



ÁLVARO HENRIQUE ALVES MAIA

**POSICIONAMENTO POR MEIO DA LUZ
VISÍVEL APLICADO AO PROBLEMA DE
COMBOIO DE VEÍCULOS**

LAVRAS – MG

2021

ÁLVARO HENRIQUE ALVES MAIA

**POSICIONAMENTO POR MEIO DA LUZ VISÍVEL APLICADO AO
PROBLEMA DE COMBOIO DE VEÍCULOS**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia de Controle e Automação, para obtenção do título de Bacharel.

Prof. Dr. Danilo Alves de Lima
Orientador

LAVRAS – MG

2021

Dedico este trabalho à toda comunidade acadêmica e pesquisadores brasileiros.

AGRADECIMENTOS

Agradeço primeiramente, à Deus por ter me proporcionado esta oportunidade de desenvolvimento acadêmico e profissional, à minha família que sempre me apoiou e incentivou nas minhas escolhas e, também, aos meus mestres e orientadores que me apresentaram e motivaram a seguir na área de pesquisa.

RESUMO

Com os altos índices de acidentes automobilísticos recorrentes em todo o mundo, milhares de vidas são perdidas. Desses acidentes, a maioria são causados por erros humanos. Sistemas *platooning*, ou comboio de veículos, estão se mostrando uma forte solução para reduzir esses acidentes, além de aumentar a segurança e a eficiência do transporte como um todo. Pensando nisso, este trabalho busca uma solução para melhorar a estimação de posicionamento de veículos dentro desses sistemas. Para isso, é desenvolvido um sistema em simulação utilizando técnicas de posicionamento por meio de luz visível (VLP) com componentes de baixo custo e filtros probabilísticos como filtro de partículas e o filtro de Kalman. O sistema utiliza os próprios faróis traseiros do veículo dianteiro e sensores fotodiodos localizados nos faróis dianteiros do veículo de trás. Desse modo, é possível realizar a aquisição dos dados e a estimação da posição e orientação do veículo por meio do filtro de partículas e melhorar a estimação da melhor partícula utilizando o filtro de Kalman. Essa solução foi avaliada em três experimentos diferentes, simulados em Matlab, para analisar seu comportamento em situações em que os veículos estejam alinhados e mesma velocidade linear, alinhados e velocidade linear diferentes e em situação em que estejam desalinhados. Os resultados obtidos foram muito promissores obtendo, em sua maioria, uma exatidão na faixa de 10 *cm* de erro. Portanto, pode-se considerar que o projeto obteve sucesso em seus objetivos, destacando a alta capacidade de sistemas VLP no ramo veicular.

Palavras-chave: *Platooning*, VLP, Filtro de Kalman, Filtro de partículas.

ABSTRACT

With high rates of recurrent car accidents around the world, thousands of lives are lost. These ones most are caused by human error. Platooning systems, or vehicle convoys, are proving to be a strong solution to reduce these accidents, in addition to increasing the safety and efficiency of transport as a whole. With that in mind, this work seeks a solution to improve the estimation of vehicle positioning within these systems. For this, a simulation system is developed using positioning techniques through visible light (VLP) with low-cost components and probabilistic filters such as particle filter and Kalman filter. The system uses the front vehicle's own taillights and photodiode sensors located in the rear vehicle's headlights. Thus, it is possible to perform data acquisition and the estimation of the vehicle's position and orientation through the particle filter and improve the estimation of the best particle using the Kalman filter. This solution was evaluated in three different experiments, simulated in Matlab, to analyze its behavior in situations where vehicles are aligned and the same linear velocity, aligned and different linear velocity, and in situations where they are misaligned. The results obtained were very promising obtaining, for the most part, an accuracy in the range of 10 *cm* error. Therefore, it can be considered that the project was successful in its objectives, highlighting the high capacity of VLP systems in the vehicular sector.

Keywords: Platooning, VLP, Kalman filter, Particle filter.

LISTA DE FIGURAS

Figura 3.1 – Sistema Lambertiano	24
Figura 3.2 – Comportamento da potência do sinal recebida no modelo Lambertiano em relação à distância (a), ângulo de irradiação (b) e ângulo de incidência (c).	25
Figura 4.1 – Fluxograma do sistema proposto	33
Figura 4.2 – Características envolvidas na simulação	35
Figura 4.3 – Exemplo da área amostral utilizada pelo filtro de partículas delimitada pelas linhas azuis.	37
Figura 4.4 – Peso das partículas e suas respectivas posição no mapa.	38
Figura 4.5 – Diagrama modelo cinemático de um veículo com tração dianteira.	40
Figura 5.1 – Condição inicial dos experimentos 1 e 2.	44
Figura 5.2 – Análise do erro da posição x e y para veículos alinhados e com velocidades iguais.	45
Figura 5.3 – Análise do erro da posição x e y para veículos alinhados e com velocidades diferentes.	46
Figura 5.4 – Condição inicial experimento 3.	47
Figura 5.5 – Análise do erro da posição x e y para veículos desalinhados e com velocidades iguais.	47
Figura 5.6 – Comparação da distribuição do erro entre o filtro de partículas e o filtro de Kalman	48

LISTA DE ALGORITMOS

1	Filtro de partículas	26
2	<i>Low variance sampler</i>	27
3	Filtro de Kalman	29
4	Filtro de Kalman extendido	30

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivos	15
1.2	Estrutura do documento	16
2	REVISÃO DA LITERATURA	17
2.1	VLP e VLC aplicado à veículos	17
2.2	<i>Platooning</i>	19
2.3	Contextualização do projeto	22
3	CONCEITOS GERAIS	23
3.1	Modelo Lambertiano	23
3.2	Filtro de partículas	25
3.3	Filtro de Kalman	28
4	METODOLOGIA	33
4.1	Descrição do sistema	33
4.2	Modelo matemático do sistema	35
4.3	Aplicação do filtro de partículas	36
4.4	Aplicação do filtro de Kalman estendido	39
5	RESULTADOS	43
5.1	Experimento 1 - Alinhados e com velocidades iguais	43
5.2	Experimento 2 - Alinhados e velocidades diferentes	44
5.3	Experimento 3 -Desalinhados e velocidades iguais	45
5.4	Comparativo entre resultados dos filtros de partículas apenas e de partículas + Kalman estendido	48
6	CONSIDERAÇÕES FINAIS	49
	REFERÊNCIAS	51

1 INTRODUÇÃO

O crescimento populacional e a urbanização vêm provocando o aumento do número de veículos, principalmente, em capitais e regiões metropolitanas, causando lentidão nas viagens e, muitas vezes, o aumento no número de acidentes (PRADO et al., ; NETO et al., 2012). Para reduzir esses e outros problemas, muito tem sido pesquisado sobre Sistemas Avançados de Assistência ao Condutor (ADAS, do inglês *Advanced Driver Assistance Systems*), os quais implementam técnicas e tecnologias para o auxílio do condutor visando a prevenção de acidentes e até o aumento do fluxo de trânsito nas vias.

Dentre esses sistemas, é possível destacar alguns ADAS que são comumente utilizados nos veículos atuais, como o sistema de controle de viagem, que visa reduzir a fadiga do motorista em viagens muito longas e o consumo de combustível, além de, sistemas de pré-colisão, os quais são responsáveis por detectar e alertar o motorista sobre acidentes iminentes que podem vir a ocorrer com o veículo (SHAOUT; COLELLA; AWAD, 2011). Para estas aplicações, normalmente são utilizados microprocessadores, para o tratamento dos dados coletados de sensores como: radar, laser, sensores de velocidade e entre outros. Como um todo, estes são classificados como sistemas embarcados desenvolvidos apenas para o auxílio durante a condução do veículo, normalmente, necessitando ainda da intervenção do motorista no veículo (SHAOUT; COLELLA; AWAD, 2011).

Uma alternativa que visa gerar mudanças significativas dentro do âmbito veicular, são os Sistemas Automatizados de Direção (ADS - do inglês *Automated Driving Systems*), os quais pertencem aos sistemas de 3º ao 5º nível de automação da Sociedade de Engenheiros Automotivos (SAE - do inglês *Society of Automotive Engineers*), os quais são compostos por sistemas capazes de realizar o controle parcial ou total do veículo (WARRENDALE, 2021). Desse modo, os veículos ADS possuem um grande potencial para promover segurança, redução de congestionamentos, diminuir a taxa de emissão, aumentar a eficiência da via-

gem e a possibilidade de garantir um sistema autônomo para o veículo (BIEVER; ANGELL; SEAMAN, 2020).

Dentre as técnicas de comunicação empregadas por esses sistemas, uma que demonstra ser uma solução promissora é a de comunicação entre veículos (V2V - *Vehicle-to-Vehicle*) (MARÈ et al., 2016). Ela é uma ferramenta que pode contribuir muito para o desenvolvimento da mobilidade nos grandes centros urbanos, pois, segundo Wang et al. (2021), o fluxo de trânsito é maior à medida que existe mais comunicação e controle de posicionamento entre cada veículo.

Um sistema que é estudado e apresenta grandes estimativas e resultados promissores no ramo de ADAS e, até mesmo, em ADS é o sistema de comboio de veículos (*platooning*), o qual permite que os automóveis viajem de forma controlada e com uma distância menor entre eles de forma segura, eficiente e econômica (BERGENHEM et al., 2012). Realizar viagens em comboio tem várias vantagens no processo como um todo, uma destas é o alto nível de segurança na viagem e a garantia de um maior fluxo dos veículos na via, visto que, este sistema realiza uma comunicação em tempo real entre cada veículo de modo a atualizá-los sobre os estados da via e parâmetros dos demais automóveis, como dimensões, velocidade atual ou até mesmo alertar sobre eventos como uma frenagem de emergência (BERGENHEM et al., 2012). Já a redução da distância entre cada veículo, além da comunicação, este modelo demanda a implementação de um sistema de posicionamento para garantir uma maior capacidade de automóveis na via, além de, proporcionar um melhor controle longitudinal e lateral do veículo (CALVERT; SCHAKEL; AREM, 2019). No entanto, a implementação do comboio de veículos ainda possui vários empecilhos para a sua concretização no mercado, tais como a alta complexidade dos algoritmos que descrevem os modelos do sistema, a infraestrutura de comunicação, como fazer para garantir uma alta eficiência dos algoritmos e permitir que haja segurança dos dados durante a comunicação do sistema (FAKHFAKH; TOUNSI; MOSBAH, 2020).

Uma das tecnologias que são muito estudadas para a implementação de sistemas *platooning* é a baseada em luz visível, como a comunicação e posicionamento pela luz visível (VLC e VLP - do inglês, *Visible Light Communication* e *Visible Light Positioning*).

A implementação dessas técnicas no ramo de mobilidade urbana vem crescendo cada vez mais, principalmente em sistemas internos como túneis e sistemas externos com comunicação de curto alcance (GONÇALVES et al., 2021). O funcionamento do VLC e VLP consiste na multiplexação e/ou modularização de uma fonte luminosa no intuito de realizar uma comunicação entre emissor e receptor ou, até mesmo, prover informações para gerar dados de posicionamento e localização de um objeto dentro de um determinado sistema.

O *platooning* aplicado com o VLC e VLP tem sido testado em simulação, apresentando resultados promissores. Uma vez que, a precisão estimada desse sistema chega à escala de centímetros, mesmo utilizando apenas um sensor, uma fonte emissora de luz e na presença de ruídos do ambiente (SONER; ERGEN, 2019). Além disso, essa tecnologia já é estudada nas mais diversas situações, como, por exemplo, em sistemas de comboio de motocicletas (DARLIS; PRIRAMADHI; JONI, 2021).

1.1 Objetivos

O objetivo deste trabalho é apresentar uma possível solução para o sistema de comboio utilizando tecnologias baseadas em luz visível, com um foco maior no conceito de VLP. Para esse propósito, os seguintes objetivos específicos foram definidos:

- Simular um sistema de comboio de veículos juntamente com um modelo matemático que implemente o VLP e estimar os parâmetros relacionados à orientação e posicionamento do veículo traseiro em função do dianteiro por meio do VLP;

- Implementar o Filtro de Partículas para estimar a posição provável do veículo dentro de um determinado espaço amostral;
- Implementar o Filtro de Kalman Estendido para reduzir a oscilação na estimação obtida por meio do Filtro de Partículas.

1.2 Estrutura do documento

Para o melhor entendimento do leitor, este documento é dividido da seguinte maneira: no Capítulo 2 é apresentada uma revisão da literatura sobre os conceitos das tecnologias baseadas em luz visível, com um foco maior no VLP, alguns projetos que aplicam esses conceitos no ramo de veículos e estudos de implementação em sistemas de *platooning*. No Capítulo 3 são apresentados os conceitos gerais utilizados para o desenvolvimento deste projeto. A metodologia desenvolvida neste trabalho é discutida no Capítulo 4, no qual são apresentadas as equações e os modelos desenvolvidos para a implementação de filtros probabilísticos. No Capítulo 5 são encontrados os resultados do sistema obtidos em simulação. Por fim, no Capítulo 6 são apresentadas as considerações finais do trabalho e apresenta possíveis trabalhos que podem surgir desta pesquisa.

2 REVISÃO DA LITERATURA

Este capítulo possui como objetivo apresentar uma revisão da literatura sobre os conceitos das tecnologias baseadas em luz visível, por meio de análises de projetos os quais implementaram tais tecnologias e os desafios de aplicá-las em sistemas de veículos. Além disso, é realizada uma apresentação do conceito de *platooning*, um estudo de projetos que desenvolveram tal sistema e uma breve análise dos resultados e desafios encontrados.

2.1 VLP e VLC aplicado à veículos

Apesar do atual desenvolvimento da mobilidade inteligente e do nível de automação dos veículos que compõe o mercado atual, ainda existem algumas limitações físicas e computacionais nos sistemas de inteligência veicular. No âmbito do posicionamento global, parâmetro fundamental para grande parte dos sistemas de automação veicular, a limitação se encontra nos sistemas de localização tradicionais baseados no GNSS (*Global Navigation Satellite System*), os quais não fornecem precisão suficiente para garantir a segurança em tarefas de navegação e tem seu funcionamento limitado em áreas urbanas (LIMA; VICTORINO, 2015).

Esse cenário converge na busca por métodos alternativos que viabilizem a localização precisa, não apenas em ambientes urbanos, mas também em ambientes internos, como túneis, estacionamentos subterrâneos, entre outros. A Mobilidade como um Serviço (MaaS - *Mobility-as-a-Service*) considera o deslocamento como um ato contínuo e que pode ser realizado por diferentes modais, inclusive à pé, na última milha ou nos trechos de integração entre as opções de modais. Nesse sentido, o VLP e o VLC se mostram como uma solução atrativa, visto a possibilidade da junção de um posicionamento local, relativamente preciso, com posicionamento em grandes área. Ademais, tem-se a possibilidade de utilizar a própria infraestrutura de iluminação existente para esse fim (KIM; JUNG, 2016).

Uma vantagem para o uso dessas tecnologias em veículos de passeio está no fato de todos eles já possuírem dispositivos luminosos (faróis e lanternas de freio, por exemplo), possibilitando seu uso no ramo da Internet dos Veículos (IoV - *Internet of Vehicles*) (CONTRERAS-CASTILLO; ZEADALLY; GUERRERO-IBÁÑEZ, 2018). Isso viabiliza a comunicação entre veículos e a infraestrutura (V2I - *Vehicle to Infrastructure* e I2V - *Infrastructure to Vehicle*) e entre veículos (V2V - *Vehicle to Vehicle*) (MARÈ et al., 2016). Alguns projetos aplicam o V2V utilizando técnicas de VLC para comunicação entre os faróis dos automóveis (ABDUSALAM et al., 2015) e (MOHAMMED et al., 2016).

Neste último cenário, muito já se estuda sobre a implementação dessas tecnologias aplicadas a sistemas de *plattoning*. Em Soner e Coleri (2021), por exemplo, é desenvolvido um modelo no qual o sistema é capaz de fornecer, simultaneamente, uma alta taxa de comunicação, por meio de VLC, e características altas de precisão, resolução e medição para o posicionamento do veículo, por meio de sistema de Ângulo de Chegada (AoA - do inglês *Angle of Arrival*) (ZHU et al., 2019).

A comunicação I2V também já é uma das áreas de estudo para a implementação de tecnologias de luz visível. Alguns trabalhos apresentam resultados promissores para a implementação de VLP de forma complementar à VLC, como em (MATOS; VITOR; KAROLAK, 2019). Nele é apresentado um protótipo de infraestrutura pública em escala reduzida onde se aplica o VLC. Um fotodiodo identifica cada um dos cinco emissores (LEDs - *Light Emitting Diodes*), simbolizando quatro postes diferentes e um semáforo, cada um com o seu próprio código de identificação.

Apesar do fato de que a maioria dos projetos que aplicam tecnologias de luz visível em sistemas de veículos, sejam autônomos ou não, serem apenas para fins de comunicação VLC, muitos desses trabalhos fornecem os recursos necessários para a integração do VLP (GONÇALVES et al., 2021). Isso ocorre porque,

com a existência de um canal de comunicação no sistema, é possível realizar o envio das informações necessárias para que o VLP possa ser implementado de forma segura (SONER; COLERI, 2021).

2.2 *Platooning*

Sistemas de comboio de veículos, ou *Platooning*, são considerados um Sistema de Transporte Inteligente (ITS - do inglês *Intelligent Transport System*) (BĚLINOVÁ; BUREŠ; JESTY, 2010), o qual surgiu como uma solução promissora para o gerenciamento de veículos nas pistas. A ideia sugere um conjunto de veículos viajando juntos mantendo uma pequena distância entre eles de modo a aumentar a capacidade do tráfego, garantir o gerenciamento de veículos e reduzir o tempo de viagem. Nesse conjunto, um dos automóveis permanece na frente do comboio, denominado de líder, o qual possui o objetivo de detectar e orientar as ações do pelotão por meio de comunicação V2V. Desse modo, é possível antever possíveis eventos na pista e garantir conforto e segurança aos passageiros, uma vez que cenários de aceleração e desaceleração extrema são eliminados, além de reduzir a taxa de emissão e o consumo de combustível significativamente (FAKHFAKH; TOUNSI; MOSBAH, 2020).

Além dessas e outras vantagens que o *Platooning* é capaz de proporcionar, existem muitos desafios para garantir tais características no sistema. Os algoritmos a serem implementados para o controle do comboio possuem uma alta complexidade devido ao comportamento dos veículos e a diversidade de operações que estes podem executar no *platooning* (FAKHFAKH; TOUNSI; MOSBAH, 2020). Em Fakhfakh, Tounsi e Mosbah (2020), são apresentadas operações mais comuns realizadas no comboio de veículos, sendo elas classificadas em dois diferentes conjuntos. Um desses contém as operações que são realizadas dentro do *platooning* e no outro as que podem alterar a estrutura do comboio. Com relação às operações

exercidas dentro do *platooning*, essas estão associadas a uma ação que, na maioria das vezes, o conjunto inteiro deve realizá-las. Elas são listadas da seguinte forma:

- **Aceleração ou Desaceleração:** Possui o propósito de todos os veículos do conjunto realizarem a mesma ação de modo a manter sempre a mesma distância entre eles.
- **Frenagem:** É uma operação que pode ser iniciada por qualquer membro do comboio, criando uma situação em que os seguidores são obrigados a repetir tal ação de modo a evitar colisões entre os veículos.
- **Mudança de faixa:** Realizado em situações em que o veículo líder do comboio detecta algum obstáculo na faixa e faz-se necessário realizar a mudança de faixa para desviar dele, ou simplesmente ultrapassar outro veículo. Em ambos os casos, os veículos seguidores também farão a mudança de faixa.

Já as operações que provocam mudanças na estrutura do *platooning*, não necessariamente devem ser executadas por todo o conjunto de veículos, pois são mais relacionadas à união ou ao desacoplamento de veículos do comboio, as quais são listadas a seguir:

- **Unir ao comboio:** Realizada quando um veículo deseja se unir ao *platooning*.
- **Fundir comboios:** Consiste na junção de dois comboios distintos, formando um maior.
- **Sair do comboio:** Realizada quando um veículo deseja deixar o comboio, não importando sua posição nesse.
- **Dividir o comboio:** Normalmente realizada quando vários veículos desejam sair do comboio dividindo-o assim em dois comboios menores.

Alguns trabalhos apresentam estudos de algoritmos para provar a eficiência do *Platooning* diante dessas operações, como sistema de não colisão entre os veículos presentes no conjunto (EL-ZAHER et al., 2012), um veículo se unindo ou deixando o comboio (KAROUI et al., 2017), fusão entre dois conjuntos de comboios menores afim de resultar em um maior (MAITI; WINTER; KULIK, 2017). Além disso, alguns trabalhos conseguiram realizar na prática o sistema *platooning*, possibilitando, assim, validar características de segurança, eficiência, entre outras. Porém, em (BERGENHEM et al., 2012), é apresentado um desafio relacionado ao sensoriamento empregado nos projetos, o qual os deixaria inviáveis ou muito caros para serem produzidos comercialmente. Desse modo, um outro desafio para implementação desses sistemas é a viabilidade financeira.

Ao analisar a quantidade de operações básicas que podem ser executadas em sistema *platooning*, é possível perceber a complexidade de se desenvolver algoritmos seguros para executar tais tarefas, além disso, se faz necessário implementar sistemas de posicionamento precisos afim de evitar acidentes nas pistas (MÜLLER, 2017). Alguns métodos de posicionamento baseado em sensores são comumente estudados para melhor execução nessas tarefas. No entanto, esses métodos, os quais já são usados para tarefas de direção autônoma convencionais menos exigentes, falham em atender aos requisitos de taxa e precisão dos sistemas de prevenção de colisão e de *platooning* (MÜLLER, 2017).

A partir dos conceitos apresentados neste Capítulo, este trabalho buscou realizar em simulação a implementação das técnicas de luz visível, com um foco maior no sistema de VLP. O projeto busca integrar essa tecnologia em comboio de veículos, com o intuito de proporcionar uma ferramenta capaz de fornecer precisão e confiabilidade na estimação de posicionamento dos veículos contidos no *platooning*. A partir de informações de localização vindas do veículo líder do conjunto e das medidas realizadas com o VLP, deseja-se realizar tal estimação e garantir uma melhor eficiência do sistema.

2.3 Contextualização do projeto

Tendo em vista os projetos apresentados anteriormente, este trabalho busca simular um sistema semelhante ao implementado em Soner e Coleri (2021), porém, com algumas alterações. Esse projeto utiliza sensores capazes de estimar os ângulos de incidências de feixes luminosos e a posição dos emissores no ambiente. No presente trabalho, emprega-se sensores fotodiodos mais simples e de menor custo, além de ser estimada a posição e orientação do veículo de trás ao invés das coordenadas dos emissores. Dessa forma, almeja-se obter os mesmos valores que o projeto de Soner e Coleri (2021) atinge, com precisão inferior à 10 *cm* a uma taxa de 50 *Hz* e implementar adicionalmente os filtros de partículas e de Kalman para obter tais resultados.

3 CONCEITOS GERAIS

Este Capítulo apresenta os principais conceitos aplicados neste trabalho e adaptados na Metodologia (Capítulo 4). Dentre eles, o Modelo Lambertiano, que descreve o comportamento da intensidade luminosa de acordo com os parâmetros de emissão e aquisição do feixe luminoso, e os filtros probabilísticos de partículas e de Kalman, para filtragem e fusão de dados.

3.1 Modelo Lambertiano

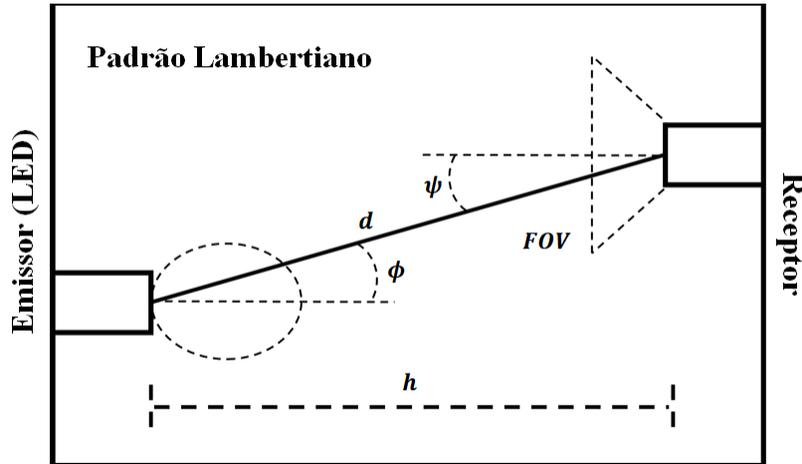
Para se compreender o modelo básico de um sistema de posicionamento por meio da luz visível (VLP, do inglês - *Visible Light Positioning*), deve-se considerar três elementos principais: o emissor, o receptor e o ambiente. Eles estão simplificados na Fig. 3.1, na qual se tem o funcionamento básico da camada física do VLP.

Algumas características devem ser consideradas para a aplicação dessa tecnologia, tais como os caminhos diretos e indiretos da luz emitida até o sensor (LOS - *Line-of-Sight* e NLOS - *Non-Line-of-Sight*, respectivamente) (YAN et al., 2015) e o modelo Lambertiano. Esse modelo representa o comportamento da potência luminosa recebida pelo sensor de acordo com a distância entre emissor e receptor, ângulo de emissão, ângulo de recepção e outras características relacionadas aos componentes utilizados (LAUSNAY et al., 2016; KIM et al., 2013) e (WANG et al., 2018). A Fig. 3.1 também ilustra o padrão Lambertiano de irradiação e o campo de visão de incidência (FOV).

Para simular os valores recebidos nos sensores, a equação que representa esse modelo e um exemplo de como são encontrados seus parâmetros podem ser observados na Equação (3.1) e na Figura 3.1, respectivamente.

$$P_r = \frac{P_e(M+1)A}{2\pi d_{ij}^2} \cos^M(\psi_{ij}) \cos(\phi_{ij}) \quad (3.1)$$

Figura 3.1 – Sistema Lambertiano



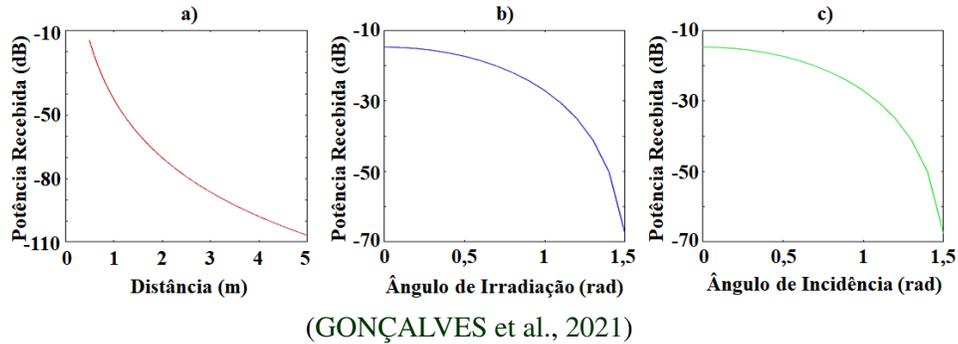
(GONÇALVES et al., 2021)

Nessa equação, P_r e P_e são as potências luminosas recebida pelo sensor e emitidas pela fonte, respectivamente, A é a área útil do sensor fotovoltaico, ϕ_{ij} e ψ_{ij} são, os ângulos de emissão e recepção, também denotados como ângulos de irradiação e incidência, formados a partir da normal de seus respectivos componentes do feixe luminoso entre o sensor i e a fonte luminosa j e M denominado como ganho Lambertiano. Esse ultimo é encontrado por meio da equação 3.2, na qual $\psi_{1/2}$ é o semi-ângulo de recepção do sensor, normalmente descrito nas especificações funcionais dele, onde também é descrito o campo de visão do componente. No caso de alguns dos sensores fotodiodos, esse parâmetro, $\psi_{1/2}$, é equivalente à 60° , fazendo com que o ganho de Lambert seja igual a 1.

$$M = \frac{\ln(2)}{\ln(\cos(\psi_{1/2}))} \quad (3.2)$$

Por fim, a variável d é referente à menor distância existente entre a fonte emissora de luz e o receptor, diferente de h , que seria a distância entre esses componentes em apenas um dos eixos.

Figura 3.2 – Comportamento da potência do sinal recebida no modelo Lambertiano em relação à distância (a), ângulo de irradiação (b) e ângulo de incidência (c).



O conhecimento do comportamento de tais parâmetros é de grande importância dentre os métodos de VLP encontrados na literatura, os quais utilizam principalmente a amplitude do sinal recebido como parâmetro principal nos algoritmos de posicionamento. A Fig. 3.2 ilustra o comportamento da amplitude do sinal recebido em função da variação de cada parâmetro espacial individualmente, sendo que para essa representação foi utilizado um fotodiodo que possui $\psi_{1/2}$ igual à 60° . Nessa Figura é possível perceber um comportamento quase exponencial da potência recebida no sensor com relação à sua distância ao emissor (LED, por exemplo). Para os ângulos de recepção e emissão, nota-se um comportamento que se aproxima de uma curva logarítmica. Também é possível observar que, a partir do semi-ângulo de emissão do LED, o qual também é uma característica do componente, o ângulo de irradiação faz com que a potência que chega no sensor seja baixa. Algo semelhante acontece com o ângulo de recepção, à medida que ele aumenta, a potência recebida é reduzida até que o feixe de luz não esteja mais no campo de visão do receptor.

3.2 Filtro de partículas

O Filtro de Partículas é uma ferramenta capaz de garantir uma rápida convergência para sistemas de localização. Essa técnica visa observar um conjunto de

dados no plano amostral e analisar, dentre eles, qual se aproxima mais das medições realizadas pelo sistema físico. Essa análise consiste em estipular um grau de importância às amostras de acordo com o quão exatas elas forem.

Algoritmo 1: Filtro de partículas

Entrada: χ_{t-1}, u_t, z_t ;
Saída: χ_t ;
1 $\chi_t = \eta = \emptyset$;
2 **para** $m = 1$ até M **faça**
3 Amostragem $x_t^{[m]} \sim p(x_t | u_t, x_{t-1}^{[m]})$;
4 $w_t^{[m]} = p(z_t | x_t^{[m]})$;
5 $\eta = \eta + w_t^{[m]}$;
6 $\chi_t = \chi_t + \langle x_t^{[m]}, w_t^{[m]} \rangle$;
7 **fim**
8 **para** $m = 1$ até M **faça**
9 $w_t^{[m]} = w_t^{[m]} / \eta$;
10 **fim**
11 Reamostragem das melhores partículas em χ_t ;

Fonte: (THRUN; BURGARD; FOX, 2005)

Os procedimentos básicos realizados pelo filtro são apresentados no Algoritmo 1, sendo M o número de partículas do conjunto, χ_t o conjunto de partículas ou amostras do sistema no tempo t , u_t o vetor de entradas do sistema, z_t o vetor das aquisições realizadas pelo sistema físico real, η o fator de normalização e w_t o vetor de pesos referente ao grau de exatidão de cada partícula. O ciclo apresentado na linha 2 à 7, consiste em atualizar os estados das partículas e atribuir um grau de importância para cada uma com relação ao quão próximo do sistema real ela está. Na linha 3 o filtro estima o estado atual de cada uma das amostras, a partir dos parâmetros de entrada do sistemas e dos estados anteriores de cada partícula. Em seguida, na linha 4, é atribuído um peso a essa partícula levando em conta as medições realizadas pelo sistema, sendo que, quanto mais próximo a partícula estiver do sistema real, maior será seu peso.

Em (THRUN; BURGARD; FOX, 2005) é apresentado que o peso de cada partícula é relacionado à probabilidade de se obter z_t a partir da partícula $x_t^{[m]}$, isto é, $w_t^{[m]} = p(z_t | x_t^{[m]})$. De forma semelhante, é possível relacionar o peso das partículas ao grau de confiabilidade que essa possui, ou seja, quanto menor o erro dos estados dessa amostra

com relação aos estados do sistema real, mais confiança ela possui e, portanto, melhor esta representará o sistema.

Na linha 5, o peso da partícula é somado ao Fator de Normalização, η , para apenas uniformizar estes e para facilitar a análise. Em seguida, a partícula e seu respectivo peso são adicionados ao conjunto de amostras χ_t , para manipulações posteriores.

Por fim, na linha 9, é o momento em que todos os pesos são normalizados antes da amostragem das melhores partículas do conjunto, realizada na linha 11. Tal amostragem consiste em sobrepor as partículas de menor confiança (menor peso) com as de maior peso. Para isso, alguns algoritmos são elegíveis, como é o caso do *Low variance sampler*, Algoritmo 2.

Algoritmo 2: <i>Low variance sampler</i>	
	Entrada: χ_t, W_t
	Saída: $\bar{\chi}_t$
1	$\bar{\chi}_t = \emptyset;$
2	$r = rand(0; M^{-1});$
3	$c = w_t^{[1]};$
4	$i = 1;$
5	para $m = 1$ até M faça
6	$u = r + (m - 1) * M^{-1};$
7	while $u > c$ do
8	$i = i + 1;$
9	$c = c + w_t^{[i]};$
10	end
11	$\bar{\chi}_t = \bar{\chi}_t + \langle x_t^{[i]} \rangle;$
12	fim

Fonte: (THRUN; BURGARD; FOX, 2005)

O algoritmo *Low variance sampler* busca, por meio de uma equação aleatória, u , as partículas que garantem uma maior confiança ao sistema, sendo elas armazenadas em um novo conjunto de amostras. Para isso, o algoritmo utiliza um valor aleatório, r , pertencente ao conjunto $[0; M^{-1}[$, como limiar de escolha da partícula.

Dessa forma, para encontrar a partícula sorteada, realiza-se o somatório dos pesos de cada uma até que o valor atinja o resultado da equação u . A partícula cujo o peso atingiu o limiar é a sorteada e armazenada no novo conjunto de amostras $\bar{\chi}_t$.

Ao observar a linha 6 do Algoritmo 2, nota-se que o passo do limiar será sempre inversamente proporcional ao número de partículas utilizadas. Portanto, é importante destacar que, caso o peso da partícula seja maior do que M^{-1} , ela possui 100% de probabilidade de ser mantida pelo algoritmo do *Low variance sampler*. Isso ocorre uma vez que, independente do valor inicial r , o valor de u será sempre incrementado de M^{-1} .

Uma das vantagens de se utilizar o *Low variance sampler* é a garantia de uma menor complexidade para a re-amostragem das partículas. Isso se deve pois, ao contrário de uma amostragem sistemática (YATES, 1948), a qual analisa todas as partículas para a escolha das melhores, o *Low variance sampler* utiliza um sorteio aleatório das partículas com a garantia de que apenas as melhores serão mantidas.

Contudo, apesar das facilidades que esse filtro proporciona, vale salientar algumas de suas limitações. Uma delas é a dependência com o modelo utilizado para atualizar os estados das partículas, por exemplo, em sistemas nos quais as partículas devem se movimentar para acompanhar o sistema real, caso a movimentação possua uma baixa precisão, as partículas podem se tornar ineficientes para representar os estados reais. Principalmente em casos em que se utilizam sensores de alta precisão, quase todos os pesos das partículas serão muito próximos de zero (THRUN; BURGARD; FOX, 2005), o que, também, pode resultar em variações bruscas na estimação dos estados e, conseqüentemente, em uma maior incerteza na saída do sistema.

Em (THRUN; BURGARD; FOX, 2005), é comentada uma outra limitação que o filtro de partículas possui na aplicação em sistemas com uma área de amostragem muito grande quando comparado ao número de partículas utilizado. Uma vez que, o conjunto não contém uma quantidade de amostras suficiente para cobrir todo o espaço de estados do sistema, a probabilidade das partículas convergirem para o estado real se torna baixa. Contudo, uma das soluções para contornar essa limitação seria aumentar o número de partículas do conjunto, o que demanda uma maior capacidade computacional, ou reduzir o espaço de cobertura do filtro (THRUN; BURGARD; FOX, 2005).

3.3 Filtro de Kalman

O Filtro de Kalman e suas variantes, tem como objetivo melhorar a confiança das medições de um ou mais sensores por meio de ajustes proporcionais à suas respectivas incertezas e estimativa dos estados do sistema. Isso é feito por meio de aproximações dos

estados e observações sensoriais a modelos gaussianos que representam sua probabilidade. Por ser capaz de utilizar informações de várias fontes para estimar o estado, essa é uma técnica muito comum na fusão de dados sensoriais (THRUN; BURGARD; FOX, 2005).

O filtro de Kalman é dividido em duas etapas principais de funcionamento, a etapa de predição, e a de correção. Na etapa de predição, estima-se o valor dos estados do sistema, com base em um modelo dinâmico que descreve o mesmo, para a próxima interação. Na etapa de correção, por sua vez, é feito um ajuste no valor dos estados de acordo com medidas sensoriais e a estimativa dos estados realizada na etapa anterior. Os cálculos realizados nessas etapas podem ser observados no Algoritmo 3.

Algoritmo 3: Filtro de Kalman

Entrada: $\mu_{t-1}, \Sigma_{t-1}, u_t, z_t$

Saída: μ_t, Σ_t ;

- 1 $\bar{\mu}_t = A_t \mu_{t-1} + B_t u_t$;
- 2 $\bar{\Sigma}_t = A_t \Sigma_{t-1} A_t^T + Q_t$;
- 3 $K_t = \bar{\Sigma}_t C_t^T (C_t \bar{\Sigma}_t C_t^T + R_t)^{-1}$;
- 4 $\mu_t = \bar{\mu}_t + K_t (z_t - C_t \bar{\mu}_t)$;
- 5 $\Sigma_t = (I - K_t C_t) \bar{\Sigma}_t$;

Fonte: (THRUN; BURGARD; FOX, 2005)

Para o funcionamento do filtro, inicialmente é recebido o valor referente ao estado anterior μ_{t-1} , a matriz de covariância destes valores Σ_{t-1} , os valores de entrada do sistema u_t , e as medições dos sensores z_t . Nas linhas 1 e 2 do algoritmo, é realizada a operação de predição do sistema, no qual o filtro estima, por meio de equações lineares, o estado do sistema e sua covariância para a próxima interação. Para isso, o sistema utiliza a Matriz A_t para descrever a evolução do estado entre o período de amostragem, sem considerar ruídos ou controles externos, e a Matriz B_t para descrever como a entrada de controle influencia na evolução do estado.

Após a estimação do estado do sistema, o filtro realiza a etapa de observação nas linhas 3, 4 e 5. Nelas, realiza-se a correção dos valores obtidos na predição, ponderando-os com as aquisições realizadas pelos sensores, z_t . A matriz C , por sua vez, é denominada como matriz de correção, a qual possui o objetivo de relacionar os estados do filtro com o vetor de medidas z_t . Essa operação de correção tem por objetivo aumentar a confiabilidade em cada medida e estimação, no intuito de adquirir uma melhor probabilidade para os estados do sistema.

Na linha 3, a variável K_t é denominada de Ganho de Kalman, sendo a responsável por determinar a influência de cada medida no novo estado do sistema, realizando a ponderação delas de acordo com o grau de confiabilidade destes. A confiabilidade dos sensores é dada pela matriz R_t , a qual expressa a covariância dos ruídos de medição, e a confiança da predição é dada pela matriz de covariância dos ruídos de predição Q_t . Por fim, nas linhas 4 e 5 são calculados valores atualizados para os estados do sistema e suas covariâncias, dado as medidas sensoriais e o ganho de Kalman.

Apesar desse algoritmo garantir uma boa confiança sobre os estados do sistema, ele é limitado a sistemas lineares. Outro requisito que limita a aplicação desse modelo do filtro de Kalman é a necessidade que ambos os estados e medições sejam corrompidos por ruídos brancos Gaussianos. Para sistemas que não cumprem esses requisitos, a solução é o Filtro de Kalman estendido (EKF - do inglês, *Extended Kalman Filter*). Essa versão é capaz de aproximar, localmente, a linearização de um sistema não-linear e obter uma distribuição Gaussiana para as suas incertezas. Para que isso ocorra, algumas pequenas alterações são realizadas no código da ferramenta, como é possível observar no Algoritmo 4.

Algoritmo 4: Filtro de Kalman estendido

Entrada: $\mu_{t-1}, \Sigma_{t-1}, u_t, z_t$
Saída: μ_t, Σ_t ;

- 1 $\bar{\mu}_t = g(\mu_{t-1}, u_t)$;
- 2 $\bar{\Sigma}_t = G_t \Sigma_{t-1} G_t^T + Q_t$;
- 3 $K_t = \bar{\Sigma}_t H_t^T (H_t \bar{\Sigma}_t H_t^T + R_t)^{-1}$;
- 4 $\mu_t = \bar{\mu}_t + K_t (z_t - h(\bar{\mu}_t))$;
- 5 $\Sigma_t = (I - K_t H_t) \bar{\Sigma}_t$;

Fonte: (THRUN; BURGARD; FOX, 2005)

Nesse algoritmo, μ_{t-1} é a matriz de estados $N \times 1$, onde N é o número de estados do sistema, $g(\mu_{t-1}, u_t)$ é a função que descreve a evolução dos estados por meio de equações não-lineares e $h(\bar{\mu}_t)$ é a função linear que relaciona os estados do sistema com as variáveis de medição. Já as matrizes G_t e H_t são, respectivamente, os jacobianos das funções $g(\mu_{t-1}, u_t)$ e $h(\bar{\mu}_t)$.

Uma outra vantagem em se utilizar o EKF, além de garantir uma excelente precisão na estimação dos estados, é a grande eficiência computacional que ele possui ao aproximar a confiança de sistemas à distribuições Gaussianas, independentemente de suas

dimensões. Esse fato faz com que essa ferramenta seja implementada na maioria dos sistemas envolvendo robótica probabilística.

Porém, uma importante limitação do EKF envolvendo a aproximação dos estados é o grau de não-linearidade do sistema. Se as funções que descrevem o sistema possuírem um alto grau de não-linearidade, essa ferramenta não conseguirá garantir uma boa qualidade de estimação dos estados (THRUN; BURGARD; FOX, 2005).

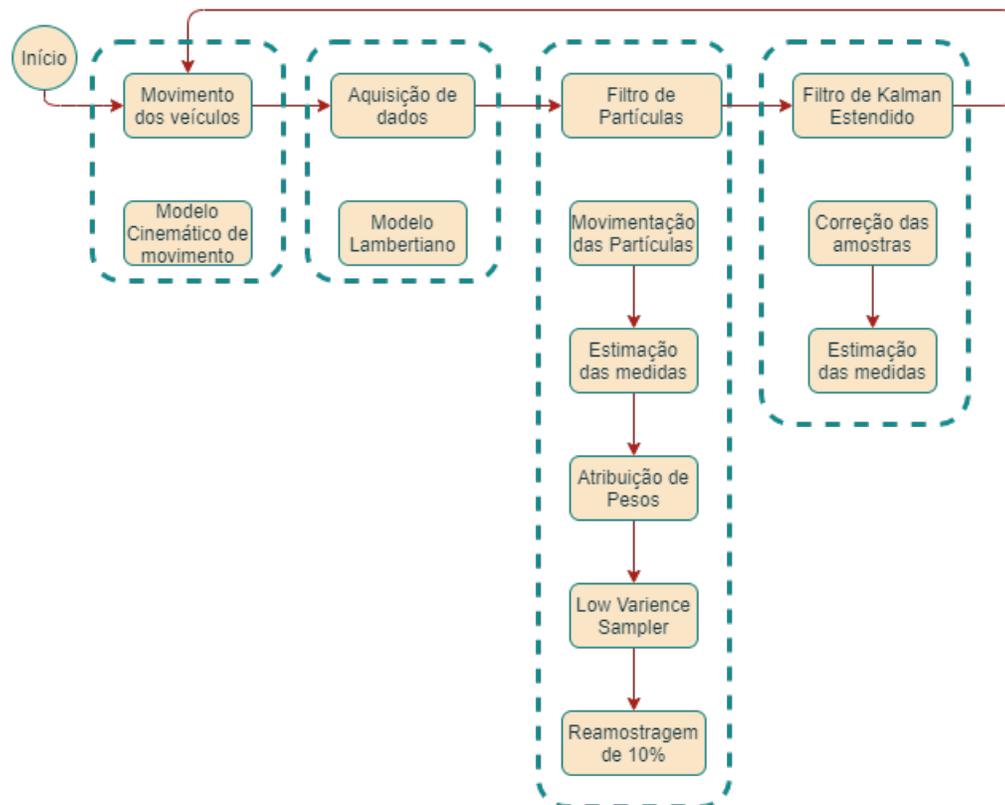
4 METODOLOGIA

Neste capítulo, são apresentadas as considerações que foram utilizadas para simular o sistema de comboio e as estruturas dos filtros de Kalman e partículas. Para isso, são destacados, também, os modelos matemáticos utilizados para se obter os parâmetros necessários para a descrição do sistema.

4.1 Descrição do sistema

O sistema proposto neste trabalho segue o diagrama da Figura 4.1. Os componentes dessa Figura são detalhados nas demais seções deste Capítulo.

Figura 4.1 – Fluxograma do sistema proposto



Fonte: Do autor.

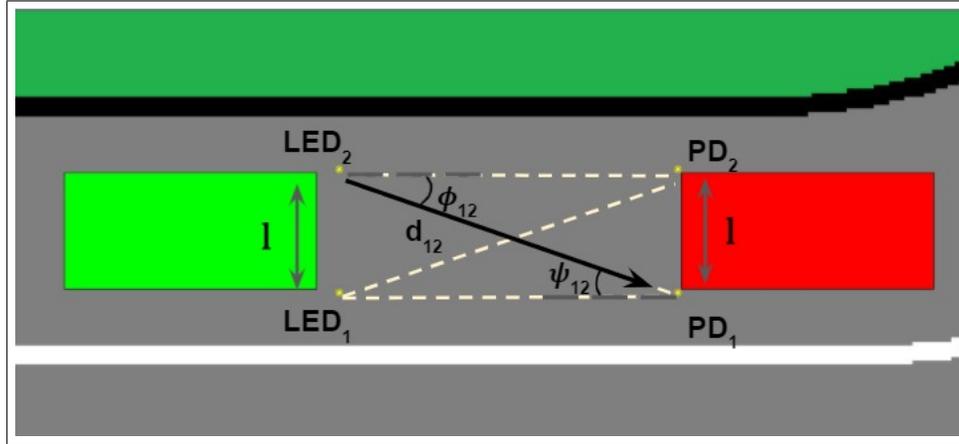
Para conceber a solução proposta, algumas considerações foram feitas:

- Os veículos são tracionados nas rodas dianteiras, sendo que as equações que representam seus movimentos são restritas ao movimento cinemático;
- Os cálculos foram realizados somente no plano X-Y, ou seja, considerou-se que toda a pista de teste, assim como o plano entre os emissores e receptores, estão em um mesmo nível. Dessa forma, são desconsideradas quaisquer dependências de variáveis relacionadas ao eixo Z;
- Existe uma comunicação entre os veículos, por meio de VLC, para a transferências de dados referentes ao veículo da frente, tais como, posição e orientação, velocidade linear e de esterçamento, orientação do veículo e ângulo de esterçamento das rodas. Isso permitirá reduzir o espaço amostral das partículas geradas pelo sistema;
- O sinal da comunicação VLC não interfere nas medidas realizadas com o VLP;
- As coordenadas reais do veículo de trás são utilizadas somente para avaliar a efetividade dos resultados obtidos da implementação;
- A localização dos receptores e emissores nos veículos são, respectivamente, nos faróis dianteiros e traseiros, ou seja, as distâncias entre os emissores, assim como entre os sensores são iguais à largura do veículo;
- O período de amostragem foi de $dt = 0,02 s$, uma vez que este garante a frequência de amostragem considerada satisfatória para esse tipo de sistema (SONER; COLLERI, 2021);
- Para a identificação, atribuiu-se os índices i e j aos receptores e emissores, respectivamente, nos parâmetros das equações. Por exemplo, d_{ij} é a distância entre o emissor j e o receptor i , sendo que, i e $j \in \{1, 2\}$;

Sobre a simulação, os veículos iniciam os testes sempre a uma distância de $10 m$, no eixo x , entre seus centros de massa. A velocidade linear do veículo líder em todos os testes foi de $1 m/s$, e a de esterçamento de ambos foram nulas. A Figura 4.2 apresenta alguns parâmetros e características que envolvem a simulação.

Na Figura 4.2 é ilustrado alguns parâmetros e componentes da simulação como o bloco verde à esquerda, representando o veículo líder do comboio, o bloco vermelho à direita, representando o veículo seguidor, salientando que, o sentido do movimento dos

Figura 4.2 – Características envolvidas na simulação



veículos se dá na horizontal da direita para a esquerda. Também é apresentado a localização dos emissores LED_1 e LED_2 e os sensores fotodiodos PD_1 e PD_2 (do inglês - *photodiode*). Alguns parâmetros utilizados para os cálculos do modelo matemático também são exemplificados como os ângulos de emissão e recepção do feixe luminoso, ψ_{12} e ϕ_{12} , a distância entre o emissor e o receptor d_{12} e a largura do veículo, l .

Além disso, as incertezas das velocidades dos veículos e partículas são calculadas utilizando uma distribuição normal com média zero e variância igual à 2% da velocidade. Este valor leva em consideração o uso de sensores precisos e o fato de que o tempo de amostragem é muito alto para as velocidades utilizadas. Desse modo, garante-se uma incerteza que não causará instabilidade no sistema.

4.2 Modelo matemático do sistema

Para a movimentação dos veículos em simulação, utilizou-se o modelo cinemático para veículos de tração na roda dianteira. Nesse caso, as equações que descrevem o movimento dos veículos são descritas da seguinte maneira:

$$\begin{bmatrix} x(k+1) \\ y(k+1) \\ \theta(k+1) \\ \phi(k+1) \end{bmatrix} = \begin{bmatrix} x(k) + v_l(k) \cos[\theta(k)] \cos[\phi(k)] dt \\ y(k) + v_l(k) \sin[\theta(k)] \cos[\phi(k)] dt \\ \theta(k) + \frac{v_l \sin[\phi(k)] dt}{l} \\ \phi(k) + v_a(k) dt \end{bmatrix}. \quad (4.1)$$

Sendo que, x e y são as posições do centro do eixo traseiro do veículo, θ é a orientação do veículo em radianos e ϕ é o ângulo de esterçamento das rodas dianteiras do veículo. Além disso, v_l e v_a são, respectivamente, as velocidades linear e de esterçamento do veículo e l a distância entre aos eixos do automóvel.

Com relação à simulação da intensidade luminosa recebida pelos sensores, utilizou-se princípios básicos de trigonometria para encontrar as variáveis existentes no modelo de Lambert. Primeiramente, calculou-se a distância euclidiana entre cada emissor-receptor, de modo a encontrar os parâmetros d_{ij} . Em seguida, para os cálculos de ângulo de incidência e de emissão, utilizou-se a lei dos cossenos, obtendo o seguinte conjunto de equações:

$$\psi_{1j} = \arccos\left(\frac{l^2 + d_{1j}^2 - d_{2j}^2}{2ld_{1j}}\right) - \frac{\pi}{2}. \quad (4.2)$$

$$\psi_{2j} = \frac{\pi}{2} - \arccos\left(\frac{l^2 + d_{2j}^2 - d_{1j}^2}{2ld_{2j}}\right). \quad (4.3)$$

$$\phi_{i1} = \frac{\pi}{2} - \arccos\left(\frac{l^2 + d_{i1}^2 - d_{i2}^2}{2ld_{i1}}\right). \quad (4.4)$$

$$\phi_{i2} = \arccos\left(\frac{l^2 + d_{i2}^2 - d_{i1}^2}{2ld_{i2}}\right) - \frac{\pi}{2}. \quad (4.5)$$

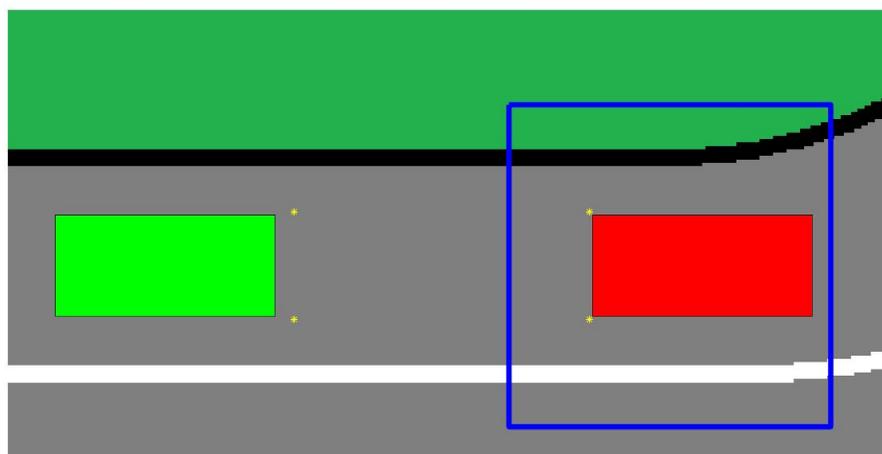
Uma vez obtidos os valores desses parâmetros em simulação, é possível estimar o comportamento do modelo Lambertiano para cada partícula do sistema. Além disso, para simular os ruídos presentes nas medições, inseriu-se um ruído randômico com uma distribuição normal de média zero e desvio padrão igual à 10% da medida simulada no modelo. Outros métodos são encontrados na literatura (SONER; COLERI, 2021) para uma melhor simulação desse ruído de medição. No entanto esses modelos necessitam de parâmetros físicos que não são possíveis de estimar neste projeto, como temperatura dos circuitos, corrente de iluminação de fundo e entre outros. Portanto, a integração dessa metodologia para o ruído será realizada em projetos futuros envolvendo experimentos práticos.

4.3 Aplicação do filtro de partículas

Para estimar a melhor posição do veículo de trás optou-se por utilizar o filtro de partículas, de modo que, o espaço amostral seja uma área quadrangular com lados iguais

à 6 m, o qual possui o centro localizado a 7m de distância do veículo da frente, conforme representado na Figura 4.3. É possível definir essa região a cada iteração do algoritmo, uma vez que os dados de posição e orientação do veículo da frente são enviados via VLC ao veículo traseiro. Também é possível utilizar uma área amostral maior do que essa, porém o tempo de conversão das partículas se torna muito grande para o sistema.

Figura 4.3 – Exemplo da área amostral utilizada pelo filtro de partículas delimitada pelas linhas azuis.



Antes do início do *loop* apresentado na Figura 4.1, são geradas 5000 partículas dentro do espaço amostral com poses aleatórias para posteriormente serem manipuladas dentro do filtro. O movimento das partículas é realizado de acordo com a sua pose e as velocidades do veículo traseiro, representando as entradas de controle do veículo, as quais podem ser obtidas por meio da rede CAN (do inglês *Controller Area Network*) do veículo, por exemplo. Esse também obedece o comportamento cinemático de um veículo com tração dianteira. Ou seja, a cada iteração, o modelo cinemático do veículo (Seção 4.2) é integrado em um intervalo dt gerando a nova pose na partícula. Por fim, após realizar o deslocamento das partículas, todas estas que estiverem fora do espaço amostral serão substituídas por novas partículas, no intuito de mantê-las sempre dentro da área de análise.

Conforme apresentado na Seção 4.2, utilizou-se o modelo de Lambert para simular a intensidade luminosa recebida pelos sensores. Desse modo, cada sensor realizara

duas medidas referente a cada um dos faróis do veículo líder, totalizando quatro dados, P_{ij} , para coleta e manipulação.

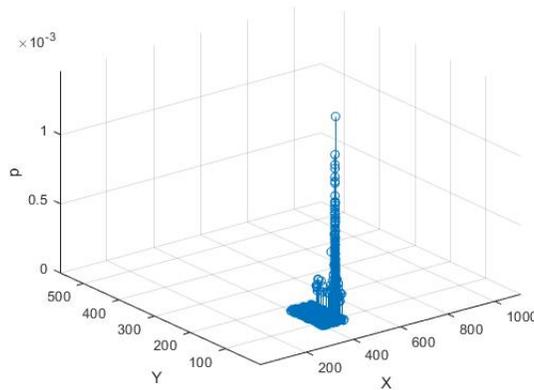
Com a simulação desse modelo para cada partícula, foi possível realizar a diferença das medidas estimadas com as medições reais do sistema e, assim, realizar a normalização dessas aquisições. Com isso, atribuiu-se a inversa dessa normalização ao peso da partícula como mostrado nas Equações (4.6) e (4.7), nas quais, $P_{ij,medida}$ e $P_{ij,n}$ são as potências recebidas, pela aquisição do sistema real e da partícula n , respectivamente, η é o valor normalizado da diferença das medidas e $w^{[n]}$ o peso da partícula n . Desse modo, quanto maior for o erro das medidas maior será o valor da normalização e, consequentemente, menor será o peso da partícula.

$$\eta = \sqrt{\sum (P_{ij,medida} - P_{ij,n})^2 \forall i, j \in \{1, 2\}}. \quad (4.6)$$

$$w^{[n]} = \frac{1}{\eta}. \quad (4.7)$$

Como uma forma de acompanhar os valores de pesos das partículas, gerou-se em tempo real um gráfico em 3D para acompanhar a pose dessas e seus respectivos pesos, conforme demonstrado na Figura 4.4.

Figura 4.4 – Peso das partículas e suas respectivas posição no mapa.



Após a atribuição dos pesos às partículas e da re-amostragem das melhores partículas utilizando o algoritmo *Low Variance Sampler*, 10% das amostras que possuem baixa

confiabilidade são substituídas por novas partículas. Isso é necessário devido ao fato de que, mesmo limitando o espaço amostral, este ainda permite que as partículas converjam para um mínimo local, impossibilitando que o sistema encontre a melhor solução para o sistema.

4.4 Aplicação do filtro de Kalman estendido

Apesar de ser capaz de garantir uma boa estimativa do estado do sistema real, o filtro de partículas possui algumas limitações que podem proporcionar grandes incertezas durante a sua execução (THRUN; BURGARD; FOX, 2005). Por se tratar de um sistema amostral, a oscilação dos estados da melhor partícula entre cada interação e o custo computacional para processar o filtro podem prejudicar a convergência do filtro. Uma das soluções para se minimizar esses problemas é suavizar a estimativa resultante como o filtro de Kalman. Dessa forma, esse trata a melhor amostra obtida no filtro de partículas como uma medida de um sensor virtual, podendo, assim, melhorar a estimativa obtida pelas partículas.

Para este projeto, optou-se por utilizar o filtro de Kalman Estendido, devido ao fato de que se deseja obter uma melhoria na estimativa da melhor amostra obtida no filtro de partículas. É necessário a implementação deste, principalmente devido a oscilação da melhor partícula no espaço amostral, que é provocada pelas incertezas envolvidas e pela constante geração de novas partículas.

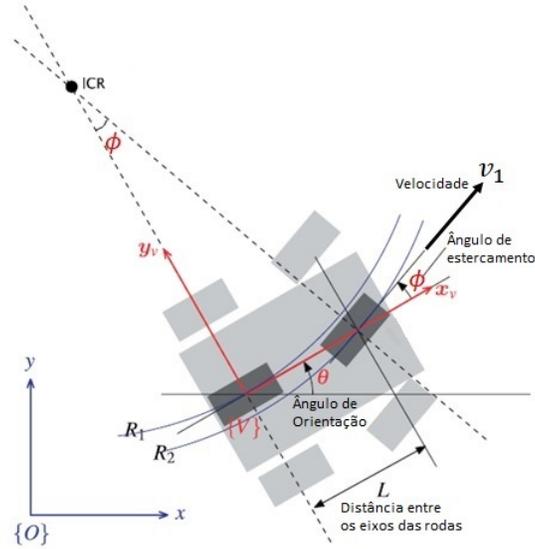
Para esta implementação, o vetor de estados, μ escolhidos foi o seguinte:

$$\mu = \begin{bmatrix} x \\ y \\ \theta \\ \phi \end{bmatrix}. \quad (4.8)$$

Onde, x e y são as posições do veículo referenciadas no plano local. θ é o ângulo de guinada dele e ϕ ângulo de esterçamento das rodas em relação ao eixo x do veículo (ver Figura 4.5 para maiores detalhes).

Para a predição dos estados, utilizou-se o mesmo modelo utilizado para a simular o movimento do veículo e das partículas. Uma vez que esse modelo é composto por um conjunto de equações não lineares, fez-se necessário implementar o filtro de Kalman

Figura 4.5 – Diagrama modelo cinemático de um veículo com tração dianteira.



Estendido. Desse modo, a função que descreve a evolução dos estados e o seu jacobiano são:

$$g(\mu_{k-1}, u_k) = \begin{bmatrix} x_{k-1} + \cos(\theta_{k-1}) \cos(\phi_{k-1}) v_l \Delta t \\ y_{k-1} + \sin(\theta_{k-1}) \cos(\phi_{k-1}) v_l \Delta t \\ \theta_{k-1} + \frac{\sin(\phi_{k-1})}{l} v_l \Delta t \\ \phi_{k-1} + v_a \Delta t \end{bmatrix}. \quad (4.9)$$

$$G_k = \begin{bmatrix} 1 & 0 & \sin(\theta_{k-1}) \cos(\phi_{k-1}) v_l \Delta t & \cos(\theta_{k-1}) \sin(\phi_{k-1}) v_l \Delta t \\ 0 & 1 & \cos(\theta_{k-1}) \cos(\phi_{k-1}) v_l \Delta t & \sin(\theta_{k-1}) \sin(\phi_{k-1}) v_l \Delta t \\ 0 & 0 & 1 & \frac{\cos(\phi_{k-1})}{l} v_l \Delta t \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (4.10)$$

Onde x , y , θ e ϕ são os estados do filtro e dt é o período de amostragem da simulação, no caso $0,02 s$. A etapa de correção do filtro é linear e foi considerada o próprio estado da melhor partícula como leitura sensorial da correção. Nesse sentido, a matriz de correção C , que relaciona as medições com o estado do filtro, pode ser representada pela matriz identidade, segundo a equação (4.11).

As matrizes de covariâncias Q e R foram construídas de modo à proporcionar uma maior confiança para a predição das coordenadas x e y obtidas no filtro de Kalman do que pela melhor partícula do sistema. As matrizes resultantes são (4.12) e (4.13).

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (4.11)$$

$$Q = \begin{bmatrix} 0,006^2 & 0 & 0 & 0 \\ 0 & 0,006^2 & 0 & 0 \\ 0 & 0 & \left(\frac{0,02\pi}{180}\right)^2 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}. \quad (4.12)$$

$$R = \begin{bmatrix} 1,5^2 & 0 & 0 & 0 \\ 0 & 1,5^2 & 0 & 0 \\ 0 & 0 & \left(\frac{0,01\pi}{180}\right)^2 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}. \quad (4.13)$$

Os valores de covariâncias das incertezas das medidas e estimações são apresentados na diagonal principal das matrizes R e Q , respectivamente. Nessa primeira, os valores referentes aos estados x e y resultaram em $1,5^2 m$ de covariância devido ao fato de que a estimação destas variáveis atinge tal valor de erro pela estimação do filtro de partículas. Já na matriz Q , as covariâncias referentes aos ruídos de estimação dos estados foram de $0,006^2 m$, devido a baixa velocidade do veículo e a alta frequência de amostragem do sistema.

Com relação aos valores de covariâncias para o estado θ , foi atribuída uma confiança maior ao filtro de partícula, com uma incerteza de $0,01^\circ$, conforme mostrado em (4.13). Com a estimação do modelo do filtro, esse estado é estimado com $0,02^\circ$ de desvio padrão. Novamente, os valores foram pequenos devido a alta frequência de amostragem do sistema. O estado ϕ não possui covariância devido ao fato de este parâmetro é coletado diretamente da rede CAN do veículo, portanto não precisará ser corrigido ou estimado por nenhum dos filtros.

5 RESULTADOS

Uma vez apresentado o sistema proposto (Capítulo 4), este capítulo apresenta e discute alguns dos testes realizados em simulação. O código básico utilizado para a implementação deles consiste em um simulador desenvolvido em Matlab pelo professor e orientador deste projeto Dr. Danilo Alves de Lima (LIMA; VICTORINO, 2016). O simulador permite representar um veículo no plano 2D, realizar seu movimento segundo um modelo cinemático ou dinâmico e adquirir dados sensoriais de câmeras e lasers. Neste trabalho, o código do simulador foi adaptado para permitir a inserção de um novo veículo e simular a presença de emissores LEDs no veículo dianteiro e fotodiodos no veículo traseiro.

Os testes consistem em analisar a eficiência do sistema de VLP, utilizando o filtro de partículas e de Kalman, em três situações diferentes:

1. Com veículos perfeitamente alinhados e com velocidades iguais;
2. Alinhados e com velocidades diferentes;
3. Desalinhados e com mesmas velocidades.

Optou-se por realizar estes testes para verificar, também, se o comportamento do modelo é diretamente influenciado pela variação da distância relativa entre os veículos ou pelo alinhamento entre estes.

5.1 Experimento 1 - Alinhados e com velocidades iguais

Nesse teste, ambos os veículos estão perfeitamente alinhados, ou seja, possuem a mesma orientação e posição y . Além disso, os veículos foram simulados mantendo a mesma velocidade de 1 m/s , para que, não haja alteração da distância entre esses durante o percurso. A Figura 5.1 ilustra a condição inicial do experimento. Os erros relativos e as ocorrências a esse experimento estão na Figura 5.2, sendo o erro das variáveis x e y representado nas Figuras 5.2(a) e 5.2(b) e as ocorrências da partículas em função do erro nas Figuras 5.2(c) e 5.2(d).

Com relação ao erro em x e y , verifica-se uma convergência para valores próximo de zero. Nota-se, também, que ainda possui um erro associado ao valor de estabilização da variável x , o qual se estabiliza próximo de 3 cm de erro. Isso pode ser confirmado na

Figura 5.1 – Condição inicial dos experimentos 1 e 2.

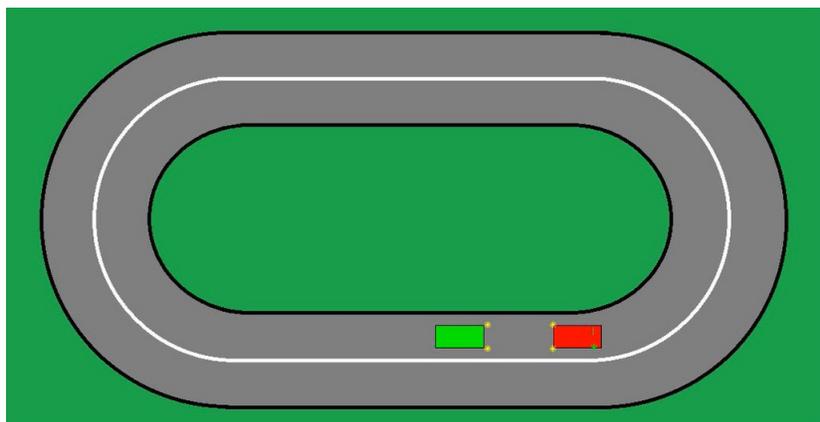


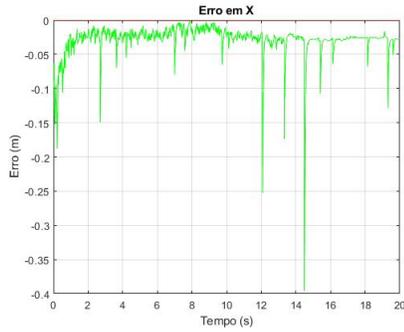
Figura 5.3(c), a qual apresenta o número de ocorrências dos erros em x sendo ela próxima a uma distribuição normal com média de $-2,9 \text{ cm}$ e um desvio padrão de $2,4 \text{ cm}$. Já em relação a y , a estimação resultou em uma precisão inferior relacionada à estimação de x , apresentando um desvio de $14,6 \text{ cm}$ e uma média de $-6,4 \text{ cm}$ de erro na distribuição normal, como é possível perceber na Figura 5.3(d).

5.2 Experimento 2 - Alinhados e velocidades diferentes

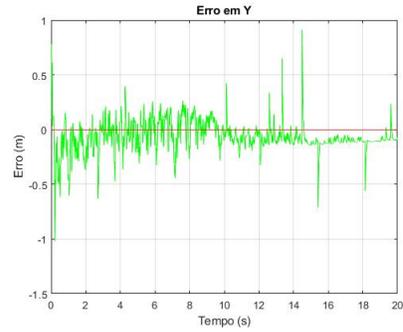
Para validar se o sistema possui alguma influência significativa com a distância entre os veículos do comboio, realizou-se um teste no qual o veículo líder possui uma velocidade original de 1 m/s enquanto a do veículo seguidor é de $1,2 \text{ m/s}$, resultando na aproximação desses durante o percurso. A condição inicial deste experimento também corresponde à Figura 5.1. Como esperado, os resultados não foram muito diferentes dos encontrados no teste anterior, com erros de x e y convergindo, respectivamente, para $9,4 \pm 5,8 \text{ cm}$ e $1,1 \pm 17,7 \text{ cm}$ de erro. Apesar desse teste também possuir uma alta exatidão para esse tipo de sistema, a precisão obtida em y , é um ponto que ainda deve ser devidamente desenvolvido, uma vez que, o desvio padrão desse erro está alcançando até 10 vezes mais que a média da distribuição dos dados.

Com um breve comparativo entre os dois primeiros testes, é interessante comentar que o erro relacionado à coordenada x no segundo experimento obteve um valor maior em regime permanente, como apresentado na Figura 5.3(a). Ao contrário do que é apresentado

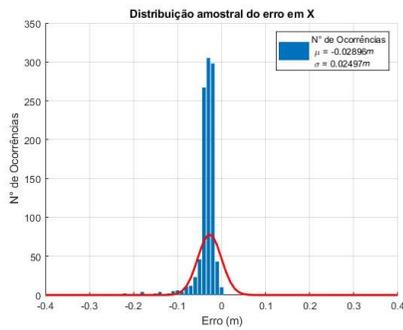
Figura 5.2 – Análise do erro da posição x e y para veículos alinhados e com velocidades iguais.



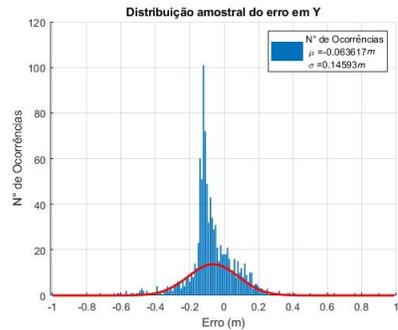
(a) Erro da estimativa do estado x .



(b) Erro da estimativa do estado y .



(c) Análise de ocorrências de erro em x .



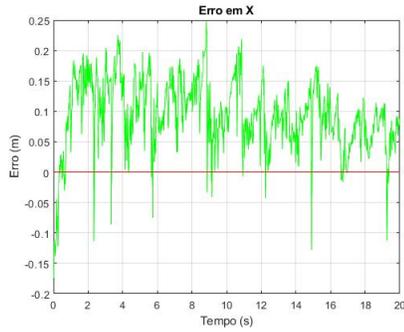
(d) Análise de ocorrências de erro em y .

na Figura 5.2(a) a qual aparenta indicar que o sistema estabiliza em um erro próximo de zero. Esse comportamento indica que a redução da distância entre os emissores e receptores possui uma relação inversamente proporcional ao erro da estimação. Apesar da grande variação resultante nos dados, em ambos os experimentos obteve-se uma alta exatidão para o sistema, conforme apresentado em (SONER; COLERI, 2021). No caso da estimação da posição em y , houve uma melhoria na exatidão das medidas, podendo indicar uma relação diretamente proporcional à distancia entre os veículos, porém com uma perda na precisão dessas.

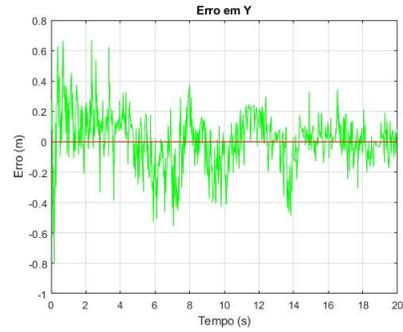
5.3 Experimento 3 -Desalinhados e velocidades iguais

Nesse último experimento, simulou-se um sistema no qual ambos os veículos estavam com o mesmo valor de velocidade, 1 m/s , porém com o veículo seguidor deslocado

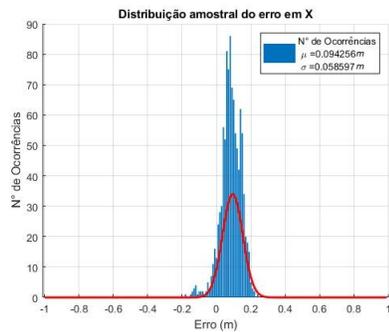
Figura 5.3 – Análise do erro da posição x e y para veículos alinhados e com velocidades diferentes.



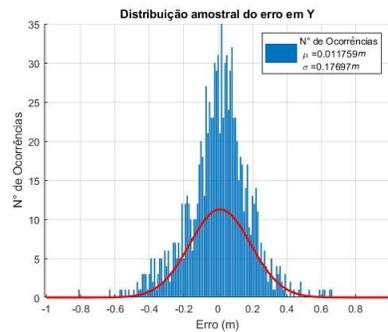
(a) Erro da estimativa do estado x .



(b) Erro da estimativa do estado y .



(c) Análise de ocorrências de erro em x .

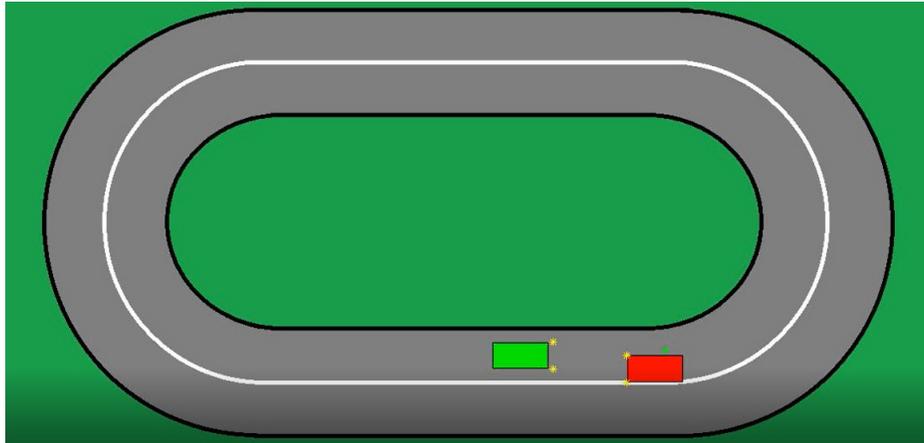
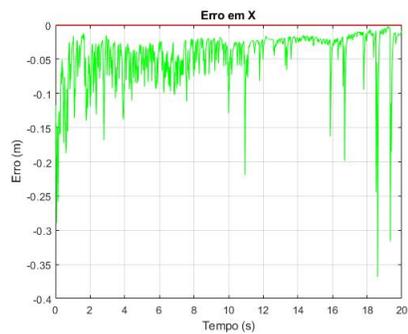
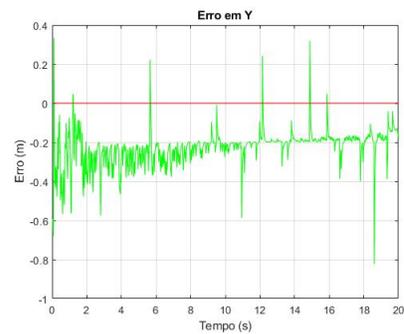
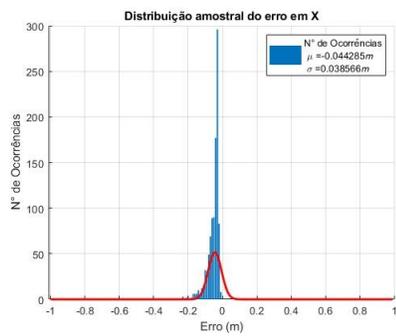
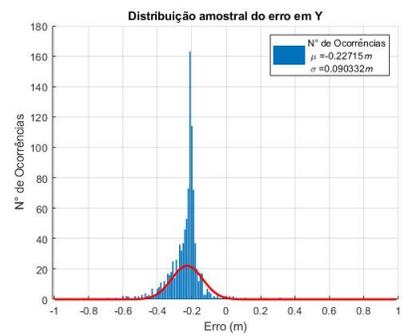


(d) Análise de ocorrências de erro em y .

de 1 m em y , conforme apresentado na Figura 5.4. Este experimento visou avaliar a influência do alinhamento dos veículos nos resultados obtidos pelo projeto e realizar uma comparação entre os três experimentos.

Nesse experimento, a estimativa do estado x obteve comportamentos similares aos resultados anteriores, dessa vez com erro médio de $-4,4\text{ cm}$ e desvio padrão de $-3,9\text{ cm}$, mantendo a exatidão menor do que 10 cm . Porém, a estimativa de y , resultou em um erro médio de $-22,7\text{ cm}$ e um desvio de 9 cm . Esses dados podem ser observados na Figura 5.5. Apesar de atingir uma precisão maior neste experimento, o estado y obteve um erro maior do que os obtidos no testes anteriores e, também, maior que o desejado para o sistema. Essa discrepância obtida pode estar relacionada a uma dependência do estado com os modelos implementados na simulação.

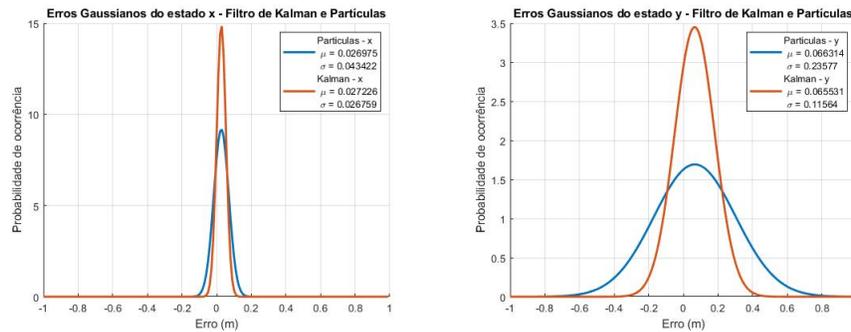
Figura 5.4 – Condição inicial experimento 3.

Figura 5.5 – Análise do erro da posição x e y para veículos desalinhados e com velocidades iguais.(a) Erro da estimativa do estado x .(b) Erro da estimativa do estado y .(c) Análise de ocorrências de erro em x .(d) Análise de ocorrências de erro em y .

5.4 Comparativo entre resultados dos filtros de partículas apenas e de partículas + Kalman estendido

Como mencionado em Capítulos anteriores, o intuito de implementar o filtro de Kalman nas medidas fornecidas pelo filtro de partículas é garantir uma melhoria na estimação dos estados reduzindo a oscilação resultante das partículas entre cada interação. Para validar a melhoria provocada por essa integração, gerou-se alguns gráficos com as distribuições normais dos erros dos estados x e y utilizando somente o filtro de partículas e implementando o filtro de Kalman nas amostras da melhor partícula encontrada no sistema. O cenário utilizado para realizar os testes é o utilizado para o experimento 1. A comparação desse pode ser observada na Figura 5.6.

Figura 5.6 – Comparação da distribuição do erro entre o filtro de partículas e o filtro de Kalman



(a) Distribuição normal do erro do estado x (b) Distribuição normal do erro do estado y

Pelas análises dos gráficos 5.6(a) e 5.6(b), é possível notar uma melhoria, principalmente na precisão das estimativas, quando se integra o filtro de Kalman ao sistema. As reduções provocadas nos desvios padrões dos erros foram de 1 cm em x e 20 cm em y . Somente por essa pequena alteração, é justificável a integração do filtro de Kalman, melhorando assim a confiabilidade no sistema.

6 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo desenvolver uma solução para estimar o posicionamento de veículos dentro de um sistema *platooning* utilizando VLP. Para isso, a meta dos resultados foi atingir uma precisão e exatidão equivalente à obtida em (SONER; COLERI, 2021), com incertezas inferiores à 10 cm e utilizando componentes de menor custo. Além disso, foi desejado implementar os filtros de partículas para estimar a posição e orientação do veículo traseiro em relação ao dianteiro e o filtro de Kalman para reduzir a variação da melhor partícula do sistema.

A partir dos resultados e análises apresentados no Capítulo 5, pode-se concluir que o projeto atingiu o objetivo esperado na maioria das estimações, obtendo uma exatidão na faixa de 10 cm para a posição em x e y . No entanto, ainda deve ser melhorado a precisão em y , a qual obteve um desvio padrão acima dos ocorridos no estado x , cerca de duas vezes maior. Além disso, a exatidão de y , quando os veículos estão desalinhados, atingiu um erro de 20 cm na estimação, o que leva a concluir que existe uma possível dependência desse estado com as variáveis presentes nos modelos do sistema. Dentre essas variáveis, as que podem estar mais relacionadas a essa perda de exatidão seriam os ângulos de emissão e incidência do modelo Lambartiano, ψ e ϕ , uma vez que essas foram as que sofreram alterações significativas no Experimento 3. Apesar desses ocorridos, foi possível novamente comprovar o alto potencial que as tecnologias por meio de luz visível podem proporcionar quando empregadas no ramo de veículos.

Para projetos futuros, pretende-se realizar na prática esta solução, com o intuito de validar o comportamento desta sobre a luz ambiente e incertezas relacionadas às medições reais do sistema. Além disso, planeja-se melhorar a estimação do modelo Lambartiano, assim como a aplicação de incertezas mais realísticas para o modelo de medição. Outra situação que se deseja implementar essa solução é a que se utiliza mais de dois veículos no comboio, assim, será possível avaliar a propagação do erro entre cada estimação do sistema. Já esta em desenvolvimento um sistema para a implementação dessa solução em ambiente real, esse utiliza linguagem de programação C++ e um microcomputador RaspberryPi para a aquisição e processamento dos dados utilizando os mesmos filtros empregados em simulação.

REFERÊNCIAS

- ABDULSALAM, N. A. et al. Design and implementation of a vehicle to vehicle communication system using li-fi technology. In: IEEE. **2015 Int. Conf. Inf. Commun. Technol. Res. (ICTRC)**. [S.l.], 2015. p. 136–139.
- BĚLINOVÁ, Z.; BUREŠ, P.; JESTY, P. Intelligent transport system architecture different approaches and future trends. In: **Data and Mobility**. [S.l.]: Springer, 2010. p. 115–125.
- BERGENHEM, C. et al. Overview of platooning systems. In: **Proceedings of the 19th ITS World Congress, Oct 22-26, Vienna, Austria (2012)**. [S.l.: s.n.], 2012.
- BIEVER, W.; ANGELL, L.; SEAMAN, S. Automated driving system collisions: early lessons. **Human factors**, SAGE Publications Sage CA: Los Angeles, CA, v. 62, n. 2, p. 249–259, 2020.
- CALVERT, S.; SCHAKEL, W. J.; AREM, B. van. Evaluation and modelling of the traffic flow effects of truck platooning. **Transportation research part C: emerging technologies**, Elsevier, v. 105, p. 1–22, 2019.
- CONTRERAS-CASTILLO, J.; ZEADALLY, S.; GUERRERO-IBÁÑEZ, J. A. Internet of vehicles: Architecture, protocols, and security. **IEEE Internet Things J.**, v. 5, n. 5, p. 3701–3709, 2018.
- DARLIS, D.; PRIRAMADHI, R.; JONI, K. Implementation of vehicular-visible light communication for motorcycle platooning. In: IOP PUBLISHING. **IOP Conference Series: Materials Science and Engineering**. [S.l.], 2021. v. 1098, n. 3, p. 032023.
- EL-ZAHER, M. et al. Compositional verification for reactive multi-agent systems applied to platoon non collision verification. **Stud. Inform. Univ.**, v. 10, n. 3, p. 119–141, 2012.
- FAKHFAKH, F.; TOUNSI, M.; MOSBAH, M. Vehicle platooning systems: Review, classification and validation strategies. **International Journal of Networked and Distributed Computing**, v. 8, p. 203–213, 2020. ISSN 2211-7946. Disponível em: <<https://doi.org/10.2991/ijndc.k.200829.001>>.
- GONÇALVES, A. L. R. et al. Visible light positioning and communication methods and their application in the intelligent mobility. **IEEE Latin America Transactions**, IEEE, v. 19, n. 11, p. 1883–1894, 2021.
- KAROUI, O. et al. Dual mode for vehicular platoon safety: Simulation and formal verification. **Information Sciences**, Elsevier, v. 402, p. 216–232, 2017.
- KIM, B. W.; JUNG, S.-Y. Vehicle positioning scheme using v2v and v2i visible light communications. In: IEEE. **2016 IEEE 83rd Veh. Technol. Conf. (VTC Spring)**. [S.l.], 2016. p. 1–5.
- KIM, H. et al. An indoor visible light communication positioning system using a RF carrier allocation technique. **J. Lightwave Technol.**, v. 31, n. 1, p. 134–144, 2013.
- LAUSNAY, S. D. et al. A survey on multiple access visible light positioning. In: IEEE. **2016 IEEE Int. Conf. Emerg. Techn. Innov. Bus. Pract. Transf. Soc. (EmergiTech)**. [S.l.], 2016. p. 38–42.

LIMA, D. A.; VICTORINO, A. C. Sensor-based control with digital maps association for global navigation: A real application for autonomous vehicles. In: **Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on**. [S.l.: s.n.], 2015. p. 1791–1796.

LIMA, D. A. de; VICTORINO, A. C. A hybrid controller for vision-based navigation of autonomous vehicles in urban environments. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 17, n. 8, p. 2310–2323, 2016.

MAITI, S.; WINTER, S.; KULIK, L. A conceptualization of vehicle platoons and platoon operations. **Transportation Research Part C: Emerging Technologies**, Elsevier, v. 80, p. 1–19, 2017.

MARÈ, R. M. et al. Intelligent transport systems and visible light communication applications: An overview. In: IEEE. **2016 IEEE 19th Int. Conf. Intell. Transp. Syst. (ITSC)**. [S.l.], 2016. p. 2101–2106.

MATOS, D. de; VITOR, G. B.; KAROLAK, D. B. Desenvolvimento de uma comunicação vlc aplicada à sistemas i2v nas emergentes cidades inteligentes. **Anais da Sociedade Brasileira de Automática**, v. 1, n. 1, 2019.

MOHAMMED, D. et al. Digital data transmission via visible light communication (vlc): Application to vehicle to vehicle communication. In: IEEE. **2016 4th Int. Conf. Control Eng. Inf. Technol. (CEIT)**. [S.l.], 2016. p. 1–5.

MÜLLER, F. de P. Survey on ranging sensors and cooperative techniques for relative positioning of vehicles. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 17, n. 2, p. 271, 2017.

NETO, O. L. d. M. et al. Mortalidade por acidentes de transporte terrestre no brasil na última década: tendência e aglomerados de risco. **Ciência & Saúde Coletiva**, SciELO Public Health, v. 17, p. 2223–2236, 2012.

PRADO, W. R. D. et al. Análise da mortalidade em acidentes de trânsito por porte populacional brasileiro.

SHAOUT, A.; COLELLA, D.; AWAD, S. Advanced driver assistance systems-past, present and future. In: IEEE. **2011 Seventh International Computer Engineering Conference (ICENCO'2011)**. [S.l.], 2011. p. 72–82.

SONER, B.; COLERI, S. Visible light communication based vehicle localization for collision avoidance and platooning. **IEEE Transactions on Vehicular Technology**, IEEE, v. 70, n. 3, p. 2167–2180, 2021.

SONER, B.; ERGEN, S. C. Vehicular visible light positioning with a single receiver. In: IEEE. **2019 IEEE 30th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)**. [S.l.], 2019. p. 1–6.

THRUN, S.; BURGARD, W.; FOX, D. **Probabilistic Robotics**. [S.l.]: The MIT Press, 2005.

WANG, J. et al. Optimal toll design problems under mixed traffic flow of human-driven vehicles and connected and autonomous vehicles. **Transportation Research Part C: Emerging Technologies**, Elsevier, v. 125, p. 102952, 2021.

WANG, Q. et al. Light positioning: A high-accuracy visible light indoor positioning system based on attitude identification and propagation model. **Int. J. Distrib. Sens. N.**, SAGE Publications Sage UK: London, England, v. 14, n. 2, p. 1550147718758263, 2018.

WARRENDALE, P. **SAE International Releases Updated Visual Chart for Its “Levels of Driving Automation” Standard for Self-Driving Vehicles.** 2021. <<https://www.sae.org/news/press-room/2018/12/sae-international-releases-updated-visual-chart-for-its-%E2%80%99Clevels-of-driving-automation%E2%80%9D-standard-for-self-driving-vehicles>>.

YAN, K. et al. Current status of indoor positioning system based on visible light. In: **2015 15th Int. Conf. Contr. Autom. Syst. (ICCAS)**. [S.l.: s.n.], 2015. p. 565–569.

YATES, F. Systematic sampling. **Philosophical Transactions of the Royal Society of London. Series A, Mathematical and Physical Sciences**, The Royal Society London, v. 241, n. 834, p. 345–377, 1948.

ZHU, Z. et al. Angle-of-arrival estimator for light signals based on optimized photodiode array. In: IEEE. **2019 International Conference on Computing, Networking and Communications (ICNC)**. [S.l.], 2019. p. 62–66.