 2018.
- [16] C.-Z. Sun, B. Zhang, J.-K. Wang, and C.-S. Zhang, "A review of visual slam based on unmanned systems," in *2nd International Conference on Artificial Intelligence and Education (ICAIE)*, 2021, pp. 226–234.
- [17] D. Xie, W. Zhu, F. Rong, X. Xia, and H. Shang, "Registration of point clouds: A survey," in *2021 International Conference on Networking Systems of AI (INSAI)*, 2021, pp. 136–142.
- [18] Y. Zhang, S. Sun, J. Shang, and M. Yang, "Research on three-dimensional point cloud registration algorithm," in *7th International Conf. Signal and Image Processing (ICSIP)*, 2022, pp. 645–649.
- [19] B. Reddy and B. Chatterji, "An fft-based technique for translation, rotation, and scale-invariant image registration," *IEEE Transactions on Image Processing*, vol. 5, no. 8, pp. 1266–1271, 1996.
- [20] C. Kuglin and D. Hines, "The phase correlation image alignment method," in *IEEE Intl. Conf. Cybernetics and Society.*, 1975.
- [21] D. Persson and H. Deragården, "Method and system for determining an articulation angle of a vehicle combination," Patent US 2023/0194699 A1, June 2023.
- [22] J. Traa and P. Smaragdis, "A wrapped kalman filter for azimuthal speaker tracking," *IEEE Signal Processing Letters*, vol. 20, no. 12, pp. 1257–1260, 2013.