



**INSTITUTO
TECNOLÓGICO
VALE**

**Programa de Pós-Graduação em Instrumentação, Controle e
Automação de Processos de Mineração (PROFICAM)
Escola de Minas, Universidade Federal de Ouro Preto (UFOP)
Associação Instituto Tecnológico Vale (ITV)**

Dissertação

**LOCALIZAÇÃO DE ROBÔS MÓVEIS POR MEIO DE FLUXO ÓTICO E FUSÃO
SENSORIAL EM AMBIENTES DE MINERAÇÃO**

Jacó Dias Domingues

**Ouro Preto
Minas Gerais, Brasil
2022**

Jacó Dias Domingues

**LOCALIZAÇÃO DE ROBÔS MÓVEIS POR MEIO DE FLUXO ÓTICO E FUSÃO
SENSORIAL EM AMBIENTES DE MINERAÇÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. Gustavo Pessin, D.Sc.

Coorientador: Prof. Gustavo Freitas, D.Sc.

Coorientador: Héctor Azpúrua, D.Sc.

Ouro Preto

2022

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

D671l Domingues, Jaco Dias.

Localização de robôs móveis por meio de fluxo ótico e fusão sensorial em ambientes de mineração. [manuscrito] / Jaco Dias Domingues. - 2022.

60 f.: il.: color., gráf., tab..

Orientador: Dr. Gustavo Pessin.

Coorientadores: Prof. Dr. Gustavo Medeiros Freitas, Dr. Héctor Azpúrua.

Dissertação (Mestrado Profissional). Universidade Federal de Ouro Preto. Programa de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração. Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração.

Área de Concentração: Engenharia de Controle e Automação de Processos Mineraiis.

1. Medição - Odometria. 2. Gravações de vídeo - Fluxo ótico. 3. Veículos Autônomos. I. Azpúrua, Héctor. II. Freitas, Gustavo Medeiros. III. Pessin, Gustavo. IV. Universidade Federal de Ouro Preto. V. Título.

CDU 681.5:622.2

Bibliotecário(a) Responsável: Maristela Sanches Lima Mesquita - CRB-1716



FOLHA DE APROVAÇÃO

Jacó Dias Domingues

Localização de robôs móveis por meio de fluxo ótico e fusão sensorial em ambientes de mineração

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração (PROFICAM), Convênio Universidade Federal de Ouro Preto/Associação Instituto Tecnológico Vale - UFOP/ITV, como requisito parcial para obtenção do título de Mestre em Engenharia de Controle e Automação na área de concentração em Instrumentação, Controle e Automação de Processos de Mineração
Aprovada em 02 de setembro de 2022

Membros da banca

Doutor - Gustavo Pessin - Orientador - Instituto Tecnológico Vale
Doutor - Gustavo Medeiros Freitas - Universidade Federal de Minas Gerais
Doutor - Héctor Ignacio Azpúrua Perez-Imaz - Modular Mining
Doutor - Filipe Alves Neto Verri - Instituto Tecnológico de Aeronáutica
Doutor - Fernando Santos Osório - Universidade de São Paulo

Gustavo Pessin, orientador do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 01/11/2022



Documento assinado eletronicamente por **Bruno Nazário Coelho**, **COORDENADOR(A) DE CURSO DE PÓS-GRADUAÇÃO EM INST. CONTROLE AUTOMAÇÃO DE PROCESSOS DE MINERAÇÃO**, em 03/11/2022, às 19:15, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0421745** e o código CRC **BCA5BFDA**.

Referência: Caso responda este documento, indicar expressamente o Processo nº 23109.014952/2022-11

SEI nº
0421745

R. Diogo de Vasconcelos, 122, - Bairro Pilar Ouro Preto/MG, CEP 35402-163
Telefone: (31)3552-7352 - www.ufop.br

*Dedico este trabalho a todos
aqueles que em algum momento
difundiram ideias, histórias e
conhecimentos.*

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código de Financiamento 001; do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); e da Vale S.A.

“São as perguntas que não sabemos responder que mais nos ensinam. Elas nos ensinam a pensar. Se você dá uma resposta a um homem, tudo o que ele ganha é um fato qualquer. Mas, se você lhe der uma pergunta, ele procurará suas próprias respostas.” (Patrick Rothfuss).

RESUMO

Resumo da Dissertação apresentada ao Programa de Pós Graduação em Instrumentação, Controle e Automação de Processos de Mineração como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

LOCALIZAÇÃO DE ROBÔS MÓVEIS POR MEIO DE FLUXO ÓTICO E FUSÃO SENSORIAL EM AMBIENTES DE MINERAÇÃO

Jacó Dias Domingues

Setembro/2022

Orientadores: Gustavo Pessin
Gustavo Freitas
Héctor Azpúrua

Atualmente, veículos autônomos, em mineração a céu aberto, usam GNSS para localização. Devido a fenômenos atmosféricos, o sinal GNSS pode tornar-se instável, podendo fazer com que equipamentos autônomos parem seus movimentos, diminuindo assim a produtividade da mina. Esta dissertação propõe métodos para estimar a localização 2D de veículos terrestres através do fluxo óptico de imagens de uma câmera apontada para o chão, IMU e encoders de rodas, com foco nos ambientes de mineração. A utilização de uma câmera voltada para o solo é mais robusta a partículas no ar, como neblina e poeira, do que as técnicas que utilizam sensores voltados para o horizonte. Analisamos cinco implementações para localização: (1) usando encoders de roda, (2) um método visual, (3) usando a orientação IMU e deslocamento linear por informação visual, (4) obtido pela fusão de dados de encoders de roda e IMU usando Filtro Kalman Estendido (EKF), e (5) EKF usando dados visuais, encoders e IMU. Testes são feitos em ambientes semelhantes a minas em simulação e em experimentos de campo. As simulações são implementadas no software CoppeliaSim e faz uso de texturas realistas. Nos experimentos de campo, usamos um robô móvel equipado com uma câmera, IMU e receptor GNSS com correção RTK, o qual consideramos a posição real do robô (*ground truth*). Os resultados mostram que os métodos propostos são promissores, porém com o tempo o erro na localização cresce acima do limiar permitido.

Palavras-chave: Veículos Autônomos, Odometria, Fluxo óptico.

Macrotema: Mina; **Linha de Pesquisa:** Robótica Aplicada à Mineração; **Tema:** Caminhão Autônomo;

ABSTRACT

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and Automation of Mining Process as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

LOCALIZATION OF MOBILE ROBOTS THROUGH OPTICAL FLOW AND SENSOR FUSION IN MINING ENVIRONMENTS

Jacó Dias Domingues

September/2022

Advisors: Gustavo Pessin
Gustavo Freitas
Héctor Azpúrua

Currently, autonomous mining vehicles are using GNSS for localization. Due to atmospheric phenomena, the GNSS signal becomes unstable, making autonomous equipment stop their movements, thus decreasing the mine's productivity. This paper presents a method to estimate the 2D localization of ground vehicles through the optical flow from images of a camera pointed at the ground, IMU, and wheel encoder, focusing on mining environments. Using a ground-facing camera is more robust to particulates in the air, like fog and dust, than techniques using horizon-facing sensors. We analyze five implementations for localization: (1) using wheel encoders, (2) a visual-only method, (3) using the IMU orientation and linear displacement by visual information, (4) obtained by merging wheel encoder and IMU data using Kalman Filter, and (5) a EKF using visual, encoder, and IMU data. We perform tests in mining-like environments in simulation and the field experiments. Simulations are implemented in CoppeliaSim software and makes use of realistic textures. In the field experiments, we use a mobile robot equipped with a camera, IMU, and GNSS receiver with RTK correction, which we consider the robot's actual position (ground truth). Results show that the proposed methods are promising but need to become more accurate for using in heavy mining vehicles.

Keywords: Autonomous vehicles, Odometry, Optical Flow.

Macrotheme: Mine; **Research Line:** Robotics applied to Mining; **Theme:** Autonomous Truck;

LISTA DE FIGURAS

Figura 1.1	Equipamentos autônomos que podem ser encontrados na mineração: (a) trator, (b) escavadeira, (c) caminhão, (d) motoniveladora e (e) perfuratriz.	13
Figura 1.2	Cenário típico do ambiente de mineração onde falhas de GNSS podem gerar paralisação da operação. Mina Brucutu, VALE S.A. localizada em São Gonçalo do Rio Abaixo, MG.	15
Figura 1.3	Exemplo do sistema proposto instalado em um caminhão fora de estrada modelo CAT793F da fabricante Caterpillar®	16
Figura 2.1	Modelo cinemático diferencial.	21
Figura 2.2	Modelo cinemático <i>skid-steering</i>	21
Figura 2.3	Modelo cinemático <i>Ackerman</i>	22
Figura 2.4	Geometria de uma câmera de perspectiva ou <i>pinhole camera</i>	25
Figura 2.5	Exemplo de fluxo ótico. <i>Img1</i> e <i>Img2</i> são imagens com movimento relativo entre as capturas. (a) é a representação do fluxo ótico entre <i>Img1</i> e <i>Img2</i> utilizando o padrão de setas (a.1). (b) é a representação do fluxo ótico entre <i>Img1</i> e <i>Img2</i> utilizando o padrão de cor (b.1)	26
Figura 3.1	Fluxograma geral das implementações propostas.	31
Figura 3.2	Exemplo de configuração para utilizar o método de fluxo ótico proposto, câmera a uma distancia <i>Z</i> do plano do chão e a uma distância <i>D</i> do centro de rotação do robô móvel.	32
Figura 3.3	Exemplo de fluxo ótico estimado pelo método de Gunnar-Färneback.	33
Figura 3.4	Configuração do robô utilizado nos experimentos de campo.	36
Figura 3.5	Configuração do robô utilizado nos experimentos simulados.	36
Figura 3.6	Configuração do robô Rosi utilizado nos experimentos de campo.	37
Figura 4.1	Exemplos de imagens visualizadas pela câmera apontada ao chão nos experimentos em simulação.	38
Figura 4.2	Configuração do experimento de calibração de covariância em simulação.	39
Figura 4.3	Rotas estimadas e rota real (GT) calibração de covariância em simulação.	39
Figura 4.4	Erro de posição da calibração de covariância em simulação.	40
Figura 4.5	Erro de translação da calibração de covariância em simulação.	40
Figura 4.6	Configuração do experimento em ambiente plano em simulação.	41

Figura 4.7	Rotas estimadas e rota real (GT) do experimento em ambiente plano em simulação.	42
Figura 4.8	Erro de posição do experimento em ambiente plano em simulação.	42
Figura 4.9	Erro de translação do experimento em ambiente plano em simulação.	43
Figura 4.10	Configuração do experimento com mina reconstruída em simulação.	44
Figura 4.11	Rotas estimadas e rota real (GT) experimento com mina reconstruída em simulação.	44
Figura 4.12	Erro de posição do experimento com mina reconstruída em simulação.	45
Figura 4.13	Erro de translação do experimento com mina reconstruída em simulação.	45
Figura 4.14	Configuração do experimento de campo.	47
Figura 4.15	Exemplos de imagens visualizadas pela câmera apontada ao chão nos experimentos em campo.	47
Figura 4.16	Rotas estimadas e rota real (GT) da calibração de covariância em campo.	48
Figura 4.17	Erro de posição da calibração de covariância em campo.	48
Figura 4.18	Erro de translação da calibração de covariância em campo.	49
Figura 4.19	Rotas estimadas e rota real (GT) do experimento de campo.	50
Figura 4.20	Erro de posição do experimento de campo.	50
Figura 4.21	Erro de translação do experimento de campo.	51
Figura 5.1	Histograma do Erro de Posição. Em cima: Simulação em ambiente plano. Meio: Simulação em Mina reconstruída. Em baixo: Experimentos de campo.	53
Figura 5.2	Influência da sombra no fluxo ótico. Imagens a esquerda são as imagens vista pela câmera e a direita são a representação do fluxo ótico por cor.	53

LISTA DE TABELAS

Tabela 4.1	Tabela de erros de posição referente à calibração das covariâncias em simulação.	41
Tabela 4.2	Tabela de erros translação referente à calibração das covariâncias em simulação.	41
Tabela 4.3	Tabela de erros de posição referente ao experimento em ambiente plano em simulação.	43
Tabela 4.4	Tabela de erros de translação referente ao experimento em ambiente plano em simulação.	43
Tabela 4.5	Tabela de erros de posição referentes ao experimento com mina reconstruída em simulação.	46
Tabela 4.6	Tabela de erros de translação referente ao experimento com mina reconstruída em simulação.	46
Tabela 4.7	Tabela de erros de posição referente à calibração das covariâncias em campo.	49
Tabela 4.8	Tabela de erros de translação referentes à calibração das covariâncias em campo.	49
Tabela 4.9	Tabela de erros de posição referentes ao experimento de campo.	51
Tabela 4.10	Tabela de erros de translação referentes ao experimento de campo.	51

SUMÁRIO

1	Introdução	13
1.1	Motivação	16
1.2	Objetivos gerais e específicos	17
1.2.1	Objetivos específicos	17
1.3	Contribuições técnicas e científicas	17
1.4	Estrutura da dissertação	17
2	Fundamentação Científica e Estado da Arte	19
2.1	Odometria	19
2.1.1	Técnicas de odometria por sensor	20
2.2	Processamento digital de imagens	25
2.2.1	Fluxo ótico	26
2.3	Fusão sensorial e estimação de estado	28
2.4	Trabalhos relacionados	30
3	Materiais e Métodos	31
3.1	Odometria por fluxo ótico de Gunnar-Farneback	31
3.2	Implementações do Filtro de Kalman Estendido	34
3.3	Controle de rota autônomo	34
3.4	Métricas de avaliação	35
3.5	Sistema utilizado nos experimentos	35
3.5.1	Experimentos em simulação	36
3.5.2	Experimentos em campo	37
4	Experimentos e Resultados	38
4.1	Simulação	38
4.1.1	Calibração de covariância	39
4.1.2	Rota em ambiente plano	41
4.1.3	Rota em ambiente reconstruído de cava de mina	44
4.2	Testes em campo	46
4.2.1	Calibração das covariâncias	47
4.2.2	Rota em terreno plano	49

5	Discussão	52
6	Conclusão	55
6.1	Trabalhos futuros	55
	REFERÊNCIAS BIBLIOGRÁFICAS	57

1. Introdução

A indústria de mineração vem adotando cada vez mais automatização em suas atividades. A implementação de tecnologias como veículos autônomos tem o objetivo de diminuir riscos de saúde e segurança, retirando operadores de ambientes com alto nível de risco, e aumentar a produtividade na operação. Equipamentos autônomos também podem servir para suprir necessidades de recursos humanos, visto que muitas vezes a mineração está presente em ambientes ermos sem suporte necessário a habitação humana. A frota de equipamentos autônomos em minas é composta por caminhões, motoniveladoras, tratores e perfuratrizes, exemplos destes equipamentos podem ser vistos na Figura 1.1. As operações de basculamento, transporte e contra-pilhamento já podem ser realizadas completamente autônomas. Um exemplo de mina utilizando veículos autônomos é a mina de Brucutu, São Gonçalo do Rio Abaixo, MG, da mineradora VALE S.A., onde existem caminhões e perfuratrizes completamente autônomos.



Figura 1.1: Equipamentos autônomos que podem ser encontrados na mineração: (a) trator, (b) escavadeira, (c) caminhão, (d) motoniveladora e (e) perfuratriz.

FONTE: CAT®

A localização é uma etapa essencial em atividades com equipamentos autônomos. Para que os equipamentos autônomos possam realizar as tarefas programadas eles devem manter conhecimento de sua localização ao longo do tempo. Alguns exemplos são as perfuratrizes que precisam perfurar em coordenadas específicas e os caminhões que percorrem uma rota determinada e descarregam o minério em pilhas com localização definida. Hoje, para aplicações na mineração, é necessário que os equipamentos estimem sua localização com acurácia centimétrica (aproximadamente 10 cm de erro). Quando um equipamento, por qualquer motivo, tem um erro de localização acima do limite este não pode se movimentar e cria-se uma zona de segurança em torno deste equipamento onde outros equipamentos não podem adentrar. A parada de equipamentos ao longo de uma operação atrasa a produção diminuindo a produtividade da

mina.

Atualmente, para realizar a localização dos equipamentos da frota autônoma, em minas a céu aberto, caso de Brucutu, é utilizado o sistema de navegação por satélite, *Global Navigation Satellite System* (GNSS), com correção *Real Time Kinematic* (RTK). O GNSS utiliza a triangulação de sinais de satélites para localizar um receptor, e conseqüentemente o equipamento onde ele está acoplado. Na correção RTK é utilizado um receptor com base fixa em posição conhecida para enviar as correções para os receptores nos equipamentos. Para um receptor do sinal GNSS estimar sua localização ele necessita possuir visada direta para, no mínimo, 4 satélites, e na solução utilizando correção RTK ainda necessita comunicação com a base (LI *et al.*, 2015).

O GNSS é dividido em constelações de satélites, sendo as principais o GPS (Estados Unidos), GLONAS (Rússia), Galileo (União Europeia) e Beidou (China). Os satélites do GNSS orbitam a Terra em altura próxima de 20.000 km, assim para que seu sinal possa alcançar os receptores nos equipamentos da mina, ele passa pelas camadas da atmosfera terrestre. A ionosfera é a região da atmosfera entre 48 km e 965 km de altitude, por possuir uma alta concentração de íons ela afeta a propagação de ondas eletromagnéticas, o que comumente provoca ruídos no sinal do GNSS. A interferência da ionosfera é a principal fonte de erro sistemático em localização via GNSS desde a desativação da técnica *Selective Availability*¹ em 2000 (PEREIRA, 2015). Durante fenômenos de cintilação ionosférica, causados principalmente devido a tempestades geo-magnéticas solares, o erro na localização por GNSS pode crescer o suficiente para impedir o funcionamento dos equipamentos autônomos na mineração. O GNSS também tem limitações conhecidas: não funcionam em ambientes subterrâneos, interior de construções e onde grandes estruturas impedem a visada direta entre os receptores e os satélites (regiões com grande concentração de prédios ou no caso da mineração quando a cava da mina é muito profunda e pouco larga).

Uma alternativa ao GNSS é a utilização de sensores embarcados no equipamento para estimar sua localização (MOHAMED *et al.*, 2019). A localização por sensores embarcados também pode ser chamada de odometria ou *ego-motion estimation*. As principais categorias de sensores que podem ser embarcados em um equipamento para estimação de localização são: Câmeras, LiDAR (*Light Detection And Ranging*), RaDAR (*Radio Detection And Ranging*), IMU (*Inertial Measurement Unit*) e encoder de roda. Cada sensor pode ser utilizado em diferentes técnicas de odometria, apresentando vantagens e desvantagens específicas, detalhadas no Capítulo 2.

As técnicas de odometria com maior acurácia hoje utilizam LiDARs e/ou câmeras apontadas para o horizonte como principal sensor (PANIGRAHI e BISOY, 2021). A acurácia da estimação da localização utilizando câmeras e LiDARs depende do ambiente utilizado, pois utilizam características visuais e geométricas. Muitas pesquisas em odometria tem como foco desenvolvimento de carros autônomos, portanto, ambientes urbanos (GEIGER *et al.*, 2013). O ambiente de mineração geralmente não possui características que facilitam o uso das técnicas

¹Forma utilizada pelo governo do E.U.A. para mascarar sinais de GPS e diminuir sua precisão

de odometria por câmeras e LiDARs; um cenário típico é mostrado na Figura 1.2.

Na mineração objetos podem estar distantes um dos outros e são pouco distintos em relação a textura e geometria, o que dificulta o uso de técnicas com sensores observando o horizonte. A presença de particulados no ar como poeira, chuva e neblina também pode afetar o uso das técnicas baseadas em câmeras e LiDARs. Na mineração os equipamentos operam 24 horas por dia lidando com diferentes condições climáticas e de iluminação, sendo assim, é necessário que a técnica de localização seja robusta as essas variações.



Figura 1.2: Cenário típico do ambiente de mineração onde falhas de GNSS podem gerar paralisação da operação. Mina Brucutu, VALE S.A. localizada em São Gonçalo do Rio Abaixo, MG.

FONTE: VALE S.A.

Visando mitigar possíveis interferências do ambiente e a dependência do GNSS, nesta dissertação é proposta uma técnica de odometria baseada em câmera apontada para o chão e fusão com sensores IMU e encoders de roda. É utilizado o fluxo ótico, seguindo a abordagem de Farneback (2003) e a geometria entre a câmera e veículo para estimar a odometria visual. A câmera visando o chão, pelo alvo estar mais próximo, sofre menos influência de particulados no ar que as apontadas para o horizonte (NOURANI-VATANI e BORGES, 2011). O uso de fluxo ótico não exige características distinguíveis, como quinas e arestas o que pode tornar a estimação de odometria mais robusta nos cenários de mineração. IMU e encoders de roda são sensores que medem informações do próprio veículo assim já apresentam robustez à variações

do ambiente. A fusão sensorial é feita por meio de um Filtro de Kalman Estendido (EKF) (KALMAN, 1960). A acurácia do método proposto é medida em simulação e em relação a um sistema GNSS com correção RTK, em experimentos de campo. Comparações entre vários tipos de configurações de sensores e técnicas são feitas ao longo do trabalho. A Figura 1.3 exemplifica o sistema proposto em um equipamento de mina.

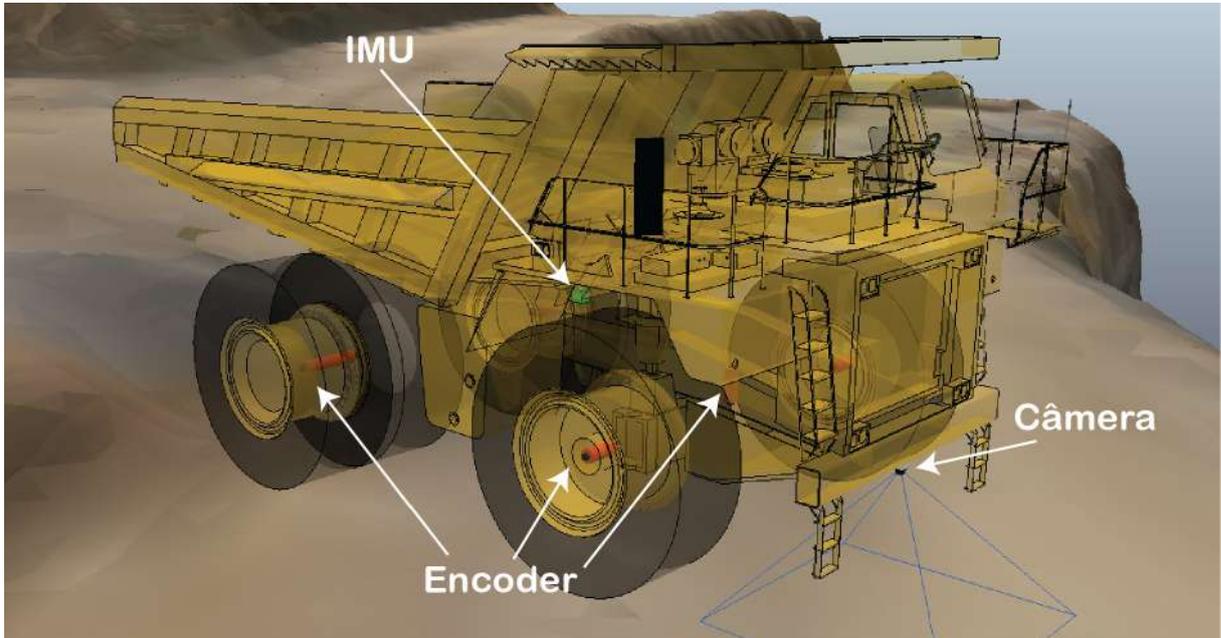


Figura 1.3: Exemplo do sistema proposto instalado em um caminhão fora de estrada modelo CAT793F da fabricante Caterpillar®

1.1. Motivação

Na mina de Brucutu, VALE S.A, existe uma solução de mina autônoma implementada. Atualmente a frota autônoma de Brucutu inclui 13 caminhões 793F e 2 perfuratrizes MD6240 ambas da Caterpillar®. Diversas operações são realizadas de forma completamente autônoma e unicamente por esses equipamentos. Em caso de falhas de GNSS esses equipamentos devem interromper todas as atividades e criam uma zona de não transição em seu entorno. Durante os meses de novembro, dezembro e janeiro esses equipamentos necessitam interromper suas atividades por aumento no erro de localização do GNSS (VALE S.A., 2020), o que foi correlacionado com dados de cintilação ionosférica, como mostrado no trabalho de Dal'Col et al. (2022).

Ainda, sinal de GNSS fica instável em cavas muito profundas, onde a partir de determinada profundidade a própria estrutura da mina impede a visada direta para os satélites, assim é necessário um sistema que atue em locais que o sinal não alcance. Além disso o GNSS pode vir a sofrer ataques hackers e militares como *spoofing* e *jamming* ou controle dos governos ao qual as constelações pertencem (CAN, 2015; PSIAKI e HUMPHREYS, 2016).

Uma alternativa levantada para aumentar a disponibilidade destes equipamentos é utilizar sensores embarcados nos equipamentos e técnicas de odometria para atuarem em casos de falha do sinal GNSS aumentando assim a disponibilidade desses equipamentos. O cenário de mineração não favorece o uso da maioria das técnicas disponíveis hoje no estado da arte, assim o método proposto é pensado para ser menos influenciado pelas condições de particulados no ar, como poeira e neblina e a necessidade de objetos próximos que os sensores possam detectar.

1.2. Objetivos gerais e específicos

O objetivo geral desta dissertação é propor, desenvolver e avaliar modelos de localização, usando fluxo ótico e fusão sensorial, para cenários similares aos encontrados em mineração.

1.2.1. Objetivos específicos

Como objetivos específicos dessa dissertação estão incluídos:

- Propor e desenvolver um algoritmo capaz de estimar a odometria de um equipamento móvel a partir de uma câmera voltada para o chão, sensor inercial e encoder de roda.
- Investigar a acurácia das implementações propostas em relação a medições de um GNSS com correção RTK.
- Analisar a técnica proposta em simulação com textura similar a ambientes de mineração.
- Analisar a técnica proposta em experimentos de campo, em ambiente similar ao de mineração, com um robô autônomo.

1.3. Contribuições técnicas e científicas

Os resultados dos estudos e desenvolvimentos realizados durante o mestrado foram publicados no 19th IEEE Latin American Robotics Symposium - LARS 2022, em um artigo intitulado *Localization of mobile robots through optical flow and sensor fusion in mining environments* (DOMINGUES *et al.*, 2022). Todos os códigos implementados, os dados utilizados e os vídeos dos experimentos estão disponíveis em um repositório ².

1.4. Estrutura da dissertação

Esta dissertação está organizada em 6 capítulos divididos da seguinte forma. O Capítulo 1 traz uma visão geral sobre a localização para equipamentos autônomos, as limitações

²<https://github.com/jacodd/OpticalFlowOdom>

do GNSS e a necessidade de um sistema de redundância para localização, são discutidas também as limitações das técnicas de odometria utilizando sensores embarcados em cenários de mineração. O Capítulo 2 apresenta uma introdução ao tema de odometria, contendo a definição, os sensores, as principais técnicas usadas para cada sensor, as vantagens e desvantagens de cada implementação e o estado da arte, além de trazer uma revisão sobre processamento digital de imagens e fusão sensorial por Filtro de Kalman. Os materiais e métodos utilizados são apresentados no Capítulo 3. Os experimentos realizados e os seus resultados são mostrados no Capítulo 4, e no Capítulo 5 é feita uma discussão das técnicas utilizadas e dos resultados alcançados. Por fim no Capítulo 6 são feitas as considerações finais e sugestões de trabalhos futuros.

2. Fundamentação Científica e Estado da Arte

Este Capítulo introduz os conceitos utilizados ao longo da dissertação. Na seção odometria é feita uma definição formal do problema de odometria, uma breve descrição a cada tipo de sensor, as técnicas mais comuns para cada tipo de sensor, as limitações e vantagens de cada sensor também é discutido. A seção de processamento de imagem traz uma revisão sobre a formação de imagem e cálculo de fluxo ótico e a seção de fusão sensorial traz uma revisão sobre Filtros de Kalman para estimação de estado de veículos terrestres.

2.1. Odometria

Estudos na área de odometria e termos relacionados tem tido bastante atenção da comunidade científica e isto ocorre principalmente ao grande investimento em carros autônomos nos últimos anos (MOHAMED *et al.*, 2019). Existe uma gama de técnicas utilizando diferentes sensores. As implementações de odometria muitas vezes estão em conjunto com técnicas de *Simultaneous Localization And Mapping* (SLAM). A principal diferença entre odometria e SLAM é que odometria concentra-se principalmente na consistência local e visa estimar incrementalmente o caminho da pose do equipamento, já SLAM visa obter um mapa do ambiente e localizar o equipamento dentro dele, obtendo uma estimativa globalmente consistente da trajetória. A consistência global é alcançada ao perceber que uma área previamente mapeada foi revisitada (chamado de fechamento de *loop*) e esta informação é utilizada para reduzir erros na estimativa de localização (YOUSIF *et al.*, 2015). Como o SLAM resolve um problema maior, muitas técnicas de odometria estão incorporadas a ele.

A odometria (do grego *odos*, que significa rota, e *metron*, que significa medida) busca estimar a trajetória de um equipamento ao longo do tempo. Nesta dissertação é adotada a definição de odometria proposta por Scaramuzza e Fraundorfer (2011), generalizando-a para o caso de um sensor qualquer. Considere um agente, como um dispositivo móvel, dotado de um ou mais sensores rigidamente acoplados a ele e um sistema temporal discreto k . Assumindo um sensor genérico S que captura o dado D_k a cada instante temporal k . A relação da pose do agente nos instantes adjacentes $k - 1$ e k é definida pela transformada homogênea mostrada na Equação 2.1. Para simplificação, os sistemas de coordenada do sensor e do agente são coincidentes.

$$T_{k,k-1} = \begin{bmatrix} R_{k,k-1} & t_{k,k-1} \\ \mathbf{0} & 1 \end{bmatrix}, \quad (2.1)$$

onde $R_{k,k-1} \in SO(3)$ é a matriz de rotação e $t_{k,k-1} \in \mathbb{R}^{3 \times 1}$ o vetor de translação. O conjunto $T_{1:n} = \{T_{1:0}, \dots, T_{n:n-1}\}$ contém todos os movimentos subseqüentes desde o momento inicial $k = 0$ até o atual $k = n$. O objetivo da odometria consiste em calcular a transformada $T_{k:k-1}$ dado as leituras dos sensores nos instantes k e $k - 1$. A pose corrente é dada concatenando

todas as transformadas do conjunto $T_{1:n}$. Como uma pose é calculada a cada nova aquisição dos sensores, o erro a cada nova iteração acumula. O acúmulo de erros leva ao problema chamado de afastamento ou *drifting*.

2.1.1. Técnicas de odometria por sensor

A odometria pode ser classificada pelo tipo de sensor utilizado na implementação, e esses podem ser classificados em sensores interoceptivos, que medem variáveis internas ao agente, e exteroceptivos, que medem variáveis do ambiente. Dentre os sensores introspectivos encontram-se as unidades inerciais e os sensores de roda, como encoders de roda e tacômetros. Os sensores exteroceptivos podem ser divididos em ativos (emitem energia e medem a resposta do ambiente) e passivos (capturam somente energia do ambiente). São sensores exteroceptivos ativos os LiDARs e RaDARs, e sensores exteroceptivos passivos as câmeras.

Odometria por encoder

Encoders são sensores que medem as revoluções de uma junta rotativa. Geralmente encoders vão acoplados as rodas de veículos terrestres para medir suas velocidade. A odometria por encoders utiliza a cinemática inversa do veículo para realizar a localização por meio das velocidades da roda. A vantagem deste modelo de odometria é sua simples implementação, porém tem limitações importantes. As desvantagens da odometria por encoders é que são limitados à veículos terrestres com rodas e como as rodas muitas vezes sofrem escorregamento, estas rotações são contabilizadas como movimento do veículo.

Modelos cinemáticos

Na robótica a cinemática estuda como as velocidades, forças e deslocamento de juntas influenciam no movimento de um robô. Para o cálculo de odometria por meio de encoders de roda é necessário utilizar o modelo cinemático do veículo. Nesta seção são apresentados os principais modelos de equipamentos móveis encontrados na mineração. Uma análise mais profunda de cinemática de equipamentos móveis terrestres pode ser encontrada nos trabalhos de Siciliano *et al.* (2008) e Spong *et al.* (2006).

O modelo cinamético diferencial é utilizado como simplificação para equipamentos onde seu movimento é baseado em juntas rotativas em cada lado. A Figura 2.1 exemplifica esse modelo cinemático. A relação entre as velocidades da junta e velocidade de um equipamento móvel é dado pela Equação 2.2:

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ \dot{\theta} \end{bmatrix} = \frac{r}{2} \begin{bmatrix} \cos(\theta) & \cos(\theta) \\ \sin(\theta) & \sin(\theta) \\ \frac{1}{b} & \frac{1}{b} \end{bmatrix} \begin{bmatrix} \omega_D \\ \omega_E \end{bmatrix}, \quad (2.2)$$

onde X, Y, θ é a pose do robô, ω_D é a velocidade da roda direita, ω_E a velocidade da roda esquerda, r é o raio da roda e b é a metade da distância entre as rodas.

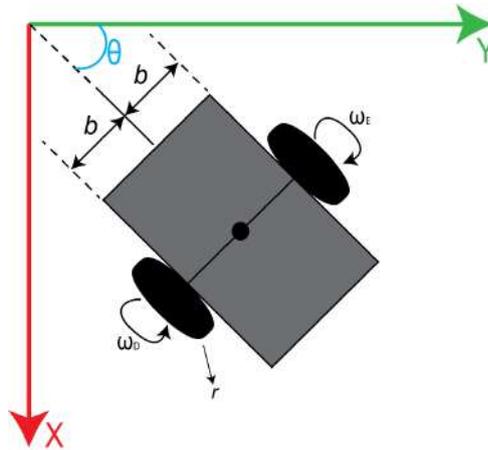


Figura 2.1: Modelo cinemático diferencial.

O modelo *Skid-steering* é o modelo de robôs com dois eixos de rodas ou movidos a esteira, como perfuratrizes, escavadeiras e tratores (Figura 1.1). A Figura 2.2 exemplifica o modelo cinemático *Skid-steering*. Um possível modelo cinemático para esse tipo de equipamento é o apresentado por Dogru e Marques (2021), onde de a relação entre velocidades das rodas e a velocidade do veículo é dado pela Equação 2.3:

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ \dot{\theta} \end{bmatrix} = \frac{r}{2} \begin{bmatrix} \cos(\theta) & \cos(\theta) \\ \sin(\theta) & \sin(\theta) \\ \frac{b}{b^2+a^2} & \frac{b}{b^2+a^2} \end{bmatrix} \begin{bmatrix} \omega_D \\ \omega_E \end{bmatrix}, \quad (2.3)$$

onde $[X, Y, \theta]$ é a pose do robô, ω_D é a velocidade da roda direita, ω_E a velocidade da roda esquerda, r é o raio da roda, b é a metade da distância entre as rodas e a é a metade da distância entre os eixos.

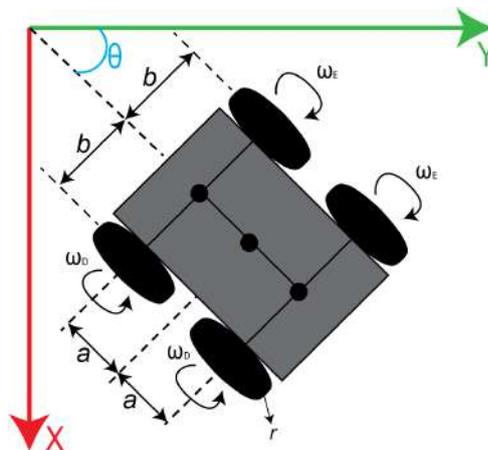


Figura 2.2: Modelo cinemático *skid-steering*.

Caminhões e motoniveladoras (Figura 1.1) podem ser aproximados pelo modelo do tipo *ackerman*) (Figura 2.3), cuja a relação entre velocidades da rodas, angulo de direção e a velocidade do veículo é dada pela Equação 2.4:

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ \dot{\theta} \end{bmatrix} = \frac{r}{2} \begin{bmatrix} \cos(\theta) & \cos(\theta) \\ \sin(\theta) & \sin(\theta) \\ \frac{\tan(\phi)}{2a} & \frac{\tan(\phi)}{2a} \end{bmatrix} \begin{bmatrix} \omega_D \\ \omega_E \end{bmatrix}, \quad (2.4)$$

onde $[X, Y, \theta]$ é a pose do robô, ω_D é a velocidade da roda direita, ω_E a velocidade da roda esquerda, r é o raio da roda, a é a metade da distância entre os eixos e ϕ é o angulo de direção.

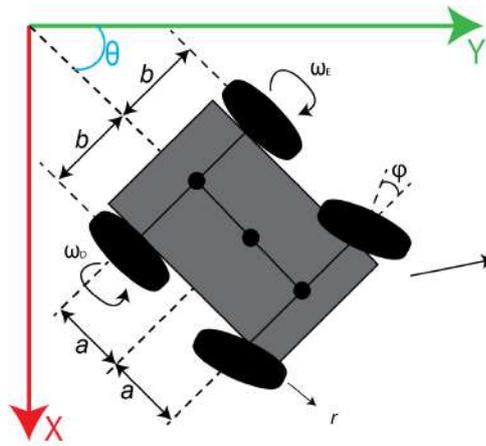


Figura 2.3: Modelo cinemático *Ackerman*.

A pose do veículo, localização e orientação, é conseguida a partir da integração das suas velocidades no tempo.

Odometria inercial

A odometria inercial utiliza sensores chamados de IMU. As IMUs consistem de acelerômetros e giroscópios e podem também conter magnetômetros. O acelerômetro mede o vetor de aceleração linear atuando no sensor. O giroscópio mede a velocidade angular do sensor. O magnetômetro mede o campo magnético atuando no sensor. A localização inercial é calculada por meio da fusão e integração no tempo dos valores medidos em pelos sensores. Os dados fornecidos pela IMU tem vantagem de não dependerem do ambiente nem do modelo cinemático do equipamento assim podem ser utilizadas em qualquer tipo de equipamento sobre diversas condições. A maior desvantagem das técnicas baseadas em sensores inerciais é o erro acumulativo, que pode crescer rapidamente pela medida de aceleração ser muito ruidosa; porém a orientação calculada por IMU costuma ser bem acurada (por contar com referências absolutas como o campo magnético terrestre e a gravidade). Devido ao erro acumulativo a precisão da odometria somente por IMU decai muito com o tempo impossibilitando o uso em grandes trajetórias. Uma implementação de IMU para estimação de pose, e consequentemente odometria, pode ser vista no trabalho de Kok et al. (2017).

Odometria por laser

A odometria laser é a técnica que tem como base os sensores do tipo LiDAR. Estes sensores em geral funcionam por meio de um princípio chamado de *Time of Flight* (ToF). Primeiro o dispositivo emite um ou vários feixes de luz (geralmente infravermelho), em uma segunda fase o sensor observa o tempo em que o feixe emitido demora para ser refletido de volta ao sensor. A distância entre o sensor e o ambiente é calculada com base no tempo de resposta. LiDARs retornam como dados um conjunto de pontos no espaço tridimensional chamado de nuvem de pontos. A técnica de odometria laser é baseada em encontrar a transformada entre duas nuvens de pontos consecutivas com um algoritmo do tipo registro de conjunto de pontos (e.g. *Iterative Closest Point* - ICP) (ZHANG e SINGH, 2014). Todo o conjunto de pontos ou apenas pontos de interesse, como quinas, podem ser utilizados na etapa de estimação da pose relativa entre as nuvens de pontos.

As principais desvantagens dos LiDARs é que só fornecem informações sobre a geometria da cena, e muitas vezes de forma esparsa; além disso, sofrem distorções provenientes de superfícies que não refletem a luz de forma difusa (HORN e SCHMIDT, 1995). Uma aplicação utilizando LiDAR para SLAM, e conseqüentemente odometria, pode ser vista no trabalho de Zhang e Singh (2014).

Odometria por RaDAR

RaDAR é um sensor que usa ondas de rádio para determinar a velocidade, distância e ângulo dos objetos ao redor, utilizando o princípio de ToF. As leituras do RaDAR podem ser formatadas em nuvem de pontos 3D ou em imagem 2D. Técnicas de odometria por RaDAR seguem os mesmo passos utilizados nas técnicas baseadas em laser, a odometria é estimada encontrando a diferença da pose entre leituras ou entre os pontos de interesse nas leituras, por meio de técnicas como o ICP. Uma aplicação de RaDAR-SLAM pode ser encontrada no trabalho de Hong *et al.* (2020). As vantagens do RaDAR é que suas medições não sofrem interferência de particulados no ar, como chuva, neblina e poeira, porém as leituras tendem a ser mais ruidosas e menos precisas que LiDARs e câmeras o que impossibilita alcançar a acurácia de odometrias que utilizam os dois últimos sensores.

Odometria visual

Técnicas de odometria visual (VO) são as baseadas em câmeras, sendo elas dos mais diversos tipos. Uma análise detalhada das técnicas e implementações de VO pode ser encontrado no trabalhos de Scaramuzza e Fraundorfer (2011) e sua sequência Fraundorfer e Scaramuzza (2012).

A odometria visual pode ser classificada conforme a informação utilizada (aparência ou *features*), pelo tipo de lente utilizada (perspectiva ou omnidirecional), número de sensores

utilizados (monocular, estéreo, RGB-D) e finalmente pela correspondência entre as capturas consecutivas (projeções 2D-2D, 3D-2D, 3D-3D).

Métodos baseados em **aparência** usam a mudança na intensidade dos pixels nas imagens. Um algoritmo de fluxo óptico é usado para determinar as diferenças em duas capturas consecutivas. Uma das implementações mais famosas é o algoritmo de Lucas-Kanade (LUCAS et al., 1981). Métodos baseados em **features** utilizam detectores (e.g. SURF de Bay et al. (2008)) para encontrar pontos ou regiões de interesse em leituras consecutivas. Os passos da estimação de movimento é similar aos LiDARs e RaDARs: captura de imagem, detecção de *features*, correspondência entre os *features* entre duas leituras consecutivas. Com os pontos comuns em duas imagens a estimação do movimento relativo é feito, sendo o algoritmo mais comum o de Nistér (2004). Técnicas de otimização, *Bundle Adjustment* (BA) podem ser usadas como pós-processamento, diminuindo os erros. Algoritmos de rejeição de *outlier* como o *RANdom SAmple Consensus* (RANSAC) são geralmente usados na etapa de correspondência para diminuir a influencia de ruídos. Uma implementação utilizando esse método pode ser vista no trabalho de Mur-Artal et al. (2015).

Métodos **monoculares** utilizam somente uma câmera para a estimação da odometria. Uma das desvantagens do método monocular é que o resultado vem acompanhado de um fator de escala e geralmente necessitam de outro sensor para obter a informação da escala relativa. Métodos que utilizam a configuração **estéreo**, RGB-D e ToF além das informações de cores obtêm a informação de profundidade da cena, o que resolve o problema da escala da odometria visual monocular. Uma observação importante é que a configuração estéreo pode vir a decair para o caso monocular quando o *baseline* (distância relativa entre os pontos focais das duas câmeras) é muito menor que a distâncias relativas na cena (SCARAMUZZA e FRAUNDORFER, 2011). As Câmeras **RGB-D** utilizam uma projeção, como um padrão conhecido em infra-vermelho, e a geometria entre o projetor e a câmera para medir a distância real de cada pixel na cena capturada. Já as ToF são similares aos LiDARs.

Em relação ao modelo de projeção de uma câmera existem os modelos perspectiva, *fish-eye/omnidirecional* e esférico. O modelo mais comum de câmera é o conhecido por **perspectiva** que utiliza o sistema de projeção *pin-hole* para mapear a cena nos pixels. Câmeras **omnidirecionais** são as que tem um campo de visão maior que 180° (podendo utilizar lentes *fish-eye* ou ser do tipo Catadióptrica) um método de odometria visual utilizando este tipo de projeção é o trabalho de Scaramuzza et al. (2006). O modelo esférico serve para ambos os modelos anteriores onde os pixels são mapeados em uma esfera em torno de um ponto de projeção.

Um tipo de câmera que também pode ser usado em odometria visual são as chamadas **event-based cameras**. As câmeras de eventos são sensores de visão bioinspirados, por exemplo, sensores de visão dinâmicos (DVS), que capturam mudanças na intensidade de forma assíncrona em todos os pixels da câmera, porém essas câmeras ainda são uma tecnologia nova e com custo alto. Uma aplicação com este tipo de câmera pode ser visto no trabalho de Kueng et al. (2016), Rebecq et al. (2017). Há também trabalhos como o de Khatkhat et al. (2019) que utilizam

câmeras térmicas para odometria visual; essas câmeras têm melhor resultado em cenários com fumaça e neblina, porém tem resolução menor de imagem o que influencia na acurácia da odometria visual.

Nessa dissertação foi utilizado uma implementação de odometria visual que não segue os padrões das técnicas mencionadas. A relação entre as imagens é estimada a partir de fluxo ótico e o movimento relativo entre as capturas é estimada utilizando a transformada perspectiva da câmera e suposições da geometria entre a câmera, o equipamento no qual esta acoplada e o chão.

2.2. Processamento digital de imagens

Uma imagem é um “aparato” utilizado para retratar ou armazenar a percepção visual. As informações armazenadas em imagens são uma discretização da intensidade da luz emitida pelo ambiente. Como uma imagem captura apenas a luz, as relações de localidade de cada feixe de luz são perdidas. Uma câmera monocular pode ser representada por um modelo geométrico chamado câmera de perspectiva ou *pinhole camera*, mostrado na Figura 2.4. Neste modelo, uma imagem é composta por todos os raios que cruzam a origem do sistema de coordenada da câmera. A distribuição dos pixels é definida pela distância f , denominada distância focal, que é um dos parâmetros intrínsecos das câmeras, geralmente obtidos por calibração.

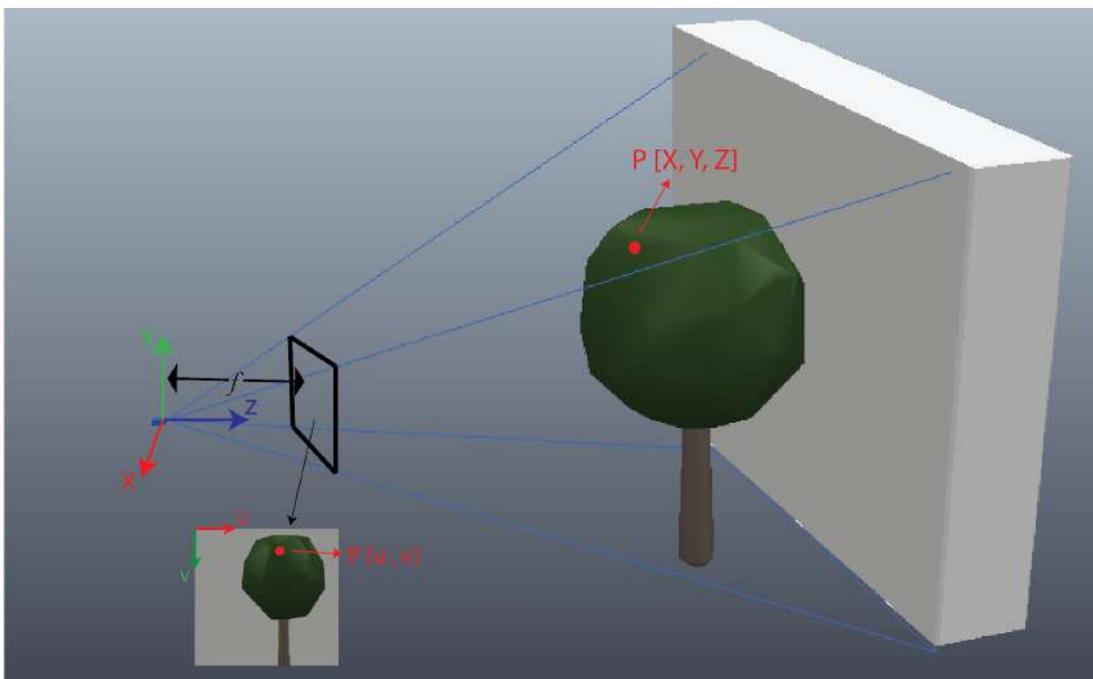


Figura 2.4: Geometria de uma câmera de perspectiva ou *pinhole camera*.

A relação entre o ponto 3D (x, y, z) , as coordenadas da imagem (u, v) e a distância focal da câmera f é dado pelas Equações 2.5 e 2.6. Essa relação é chamada de projeção perspectiva.

$$u = f * \frac{X}{Z}, \quad (2.5)$$

$$v = f * \frac{Y}{Z}. \quad (2.6)$$

2.2.1. Fluxo ótico

O fluxo ótico em uma imagem é o movimento aparente que os pixels executam quando há movimento relativo entre a câmera e os objetos na cena. Um exemplo de fluxo ótico pode ser visto na Figura 2.5, onde o fluxo ótico é representado de duas maneiras, padrão de cor e de setas.

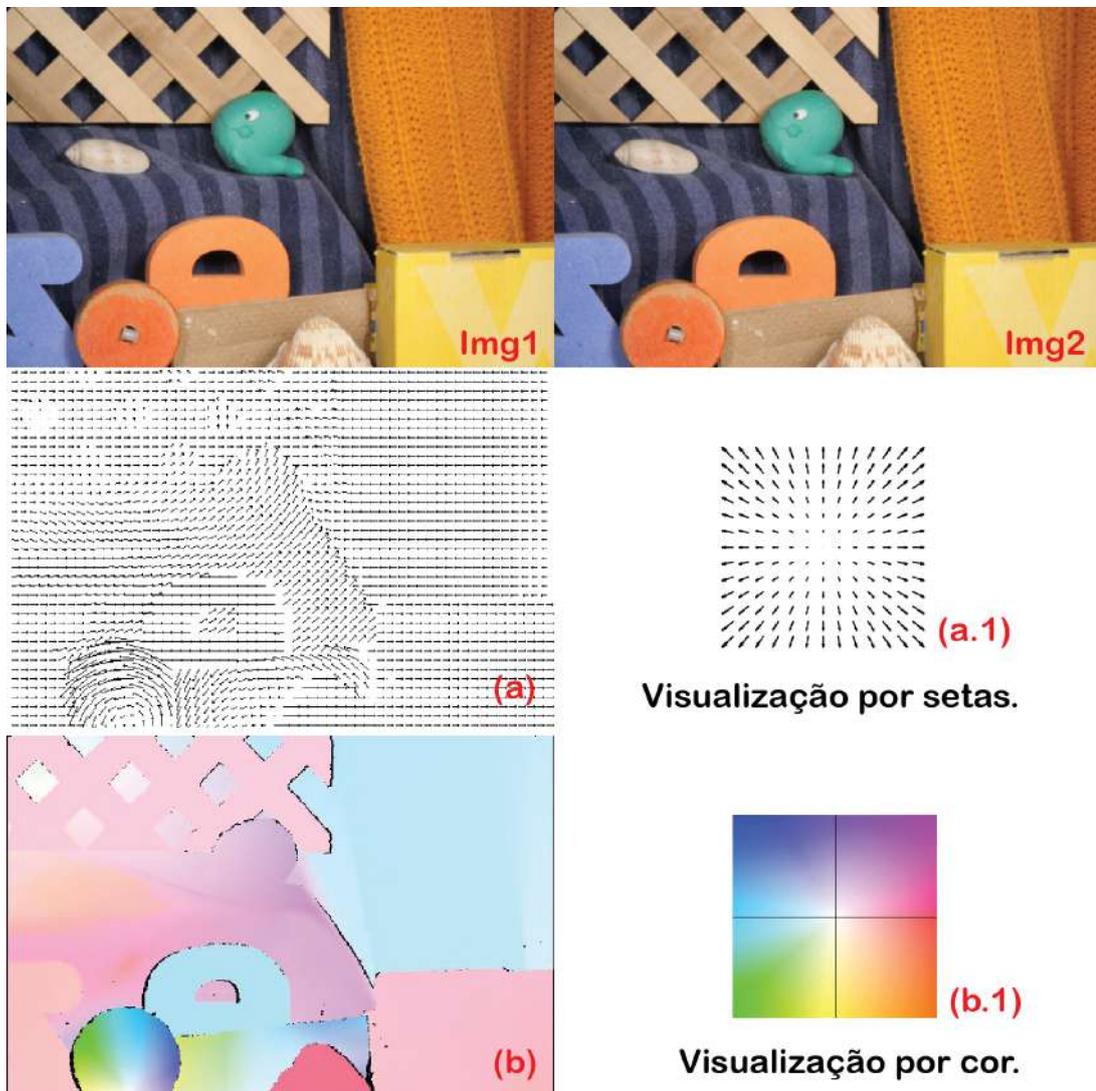


Figura 2.5: Exemplo de fluxo ótico. Img1 e Img2 são imagens com movimento relativo entre as capturas. (a) é a representação do fluxo ótico entre Img1 e Img2 utilizando o padrão de setas (a.1). (b) é a representação do fluxo ótico entre Img1 e Img2 utilizando o padrão de cor (b.1)

FONTE: Adaptado de Fortun et al. (2015).

Considere uma imagem como a função das intensidades dos pixels, assumi-se que : (1) a intensidade luminosa na imagem de um ponto no espaço entre duas aquisições é igual e (2) a localização do pixel que descreve um ponto tem pequenas variações entre duas aquisições, comportamento que é descrito pela Equação 2.7 (HORN e SCHUNCK, 1981):

$$.I(u, v, k) = I(u + \delta u, v + \delta v, \delta t), \quad (2.7)$$

onde u e v são as coordenadas da imagem, t é um sistema temporal e δt o tempo entre aquisições de imagem, δu e δv são as variações na localização do pixel nas coordenadas u e v da imagem respectivamente. Assumindo que δu e δv são pequenos pode-se aproximar a Equação 2.7 por série de Taylor obtendo a Equação 2.8:

$$I(u + \delta u, v + \delta v, t + \delta t) \approx I(u, v, t) + \frac{\partial I}{\partial u} \delta u + \frac{\partial I}{\partial v} \delta v + \frac{\partial I}{\partial t} \delta t. \quad (2.8)$$

Assim da Equação 2.7 e da Equação 2.8 obtém-se a Equação 2.9:

$$\frac{\partial I}{\partial u} \frac{\delta u}{\delta t} + \frac{\partial I}{\partial v} \frac{\delta v}{\delta t} + \frac{\partial I}{\partial t} = 0. \quad (2.9)$$

Algoritmos de fluxo ótico buscam encontrar os deslocamentos δu e δv , como há somente uma equação e duas variáveis é necessária alguma abordagem ao problema para estimá-las. Os trabalhos de Lucas et al. (1981) e Farnebäck (2003) apresentam maneiras de calcular o fluxo ótico.

O método proposto por Farnebäck (2003) apresenta menor erro e maior densidade de fluxo que Lucas et al. (1981), assim foi escolhido para ser utilizado nesta dissertação. A ideia é aproximar as vizinhanças dos pixels por polinômios quadráticos. A Equação 2.10 mostra a expansão para um sinal unidimensional:

$$f(x) \approx x^T A x + b^T x + c, \quad (2.10)$$

onde A é uma matriz simétrica, b um vetor e c um escalar. Esses coeficientes são estimados de um método de mínimos quadrados ponderados na vizinhança do pixel. Assim assumindo que o pixels tem um deslocamento δ é obtido a Equação 2.11:

$$\begin{aligned} f_2(x) &= f_1(x - \delta) = \\ x^T A_2 x + b_2^T x + c_2 &= (x - \delta)^T A_1 (x - \delta) + b_1^T (x - \delta) + c_1. \end{aligned} \quad (2.11)$$

Da Equação 2.11 é possível tirar a Equação 2.12:

$$\begin{aligned}
A_2 &= A_1, \\
b_2 &= b_1 - 2A_1\delta, \\
c_2 &= d^T A_1 \delta - b_1^T \delta + c_1.
\end{aligned} \tag{2.12}$$

Da Equação 2.12 é possível encontrar o deslocamento δ pela Equação 2.13:

$$\delta = -\frac{1}{2}A_1^{-1}(b_2 - b_1). \tag{2.13}$$

2.3. Fusão sensorial e estimação de estado

Para aproveitar das vantagens de mais de um tipo de dado ou suprir uma necessidade de alguma técnica, geralmente as implementações de odometria utilizam mais de um sensor. Por exemplo, Zhang e Singh (2014) utilizam LiDARs e IMU. O trabalho de Leutenegger *et al.* (2015) faz uso de câmeras monoculares e IMU. Zuo *et al.* (2019) utilizam câmeras LiDARs e IMU. No trabalho de Dang *et al.* (2021) tem uma implementação usando RaDAR, LiDAR e IMU. Uma das maneiras de fundir dados para estimação de estado e localização de um equipamentos móveis é por meio do Filtro de Kalman (KALMAN, 1960).

O Filtro de Kalman tem formulação bem conhecida, como vista nos trabalhos de Smith *et al.* (1962) e Welch *et al.* (1995). O Filtro de Kalman é um conjunto de equações matemáticas que fornece uma solução computacional (recursiva) eficiente do método dos mínimos quadrados. O filtro é muito poderoso em vários aspectos: suporta estimativas de estados passados, presente e futuros, e mesmo quando a modelagem do sistema modelado é desconhecida (WELCH *et al.*, 1995). Nesta dissertação é mostrado o procedimento do Filtro de Kalman Estendido (EKF) pois ele é não linear, o que é necessário para estimar a pose de robôs móveis.

A ideia de um Filtro de Kalman é estimar o estado atual ou futuro de um sistema governado por equações diferenciais. O processo para estimar um estado é descrito pela Equação 2.14, onde o estado atual é uma função do estado anterior.

$$\hat{X}_k = f(X_{k-1}) + W_{k-1}, \tag{2.14}$$

onde X_k é o estado atual, X_{k-1} o estado anterior, f é uma função não-linear de transição de estado e W é o ruído do processo. Para localização 2D, X_k é um vetor 1x3 contendo a posição (X,Y) e a orientação (θ) .

As medidas dos sensores e/ou algoritmos pode ser descrita pela Equação 2.15.

$$Z_k = h(X_k) + v_k, \tag{2.15}$$

onde Z é a medida atual e h é o modelo não linear do sensor que mapeia o estado no espaço das

medições e v é o ruído das medições.

A covariância do valor estimado é dado pela Equação 2.16:

$$\hat{P}_k = FP_{k-1}F^T + Q, \quad (2.16)$$

no caso de localização 2D, f é o modelo cinemático, P é a covariância estimada projetada por F , jacobiano de f e perturbada pelo ruído do processo Q .

Então é feito o cálculo do ganho do filtro, chamado de ganho de Kalman, pela Equação 2.17:

$$K_k = \hat{P}_k H^T (H_k \hat{P}_k H^T + R)^{-1}, \quad (2.17)$$

onde K é o ganho do Kalman, H é a matriz de observação, R a covariância das medidas.

O estado atual então é calculado pela Equação 2.18:

$$X_k = \hat{X}_k + K_k(z_k - H_k \hat{X}_k), \quad (2.18)$$

e a covariância atual é calculada pela Equação 2.19:

$$P_k = (I - K_k H_k) \hat{P}_k (I - K_k H_k)^T + K_k R_k K_k^T. \quad (2.19)$$

O Algoritmo 1 exemplifica a implementação do EKF. O algoritmo basicamente pode ser dividido em duas etapas: (1) previsão, onde o estado atual é estimado a partir do estado anterior e (2) correção, onde é feita uma ponderação entre o estado estimado e as medições.

Algoritmo 1: Pseudo-código do EKF.

```

1 k: 0;
2  $X_k$ : Estado inicial;
3  $P_k$ : covariância inicial;
4 while True do
5     k: k + 1;
6     Atualização no tempo (previsão);
7     Prevê um estado atual: Equação 2.14;
8     Prevê a covariância atual: Equação 2.16;
9     Atualização de medidas (correção);
10    Calcula o Ganho de Kalman: Equação 2.17;
11    Atualiza Estimativa com base nas medições: Equação 2.18;
12    Calcula a covariância: Equação 2.19;
13 end

```

2.4. Trabalhos relacionados

Esta seção descreve alguns trabalhos relevantes na estimativa da odometria através de câmeras voltadas para o chão. Normalmente, os métodos dividem o problema em estimativa de translação e orientação. O odometria final do veículo pode ser obtida a partir do deslocamento de pixels de imagens do chão, projeção da câmera e cinemática do veículo.

Dille *et al.* (2010) usaram uma combinação de módulo de visão comercial (consistindo em quatro sensores "tipo mouse") e um módulo IMU para realizar odometria em seu *rover* Lunar. O módulo de visão é montado sob o veículo voltado para baixo e relata a velocidades de movimento linear. A odometria final do *rover* é obtida com a orientação obtida pela IMU e assumindo as restrições não holonômicas do *rover*. O foco d

Nourani-Vatani e Borges (2011) utilizaram uma câmera apontada para o chão e estimam o movimento por meio do deslocamento de sub-regiões entre dois frames. O deslocamento de pixels é obtido por uma técnica de correlação entre as imagens. Um veículo com cinemática tipo carro é assumido e a odometria é estimada a partir da projeção perspectiva.

No trabalho de Birem *et al.* (2018) uma câmera paralela à uma superfície plana é utilizada para calcular a odometria de um robô terrestre, a translação é obtida pelo deslocamento de sub-regiões entre duas imagens, que é obtido pela análise da FFT, *fast fourier transform* das imagens, a orientação é estimada utilizando uma abordagem de FMT, *Fourier–Mellin transform* em diferentes regiões da imagem.

As contribuições desta dissertação estão em utilizar o algoritmo de fluxo ótico proposto por Farnebäck (2003) para estimar o deslocamento de pixels, essa abordagem estima o deslocamento de todos os pixels em uma imagem, o que aumenta a robustez no cálculo de odometria. A odometria do veículo é obtida por meio da projeção perspectiva da câmera. Nesta dissertação também é utilizada uma abordagem de Filtro de Kalman para fundir a técnica visual com odometria de rodas e informações inerciais. As implementações de odometria são testadas em ambientes de mineração, que apresenta desafios maiores as técnicas de odometria e se diferencia do ambientes urbanos que é o foco dos trabalhos do estado da arte.

3. Materiais e Métodos

Nesta dissertação é proposto um método para estimação da odometria de um equipamento por meio de uma câmera voltada ao chão e fusão sensorial com odometria por encoder de rodas e IMU. A odometria visual é estimada utilizando o fluxo ótico, calculado usando a implementação do OpenCV¹ de Gunnar-Färneback, e a geometria entre a câmera e o centro de movimento do equipamento.

São propostas 5 implementações para comparações entre si e em relação a posição verdadeira: (1) odometria calculada por encoders de roda, (2) odometria calculada totalmente pela câmera apontada para o chão, (3) odometria calculada utilizando a orientação da IMU e deslocamento linear pela odometria visual proposta, (4) odometria obtida pela fusão da odometria de encoders de roda e dados da IMU utilizando EKF e (5) odometria obtida pela fusão da odometria visual, odometria dos encoders da roda e dados da IMU por meio de EKF. Todos os códigos e sensores, tanto em simulação e nos testes de campo, foram integrados e/ou implementados utilizando o ROS (QUIGLEY *et al.*, 2009). A Figura 3.1 exemplifica as implementações propostas.

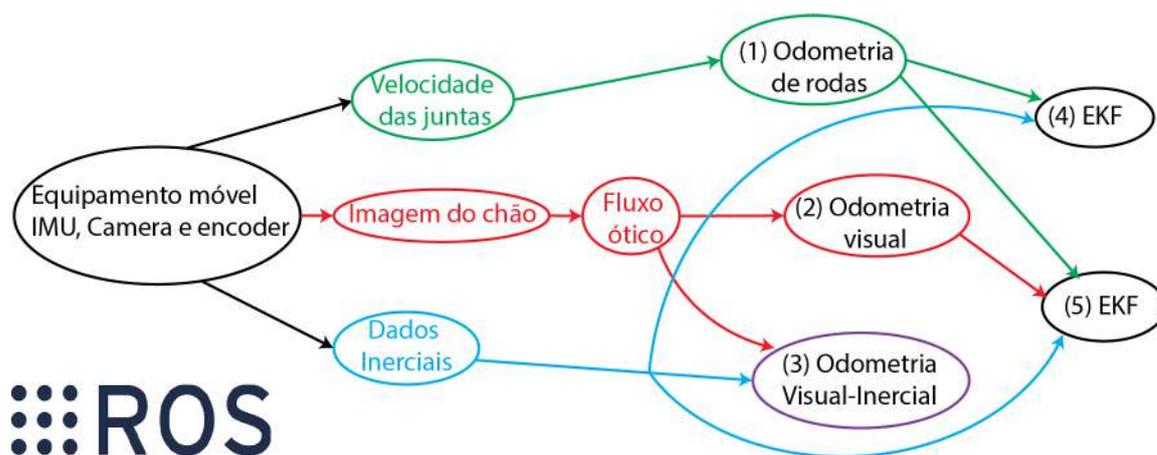


Figura 3.1: Fluxograma geral das implementações propostas.

3.1. Odometria por fluxo ótico de Gunnar-Farneback

Considere o sistema mostrado na Figura 3.2 onde uma câmera esta rigidamente acoplada a um veículo e apontada para o chão. O fluxo ótico calcula o deslocamento dos pixels nas direções U e V no plano da imagem. Assumindo as hipóteses: (1) o chão é um plano paralelo ao plano da imagem formada pela câmera e (2) a câmera executa pequenos movimentos a cada aquisição de imagem. A odometria do equipamento pode ser calculada a partir do fluxo ótico e projeção perspectiva pela Equação 3.1.

¹Biblioteca de visão computacional disponível em <https://opencv.org/>

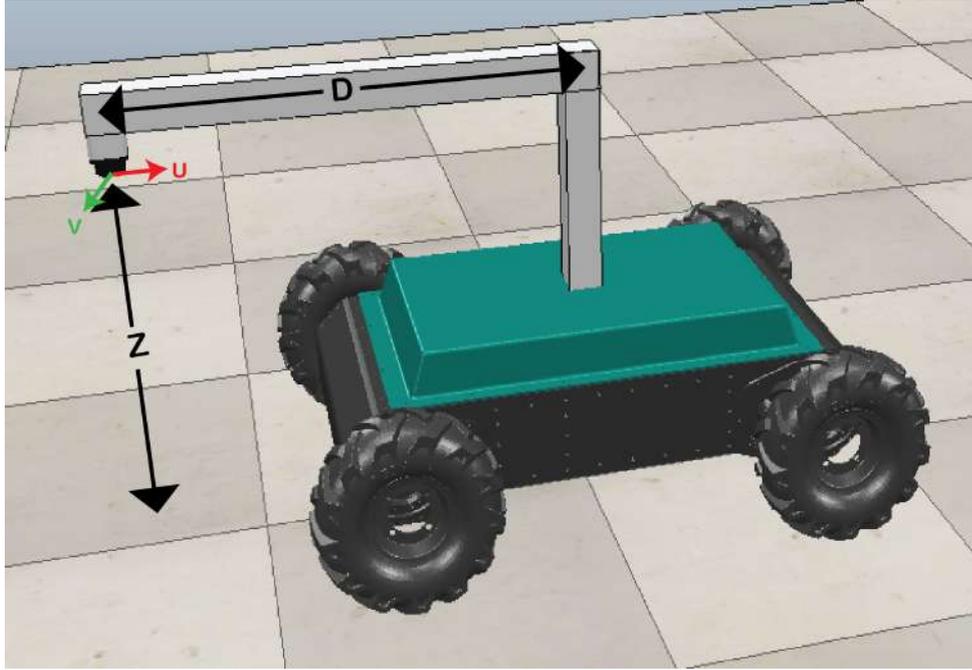


Figura 3.2: Exemplo de configuração para utilizar o método de fluxo ótico proposto, câmera a uma distancia Z do plano do chão e a uma distância D do centro de rotação do robô móvel.

$$\begin{aligned}
 \theta &= \arctan\left(\frac{\delta v Z}{D}\right), \\
 X &= \frac{\delta u Z}{f_u} \cos(\theta), \\
 Y &= \frac{\delta u Z}{f_u} \sin(\theta),
 \end{aligned} \tag{3.1}$$

onde X, Y, θ são a pose do veículo, δu e δv são o fluxo ótico estimado na direção U e V do plano da imagem respectivamente, f_u e f_v são as distâncias focais da câmera na direção u e v do plano da imagem, D é a distância da câmera ao centro de rotação do equipamento e Z a distância da câmera ao chão.

A Figura 3.3 mostra um exemplo de fluxo ótico de uma câmera apontada para o chão (para efeito visual foi considerado somente um pixel em uma janela de 25x25). O deslocamento de pixels considerado para o cálculo de odometria é a mediana do valor de todos os pixels da imagem, o que o torna mais robusto contra *outliers*. O Algoritmo 2 demonstra como seria o funcionamento dos métodos de odometria por fluxo ótico.

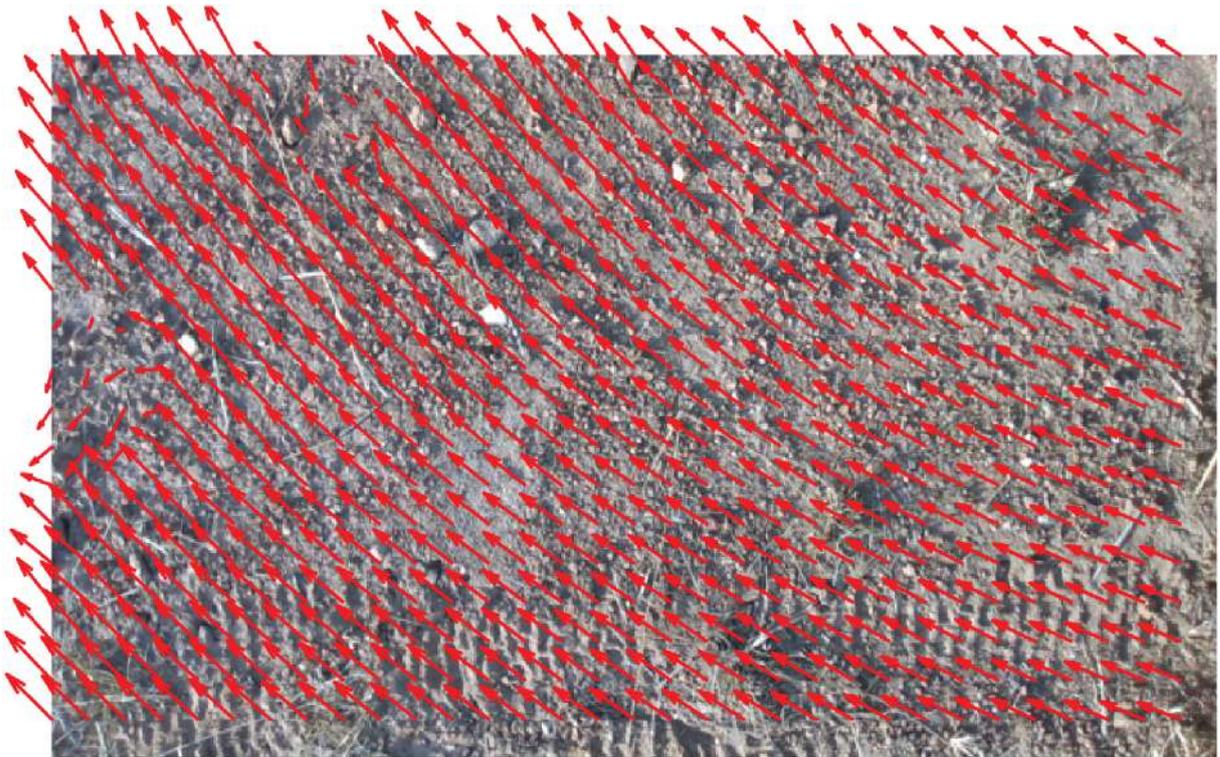


Figura 3.3: Exemplo de fluxo ótico estimado pelo método de Gunnar-Färneback.

Algoritmo 2: Pseudo-código do método proposto de odometria visual.

```

1 IMG: Imagens capturadas pela câmera;
2  $f_u, f_v$ : Distância focal da câmera na direção u e v;
3 Z: Distância da câmera para o chão;
4 D: Distância da câmera para o centro do robô ;
5 for ( $img \in IMG$ ) do
6    $flow$ : calcOpticalFlowFarneback( $img_k, img_{k-1}$ );
7    $dx_u$ : mediana( $flow.direção\_u$ );
8    $dx_v$ : mediana( $flow.direção\_v$ );
9    $\theta_k$ :  $\theta_{k-1} + \text{arctangente}(dx_v f_v / D)$ ;
10   $X_k$ :  $X_{k-1} + dx_u Z / f_u \cos(\theta_k)$ ;
11   $Y_k$ :  $Y_{k-1} + dx_u Z / f_u \sin(\theta_k)$ ;
12   $Pose_k$ :  $[X, Y, \theta]$ ;
13 end

```

Uma segunda implementação considera a orientação do equipamento direto de uma IMU e estima somente o deslocamento linear do robô pelo fluxo ótico. Assim, na Equação 3.1, o θ usado é direto da IMU. O Algoritmo 3 apresenta o funcionamento dos métodos de odometria por fluxo ótico e IMU fundidas diretamente.

Algoritmo 3: Pseudo-código do método proposto de odometria visual com orientação provida de IMU.

```
1 IMG: Imagens capturadas pela câmera;  
2 IMU: Orientações  $\theta$  capturadas pela IMU;  
3  $f_u, f_v$ : Distância focal da câmera na direção u e v;  
4 Z: Distância da câmera para o chão;  
5 D: Distância da câmera para o centro do robô ;  
6 for ( $img \in IMG$ ) && ( $\theta \in IMU$ ) do  
7    $flow$ : calcOpticalFlowFarneback( $img_k, img_{k-1}$ );  
8    $dx_u$ : mediana( $flow.direção\_u$ );  
9    $X_k$ :  $X_{k-1} + dx_u Z / f_u \cos(\theta)$ ;  
10   $Y_k$ :  $Y_{k-1} + dx_u Z / f_u \sin(\theta)$ ;  
11   $Pose_k$ : [X, Y,  $\theta$ ];  
12 end
```

3.2. Implementações do Filtro de Kalman Estendido

Nesta dissertação foi utilizado a implementação do Filtro de Kalman estendido proposta por Moore e Stouch (2014). A implementação proposta esta disponível como um pacote² do ROS. Na implementação utilizada os diversos sensores são fundidos de acordo com as variáveis que eles fornecem. Como é proposto somente a estimação de pose 2D, para a odometria (visual e de roda) são utilizados a pose (X, Y, θ) e para a IMU a orientação (θ) e a velocidade angular $(\frac{\partial \theta}{\partial t})$. As covariâncias, necessárias para o filtro, das variáveis estimadas são calculadas por meio de uma rota de calibração.

3.3. Controle de rota autônomo

Em todos os experimentos propostos, o robô segue os caminhos propostos de forma autônoma usando um controlador de campo vetorial artificial apresentado em Rezende et al. (2021). A implementação desta técnica esta disponível como um pacote³ ROS. Devido às limitações do robô Rosi e do simulador utilizado, a velocidade linear máxima é definida para 0,5 m/s.

²https://github.com/cra-ros-pkg/robot_localization

³https://github.com/ITVRoC/espeleo_control

3.4. Métricas de avaliação

Para avaliação do sistema proposto e suas implementações são propostas algumas métricas de erro, considerando somente a posição 2D (X,Y) do equipamento móvel. A análise é feita somente utilizando a localização 2D pelo fato de nos experimentos de campo só essa informação esta disponível. A primeira é o erro de posição (EP), que é a distância euclidiana, a diferença entre o valor estimado e verdadeiro a cada iteração k é dado pela Equação 3.2:

$$EP_k = \sqrt{(X_k - \hat{X}_k)^2 + (Y_k - \hat{Y}_k)^2}, \quad (3.2)$$

onde X_k e Y_k são as coordenadas verdadeiras do equipamento e \hat{X}_k e \hat{Y}_k as coordenadas estimadas pelo algoritmo de odometria.

Como discutido por Kümmerle et al. (2009) o erro da posição pode levar a interpretações errôneas, pois se a técnica de odometria tem grande erro nas primeiras iterações esse erro repercute no restante da trajetória. O trabalho de Kümmerle et al. (2009) propõe uma métrica baseada na diferença das transformadas entre a iteração k e $k - 1$ para melhor análise do comportamento das técnicas de odometria. Baseado na métrica de Kümmerle et al. (2009) nesta dissertação é utilizado uma métrica que vê a diferença entre os deslocamentos a cada iteração, a métrica é definida pela Equação 3.3, chamada de erro de translação (ET).

$$ET_k = \sqrt{((X_k - X_{k-1}) - (\hat{X}_k - \hat{X}_{k-1}))^2 + ((Y_k - Y_{k-1}) - (\hat{Y}_k - \hat{Y}_{k-1}))^2} \quad (3.3)$$

Para cada implementação de algoritmo de odometria são calculados também os erros máximos (MaxE), erros médios absolutos (MAE) e a raiz do erro quadrático médio (RMSE), do erro de posição e do erro de translação.

3.5. Sistema utilizado nos experimentos

Para avaliar o método e as implementações de localização propostas foi utilizado um robô com cinemática *skid-steering* com dimensões mostradas na Figura 3.4, mais informações sobre o robô utilizado pode ser encontrado no trabalho de Rocha et al. (2021). A câmera é montada a uma altura de 0,5 m do chão e a uma distância de 0,75 m do centro de rotação do robô e a IMU montada no centro de rotação do robô. Estes valores foram escolhidos experimentalmente para diminuir a vibração e para que a imagem não contenha partes do robô. A covariância necessária para as implementações que utilizam EKF foram calculadas a partir de uma rota de calibração onde a variância é definida como o $RMSE^2$ dos erros de translação.

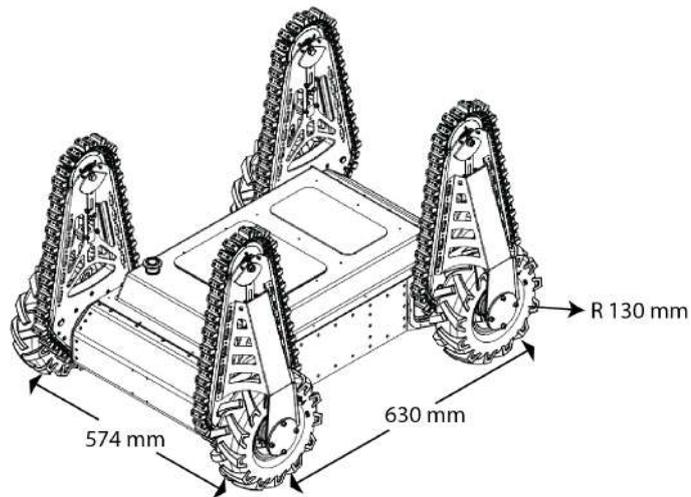


Figura 3.4: Configuração do robô utilizado nos experimentos de campo.

3.5.1. Experimentos em simulação

Para estudo do comportamento dos algoritmos e sistemas propostos foram implementados em um ambiente de simulação, utilizando o simulador de robótica CoppeliaSim (ROHMER et al., 2013). O CoppeliaSim oferece varias opções de motores de física, nesta dissertação foi utilizado o Bullet 2.78 (COUMANS e BAI, 2016–2021). Para reproduzir o cenário dos experimentos de campo foi utilizado um robô com a mesma cinemática e sensores com comportamento similares. O CoppeliaSim fornece várias implementações de sensores virtuais, como a câmera e a IMU utilizados nesta dissertação. Para a textura do chão foi utilizado uma imagem do tipo *seamless* que podem ser intercalada sem efeito de descontinuidade. Para efeitos mais realísticos da odometria de roda foi utilizada como coeficiente de atrito para as rodas 0.8 (borracha) e 0.6 para o chão. A Figura 3.5 mostra como o robô foi implementado em simulação

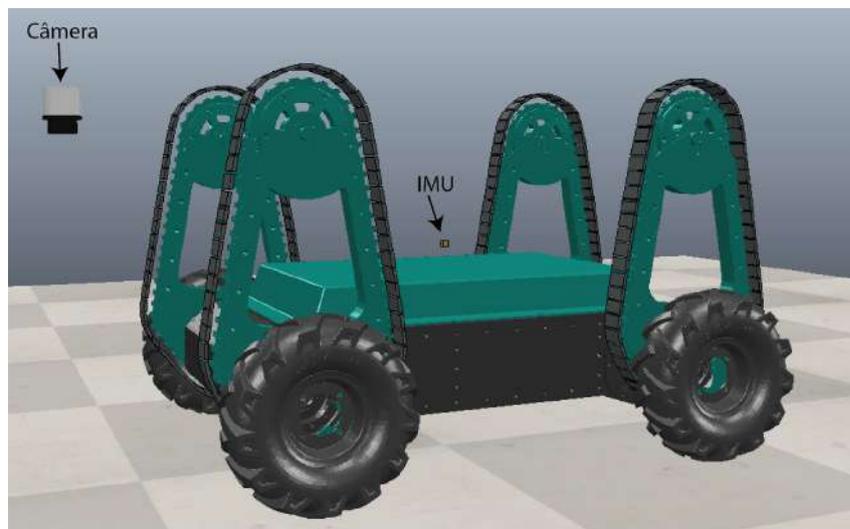


Figura 3.5: Configuração do robô utilizado nos experimentos simulados.

3.5.2. Experimentos em campo

Para o estudo do comportamento das implementações em campo foram utilizados os equipamentos disponíveis no laboratório de robótica do Instituto Tecnológico Vale. Uma câmera intel realsense D435⁴ (FoV: 69°x 42°, 30 FPS, resolução 1920x1080 px) foi utilizada para capturar as imagens do chão e uma IMU Xsens MTI-300⁵ (30hz) para adquirir os dados inerciais. Para efeitos de comparação, foi utilizado um receptor GNSS com correção RTK modelo JAVAD Delta⁶ (utilizando as constelações GLONASS e GPS, acurácia 0,05 m, 1 hz). Os sensores foram montados no robô conforme visto na Figura 3.6.

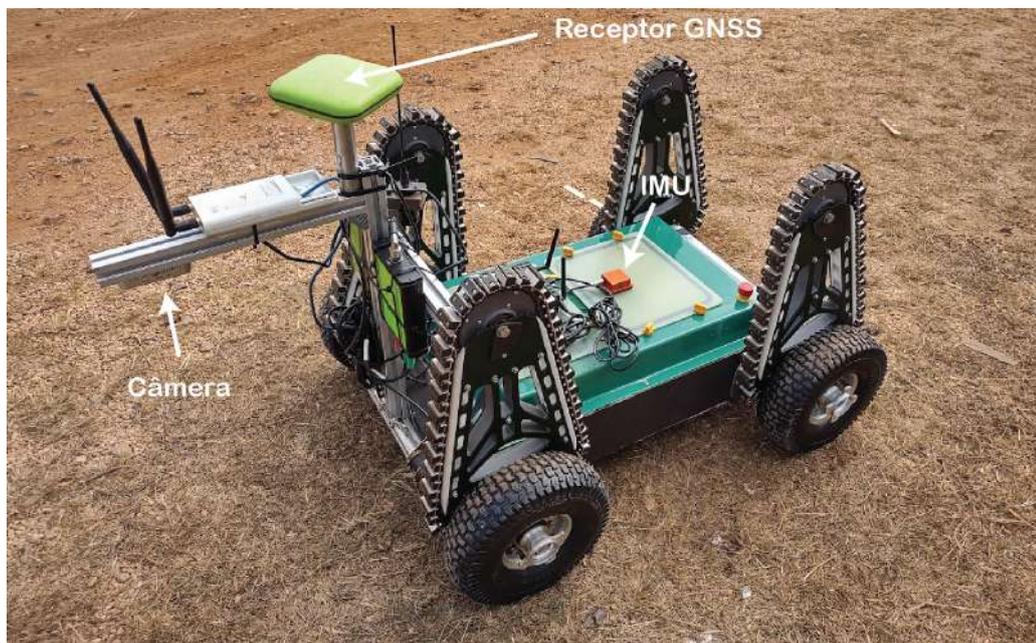


Figura 3.6: Configuração do robô Rosi utilizado nos experimentos de campo.

⁴<https://www.intelrealsense.com/depth-camera-d435/>

⁵<https://www.xsens.com/mti-300>

⁶<https://www.javad.com/jgnss/products/receivers/delta.html>

4. Experimentos e Resultados

Este Capítulo apresenta os experimentos em campo e em simulação e os resultados das implementações de odometria, avaliadas segundo as métricas propostas. Primeiro é feita uma rota de calibração para se obter as covariâncias necessárias para as implementações que utilizam EKF. Para avaliar todas as cinco implementações é utilizada uma segunda rota, e em simulação uma terceira rota é avaliada quando se utiliza um cenário de uma mina reconstruída digitalmente. Quando possível, as mesmas rotas são propostas em campo e em simulação. As rotas percorridas em campo necessitaram ser alteradas em relação a escala e a totalidade percorrida por limitações de hardware (armazenamento de dados) e de cenário (dimensões físicas disponíveis). A rota verdadeira, ou *ground truth*, nas imagens das rotas recebe o rótulo de GT. Para efeitos visuais, nas figuras e tabelas, as implementações são chamadas de (1) Roda, (2) VO, (3) VO IMU, (4) EKF Roda + IMU e (5) EKF VO + Roda + IMU. É considerado como uma iteração toda vez que um novo valor de posição verdadeira é adquirido pelo robô.

4.1. Simulação

São feitas análises em duas cenas, uma em ambiente plano e uma com a reconstrução de uma frente de lavra por fotogrametria. A mesma textura é utilizada nas duas cenas. Exemplos de imagens visualizadas pela câmera nas simulações podem ser vistas na Figura 4.1.

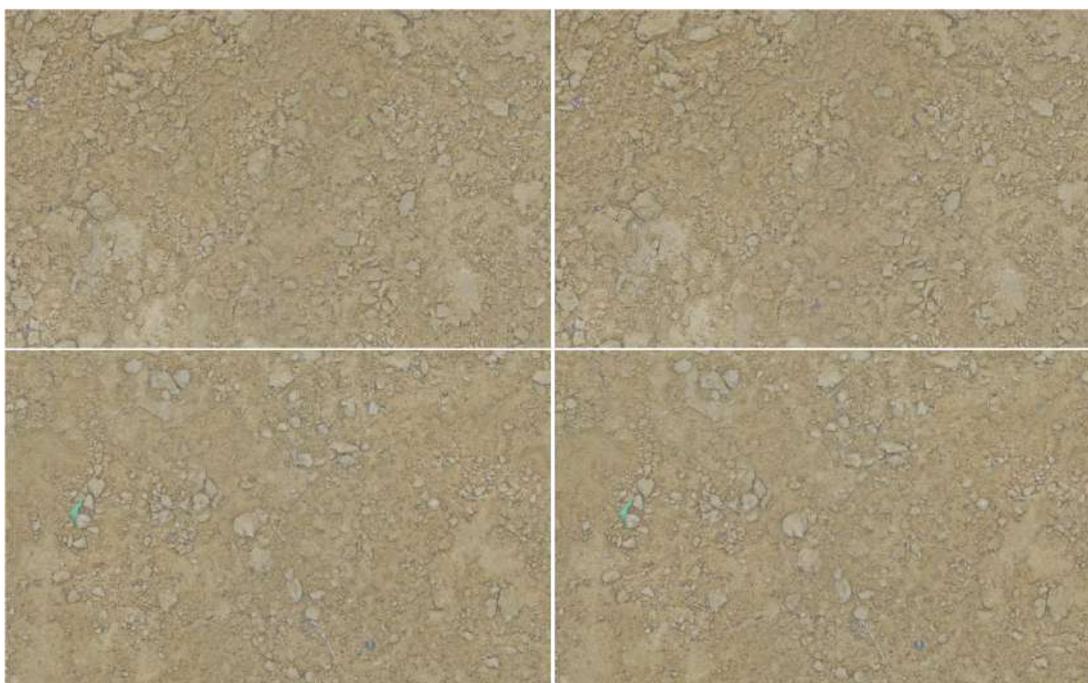


Figura 4.1: Exemplos de imagens visualizadas pela câmera apontada ao chão nos experimentos em simulação.

4.1.1. Calibração de covariância

O cenário utilizado juntamente com a rota programada para o robô seguir podem ser vistos na Figura 4.2.

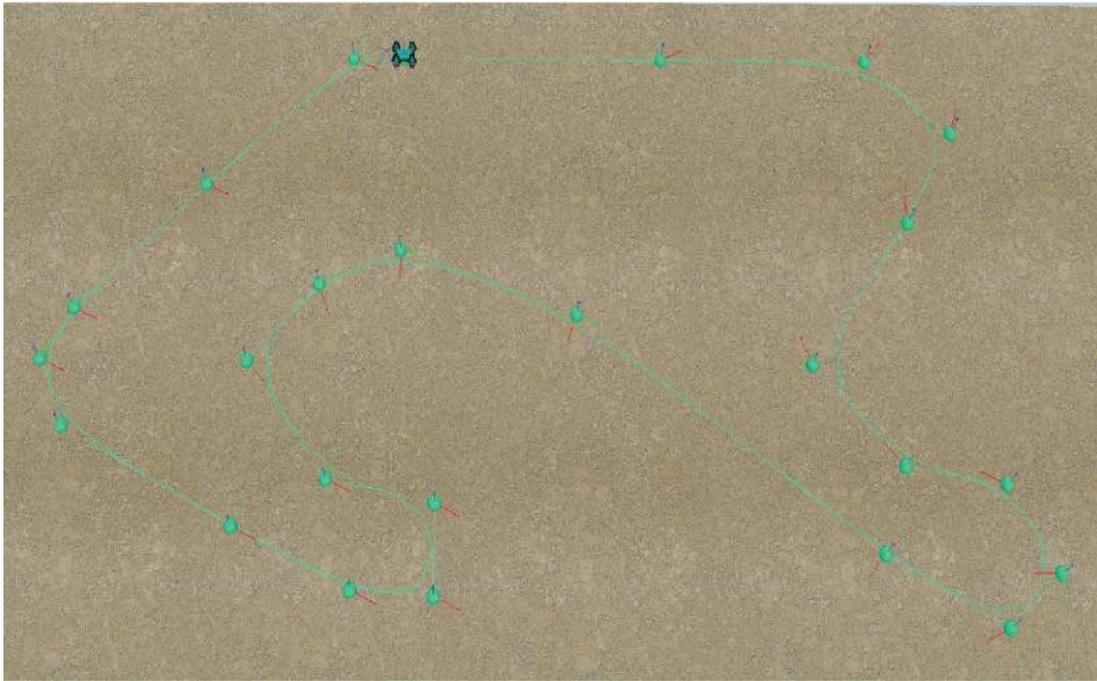


Figura 4.2: Configuração do experimento de calibração de covariância em simulação.

As rotas estimadas pelas implementações propostas e a rota verdadeira podem ser vistas na Figura 4.16.

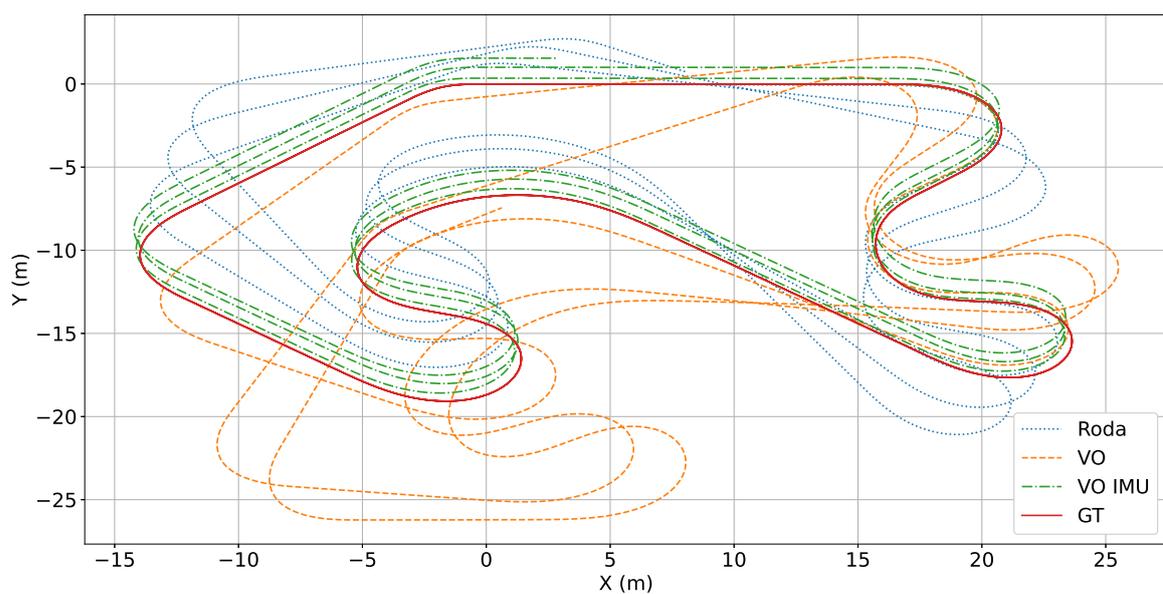


Figura 4.3: Rotas estimadas e rota real (GT) calibração de covariância em simulação.

A Figura 4.4 mostra o erro de posição ao longo das iterações.

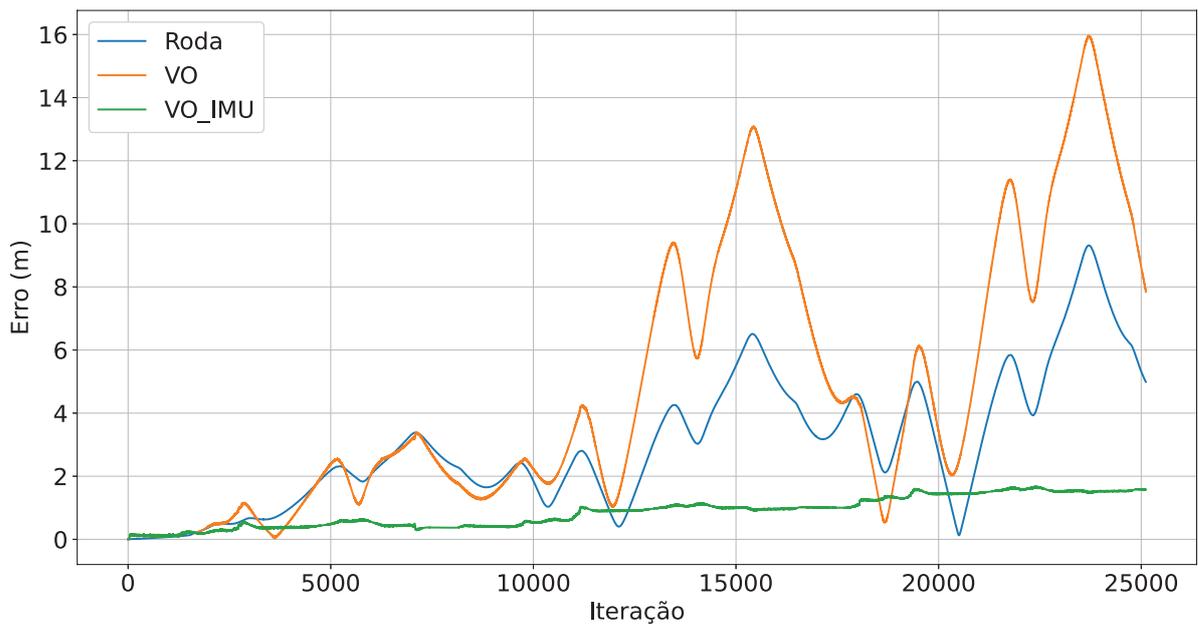


Figura 4.4: Erro de posição da calibração de covariância em simulação.

O erro de translação ao longo das iterações pode ser visto na Figura 4.5.

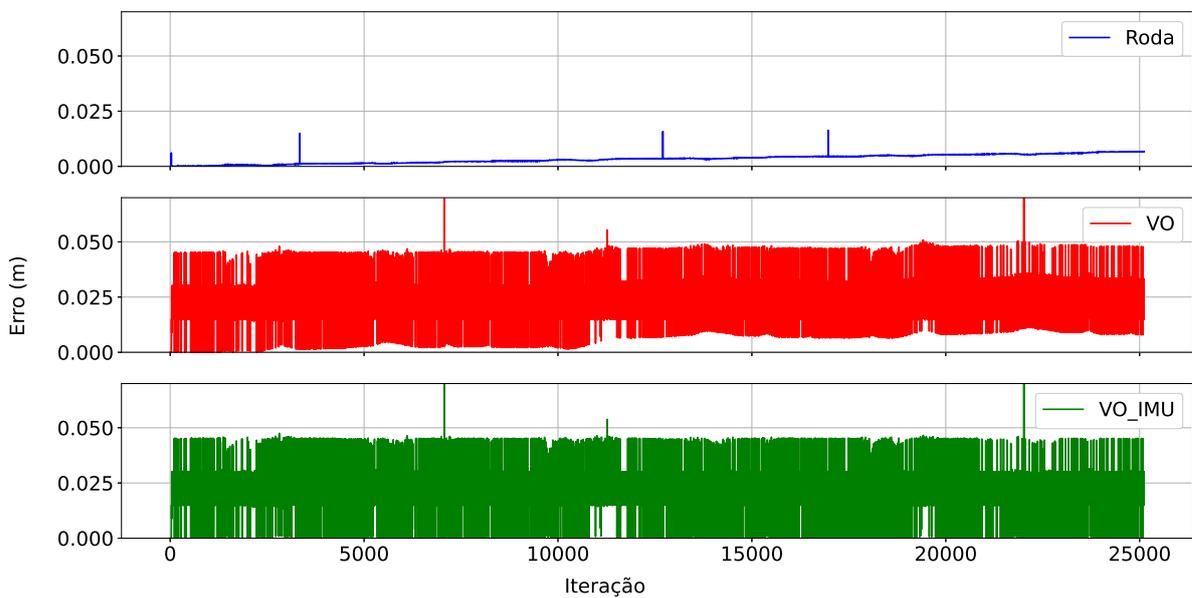


Figura 4.5: Erro de translação da calibração de covariância em simulação.

Na Tabela 4.1 são apresentadas as avaliações dos erro de posição. Destacado em **negrito** o que foi considerado o melhor resultado.

Tabela 4.1: Tabela de erros de posição referente à calibração das covariâncias em simulação.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	9,315	3,012	3,683
VO	15,965	4,805	6,394
VO IMU	1,675	0,864	0,986

Na Tabela 4.2 são apresentadas as avaliações dos erro de translação, onde é possível avaliar a variância dos métodos implementados, destacado em negrito os valores utilizados para o cálculo da covariância utilizada nos filtros implementados.

Tabela 4.2: Tabela de erros translação referente à calibração das covariâncias em simulação.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	0,016	0,003	0,004
VO	0,125	0,019	0,021
VO IMU	0,120	0,018	0,021

4.1.2. Rota em ambiente plano

O cenário utilizado juntamente com a rota programada para o robô seguir podem ser vistos na Figura 4.6.

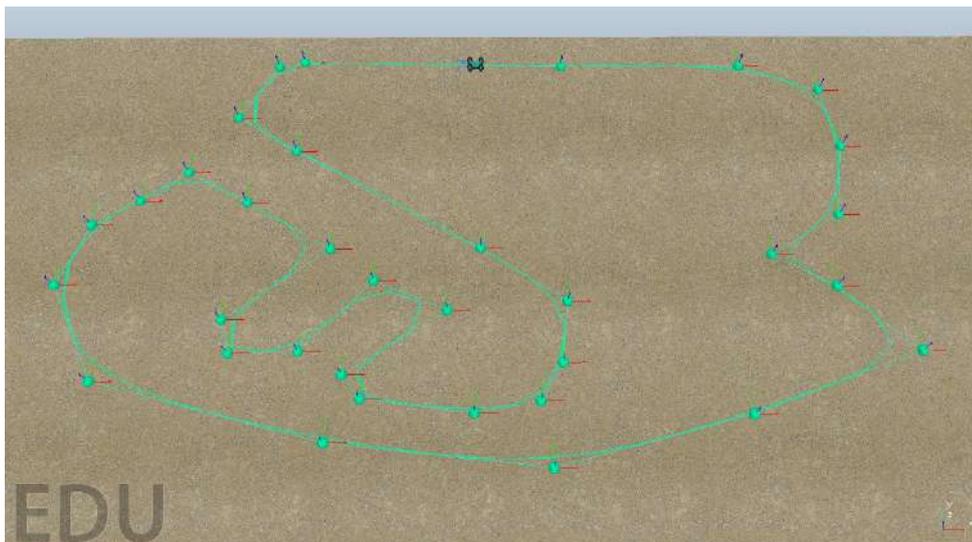


Figura 4.6: Configuração do experimento em ambiente plano em simulação.

As rotas estimadas e a rota verdadeira são mostradas na Figura 4.7.

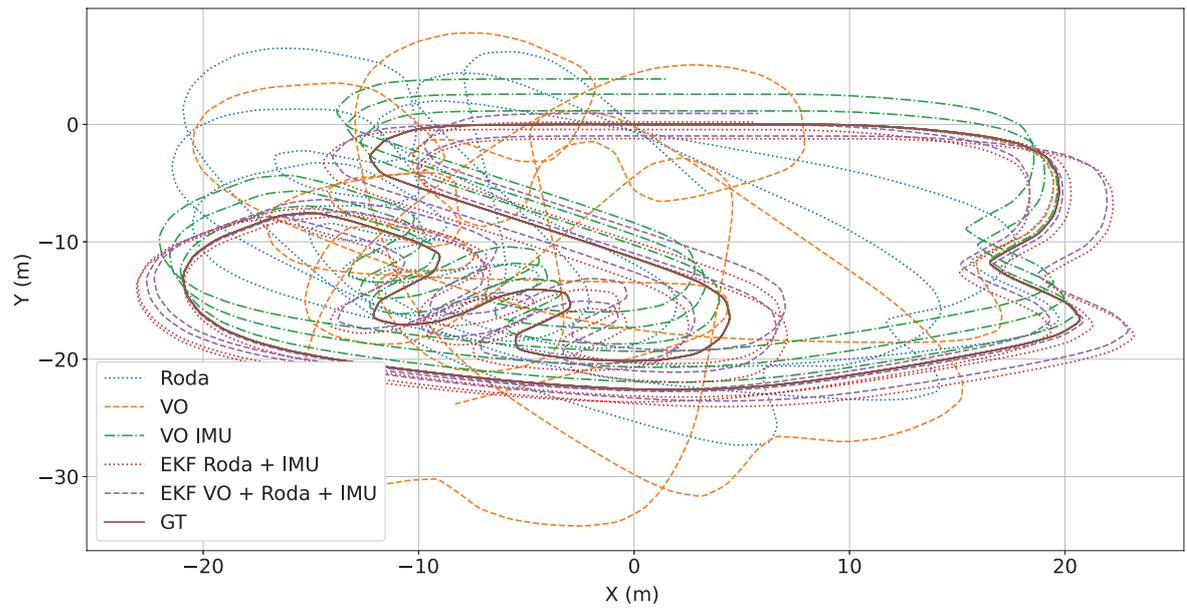


Figura 4.7: Rotas estimadas e rota real (GT) do experimento em ambiente plano em simulação.

O erro de posição ao longo das iterações pode ser visto na Figura 4.8.

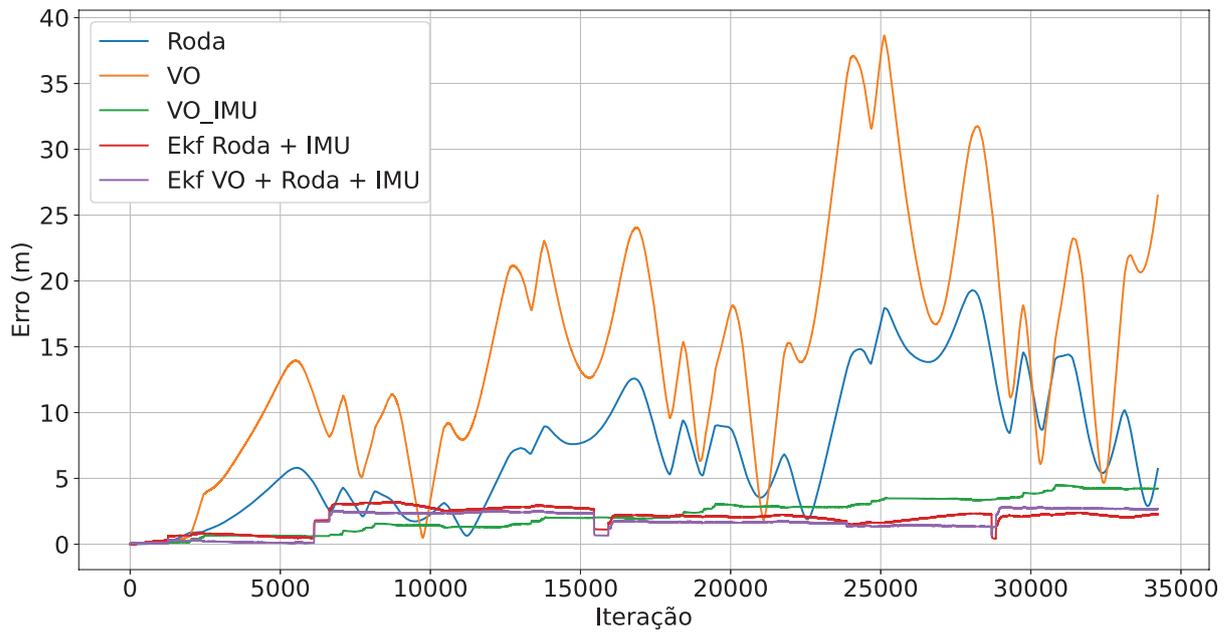


Figura 4.8: Erro de posição do experimento em ambiente plano em simulação.

A Figura 4.9 descreve o erro de translação ao longo das iterações.

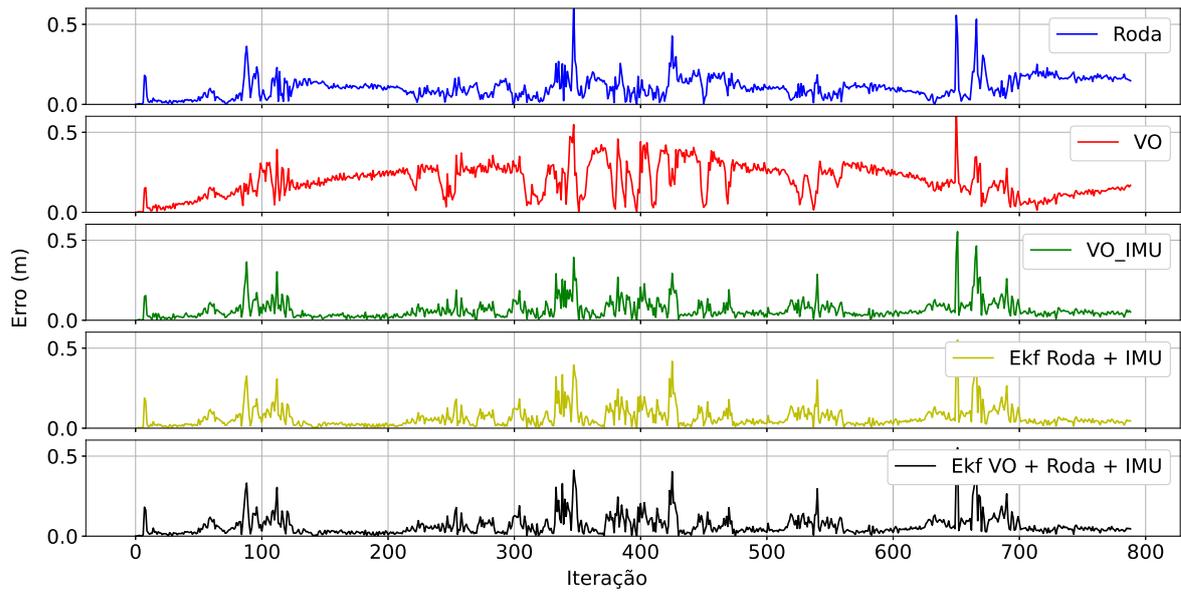


Figura 4.9: Erro de translação do experimento em ambiente plano em simulação.

A Tabela 4.3 contém as avaliações do erro de posição. Destacado em **negrito** o que foi considerado o melhor resultado.

Tabela 4.3: Tabela de erros de posição referente ao experimento em ambiente plano em simulação.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	19,287	7,197	8,724
VO	38,635	14,606	18,43
VO IMU	4,491	2,218	2,553
EKF Roda + IMU	3,202	1,981	2,134
EKF VO + Roda + IMU	2,831	1,695	1,903

A Tabela 4.4 contém as avaliações dos erro de translação, onde é possível avaliar a variância dos métodos implementados.

Tabela 4.4: Tabela de erros de translação referente ao experimento em ambiente plano em simulação.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	0,024	0,008	0,009
VO	17,060	0,094	0,020
VO IMU	0,079	0,008	0,011
EKF Roda + IMU	1,112	0,020	0,025
EKF VO + Roda + IMU	0,963	0,020	0,024

4.1.3. Rota em ambiente reconstruído de cava de mina

O cenário utilizado juntamente com a rota programada para o robô percorrer podem ser vistos na Figura 4.10. Por se tratar de um ambiente 3D, as implementações de odometria foram projetadas utilizando a orientação do robô para o caso 2D.



Figura 4.10: Configuração do experimento com mina reconstruída em simulação.

As rotas estimadas juntamente com a localização verdadeira na Figura 4.11.

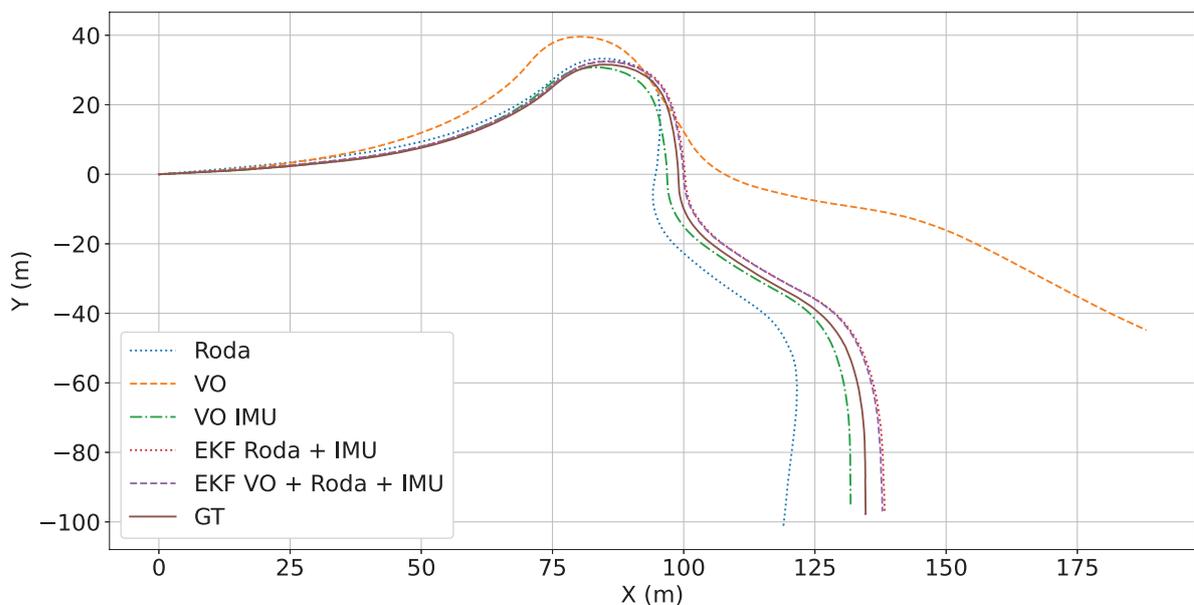


Figura 4.11: Rotas estimadas e rota real (GT) experimento com mina reconstruída em simulação.

O erro de posição ao longo das iterações pode ser visto na Figura 4.12.

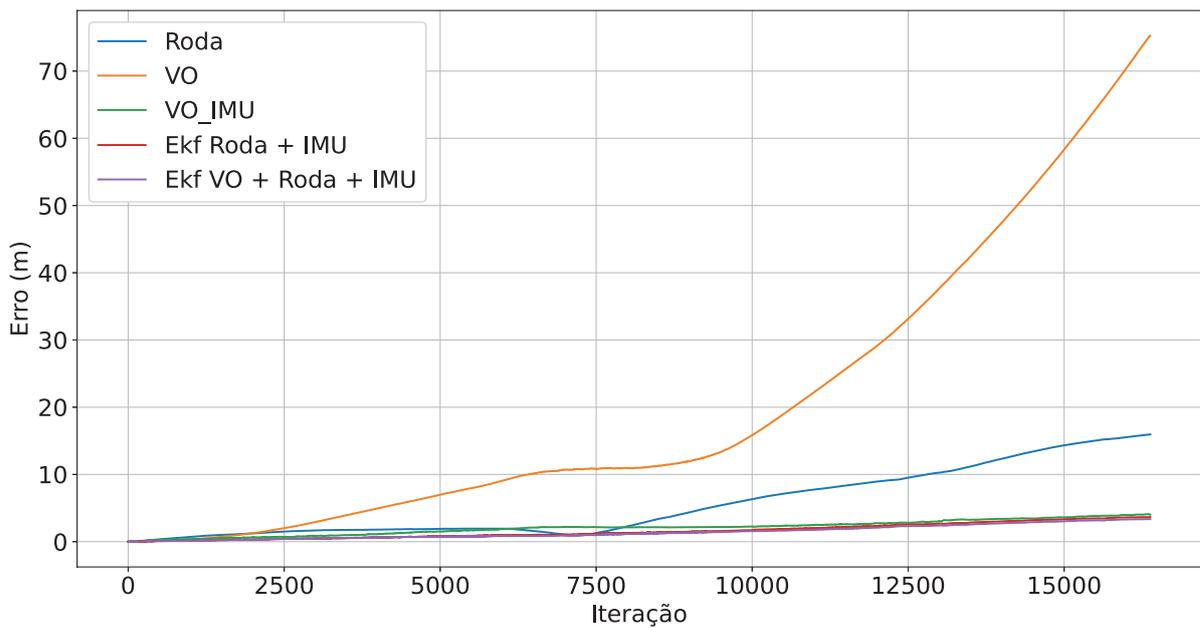


Figura 4.12: Erro de posição do experimento com mina reconstruída em simulação.

Na Figura 4.13 é possível ver os erros de translação ao longo das interações.

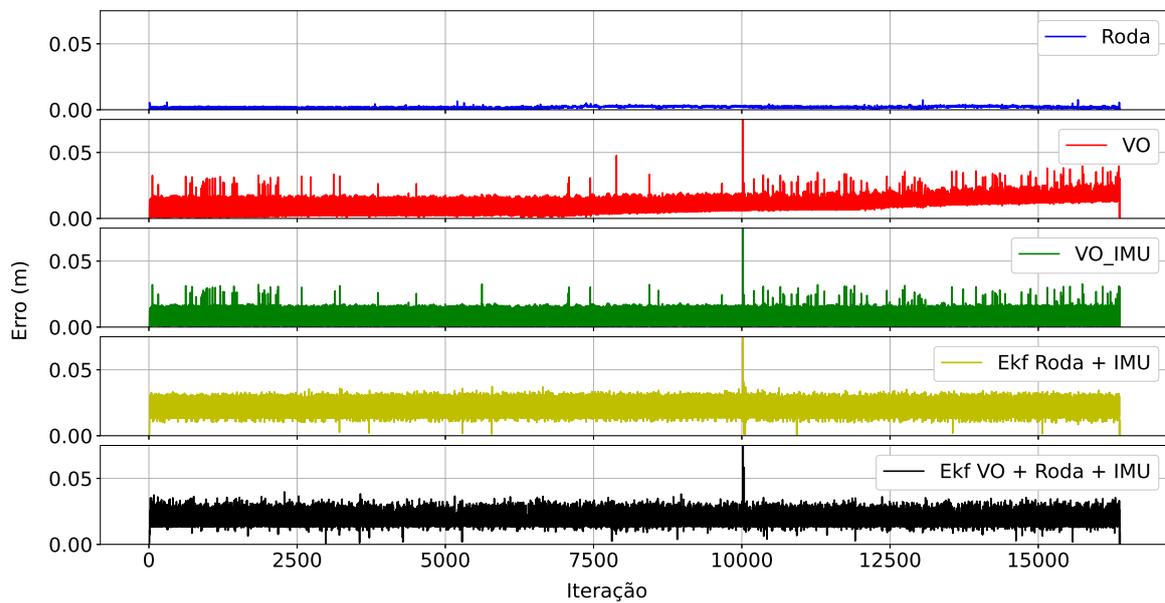


Figura 4.13: Erro de translação do experimento com mina reconstruída em simulação.

A Tabela 4.5 contém as avaliações dos erro de posição. Destacado em **negrito** o que foi considerado o melhor resultado.

Tabela 4.5: Tabela de erros de posição referentes ao experimento com mina reconstruída em simulação.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	15,962	5,533	7,396
VO	75,244	20,258	28,783
VO IMU	4,098	2,067	2,325
EKF Roda + IMU	3,649	1,550	1,889
EKF VO + Roda + IMU	3,354	1,407	1,709

A Tabela 4.6 contém as avaliações dos erro de translação, onde é possível avaliar a variância dos métodos implementados.

Tabela 4.6: Tabela de erros de translação referente ao experimento com mina reconstruída em simulação.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	0,008	0,002	0,002
VO	0,087	0,009	0,011
VO IMU	0,085	0,005	0,008
EKF Roda + IMU	0,332	0,018	0,019
EKF VO + Roda + IMU	0,367	0,017	0,018

4.2. Testes em campo

O cenário no qual o teste de campo foi realizado é mostrado na Figura 4.14. Exemplos de imagens visualizadas pela câmera nos experimentos podem ser vistas na Figura 4.15.



Figura 4.14: Configuração do experimento de campo.



Figura 4.15: Exemplos de imagens visualizadas pela câmera apontada ao chão nos experimentos em campo.

4.2.1. Calibração das covariâncias

As rotas estimadas juntamente com a verdadeira podem ser vistas na Figura 4.16.

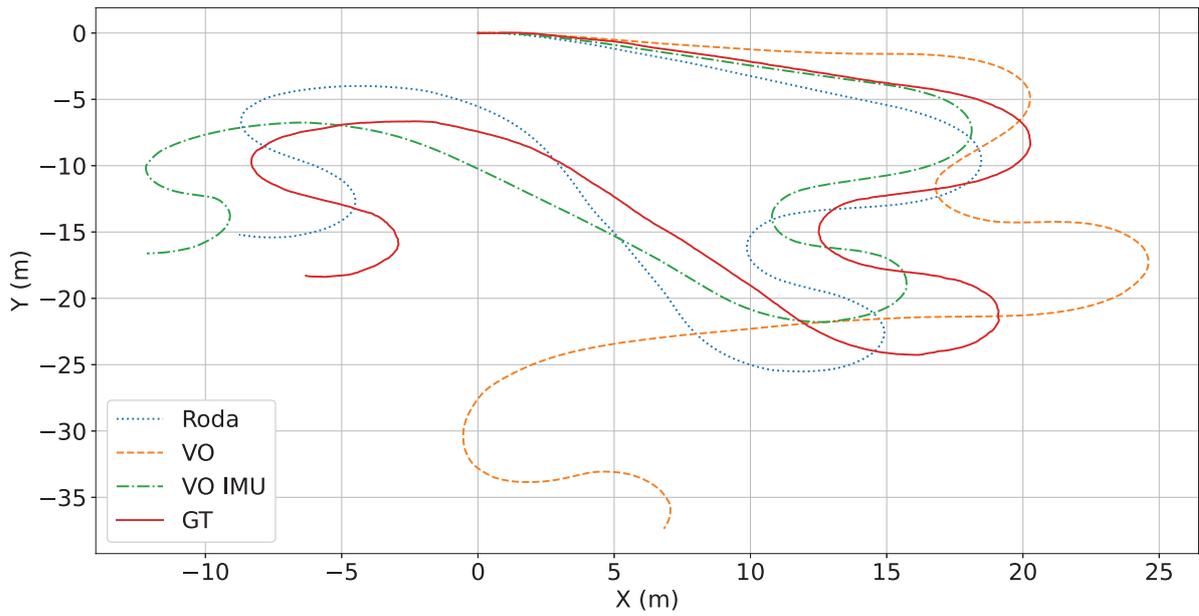


Figura 4.16: Rotas estimadas e rota real (GT) da calibração de covariância em campo.

O erro de posição ao longo das iterações pode ser visto na Figura 4.17.

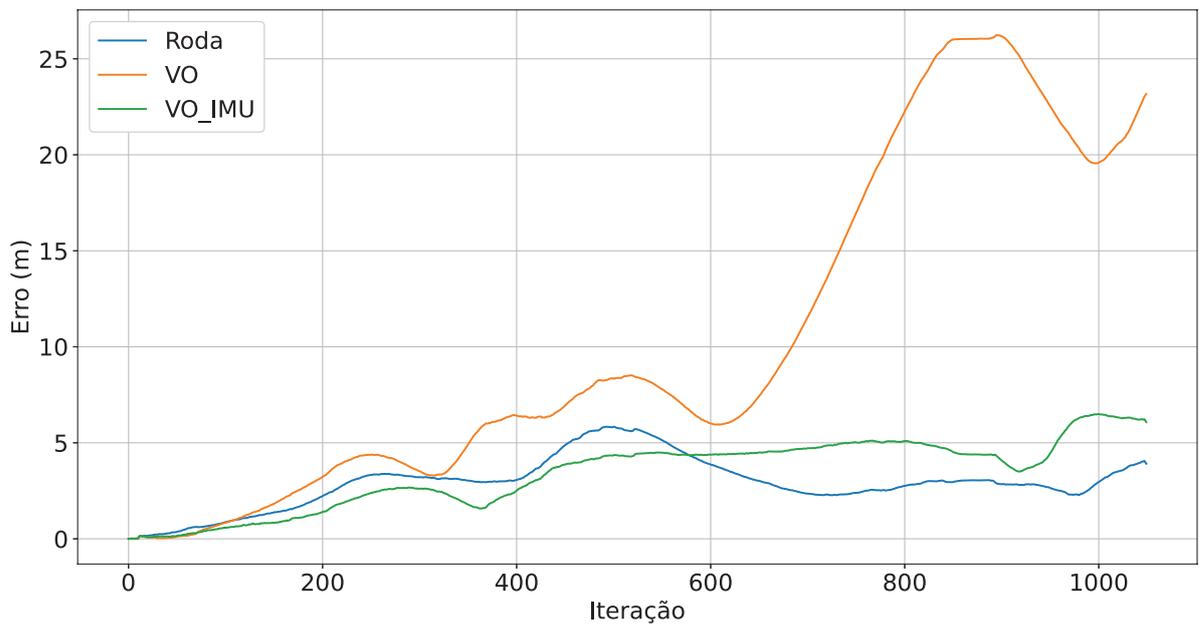


Figura 4.17: Erro de posição da calibração de covariância em campo.

O erro de translação ao longo das iterações pode ser visto na Figura 4.18.

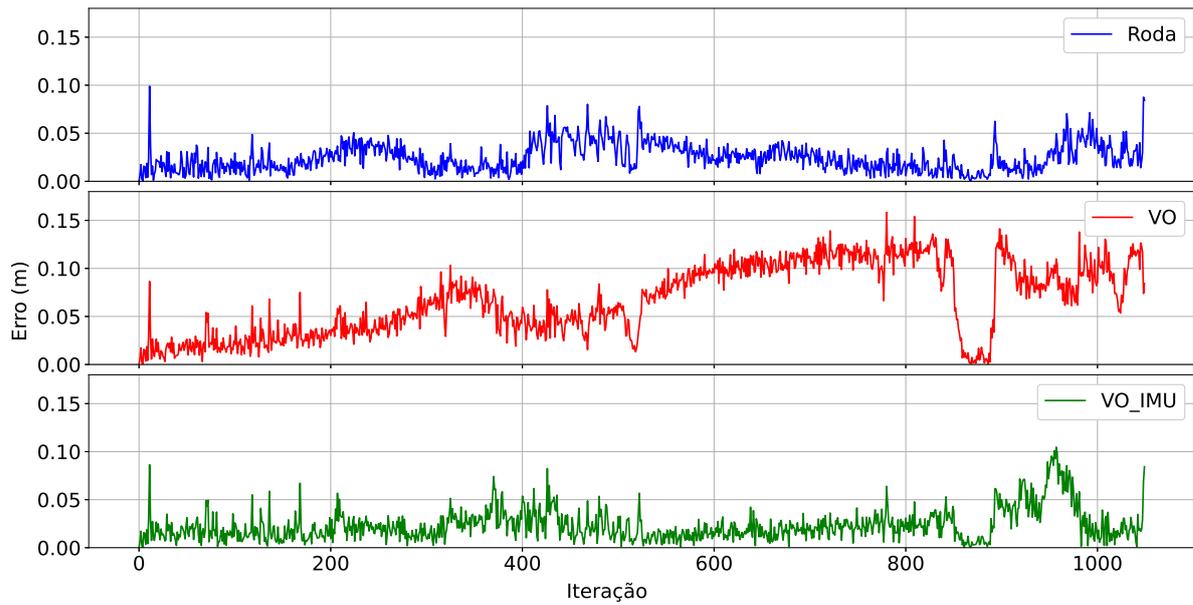


Figura 4.18: Erro de translação da calibração de covariância em campo.

A Tabela 4.7 contém as avaliações dos erro de posição, destacado em negrito o melhor resultado.

Tabela 4.7: Tabela de erros de posição referente à calibração das covariâncias em campo.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	39,211	12,179	17,492
VO	26,466	10,533	13,603
VO IMU	5,626	2,867	3,240

A Tabela 4.8 contém as avaliações dos erro de translação, onde é possível avaliar a variância dos métodos implementados. Destacado em negrito os valores utilizados para o cálculo da covariância utilizada nos filtros implementados.

Tabela 4.8: Tabela de erros de translação referentes à calibração das covariâncias em campo.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	0,199	0,072	0,089
VO	0,153	0,066	0,076
VO IMU	0,110	0,023	0,028

4.2.2. Rota em terreno plano

As rotas estimadas juntamente com a verdadeira podem ser vistas na Figura 4.19.

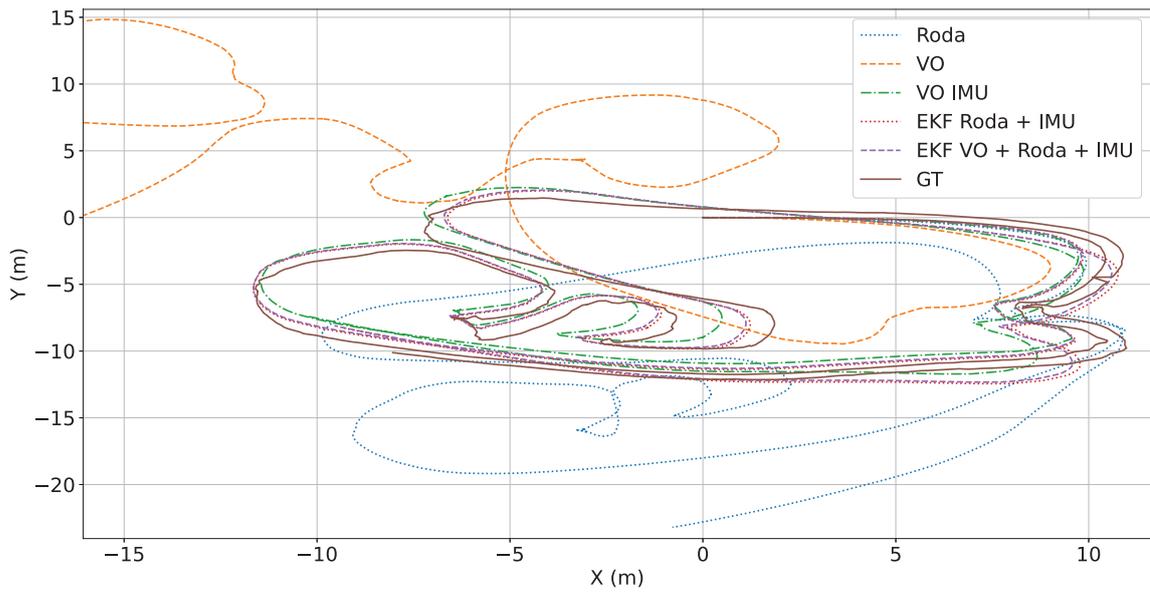


Figura 4.19: Rotas estimadas e rota real (GT) do experimento de campo.

O erro de posição ao longo das iterações pode ser visto na Figura 4.20.

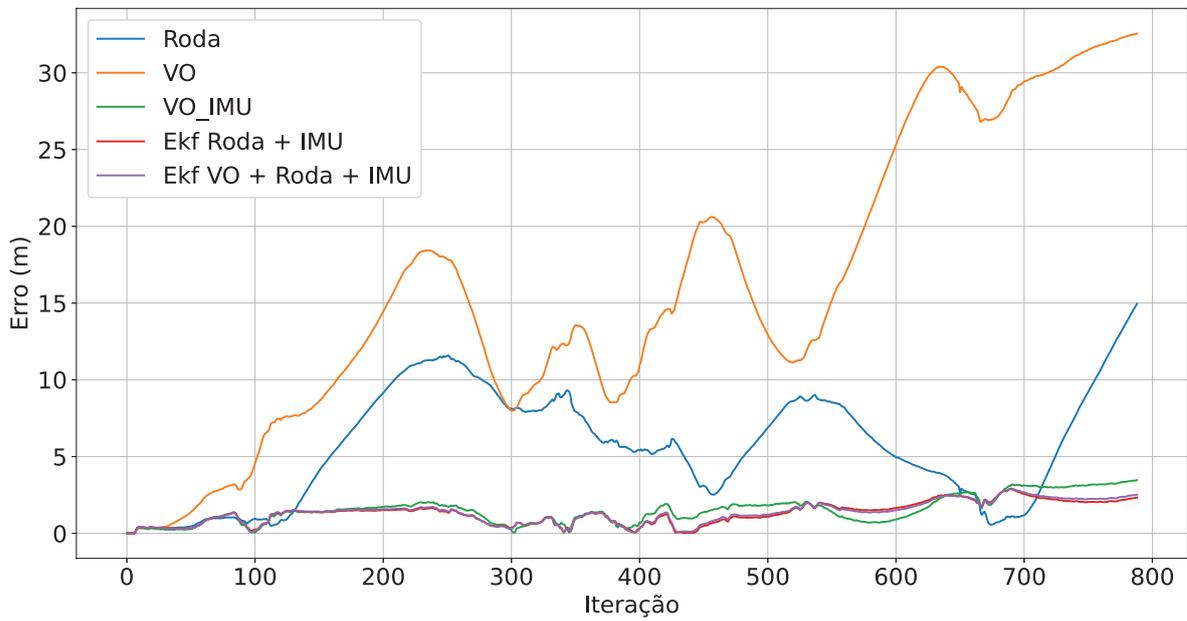


Figura 4.20: Erro de posição do experimento de campo.

O erro de translação ao longo das iterações pode ser visto na Figura 4.21.

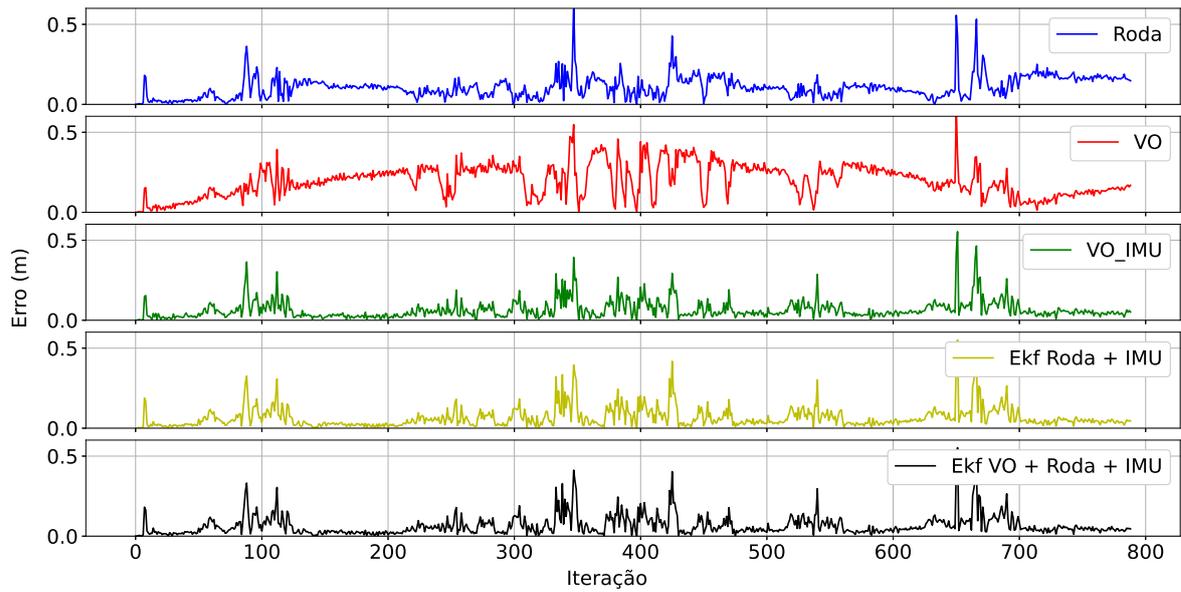


Figura 4.21: Erro de translação do experimento de campo.

A Tabela 4.9 contém as avaliações dos erro de posição. Destacado em **negrito** o que foi considerado o melhor resultado, nesse experimento as implementações de EKF tiveram resultados muito próximos em todas as métricas.

Tabela 4.9: Tabela de erros de posição referentes ao experimento de campo.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	14,955	5,670	6,716
VO	32,564	15,890	18,438
VO IMU	3,470	1,516	1,747
EKF Roda + IMU	2,887	1,307	1,481
EKF VO + Roda + IMU	2,924	1,338	1,515

A Tabela 4.10 contém as avaliações dos erros de translação, onde é possível avaliar a variância dos métodos implementados.

Tabela 4.10: Tabela de erros de translação referentes ao experimento de campo.

	MaxE (m)	MAE (m)	RMSE (m)
Roda	0,633	0,107	0,126
VO	0,653	0,197	0,221
VO IMU	0,554	0,065	0,087
EKF Roda + IMU	0,551	0,065	0,091
EKF VO + Roda + IMU	0,553	0,065	0,090

5. Discussão

Os resultados mostram que o erro de posição de todas as implementações crescem no tempo, o que é esperado devido ao método de integração contínua. Nos resultados é possível observar que o comportamento das implementações seguiu o mesmo padrão em simulação e em campo, onde erro da implementação puramente visual (EP MAE VO \simeq 20) é maior que erro da odometria de roda (EP MAE Roda \simeq 10), que é bem maior que o erro do método visual com IMU para orientação, que é próximo as implementações com EKF (EP MAE VO_-IMU/EKFs \simeq 2). As duas implementações de EKF tiveram resultados muito próximos, o que pode ser causado por uma má calibração nas covariâncias. Os erros obtidos nas calibrações de covariância são menores que os obtidos nas rotas de teste. Analisando o erro de translação (Figuras 4.5, 4.9, 4.13, 4.18 4.21) é possível ver que o erro a cada iteração é praticamente constante, podendo ter alguns picos, provavelmente causados por rotações muito rápidas no próprio eixo. Analisando as rotas estimadas (Figuras 4.7, 4.11, 4.19) é possível ver que os erros acontecem de maneira mais abrupta nas curvas.

A implementação visual (EP MAE \simeq 20) teve resultados piores que a utilizando somente a roda EP MAE \simeq 10); isso pode ser devido ao fato da topografia e do terreno avaliado, que apresentam grande coeficiente de atrito. Em outros ambientes onde o escorregamento das rodas é maior o comportamento do erro pode mudar. Muitas vezes os veículos não possuem encoders acoplados em suas rodas ou essa informação não esta disponível, assim o método utilizando somente a câmera e IMU pode ser replicado mais facilmente.

Outra maneira de avaliar o comportamento da implementações é por meio do histograma do erro de posição, apresentado na Figura 5.1. Pela Figura 5.1 podemos ver que o comportamento nos teste simulados e no experimento de campo tem comportamento semelhante. Pelos histogramas é possível ver que as implementações de EKFs têm EP menor que 3 m no intervalo de confiança 2σ ; VO IMU tem EP menor que 4 m; e implementações VO e W têm EP maior que 5 m em 90% do tempo. Essas distribuições de erros mostram como a fusão sensorial melhora as técnicas de odometria. A melhor implementação no geral é o EKF VO+W+IMU, mostrando que o método visual proposto pode melhorar a localização de equipamentos móveis terrestres.

O método visual proposto assume as hipóteses do fluxo ótico. A formação de sombra, pela posição relativa entre o robô e o sol, pode quebrar a hipótese de que o mesmo ponto tem a mesma intensidade em imagens consecutivas. Um pixel quando vai de uma região de sombra para uma região de sol muda de intensidade instantaneamente. A Figura 5.2 mostra que esse efeito é visível nas bordas da sombra. Devido ao uso da mediana do fluxo da imagem inteira esse efeito não teve influencia aparente no cálculo de odometria

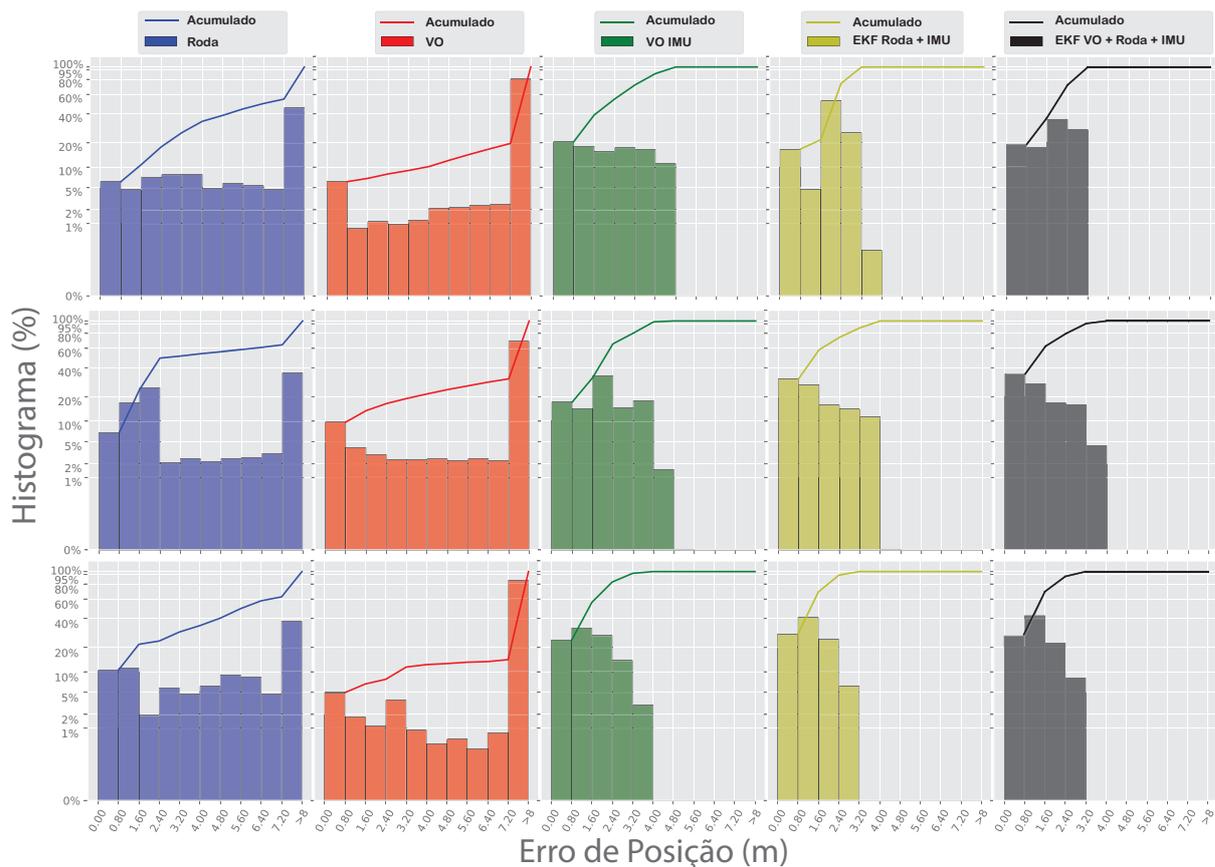


Figura 5.1: Histograma do Erro de Posição. Em cima: Simulação em ambiente plano. Meio: Simulação em Mina reconstruída. Em baixo: Experimentos de campo.



Figura 5.2: Influência da sombra no fluxo ótico. Imagens a esquerda são as imagens vista pela câmera e a direita são a representação do fluxo ótico por cor.

O fluxo ótico também assume que pequenos movimentos são feitos entre as duas imagens analisadas, assim para estimar movimentos com grande velocidade é necessário avaliar o FPS e a resolução da câmera; quanto maior a velocidade do veículo maior deverá o FPS para manter as hipóteses do fluxo ótico verdadeira. Outro ponto a de atenção é como lâminas de água no chão afetam o sistema, pois a água tem características reflexivas. A água também pode

estar em fluxo o que tornaria o método visual proposto ineficaz pois o movimento relativo na imagem já não representaria o movimento do veículo em relação ao chão .

Para o caso dos equipamentos autônomos a estimativa de localização deve acontecer em tempo de execução. Como veículos de mineração no geral possuem grande dimensão e capacidade de levar carga pode-se assumir um poder de processamento grande o suficiente para que as implementações sejam executadas em tempo real. O custo computacional das implementações não foram avaliadas neta dissertação. Caso as implementações propostas fossem utilizadas em robôs de serviço, como inspeções em ambientes de mineração, as implementações devem ter processamento em tempo real nos computadores embarcados nestes equipamentos.

6. Conclusão

Nesta dissertação é apresentado um método capaz de estimar odometria de equipamentos móveis com base no fluxo ótico da imagem de uma câmera voltada ao chão, uma IMU e encoders de roda. O fluxo ótico é estimado pelo algoritmo de Farnebäck (2003). São feitas análises de cinco implementações de localização (1) utilizando encoders de roda, (2) calculada totalmente pela câmera apontada para o chão, (3) calculada utilizando a orientação da IMU e deslocamento linear pela odometria visual proposta, (4) odometria obtida pela fusão da odometria de encoders de roda e dados da IMU utilizando filtro de Kalman e (5) odometria obtida pela fusão da odometria visual, odometria dos encoders da roda e dados da IMU por meio de filtro de Kalman. Os resultados mostram que o comportamento das implementações seguiu o mesmo padrão em simulação e em campo, onde erros das fusões de dados, com e sem EKF, são próximos (EP MAE $\simeq 2 m$) e bem menores que o erro de odometria de roda (EP MAE $\simeq 10 m$), que por sua vez é menor que o erro de odometria somente visual (EP MAE $\simeq 20 m$).

Para implementação em equipamentos de lavra de mina autônomos (erro de posição menor que 10 cm) ainda é necessário melhorar a acurácia do sistema proposto. A implementação com melhor resultados nos experimentos tem erro de posição que fica em torno de 2.5 m em 95% do tempo. Com o aprimoramento da técnica proposta esta pode ser usada também para robôs de serviço, como inspeção em áreas de barragem, onde uma estrutura de RTK pode ser inviável e para inspeção de transportadores de correia que muitas vezes passam por túneis, onde o sinal GNSS não esta presente.

6.1. Trabalhos futuros

Como trabalhos futuros é sugerido a avaliação das implementações propostas em ambientes reais de mineração, equipamentos como caminhões e perfuratrizes em uma frente de lavra, a escala do ambiente e dos equipamentos, como o grau de vibração dos sensores podem influenciar na acurácia das técnicas. É interessante uma comparação das técnicas propostas com as técnicas do estado da arte que utilizem LiDARs e câmeras voltadas ao horizonte e analisar o impacto de variações e do clima para cada técnica. Para diminuir a influência da variação de iluminação, um tipo de isolamento com iluminação artificial pode ser proposto. Como a câmera utilizada é do tipo RGB-D pode-se utilizar o canal de profundidade para estimar um fluxo ótico em 3D, sem necessitar assumir a hipótese que o chão é um plano paralelo ao plano de imagem da câmera. O algoritmo de Farnebäck (2003) permite assumir um modelo de movimento inicial assim a implementação pode vir a ser mais robusta caso as restrições não holonômicas e o modelo cinemático do equipamento forem incorporadas na estimação do fluxo ótico.

Os cenários dentro de uma frente de lavra sofrem muitas mudanças, climáticas e topográficas, assim uma técnica de estimação de covariância em tempo real seria ideal. Pode-se explorar o fato de que as falhas do GNSS se dão de forma intermitente, tanto para o cálculo de

covariância quanto para calibrar as implementações de forma dinâmica. Outro ponto que pode ser explorado é que equipamentos distintos percorrem os mesmos caminhos nas minas, assim, um algoritmo de consenso pode ser implementado para aumentar a robustez de uma solução final.

REFERÊNCIAS BIBLIOGRÁFICAS

- BAY, H.; ESS, A.; TUYTELAARS, T.; VAN GOOL, L. Speeded-up robust features (SURF). **Computer vision and image understanding**, v. 110, n. 3, pp. 346–359, 2008.
- BIREM, M.; KLEIHORST, R.; EL-GHOUTI, N. Visual odometry based on the Fourier transform using a monocular ground-facing camera. **Journal of Real-Time Image Processing**, v. 14, n. 3, pp. 637–646, 2018.
- CAN, N. Legal issues concerning the cyber security of GNSS. In: **2015 7th International Conference on Recent Advances in Space Technologies (RAST)**, pp. 861–864. IEEE, 2015.
- COUMANS, E.; BAI, Y. **PyBullet, a Python module for physics simulation for games, robotics and machine learning**. <http://pybullet.org>, 2016–2021.
- DAL'COL, C.; RESENDE, L.; CORREA, R.; MOURA, R.; PESSIN, G. THE IMPACT OF IONOSPHERIC IRREGULARITIES IN AUTONOMOUS SYSTEMS OPERATIONS. **International Geoscience and Remote Sensing Symposium**, 2022.
- DANG, X.; RONG, Z.; LIANG, X. Sensor Fusion-Based Approach to Eliminating Moving Objects for SLAM in Dynamic Environments. **Sensors**, v. 21, n. 1, pp. 230, 2021.
- DILLE, M.; GROCHOLSKY, B.; SINGH, S. Outdoor downward-facing optical flow odometry with commodity sensors. In: **Field and Service Robotics**, pp. 183–193. Springer, 2010.
- DOGRU, S.; MARQUES, L. An improved kinematic model for skid-steered wheeled platforms. **Autonomous Robots**, v. 45, n. 2, pp. 229–243, 2021.
- DOMINGUES, J.; AZPÚRUA, H.; FREITAS, G.; PESSIN, G. Localization of mobile robots through optical flow and sensor fusion in mining environments. In: **19th IEEE Latin American Robotics Symposium - LARS 2022**, IEEE, 2022.
- FARNEBÄCK, G. Two-frame motion estimation based on polynomial expansion. In: **Scandinavian conference on Image analysis**, pp. 363–370. Springer, 2003.
- FORTUN, D.; BOUTHEMY, P.; KERVRANN, C. Optical flow modeling and computation: A survey. **Computer Vision and Image Understanding**, v. 134, pp. 1–21, 2015.

- FRAUNDORFER, F.; SCARAMUZZA, D. Visual odometry: Part ii: Matching, robustness, optimization, and applications. **IEEE Robotics & Automation Magazine**, v. 19, n. 2, pp. 78–90, 2012.
- GEIGER, A.; LENZ, P.; STILLER, C.; URTASUN, R. Vision meets robotics: The kitti dataset. **The International Journal of Robotics Research**, v. 32, n. 11, pp. 1231–1237, 2013.
- HONG, Z.; PETILLOT, Y.; WANG, S. RadarSLAM: Radar based Large-Scale SLAM in All Weathers. **arXiv preprint arXiv:2005.02198**, 2020.
- HORN, B. K.; SCHUNCK, B. G. Determining optical flow. **Artificial intelligence**, v. 17, n. 1-3, pp. 185–203, 1981.
- HORN, J.; SCHMIDT, G. Continuous localization of a mobile robot based on 3D-laser-range-data, predicted sensor images, and dead-reckoning. **Robotics and Autonomous Systems**, v. 14, n. 2-3, pp. 99–118, 1995.
- KALMAN, R. E. **A new approach to linear filtering and prediction problems**. 1960.
- KHATTAK, S.; PAPACHRISTOS, C.; ALEXIS, K. Keyframe-based direct thermal–inertial odometry. In: **2019 International Conference on Robotics and Automation (ICRA)**, pp. 3563–3569. IEEE, 2019.
- KOK, M.; HOL, J. D.; SCHÖN, T. B. Using inertial sensors for position and orientation estimation. **arXiv preprint arXiv:1704.06053**, 2017.
- KUENG, B.; MUEGGLER, E.; GALLEGO, G.; SCARAMUZZA, D. Low-latency visual odometry using event-based feature tracks. In: **2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)**, pp. 16–23. IEEE, 2016.
- KÜMMERLE, R.; STEDER, B.; DORNHEGE, C.; RUHNKE, M.; GRISSETTI, G.; STACHNISS, C.; KLEINER, A. On measuring the accuracy of SLAM algorithms. **Autonomous Robots**, v. 27, n. 4, pp. 387–407, 2009.
- LEUTENEGGER, S.; LYNEN, S.; BOSSE, M.; SIEGWART, R.; FURGALE, P. Keyframe-based visual–inertial odometry using nonlinear optimization. **The International Journal of Robotics Research**, v. 34, n. 3, pp. 314–334, 2015.
- LI, X.; GE, M.; DAI, X.; REN, X.; FRITSCHKE, M.; WICKERT, J.; SCHUH, H. Accuracy and reliability of multi-GNSS real-time precise positioning: GPS, GLONASS, BeiDou, and Galileo. **Journal of Geodesy**, v. 89, n. 6, pp. 607–635, 2015.
- LUCAS, B. D.; KANADE, T.; OTHERS. **An iterative image registration technique with an application to stereo vision**. 1981.

- MOHAMED, S. A.; HAGHBAYAN, M.-H.; WESTERLUND, T.; HEIKKONEN, J.; TENHUNEN, H.; PLOSILA, J. A survey on odometry for autonomous navigation systems. **IEEE Access**, v. 7, pp. 97466–97486, 2019.
- MOORE, T.; STOUCH, D. A Generalized Extended Kalman Filter Implementation for the Robot Operating System. In: **Proceedings of the 13th International Conference on Intelligent Autonomous Systems (IAS-13)**. Springer, July 2014.
- MUR-ARTAL, R.; MONTIEL, J. M. M.; TARDOS, J. D. ORB-SLAM: a versatile and accurate monocular SLAM system. **IEEE transactions on robotics**, v. 31, n. 5, pp. 1147–1163, 2015.
- NISTÉR, D. An efficient solution to the five-point relative pose problem. **IEEE transactions on pattern analysis and machine intelligence**, v. 26, n. 6, pp. 756–770, 2004.
- NOURANI-VATANI, N.; BORGES, P. V. K. Correlation-based visual odometry for ground vehicles. **Journal of Field Robotics**, v. 28, n. 5, pp. 742–768, 2011.
- PANIGRAHI, P. K.; BISOY, S. K. Localization strategies for autonomous mobile robots: A review. **Journal of King Saud University-Computer and Information Sciences**, 2021.
- PEREIRA, V. A. S. **Monitoramento das irregularidades ionosféricas e cintilação dos sinais GNSS: em tempo real e pós-processado**. 2015.
- PSIAKI, M. L.; HUMPHREYS, T. E. GNSS spoofing and detection. **Proceedings of the IEEE**, v. 104, n. 6, pp. 1258–1270, 2016.
- QUIGLEY, M.; CONLEY, K.; GERKEY, B.; FAUST, J.; FOOTE, T.; LEIBS, J.; WHEELER, R.; NG, A. Y.; OTHERS. ROS: an open-source Robot Operating System. In: **ICRA workshop on open source software**, v. 3, p. 5. Kobe, Japan, 2009.
- REBECQ, H.; HORSTSCHAEFER, T.; SCARAMUZZA, D. **Real-time visual-inertial odometry for event cameras using keyframe-based nonlinear optimization**. 2017.
- REZENDE, A. M.; GONCALVES, V. M.; PIMENTA, L. C. Constructive Time-Varying Vector Fields for Robot Navigation. **IEEE Transactions on Robotics**, v. 38, n. 2, pp. 852–867, 2021.
- ROCHA, F.; GARCIA, G.; PEREIRA, R. F.; FARIA, H. D.; SILVA, T. H.; ANDRADE, R. H.; BARBOSA, E. S.; ALMEIDA, A.; CRUZ, E.; ANDRADE, W.; OTHERS. ROSI: A Robotic System for Harsh Outdoor Industrial Inspection-System Design and Applications. **Journal of Intelligent & Robotic Systems**, v. 103, n. 2, pp. 1–22, 2021.

- ROHMER, E.; SINGH, S. P. N.; FREESE, M. Coppeliasim (formerly V-REP): a Versatile and Scalable Robot Simulation Framework. In: **Proc. of The International Conference on Intelligent Robots and Systems (IROS)**, 2013. www.coppeliarobotics.com.
- SCARAMUZZA, D.; FRAUNDORFER, F. Visual odometry [tutorial]. **IEEE robotics & automation magazine**, v. 18, n. 4, pp. 80–92, 2011.
- SCARAMUZZA, D.; MARTINELLI, A.; SIEGWART, R. A flexible technique for accurate omnidirectional camera calibration and structure from motion. In: **Fourth IEEE International Conference on Computer Vision Systems (ICVS'06)**, pp. 45–45. IEEE, 2006.
- SICILIANO, B.; KHATIB, O.; KRÖGER, T. **Springer handbook of robotics** , v. 200. Springer, 2008.
- SMITH, G. L.; SCHMIDT, S. F.; MCGEE, L. A. **Application of statistical filter theory to the optimal estimation of position and velocity on board a circumlunar vehicle** . National Aeronautics and Space Administration, 1962.
- SPONG, M. W.; HUTCHINSON, S.; VIDYASAGAR, M.; OTHERS. **Robot modeling and control** , v. 3. Wiley New York, 2006.
- VALE S.A. **ANÁLISE DE FALHA REFERENTE A VÁRIAS PARADAS DOS AUTONOMOS NO PERIODO DE NOV A DEZ/2020**. 2020. Relatório Interno.
- WELCH, G.; BISHOP, G.; OTHERS. **An introduction to the Kalman filter**. 1995.
- YOUSIF, K.; BAB-HADIASHAR, A.; HOSEINNEZHAD, R. An overview to visual odometry and visual SLAM: Applications to mobile robotics. **Intelligent Industrial Systems**, v. 1, n. 4, pp. 289–311, 2015.
- ZHANG, J.; SINGH, S. LOAM: Lidar Odometry and Mapping in Real-time. In: **Robotics: Science and Systems**, v. 2, 2014.
- ZUO, X.; GENEVA, P.; LEE, W.; LIU, Y.; HUANG, G. Lic-fusion: Lidar-inertial-camera odometry. **arXiv preprint arXiv:1909.04102**, 2019.