



**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**

**ROBÓTICA MÓVEL NA MINERAÇÃO: ESTUDOS DE CASO COM ROBÔS  
TERRESTRES E AÉREOS EM DISPERSÃO DE ETIQUETAS ELETRÔNICAS,  
RECONSTRUÇÃO 3D E INSPEÇÃO VISUAL AUTOMATIZADA**

**Levi Welington de Resende Filho**

**Ouro Preto  
Minas Gerais, Brasil  
2021**





**Levi Welington de Resende Filho**

**ROBÓTICA MÓVEL NA MINERAÇÃO: ESTUDOS DE CASO COM ROBÔS  
TERRESTRES E AÉREOS EM DISPERSÃO DE ETIQUETAS ELETRÔNICAS,  
RECONSTRUÇÃO 3D E INSPEÇÃO VISUAL AUTOMATIZADA**

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. Fernando Santos Osório,  
D.Sc.

Ouro Preto

2021

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

R433r Resende Filho, Levi Wellington de .

Robótica Móvel na Mineração [manuscrito]: estudos de caso com robôs terrestres e aéreos em dispersão de etiquetas eletrônicas, reconstrução 3D e inspeção visual automatizada. / Levi Wellington de Resende Filho. - 2021.

95 f.: il.: color., gráf., tab., mapa. + Equações.

Orientador: Prof. Dr. Gustavo Pessin.

Coorientador: Prof. Dr. Fernando Santos Osório.

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 Minerais.

1. Robótica - Robótica de campo. 2. Robótica - Robótica móvel. 3. Drone - Dispersão. 4. Fotogrametria - Reconstrução 3D. 5. Robôs - Inspeção. I. Osório, Fernando Santos. II. Pessin, Gustavo. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 681.5:622.2

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



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DE OURO PRETO  
REITORIA  
ESCOLA DE MINAS  
PROGR. POS GRAD. PROF. INST. CONT. E AUT.  
PROCESSOS DE MIN.



## FOLHA DE APROVAÇÃO

**Levi Welington de Resende Filho**

### **Robótica Móvel na Mineração: Estudos de Caso com Robôs Terrestres e Aéreos em Dispersão de Etiquetas Eletrônicas, Reconstrução 3D e Inspeção Visual Automatizada**

Dissertação de Mestrado 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 15 de abril de 2021

#### Membros da banca

Doutor - Gustavo Pessin - Instituto Tecnológico Vale  
Doutor - Fernando Santos Osório - Universidade de São Paulo  
Doutor - Gustavo Medeiros Freitas - Universidade Federal de Minas Gerais  
Doutor - Alessandro Jacoud Peixoto - Universidade Federal do Rio de Janeiro

Gustavo Pessin, orientador do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 29/06/2021



Documento assinado eletronicamente por **Agnaldo Jose da Rocha Reis, COORDENADOR(A) DO CURSO DE PÓS-GRADUACÃO EM INSTRUMENTAÇÃO CONTROLE E AUTOMAÇÃO DE PROC DE MINERAÇÃO**, em 16/07/2021, às 12:19, 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](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0194705** e o código CRC **1676007B**.

## AGRADECIMENTOS

É um pouco clichê, porém é a verdade que se aplica a todos nós: primeiramente, gostaria de agradecer a Deus pelo dom da vida e por ter me dado a oportunidade de estudar e trabalhar numa área que sempre almejei.

Em seguida, gostaria de agradecer à minha família, que sempre me apoiou e forneceu os subsídios necessários durante toda a minha vida. Sem o suporte de vocês, eu não estaria aqui.

Quero agradecer à Bruninha pelo carinho e suporte durante o mestrado e, também, pelas críticas e sugestões, sempre bem pontuadas, realizadas na minha dissertação. Seu apoio e sua ajuda sempre me motivaram a dar o melhor de mim.

Gostaria de agradecer às comunidades do Instituto Tecnológico Vale, da Vale, da Universidade Federal de Ouro Preto, da Universidade Federal de Minas Gerais e da Universidade de São Paulo pela colaboração em todos trabalhos aqui desenvolvidos. Em específico, quero agradecer aos meus parceiros da 4ª Turma de Mestrado do PROFICAM: Robson, Speto, Léo e Luan pela amizade que construímos. Também agradeço pelas ajudas e momentos de integração os membros do ITVRoC: Jacó, Hector, Filipe, Gabriel, Rosa, André Santos, Gustavo Freitas, Buneku, Bidas, Matheus Nazário, Maurício, Fred e Mário, e a todos aqueles que trabalharam conosco. Todos vocês tiveram papel fundamental no meu crescimento profissional.

E por fim, gostaria de agradecer ao Gustavo Pessin pelas oportunidades dadas, pela orientação e por ter acreditado no meu potencial.

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.

*“A dificuldade é você quem cria,  
então é você também quem vai resolver.”*

*Daniel Lustosa*

## 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.)

### ROBÓTICA MÓVEL NA MINERAÇÃO: ESTUDOS DE CASO COM ROBÔS TERRESTRES E AÉREOS EM DISPERSÃO DE ETIQUETAS ELETRÔNICAS, RECONSTRUÇÃO 3D E INSPEÇÃO VISUAL AUTOMATIZADA

Levi Welington de Resende Filho

Abril/2021

Orientadores: Gustavo Pessin

Fernando Santos Osório

A robótica móvel, desde o seu surgimento, sempre foi uma área que despertou o interesse e atenção de pesquisadores. Hoje, graças ao avanço tecnológico, robôs móveis estão cada vez mais disponíveis. Movida pela transformação digital, a indústria viu também a possibilidade de utilizar robôs móveis em suas instalações. Dentre as áreas industriais que apresentam grande importância para a economia brasileira, destaca-se a mineração. Diferentemente de outros ambientes, a mineração apresenta um universo desafiador aos robôs, dificultando o seu desenvolvimento. Este trabalho está inserido neste contexto e é desenvolvido sobre três estudos de caso aplicados à mineração: (i) a necessidade de rastrear o minério de cobre ao longo da cadeia de produção, (ii) a necessidade de reconstruir ambientes confinados e (iii) a necessidade de inspecionar dutos da cadeia de produção. Foram propostas soluções para cada uma dessas necessidades: (i) desenvolvimento de hardware e software para melhorar o controle de rastreabilidade de minério de cobre por meio de lançamentos de etiquetas eletrônicas RFID, (ii) estudo investigativo em fotogrametria para executá-la em espaços confinados visando a reconstrução 3D do ambiente e (iii) a construção e avaliação de sistema computacional *deep learning* para a identificação de falhas precoces na tubulação de rejeitos da Usina do Salobo. Ao final de cada estudo de caso, considerações finais são apresentadas demonstrando os resultados obtidos.

**Palavras-chave:** Robótica de campo, Robótica móvel, Dispersão por drones, Reconstrução 3D, Inspeção robotizada.

**Macrotema:** Mina e usina; **Linha de Pesquisa:** Robótica Aplicada à Mineração; **Tema:** Sensoriamento de Ativos.

## 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.)

### MINING MOBILE ROBOTICS: CASE STUDIES WITH GROUND AND AIR ROBOTS IN ELECTRONIC TAG DISPERSION, 3D RECONSTRUCTION, AND AUTOMATED VISUAL INSPECTION

Levi Welington de Resende Filho

April/2021

Advisors: Gustavo Pessin

Fernando Santos Osório

Mobile robotics, since its inception, has always been a focus of interest and attention of researchers. Today, thanks to technological advancement, mobile robots are increasingly available. Driven by the digital transformation, the industry also saw the possibility of using mobile robots in its facilities. Among the industrial areas that are of great importance to the Brazilian economy, mining stands out. Unlike other environments, mining presents a challenging universe for robots, making their development difficult. This work is inserted in this context and is developed on three case studies applied to mining: (i) the need to track copper ore along the production chain, (ii) the need to reconstruct confined environments, and (iii) the need to inspect pipelines in the production chain. Solutions were proposed for each of these needs: (i) hardware and software development to improve copper ore traceability control through the launch of RFID electronic tags, (ii) investigative study in photogrammetry to perform it in confined spaces aiming at the 3D reconstruction of the environment and (iii) the construction and evaluation of a deep learning computational system for the identification of early failures in the tailings pipe of the Salobo Plant. At the end of each case study, final considerations are presented demonstrating the results obtained.

**Keywords:** Field robotic, Mobile robots, Drone Dispersion, 3D Reconstruction, Robotic Inspection.

**Macrotheme:** Mine and plant; **Research Line:** Robotics Applied to Mining; **Theme:** Asset Sensing.

## LISTA DE FIGURAS

Figura 1.1	Robôs móveis utilizados na exploração de Marte. . . . .	15
Figura 1.2	Exemplos de robôs de serviço. . . . .	16
Figura 1.3	Exemplos de robôs móveis aplicados a indústria. . . . .	17
Figura 1.4	Caminhão autônomo em operação. . . . .	17
Figura 1.5	Evolução do EspeleoRobô. . . . .	18
Figura 2.1	Exemplo de drone. . . . .	22
Figura 2.2	Exemplo de robô terrestre híbrido. . . . .	23
Figura 2.3	Drone Inspire 1. . . . .	23
Figura 2.4	Principais componentes do Inspire 1. . . . .	24
Figura 2.5	Principais componentes do EspeleoRobô. . . . .	25
Figura 2.6	Exemplo de impressora 3D do tipo de extrusão de material. . . . .	26
Figura 2.7	Exemplo de Arduino. . . . .	27
Figura 2.8	Exemplo de dado no formato Imagem de Alcance. . . . .	27
Figura 2.9	Exemplo de imagem colorida e sua respectiva profundidade. . . . .	28
Figura 2.10	Exemplo de dado em Nuvem de Pontos. . . . .	28
Figura 2.11	Representação de reconstrução 3D por meio de Mapa de Elevação. . . . .	29
Figura 2.12	Ambiente aberto representado por Grades 3D. . . . .	29
Figura 2.13	Representação 3D de ambiente por meio de Malha. . . . .	30
Figura 2.14	Exemplo de sensores utilizados para leitura de Tempo de Voo. . . . .	30
Figura 2.15	Exemplo de arranjo para o método Luz Estruturada. . . . .	31
Figura 2.16	Exemplo de câmera estéreo. . . . .	31
Figura 2.17	Fluxo básico da reconstrução 3D por fotogrametria. . . . .	32
Figura 2.18	Esquema ilustrativo de uma rede neural convolucional. . . . .	33
Figura 2.19	Comparação dos desempenhos de uma rede neural com e sem aprendizado por transferência. . . . .	34
Figura 2.20	Exemplo de uma saída por mapas de ativação de classe. . . . .	35
Figura 2.21	Predição com YOLO. . . . .	35
Figura 3.1	Fluxo de produção de Salobo. . . . .	38
Figura 3.2	Exemplo das etiquetas eletrônicas Dienamics. . . . .	38
Figura 3.3	Visão geral do protótipo desenvolvido. . . . .	40



Figura 3.4	Projeto do lançador de etiquetas eletrônicas. . . . .	41
Figura 3.5	Lançador de etiquetas acoplado a traseira do Inspire 1. . . . .	41
Figura 3.6	Implementação eletrônica do dispersor de etiquetas eletrônicas. . . . .	42
Figura 3.7	Validação em ambiente representativo. . . . .	43
Figura 3.8	Revalidação do dispositivo lançador de etiquetas em campo aberto. Caixa amarela apresentando foco no drone em voo. . . . .	44
Figura 3.9	Visita à área da mina e criação de rota. . . . .	46
Figura 3.10	Voo automatizado sobre material detonado. Caixa amarela apresentando foco no drone em voo. . . . .	47
Figura 4.1	Ambientes típicos para a realização da espeleologia. . . . .	49
Figura 4.2	EspeleoRobô em trabalhos de campo. . . . .	50
Figura 4.3	Fotogrametrias realizadas com 30 fotos. . . . .	52
Figura 4.4	Fotogrametrias realizadas com 40 e 50 fotos. A primeira linha apresenta os resultados com 40 fotos e a segunda com 50 fotos. . . . .	53
Figura 4.5	Cenário experimental no simulador CoppeliaSim. . . . .	56
Figura 4.6	Cenário experimental na Mina do Veloso. . . . .	56
Figura 4.7	Fotogrametria aplicada a caverna do DARPA <i>Subterranean</i> . . . . .	58
Figura 4.8	Fotogrametria aplicada a Mina do Veloso. . . . .	59
Figura 4.9	Análise de erro das nuvens de pontos aplicadas aos três métodos de reconstrução 3D para a caverna do DARPA <i>Subterranean</i> . . . . .	61
Figura 4.10	Análise de erro das nuvens de pontos obtidas pela fotogrametria e Visual- SLAM da Mina do Veloso, utilizando LiDAR-SLAM como referência. . . . .	62
Figura 5.1	Vista superior da Mina do Salobo. A linha em amarelo destaca a tubulação. . . . .	67
Figura 5.2	Inspeção dos tubos de rejeito. . . . .	68
Figura 5.3	Exemplos de juntas. . . . .	68
Figura 5.4	Esquemático do fluxo de software proposto para detecção e classificação das juntas. . . . .	70
Figura 5.5	Curvas de acurácia das etapas de treinamento e validação para a rede ResNet. . . . .	72
Figura 5.6	Resultados do mapa de ativação de classe. . . . .	72
Figura 5.7	Caixa delimitadora aplicado ao mapa de ativação de classe. . . . .	73
Figura 5.8	Valores resultantes do treinamento do detector YOLOv3 no conjunto de dados. . . . .	74
Figura 5.9	Deteções de juntas realizada pela rede YOLOv3. . . . .	75
Figura A1	Principais vistas da estrutura mecânica do dispositivo lançador de etiquetas eletrônicas RFID. . . . .	93
Figura B1	Fluxo de reconstrução 3D no software AliceVision - Meshroom. . . . .	94
Figura B2	Fluxo de reconstrução 3D proposto para minimizar limitações do ambiente. . . . .	95

## LISTA DE TABELAS

Tabela 3.1	Diferença de posição entre os sistemas de coordenadas da mina e do drone.	45
Tabela 4.1	Lista de softwares selecionados para análise de fotogrametria e algumas de suas características. . . . .	52
Tabela 4.2	Tempos aproximados nas reconstruções 3D. . . . .	53
Tabela 4.3	Análise das nuvens de pontos para as reconstruções 3D realizadas na caverna do DARPA <i>Subterranean</i> . . . . .	61
Tabela 4.4	Análise das nuvens de pontos para as reconstruções 3D realizadas na Mina du Veloso. . . . .	63
Tabela 5.1	Resultados de acurácia para cada rede neural convolucional testada. . . . .	71
Tabela 5.2	Resultados do tempo de execução para as redes neurais convolucionais em diferentes tipos de hardware. . . . .	74

## LISTA DE SIGLAS E ABREVIATURAS

<b>ANN</b>	Redes Neurais Artificiais (do inglês <i>Artificial Neural Networks</i> )
<b>CAD</b>	Desenho Assistido por Computador (do inglês <i>Computer-Aided Design</i> )
<b>CAM</b>	Mapas de Ativação de Classe (do inglês <i>Class Activation Mapping</i> )
<b>CNN</b>	Rede Neural Convolucional (do inglês <i>Convolutional Neural Network</i> )
<b>CONAMA</b>	Conselho Nacional do Meio Ambiente
<b>CPU</b>	Unidade Central de Processamento (do inglês <i>Central Processing Unit</i> )
<b>DA</b>	Aumento de Conjunto de Dados (do inglês <i>Dataset Augmentation</i> )
<b>DARPA</b>	Agência de Projetos de Pesquisa Avançada de Defesa (do inglês <i>Defense Advanced Research Projects Agency</i> )
<b>DJI</b>	<i>Dà-Jiāng Innovations</i>
<b>EMBRAPII</b>	Empresa Brasileira de Pesquisa e Inovação Industrial
<b>GAP</b>	Agrupamento Médio Global (do inglês <i>Global Average Pooling</i> )
<b>GPS</b>	Sistema de Posicionamento Global (do inglês <i>Global Positioning System</i> )
<b>GPU</b>	Unidade de Processamento Gráfico (do inglês <i>Graphics Processing Unit</i> )
<b>HDPE</b>	Polietileno de Alta Densidade (do inglês <i>High-Density Polyethylene</i> )
<b>IBAMA</b>	Instituto Brasileiro do Meio Ambiente
<b>IMU</b>	Unidade de Medição Inercial (do inglês <i>Inertial Measurement Unit</i> )
<b>ITV</b>	Instituto Tecnológico Vale
<b>LiDAR</b>	Detecção e Alcance de Luz (do inglês <i>Light Detection And Ranging</i> )
<b>mAP</b>	Precisão Média Ponderada (do inglês <i>mean Average Precision</i> )

<b>ML</b>	Aprendizado de Máquina (do inglês <i>Machine Learning</i> )
<b>PIB</b>	Produto Interno Bruto
<b>RFID</b>	Identificação por Radiofrequência (do inglês <i>Radio Frequency Identification</i> )
<b>RGB</b>	Vermelho, Verde e Azul (do inglês <i>Red, Green, and Blue</i> )
<b>RGB-D</b>	Vermelho, Verde, Azul e Profundidade (do inglês <i>Red, Green, Blue, and Depth</i> )
<b>ROS</b>	Sistema Operacional de Robôs (do inglês <i>Robot Operating System</i> )
<b>RPA</b>	Aeronave Remotamente Pilotada (do inglês <i>Remotely Piloted Aircraft</i> )
<b>RTK</b>	Posicionamento Cinemático em Tempo Real (do inglês <i>Real Time Kinematic</i> )
<b>SDK</b>	Kit de Desenvolvimento de Software (do inglês <i>Software Development Kit</i> )
<b>SfM</b>	Estrutura do Movimento (do inglês <i>Structure from Motion</i> )
<b>SLAM</b>	Localização e Mapeamento Simultâneos (do inglês <i>Simultaneous Localization and Mapping</i> )
<b>SSD</b>	Rede Neural Convolucional de Disparo Único (do inglês <i>Single Shot Detector</i> )
<b>TL</b>	Aprendizado por Transferência (do inglês <i>Transfer Learning</i> )
<b>ToF</b>	Tempo de Voo (do inglês <i>Time of Flight</i> )
<b>TRL</b>	Nível de Maturidade Tecnológica (do inglês <i>Technology Readiness Level</i> )
<b>UA</b>	Aeronave não Tripulada (do inglês <i>Unmanned Aircraft</i> )
<b>UAS</b>	Sistemas Aéreos não Tripulados (do inglês <i>Unmanned Aerial Systems</i> )
<b>UAV</b>	Veículo Aéreo não Tripulado (do inglês <i>Unmanned Aerial Vehicle</i> )
<b>Vale</b>	Vale S.A.
<b>YOLO</b>	<i>You Only Look Once</i>

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
1.1	Contexto . . . . .	15
1.2	Objetivos . . . . .	18
1.3	Organização do texto . . . . .	20
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>21</b>
2.1	Robótica móvel . . . . .	21
2.1.1	Robôs móveis aéreos . . . . .	21
2.1.2	Robôs móveis terrestres . . . . .	22
2.1.3	Inspire 1 . . . . .	23
2.1.4	EspeleoRobô . . . . .	24
2.2	Prototipagem rápida . . . . .	25
2.2.1	Impressoras 3D . . . . .	25
2.2.2	Microcontroladores . . . . .	26
2.3	Reconstrução 3D . . . . .	27
2.3.1	Formatos de arquivos com informações 3D . . . . .	27
2.3.2	Modelos para representação de ambientes . . . . .	28
2.3.3	Métodos de reconstrução 3D . . . . .	30
2.4	Redes neurais artificiais . . . . .	32
2.4.1	Rede neural convolucional . . . . .	32
2.4.2	Aprendizado por transferência . . . . .	33
2.4.3	Mapas de ativação de classe . . . . .	34
2.4.4	Rede neural convolucional de disparo único . . . . .	35
2.5	Considerações sobre os Referenciais Teóricos . . . . .	36
<b>3</b>	<b>ROBÔS AÉREOS PARA DISPERSÃO DE ETIQUETAS ELETRÔNICAS DE RASTREAMENTO DE MINÉRIO</b>	<b>37</b>
3.1	Trabalhos relacionados . . . . .	39
3.2	Desenvolvimento do protótipo . . . . .	40
3.2.1	Estrutura mecânica . . . . .	40
3.2.2	Desenvolvimento e implementação da eletrônica . . . . .	41

3.3	Validações do dispositivo . . . . .	43
3.3.1	Validações em ambiente representativo . . . . .	43
3.3.2	Validações em ambiente de mina . . . . .	44
3.3.2.1	Revalidação do dispositivo lançador de etiquetas . . . . .	44
3.3.2.2	Voo sobre material detonado . . . . .	45
3.4	Considerações sobre a Dispersão de Etiquetas Eletrônicas . . . . .	46
3.5	Trabalhos futuros . . . . .	47
<b>4</b>	<b>INVESTIGAÇÃO EM FOTOGRAMETRIA PARA A RECONSTRUÇÃO 3D DE AMBIENTES NA MINERAÇÃO</b>	<b>49</b>
4.1	Trabalhos relacionados . . . . .	50
4.2	Metodologia . . . . .	51
4.2.1	Análise de software para realização da fotogrametria . . . . .	52
4.2.2	Fluxo de reconstrução 3D no software escolhido . . . . .	54
4.2.3	Proposta de fluxo de reconstrução 3D . . . . .	55
4.2.4	Comparação dos fluxos de reconstrução 3D . . . . .	55
4.2.5	Comparação com outros métodos de reconstrução 3D . . . . .	57
4.3	Resultados e discussões . . . . .	57
4.3.1	Reconstruções 3D por fotogrametrias . . . . .	57
4.3.2	Comparação de métodos de reconstrução 3D . . . . .	60
4.3.2.1	Caverna do DARPA <i>Subterranean</i> . . . . .	60
4.3.2.2	Mina do Veloso . . . . .	62
4.4	Considerações sobre a Investigação em Fotogrametria . . . . .	63
4.5	Trabalhos futuros . . . . .	64
<b>5</b>	<b>DETECÇÃO DE POTENCIAIS FALHAS PRECOSES EM DUTO DE REJEITOS COM DISPOSITIVO ROBÓTICO E APRENDIZADO DE MÁQUINA</b>	<b>65</b>
5.1	Trabalhos relacionados . . . . .	66
5.2	Métodos e procedimentos . . . . .	67
5.2.1	Coleta de dados . . . . .	67
5.2.2	Desenvolvimento da rede neural convolucional . . . . .	69
5.2.3	Mapas de ativação de classe . . . . .	70
5.2.4	Tempo de execução . . . . .	70
5.2.5	Rede neural convolucional de disparo único . . . . .	70
5.2.6	Fluxo esquemático do software proposto . . . . .	70
5.3	Resultados e discussões . . . . .	71
5.3.1	Treinamento da rede neural convolucional . . . . .	71
5.3.2	Mapas de ativação de classe . . . . .	72
5.3.3	Tempo de execução . . . . .	73
5.3.4	Rede neural convolucional de disparo único . . . . .	74

5.4	Considerações sobre a Inspeção Automatizada de Dutos . . . . .	75
5.5	Trabalhos futuros . . . . .	76
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>77</b>
6.1	Contribuições . . . . .	79
6.1.1	Contribuições científicas . . . . .	79
6.1.2	Contribuições tecnológicas . . . . .	79
6.1.3	Contribuições industriais . . . . .	80
6.1.4	Contribuições sociais . . . . .	80
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>	<b>81</b>
	<b>APÊNDICES</b>	<b>92</b>

# 1. INTRODUÇÃO

Este Capítulo apresenta o contexto no qual este trabalho está inserido, os objetivos para cada um dos desenvolvimentos propostos e, por fim, a estrutura e organização dos capítulos subsequentes desta dissertação.

## 1.1. Contexto

O final do século XVIII foi marcado pela revolução industrial, a qual modificou todo o setor produtivo e iniciou a substituição da mão de obra humana por máquinas. Na busca por processos mais otimizados, a partir da década de 1960 os robôs industriais ganharam destaque. Atividades que eram consideradas repetitivas, tais como soldagem, montagem, pintura, embalagem, entre outras, passaram a ser realizadas por manipuladores robóticos. Os robôs industriais, como foram classificados, comparados aos humanos nestas atividades, são mais rápidos e mais precisos (SHIBATA, 2004).

A partir da década de 1990, com o desenvolvimento tecnológico e sua miniaturização, novos modelos de robôs começaram a ficar disponíveis no mercado, criando uma nova categoria na área: a robótica móvel. Esta área, apesar de ser jovem, tem atraído a atenção e por isso é alvo de várias pesquisas. Um robô móvel é capaz de andar ao longo de um ambiente e extrair as suas características para usufruir de seus talentos de maneira mais efetiva (SIEGWART *et al.*, 2011). Além disso, atualmente, eles são capazes de desempenhar atividades complexas de forma autônoma (YOUSIF *et al.*, 2015), por exemplo, os robôs Opportunity e Spirit (Figura 1.1) que foram enviados à Marte.



(a) Robô Opportunity



(b) Robô Spirit

Figura 1.1: Robôs móveis utilizados na exploração de Marte.

Fonte: Maimone e Matthies (2006).



Além do uso na exploração espacial, os robôs móveis estão presentes no nosso dia-a-dia. De maneira geral, eles podem ser classificados em duas subcategorias: de uso pessoal ou de uso profissional (SHIBATA, 2004). Robôs móveis de uso pessoal são aqueles que são capazes de desempenhar atividades rotineiras, tais como cortar a grama (Figura 1.2a), aspirar a casa, limpar a piscina e, até mesmo, dirigir (Figura 1.2b), enquanto os robôs móveis de uso profissional são aqueles que são capazes de desempenhar atividades que podem gerar risco a saúde humana, tais como acessar e investigar espaços confinados (Figura 1.2c), desarmar bombas (Figura 1.2d), entre outras.



(a) Robô cortador de grama



(b) Carro autônomo dirigindo na cidade



(c) Drone utilizado para inspeção de ambientes confinados



(d) Robô sendo utilizado para desarmar uma bomba

Figura 1.2: Exemplos de robôs de serviço.

Fonte: (a) Edwards (2020), (b) Ohsnman (2020), (c) Rectrix Drone Services (2020), (d) TOPSKY (2020).

Desde o início da última década, a digitalização e a transformação digital têm sido cada vez mais presentes na indústria (VAIDYA *et al.*, 2018). Este movimento, que promove, principalmente, a tomada de decisões autônomas, interoperabilidade, agilidade, flexibilidade, eficiência e redução de custo (PÉREZ D. *et al.*, 2016), proporcionou a entrada da robótica móvel, também, neste setor. Como exemplos de aplicações, pode-se citar o Energid (Figura 1.3a), que é um drone desenvolvido com um manipulador robótico embarcado, que permite a realização de atividades sofisticadas de inspeção com destreza e velocidade (TARDELLA, 2020); o FarmWi-se Robot (Figura 1.3b), que é um robô terrestre utilizado na agricultura, realiza a detecção e corte de ervas daninhas de forma autônoma (GUIZZO, 2020); e o ARIEL (Figura 1.3c), que é composto por um drone e um barco autônomos, executa a detecção de vazamento de óleo em

meios aquáticos (DE SOUZA, 2020).



(a) Drone Energid



(b) FarmWise Robot



(c) ARIEL

Figura 1.3: Exemplos de robôs móveis aplicados a indústria.

Fonte: (a) Tardella (2020), (b) Guizzo (2020), (c) de Souza (2020).

Além dos exemplos citados, a robótica móvel pode ser aplicada em quaisquer setores da indústria, inclusive na indústria de base, por exemplo na mineração. A mineração, possui forte impacto na economia brasileira, sendo que no ano de 2017 esse setor representou 4% do Produto Interno Bruto (PIB) nacional e registrou superavit de US\$ 23,4 bilhões (MINISTÉRIO DE MINAS E ENERGIA, 2018). Atualmente no Brasil existem 207 minas em operação, das quais 33% apresentam produção superior a 1 milhão de toneladas por ano. Dentre as empresas neste setor, destaca-se a Vale S.A. (Vale), que apresenta grandes parcelas de representatividade na produção nacional com participação de 71,9% na extração de ferro, 70,6% de participação na extração de cobre, e de 14,6% de participação na extração de manganês (AGÊNCIA NACIONAL DE MINERAÇÃO - ANM, 2020).

Diante de sua contribuição para a economia e das perspectivas tecnológicas do mercado atual, a Vale em 2018 iniciou a operação de ativos em modo autônomo: caminhões fora de estradas (Figura 1.4) e perfuratrizes, e em modo teleoperados: escavadeiras, na mina de Brucutu - Minas Gerais. Por exemplo, os caminhões que antes eram operados por pessoas, passaram a ser controlados por sistemas de computadores, Sistema de Posicionamento Global (do inglês *Global Positioning System*, GPS), radares e inteligência artificial (VALE, 2020).



(a) Caminhão fora de estrada autônomo na Mina de Brutucu



(b) Empregado da Vale monitorando funcionamento do caminhão

Figura 1.4: Caminhão autônomo em operação.

Fonte: Vale (2020).

Além disso, a empresa em 2014 adquiriu um robô móvel para apoiar no estudo de cavidades naturais, o qual foi batizado de EspeleoRobô (Figura 1.5). Nos últimos anos, o robô passou por diversas modificações, dando ao dispositivo a habilidade de inspecionar outros espaços confinados, tais como galerias naturais e tubulações.




Figura 1.5: Evolução do EspeleoRobô.

Fonte: Adaptado de acervo ITV.

Anteriormente foram apresentados dois exemplos de aplicações de robótica móvel aplicados à mineração, contudo, esta área ainda apresenta diversos desafios (presença de alta umidade, poeiras, variação da iluminação, diferença de relevos, entre outros) que carecem de estudos e aplicações robustas, tais como: desenvolvimento de mecanismos e sistemas robóticos, sistemas de localização e navegação para veículos e robôs móveis, sistemas autônomos ou teleoperados, sistemas de aeronaves pilotadas remotamente, estratégias de controle cooperativo para robôs heterogêneos (robôs terrestres e aéreos atuando em conjunto na realização de uma tarefa complexa).

Esta dissertação foi desenvolvida buscando apresentar estudos e aplicações robustas que visam atender à demanda da empresa do setor mineral e fomentar a sinergia entre o estudo investigativo, o desenvolvimento tecnológico, a inovação, a produção e a indústria. Mais especificamente, neste documento são apresentados três estudos de caso, os quais demonstram alinhamento com o desenvolvimento de pesquisas aplicadas ao setor de mineração com abordagens prático-científicas que proporcionam aprendizado, conhecimento e contribuições em diferentes vieses.

## 1.2. Objetivos

Esta dissertação tem como objetivo geral a proposta, o desenvolvimento e a avaliação de serviços robóticos para atuação em campo. A dissertação é organizada e desenvolvida sobre três casos aplicados: (i) **Dispersão de Etiquetas Eletrônicas**, (ii) **Investigação em Fotogrametria**, e (iii) **Inspecção Automatizada de Dutos**. Dessa forma, para cada aplicação, os objetivos específicos são listados a seguir.

No tema de **Dispersão de Etiquetas Eletrônicas** (Capítulo 3), os objetivos específicos são:

- Propor e desenvolver um dispositivo eletromecânico que seja acoplado a um drone para dispersão tele-controlada;
- Validar o protótipo desenvolvido em ambiente representativo e em ambiente de mina;
- Realizar a operação assistida na mina, validando a prova de conceito e detalhando as lições aprendidas;
- Desenvolver procedimento para execução da atividade;

No tema de **Investigação em Fotogrametria** (Capítulo 4), os objetivos específicos são:

- Investigar diferentes softwares para realização de reconstrução 3D por meio de fotogrametria;
- Propor metodologia para reconstrução 3D para ambientes subterrâneos por fotogrametria utilizando o software escolhido;
- Realizar a reconstrução 3D de diferentes ambientes, sejam eles reais ou simulados, por fotogrametria;
- Comparar resultados obtidos por fotogrametria com LiDAR-SLAM e Visual-SLAM;
- Ser capaz de reproduzir e extrapolar métodos de reconstrução 3D a diferentes ambientes dentro da área de mineração.

No tema de **Inspeção Automatizada de Dutos** (Capítulo 5), os objetivos específicos são:

- Propor e desenvolver método de *deep learning* para identificação de potenciais falhas precoces em dutos;
- Comparar os resultados obtidos para diferentes modelos de redes neurais convolucionais para o sistema proposto;
- Validar resultados obtidos através de mapas de ativação de classe;
- Avaliar consumo energético para cada rede neural convolucional em diferentes tipos de hardware;
- Identificar as juntas utilizando redes neurais convolucionais de disparo único.

### 1.3. Organização do texto

Esta dissertação é composta por 6 capítulos. Inicialmente, é apresentado um capítulo com o Referencial Teórico, Capítulo 2, que introduz a base teórica necessária para as aplicações dos estudos de caso desenvolvidos. Em seguida, nos Capítulos 3, 4 e 5 são apresentados os três estudos de caso. Cada um desses capítulos apresenta suas motivações, trabalhos relacionados, metodologias, resultados, considerações finais e trabalhos futuros. No primeiro estudo de caso, Capítulo 3, é apresentada uma inovação tecnológica, cuja principal motivação foi auxiliar a Mina do Salobo na solução de um problema, enquanto os demais estudos de caso, Capítulos 4 e 5, apresentam estudos investigativos quanto a fotogrametria aplicada ambientes subterrâneos e a inspeção automatizada. Por fim, são apresentadas as Considerações Finais, Capítulo 6, as quais realizam o fechamento do trabalho, revisam os objetivos e os resultados obtidos no desenvolvimento e apresentam a lista de contribuições.

Neste documento, são feitas referências aos trabalhos publicados pelo autor durante o período do mestrado. A seguir estão listadas as publicações referentes a cada estudo de caso desenvolvido.

- Dispersão de Etiquetas Eletrônicas:
  - Relatório técnico: Relatório de experimentos de campo na Mina do Salobo (RESENDE FILHO *et al.*, 2020);
  - Pedido de patente de invenção: Dispositivo e método para lançamento de etiquetas eletrônicas sobre rocha desmontada a partir de um veículo aéreo não tripulado (RESENDE FILHO *et al.*, 2021).
- Investigação em Fotogrametria:
  - Resumo de artigo: *Investigation on Photogrammetry and LiDAR Models for Caves/Mines 3D Reconstruction* (RESENDE FILHO *et al.*, 2019);
  - Relatório técnico: Dispositivo robótico para inspeção de ambientes restritos e confinados (FREITAS *et al.*, 2020a);
  - Artigo de periódico: *Towards semi-autonomous robotic inspection and mapping in confined spaces with the EspeleoRobô* (AZPÚRUA *et al.*, 2021).
- Inspeção Automatizada de Dutos:
  - Relatório técnico: Inspeção da tubulação de rejeitos das usinas de Salobo (MAGNO *et al.*, 2019);
  - Artigo de conferência: *Deep Learning for Early Damage Detection of Tailing Pipes Joints with a Robotic Device* (RESENDE FILHO *et al.*, 2020).



## 2. REFERENCIAL TEÓRICO

Este Capítulo apresenta um breve referencial teórico relativo aos estudos de caso que são abordados nesta dissertação. Trabalhos relacionados e mais específicos são apresentados dentro dos Capítulos que descrevem os estudos de caso, com o objetivo de mantê-los autocontidos. Os conceitos apresentados na Seção 2.1 são relativos às plataformas utilizadas neste trabalho, na Seção 2.2 são relativos ao Capítulo 3, enquanto os conceitos apresentados na Seção 2.3 são relativos ao Capítulo 4 e, por fim, os conceitos apresentados na Seção 2.4 são relativos ao Capítulo 5.

### 2.1. Robótica móvel

Um robô móvel pode ser definido como um sistema mecânico capaz de se mover em um ambiente de forma autônoma. Para este propósito, deve estar embarcado com (i) sensores, que coletam informações a respeito do ambiente ao redor, além de determinar a sua localização, (ii) atuadores que permitem que ele se mova, e (iii) um algoritmo que lhe possibilita calcular e interpretar os dados coletados pelos sensores, e enviar comandos para os atuadores com o objetivo de se realizar uma atividade (JAULIN, 2019).

Nas Subseções a seguir serão apresentados conceitos com relação aos robôs móveis aéreos e terrestres, e em seguida são apresentados as especificações dos dispositivos utilizados nesse trabalho: o Inspire 1 e o EspeleoRobô.

#### 2.1.1. Robôs móveis aéreos

Os robôs móveis aéreos (Figura 2.1) apresentam diversas nomenclaturas, sendo comumente conhecidos como drones, Aeronave Remotamente Pilotada (do inglês *Remotely Piloted Aircraft*, RPA), Aeronave não Tripulada (do inglês *Unmanned Aircraft*, UA), Veículo Aéreo não Tripulado (do inglês *Unmanned Aerial Vehicle*, UAV) e Sistemas Aéreos não Tripulados (do inglês *Unmanned Aerial Systems*, UAS) (TANG e SHAO, 2015). Nas regulamentações brasileiras, regidas pela Agência Nacional de Aviação Civil - ANAC (2020) e Departamento de Controle do Espaço Aéreo - DECEA (2020), os termos mais utilizados são: RPAs e UAs.

As RPAs, dentre as suas inúmeras classificações, podem ser categorizadas em dois grandes grupos baseados no formato de suas asas (TANG e SHAO, 2015) e (LEE e CHOI, 2016):

- Asas fixas: são equipamentos similares a aviões. Graças às asas fixas, a decolagem e o pouso são realizados na horizontal;
- Asas rotativas: são equipamentos similares a helicópteros ou autogiros. A decolagem e o pouso para estes modelos são realizados na vertical.



Figura 2.1: Exemplo de drone.

Fonte: DJI (2020b).

Os drones estão cada vez mais populares no dia-a-dia das pessoas. Nos últimos anos, o desenvolvimento de RPAs cresceu rapidamente, criando um mercado com drones de diversos formatos, tamanhos e capacidades (COLOMINA e MOLINA, 2014). Este crescimento, concomitante com a evolução da Indústria 4.0, alavancou a popularidade destes dispositivos. Atualmente os drones destacam-se na área de sensoriamento remoto. Tang e Shao (2015) introduzem o termo Sensoriamento Remoto por Drones, de forma a distinguir o que pode ser realizado por um drone daquilo que é feito com tecnologias tradicionais, tais como satélites e aviões. Dentre as vantagens do uso de drone perante aos outros métodos, pode-se destacar: maior flexibilidade, coleta em tempo real e menor custo.

Outros exemplos de utilização de drones podem ser vistos em atividades de resgate e sobrevivência (SHAHMORADI *et al.*, 2020), planejamento e gestão urbana (BILJECKI *et al.*, 2015) e monitoramentos ambientais e ecológicos (LEE e CHOI, 2016). Também podem ser vistos em aplicações em escalas industriais, como na agricultura (ELIJAH *et al.*, 2018), óleo e gás (SHAHMORADI *et al.*, 2020), mineração (LEE e CHOI, 2016), entre outras.

### 2.1.2. Robôs móveis terrestres

Os robôs móveis terrestres, geralmente, possuem mecanismos de locomoção inspirados na natureza, tais como rastejar, deslizar, correr, andar, entre outros. Podem, também, se locomover a partir de rodas, método que apresenta alta eficiência em solos planos (SIGEWART *et al.*, 2011). Além disso, os robôs podem ser desenvolvidos em sistemas híbridos de locomoção, como por exemplo o ANYmal (Figura 2.2), que é um robô que possui pernas e rodas (COXWORTH, 2020).

Neste trabalho, dentre os tipos de locomoção, são destacados os de pernas e os de rodas. Os robôs de pernas são caracterizados por uma série de pontos de contatos entre o robô e o solo. O ponto chave da utilização das pernas incluem adaptabilidade e manobrabilidade em terrenos acidentados. Além disso, o robô é capaz de cruzar buracos, desde que não exceda o seu alcance, e manipular objetos com grande habilidade. As principais desvantagens da locomoção por pernas incluem alto consumo energético e alta complexidade mecânica: as pernas podem ter vários graus de liberdade, devem ser capazes de sustentar o peso total do robô, além de levantar




Figura 2.2: Exemplo de robô terrestre híbrido.

Fonte: Coxworth (2020).

e abaixar, e, por fim, devem transmitir forças em várias direções diferentes (SIEGWART *et al.*, 2011).

Os robôs de rodas são os robôs mais populares na robótica móvel. Este sistema de locomoção apresenta alta eficiência, e geralmente não apresenta problemas de equilíbrio, uma vez que os robôs são projetados para que as rodas sempre estejam em contato com solo. Os maiores problemas dos problemas com rodas se concentram na tração, na capacidade de manobra e controle do robô que são limitadas e/ou determinadas pelas configurações de rodas dos robôs (SIEGWART *et al.*, 2011).

### 2.1.3. Inspire 1

A RPA Inspire 1 (DJI, Nanshan) (Figura 2.3) é um quadrorotor comercial que tem como principais características: peso de 3 kg, autonomia de aproximadamente 18 minutos, velocidade máxima de 22 m/s, máxima resistência a velocidade de vento de 10 m/s e peso máximo de decolagem de 3,5 kg (DJI, 2020a).



Figura 2.3: Drone Inspire 1.

Fonte: Loja Drone Mania (2020).

A Figura 2.4 apresenta o diagrama com os principais componentes do Inspire 1. Além do



GPS, este drone conta com uma Unidade de Medição Inercial (do inglês *Inertial Measurement Unit*, IMU), um magnetômetro, dois sonares e uma câmera monocular. Estes sensores são utilizados para efetuar o controle da RPA e garantir a segurança de voo.




Figura 2.4: Principais componentes do Inspire 1.

Fonte: Adaptado de DJI (2021).

#### 2.1.4. EspeleoRobô

O EspeleoRobô (Figura 1.5) é uma plataforma robótica de pequenas dimensões que é utilizada na inspeção de espaços confinados. O robô, inicialmente, foi desenvolvido para ser utilizado como uma ferramenta teleoperada na inspeção de cavernas, baseando-se no robô RHEX (Boston Dynamics, Waltham) que apresenta configurações com seis pés. Nos últimos anos, o EspeleoRobô passou por diversas alterações e atualmente é uma plataforma modular, possui diferentes sistemas de locomoção e, além disso, é capaz de fazer missões autônomas (AZPÚRUA *et al.*, 2021).

Dentre as suas principais características destacam-se: peso de 25 kg, autonomia de aproximadamente 4 h com carga útil de 5 kg, comunicação sem fio de 900 MHz com antena direcional ou rede 4 G e com fio (250 m), dimensões de 0,28 x 0,52 x 0,7 m e proteção à água e particulados (IP67). A Figura 2.5 apresenta o diagrama com os principais componentes embarcados do EspeleoRobô, não se limitando a estes, uma vez que os sensores utilizados no robô variam de acordo com a tarefa de interesse (plataforma modular).




Figura 2.5: Principais componentes do EspeleoRobô.

Fonte: Adaptado de Azpúrua *et al.* (2021).

## 2.2. Prototipagem rápida

Nas Subseções a seguir são apresentadas tecnologias que têm permitido a prototipagem rápida e, consequentemente, têm tornado possível o desenvolvimento de aplicações interoperáveis e flexíveis, que são essenciais para a robótica móvel.

### 2.2.1. Impressoras 3D

As impressoras 3D, também conhecidas como manufatura aditiva ou prototipagem rápida, existem há décadas. O primeiro trabalho com impressora 3D foi feito em 1984 por Charles W. Hull (BOGUE, 2013). Naquele momento, a tecnologia era muito cara e não se mostrou muito atrativa à indústria e aos consumidores.

Até a década de 2010, a tecnologia de impressão 3D raramente era vista fora de feiras e centros de desenvolvimento (LI *et al.*, 2016). A partir de 2010, o cenário se mostrou diferente e esta tecnologia atingiu uma expansão inimaginável. A impressão 3D foi comparada a tecnologias disruptivas, como livros digitais e downloads de música (BERMAN, 2012). Tal expansão se deve ao fato da impressão 3D apresentar um simples princípio de funcionamento, ao desenvolvimento de diferentes tipos desta tecnologia, à facilidade de integração com computador, à presença de uma comunidade ativa e, acima de tudo, à simplicidade de tornar um projeto realidade. Desde a sua invenção, a impressão 3D tem como princípio de funcionamento um processo de manufatura aditivo, em que os produtos são construídos camada por camada, por meio de uma série de seções transversais (BERMAN, 2012). As impressoras 3D

podem ser de diferentes tipos, dos quais destacam-se as de extrusão de material (Figura 2.6), fotopolimerização de cuba, jateamento de material, ligação de material granular e laminação de folha (LI *et al.*, 2016). A maioria das tecnologias de impressão 3D permitem integração com software de Desenho Assistido por Computador (do inglês *Computer-Aided Design*, CAD) e com outros arquivos digitais. No final do processo de desenvolvimento de um produto, o projetista simplesmente clica no botão “imprimir” e escolhe uma impressora aplicável (BERMAN, 2012). Além disso, hoje existem diversos sites com repositórios de desenhos, os quais usuários podem compartilhar e, até mesmo comercializar, projetos entre si.




Figura 2.6: Exemplo de impressora 3D do tipo de extrusão de material.

Fonte: Dring (2021).

Não apenas para pequenas aplicações, a tecnologia de impressão 3D está cada vez mais conquistando o seu espaço nos setores manufatureiros, criando novas oportunidades para a fabricação de itens, que no passado eram impossíveis de serem fabricados, e aumentando a qualidade daqueles que já eram produzidos (ATTARAN, 2017).

### 2.2.2. Microcontroladores

Microcontroladores podem ser definidos como pequenos computadores, desenvolvidos em um circuito integrado, contendo o núcleo do processador, memória e periféricos programáveis de entrada e saída. Eles são uma excelente forma para programar e controlar eletrônicos. Alguns exemplos de microcontroladores são as placas Wiring, o PIC, o Basic Stamp, o Arduino, Raspberry, entre outros (NUSSEY, 2013). Dentre os modelos no mercado, uma das tendências no desenvolvimento de código aberto é o microcontrolador Arduino (Figura 2.7) que se destaca por ser uma plataforma de baixo custo e amplamente apoiada pela academia e pela indústria (GONZÁLEZ e CALDERÓN, 2019). Isso se dá pelo fato do Arduino apresentar simples integração com o computador e ter comportamento facilmente alterado de acordo com a

necessidade do usuário, o que seria muito mais difícil de ser feito nos outros microcontroladores (NUSSEY, 2013).



Figura 2.7: Exemplo de Arduino.

Fonte: Net Computadores (2020).

## 2.3. Reconstrução 3D

As reconstruções 3D são hoje uma ferramentas essenciais na análise de estruturas, graças à sua capacidade de examinar desde pequenos corpos até grandes ambientes (EULITZ e REISS, 2015). Diferentemente de outras representações, as reconstruções 3D permitem a navegação e extração de informações tais como medidas ponto a ponto, volume, entre outras. Nas Subseções a seguir, são apresentados os principais formatos de arquivos com informações 3D, os modelos e os métodos utilizados na representação de ambientes.

### 2.3.1. Formatos de arquivos com informações 3D

Os principais formatos para a transferência de informação 3D são Imagem de Alcance (do inglês *Range Image*), Imagens em Vermelho, Verde, Azul e Profundidade (do inglês *Red, Green, Blue, and Depth*, RGB-D) e Nuvem de Pontos (do inglês *Point Cloud*). Segundo Besl (1988), Imagem de Alcance é o arquivo em que cada pixel é representado num espaço 2D em  $(x,y)$  apresenta um nível  $z$  que representa a distância relativa entre eles (Figura 2.8).

```

31 20 23 23 26 26 28 26 28 26 23 20 23 23 20 23 26 23 26 23
28 26 23 26 23 28 26 26 26 23 23 26 23 26 23 26 20 23 23
28 26 26 26 23 20 26 26 31 26 28 28 26 20 23 26 20 20 26
26 23 26 26 23 23 20 23 39 34 45 37 45 39 72 56 45 64 56 45
23 26 20 26 23 23 26 50 34 28 28 42 45 50 61 56 59 42 56 59
26 23 23 23 28 20 23 26 26 23 28 37 50 48 59 48 50 56 53 45
23 26 26 17 20 20 20 31 20 28 28 42 59 59 59 53 59 48 53 53
20 20 20 26 17 20 28 26 26 23 23 42 61 59 50 48 50 50 53 53
23 26 17 23 20 17 20 37 26 20 31 61 75 59 56 61 50 50 48 48
15 20 20 23 20 23 20 26 26 23 23 64 67 67 50 45 53 50 56 56
17 15 23 20 17 17 28 26 28 23 37 48 61 59 56 56 61 42 70 56
17 17 15 17 20 17 23 31 23 17 15 64 45 56 53 48 56 48 53 61
17 20 15 15 17 17 28 28 26 26 50 61 61 56 48 50 53 45 53
17 15 20 20 17 17 23 17 20 17 42 64 50 45 50 50 48 45 48
17 17 17 20 17 17 12 26 20 23 26 53 56 53 59 50 50 45 50 45
15 17 20 20 20 12 26 12 23 12 28 31 72 72 53 50 48 42 48 45
12 17 15 15 12 15 09 23 20 15 17 45 70 70 72 75 70 45 64 53
15 15 17 12 12 15 15 31 34 26 31 48 48 59 48 64 48 45 75 67
15 17 12 17 09 17 17 28 39 64 42 81 34 53 42 39 72 48 61 42
15 15 15 15 12 09 06 34 48 53 28 45 28 39 31 50 50 53 50 39

```




Figura 2.8: Exemplo de dado no formato Imagem de Alcance.

Fonte: Besl (1988).

De acordo com McGill *et al.* (2017), Imagens em RGB-D são arquivos nos quais as câmeras são capazes de capturar tanto a imagem colorida em Vermelho, Verde e Azul (do inglês *Red, Green, and Blue*, RGB), quanto a sua respectiva profundidade (Figura 2.9)




Figura 2.9: Exemplo de imagem colorida e sua respectiva profundidade.

Fonte: Lai *et al.* (2020).

Por fim, Nuvem de Pontos que é um conjunto de pontos no espaço, expresso em um mesmo sistema de coordenadas  $x, y$  e  $z$ , que representam o formato dos objetos/ambientes (Figura 2.10).




Figura 2.10: Exemplo de dado em Nuvem de Pontos.

Fonte: Sneha S (2019).

### 2.3.2. Modelos para representação de ambientes

Segundo Burgard *et al.* (2016), a representação de ambientes naturais por meio de modelos geométricos, pode ser realizada com Mapas de Elevação (do inglês *Elevation Grids*), Grades 3D (do inglês *3D Grids*) e Malhas (do inglês *Mesh*). Mapas de Elevação descrevem o terreno como uma função  $h = f(x, y)$ , os quais  $x$  e  $y$  são as coordenadas planares e  $h$  a elevação correspondente. Os Mapas de Elevação são representados por meio de voxels (unidade unitária de volume), conforme demonstrado na Figura 2.11.






Figura 2.11: Representação de reconstrução 3D por meio de Mapa de Elevação.

Fonte: Triebel *et al.* (2006).

Nas Grades 3D os dados são representados diretamente em 3D sem uma projeção ou referência em um plano 2D, preservando sua distribuição original e sem restringir a geometria do ambiente (Figura 2.12). Contudo, o uso dessa representação apresenta alto consumo computacional.




Figura 2.12: Ambiente aberto representado por Grades 3D.

Fonte: Burgard *et al.* (2016).

Finalmente, as Malhas são um conjunto de vértices, arestas e faces que definem a forma de um objeto/ambiente poliédrico. A princípio, podem representar quaisquer combinações de superfície de uma forma compacta (Figura 2.13). Entretanto, na prática, esta representação apresenta dificuldades em trabalhar em ambientes muito complexos, tais como terrenos acidentados.




Figura 2.13: Representação 3D de ambiente por meio de Malha.

Fonte: Burgard *et al.* (2016).

### 2.3.3. Métodos de reconstrução 3D

As reconstruções 3D podem ser realizadas a partir de dois métodos: passivos ou ativos. Os métodos ativos interferem ativamente com a cena/objeto reconstruído, mecanicamente ou radiometricamente, a fim de se obter o mapa de profundidade de interesse. Geralmente, são utilizadas tecnologias Tempo de Voo (do inglês *Time of Flight*, ToF) e Luz Estruturada (do inglês *Structure Light*) para essa metodologia.

Tempo de Voo é um método que opera com base no mesmo princípio de radares, medindo o tempo que a radiação emitida por um transmissor leva para percorrer uma distância em um meio (ZANUTTIGH *et al.*, 2016). Os sensores (Figura 2.14) mais utilizados neste método são LiDAR e Câmeras ToF.



(a) Puck (Velodyne, San Jose)



(b) Basler *Time-of-Flight* (Basler, Ahrensburg)

Figura 2.14: Exemplo de sensores utilizados para leitura de Tempo de Voo.

Fonte: (a) Velodyne (2020), (b) Basler (2020).

A Luz Estruturada, parte do princípio da triangulação. Sua construção básica consiste de um arranjo em que uma câmera e um projetor apresentam um ângulo  $\alpha$  entre si, e ambos apontam para um alvo (ZANUTTIGH *et al.*, 2016), conforme ilustrado na Figura 2.15. O sensor ativo, responsável pela detecção da profundidade, pode ser um laser infravermelho, uma luz projetada ou luz codificada por cores.




Figura 2.15: Exemplo de arranjo para o método Luz Estruturada.

Fonte: Adaptado de Cartola V. (2020).

Já os métodos passivos, são aqueles em que a aquisição de dados é realizada a partir da aquisição da cena por meio de diferentes ângulos de visão a partir de vídeos ou imagens. Nessa técnicas, normalmente, são utilizadas luzes artificiais para minimizar oclusões na cena de interesse. As informações coletadas são transformadas em 3D a partir da triangulação e correspondência entre similares pontos nas imagens (BIANCO *et al.*, 2013). Dentre esses métodos destacam-se a Visão Estéreo e a Fotogrametria.

A Visão Estéreo é um metodologia composta por duas câmeras que se enquadram parcialmente na mesma cena. Considerando que as câmeras são iguais, estão calibradas e há sobreposição das imagens, é possível estimar as coordenadas 3D de interesse através da triangulação (ZANUTTIGH *et al.*, 2016). A Figura 2.16 apresenta exemplo de câmera estereo.




Figura 2.16: Exemplo de câmera estereo.

Fonte: Stereo Labs (2020).

Já a Fotogrametria é uma metodologia que realiza a reconstrução 3D a partir de um conjunto de imagens que apresentam sobreposições superiores a 80%. Pelo fato de utilizar informações 2D (fotos), esta metodologia, comparado com os demais, apresenta maior custo computacional. Para a reconstrução o fluxo básico (Figura 2.17) é: extração de características (LOW, 2004); correspondência entre as imagens (NISTER e STEWENIUS, 2006); corres-



pondência entre as características extraídas (LOW, 2004); Estrutura do Movimento (do inglês *Structure from Motion*, SfM) (MOULON *et al.*, 2013); estimativa de profundidade (HIRSCHMULLER, 2005); criação da malha (JANCOSEK e PAJDLA, 2014); e, por fim, texturização (LÉVY *et al.*, 2002).

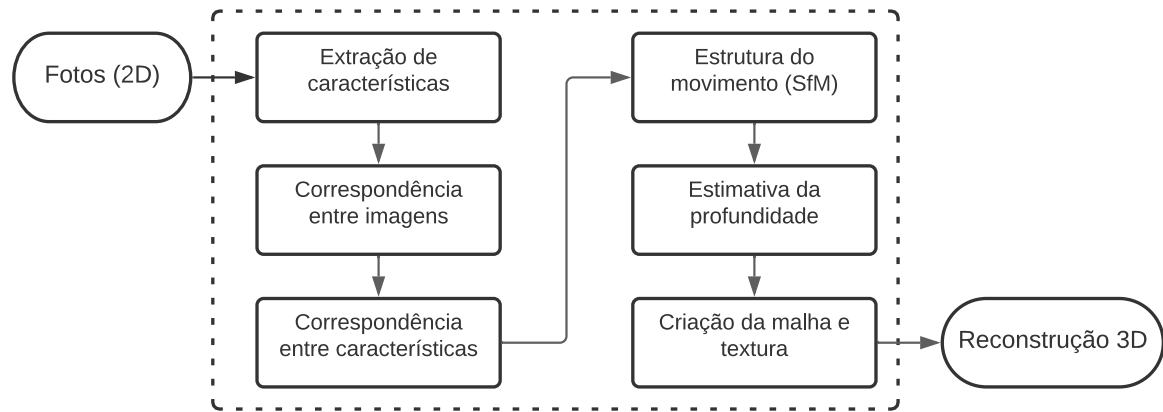


Figura 2.17: Fluxo básico da reconstrução 3D por fotogrametria.

Fonte: Adaptado de AliceVision Meshroom (2019).

## 2.4. Redes neurais artificiais

Redes Neurais Artificiais (do inglês *Artificial Neural Networks*, ANN) são técnicas computacionais que apresentam modelo matemático inspirado na estrutura neural de organismos inteligentes, que são capazes de realizar aprendizado, bem como reconhecimento de padrões. Nas Subseções a seguir, são apresentados os conceitos de Rede Neural Convolucional, Aprendizado por Transferência, Mapas de Ativação de Classe e Rede Neural Convolucional de Disparo Único.

### 2.4.1. Rede neural convolucional

Na identificação de padrões por imagens, a ANN normalmente utiliza um número muito grande de neurônios, dificultando seu uso prático (AGHDAM e HERAVI, 2017; BUDUMA e LOCASCIO, 2017). Para Aghdam e Heravi (2017), o uso da Rede Neural Convolucional (do inglês *Convolutional Neural Network*, CNN) é a solução para reduzir esse alto número de neurônios e parâmetros necessários para a classificação de imagens. Além disso, uma CNN é uma rede multicamada projetada especificamente para reconhecer formas bidimensionais com um alto grau de conversão, dimensionamento, inclinação e outras formas de distorção (HAYKIN, 2009). A Figura 2.18 apresenta um esquema de CNN simples para extrair informações e classificar uma imagem com base na rede LeNet, introduzido por LeCun *et al.* (1998). Também pela Figura 2.18, nota-se que é possível dividir as CNNs em dois grupos: nas (i) camadas de

convolução, que são compostas pelas convoluções e subamostragens, e nas (ii) camadas de classificação que são compostas pelas conexões completas.




Figura 2.18: Esquema ilustrativo de uma rede neural convolucional.

Fonte: Adaptado de LeCun *et al.* (1998).

As camadas de convolução são responsáveis por duas características: aprendizado de parâmetros invariantes na translação, o que as permite ter grande poder de generalização com poucas amostras, e aprendizado de hierarquias espaciais de padrões, o que possibilita que as camadas convolucionais extraiam mais padrões a cada camada, permitindo que as redes aprendam, com eficiência, conceitos visuais cada vez mais complexos e abstratos. Enquanto isso, as camadas de classificação são responsáveis pelo aprendizado de padrões globais, ou seja, elas consideram toda a informação recebida, como por exemplo, todos os pixels em uma imagem (CHOLLET, 2018).

#### 2.4.2. Aprendizado por transferência

Para Zhang (2011), à medida que novas tarefas complexas de classificação surgem, muitas vezes precisamos de um grande número de amostras para treinamento a fim de obter um bom desempenho de classificação. Para as pessoas, quanto mais uma nova tarefa estiver relacionada à uma experiência anterior, mais facilmente ela será dominada. De forma a imitar esse tipo de aprendizado, a técnica Aprendizado por Transferência (do inglês *Transfer Learning*, TL) representa o progresso no sentido de tornar o Aprendizado de Máquina (do inglês *Machine Learning*, ML) tão eficiente quanto o aprendizado humano (TORREY e SHAVLIK, 2009).

O TL é um método de ML no qual um modelo desenvolvido para uma tarefa é reutilizado como ponto de partida para um modelo em uma segunda tarefa (BROWNLEE, 2017). Para Goodfellow *et al.* (2016), TL refere-se à situação em que aquilo que foi aprendido em um ambiente é explorado para melhorar a generalização em outro ambiente. A Figura 2.19 apresenta três motivos pelos quais a TL pode melhorar o aprendizado: desempenho superior no início do aprendizado, uma inclinação mais acentuada na curva de aprendizado e desempenho assintótico superior.

Outra técnica que pode ser utilizada para melhorar o desempenho da ANN é conhecida




Figura 2.19: Comparação dos desempenhos de uma rede neural com e sem aprendizado por transferência.

Fonte: Adaptado de Torrey e Shavlik (2009).

como Aumento de Conjunto de Dados (do inglês *Dataset Augmentation*, DA). Esta metodologia é utilizada quando o conjunto de dados é restrito e, por isso, adicionam-se dados sintéticos ao teste de treinamento. Essa abordagem é eficaz, principalmente, para o problema de reconhecimento de objetos (GOODFELLOW *et al.*, 2016).

### 2.4.3. Mapas de ativação de classe

A maioria das CNNs é treinada com rótulos a nível da imagem, de forma que as camadas convolucionais aprendem representações hierárquicas para tomar suas decisões de classificação (BUDUMA e LOCASCIO, 2017). No entanto, trabalhos recentes, como Bazzani *et al.* (2016), mostram que as CNNs têm a capacidade de localizar objetos nas imagens sem informações prévias.

Para aprender recursos profundos para localização discriminativa, Zhou *et al.* (2016) propuseram uma técnica para gerar Mapas de Ativação de Classe (do inglês *Class Activation Mapping*, CAM) utilizando o Agrupamento Médio Global (do inglês *Global Average Pooling*, GAP) na CNN (Figura 2.20). O CAM permite a visualização das pontuações e pesos de classe previstas em qualquer imagem, destacando as partes discriminativas dos objetos detectadas pelo modelo da CNN. O CAM da classe  $c$  é fornecido por:

$$M_c(x, y) = \sum_k w_k^c f_k(x, y) \quad (2.1)$$

os quais:  $w_k^c$  é o peso correspondente à classe  $c$  para a unidade  $k$ , e  $f_k(x, y)$  que representa a ativação da unidade  $k$  na última camada convolucional no local espacial  $(x, y)$ . Esses valores são obtidos projetando de volta os pesos da camada de saída nos mapas de recursos convolucionais.

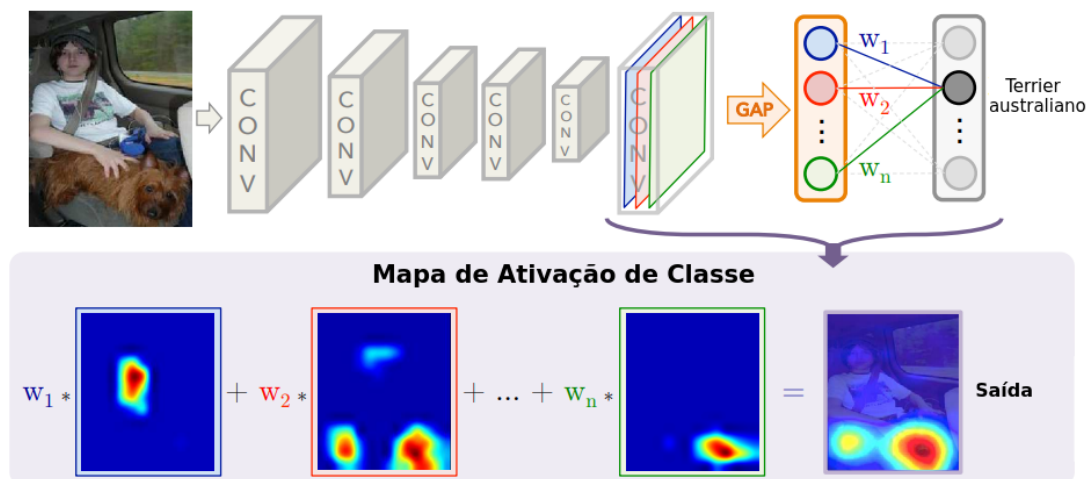


Figura 2.20: Exemplo de uma saída por mapas de ativação de classe.

Fonte: Adaptado de Zhou *et al.* (2016).

#### 2.4.4. Rede neural convolucional de disparo único

Para sistemas de detecção de objetos em tempo real, a rede *You Only Look Once* (YOLO) é considerada o estado da arte por ser mais rápida e precisa quando comparado aos outros sistemas (REDMON e FARHADI, 2020). A YOLO é uma Rede Neural Convolutiva de Disparo Único (do inglês *Single Shot Detector*, SSD) baseada em uma única rede neural que divide a imagem em regiões e prevê caixas delimitadoras e probabilidades para cada região (LIANQIAO *et al.*, 2019) (Figura 2.21). A detecção de objetos é reformulada como um único problema de regressão diretamente dos pixels da imagem para as coordenadas da caixa delimitadora e as probabilidades da classe (REDMON *et al.*, 2016).

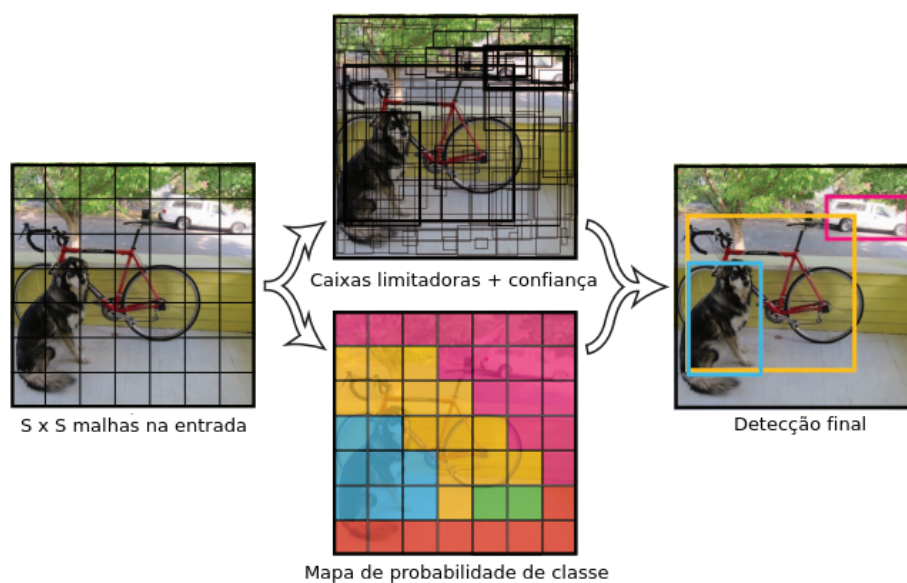


Figura 2.21: Predição com YOLO.

Fonte: Adaptado de Redmon *et al.* (2016).

A YOLOv3, que é uma das versões mais recentes do sistema, possui 53 camadas convolucionais, sendo capaz de prever em três dimensões: caixa delimitadora, objetividade e previsões de classe. A rede consegue obter informações mais significativas a partir da reutilização dos mapas de informações de iterações anteriores, aplicando a elas blocos residuais de convolução. Esta operação é realizada de maneira rápida e precisa (REDMON e FARHADI, 2020; REDMON *et al.*, 2016).

Para medir a eficácia da detecção na YOLO, a Precisão Média Ponderada (do inglês *mean Average Precision*, mAP) é usada como indicador, o qual representa um valor médio na curva de precisão (do inglês *recall*) calculada sobre o conjunto analisado (KHARCHENKO e CHYRKA, 2018).

## **2.5. Considerações sobre os Referenciais Teóricos**

Neste Capítulo foram introduzidos conceitos teóricos a respeito dos estudos de caso que são abordados neste trabalho. A Seção 2.1 apresentou o conceito de robótica móvel, introduziu as definições de robôs aéreos e terrestres, e descreveu os dispositivos utilizados neste trabalho. A Seção 2.2 apresentou tecnologias que auxiliam no desenvolvimento de prototipagem rápida: impressoras 3D e microcontroladores, que em conjunto foram a base do desenvolvimento do estudo de caso de Dispersão de Etiquetas Eletrônicas. A Seção 2.3 abordou os conceitos básicos para o entendimento de reconstruções 3D. Foram explicados os formatos de arquivos com informações 3D, os modelos para representação de ambientes e, por fim, os métodos para efetuar uma reconstrução. Esses conceitos são importantes no entendimento do estudo de caso da Investigação em Fotogrametria. A Seção 2.4 apresentou os conceitos necessários para o entendimento do sistema desenvolvido no estudo de caso de Inspeção Automatizada de Dutos. Foram abordados os conceitos de redes neurais artificiais, redes neurais convolucionais, aprendizado por transferência, mapas de ativação de classe e redes neurais convolucionais de disparo único.

### 3. ROBÔS AÉREOS PARA DISPERSÃO DE ETIQUETAS ELETRÔNICAS DE RASTREAMENTO DE MINÉRIO

Este Capítulo apresenta uma proposta de desenvolvimento e avaliação em campo de um sistema de hardware e software para melhorar o controle de rastreabilidade do minério de cobre na Mina do Salobo (Marabá - PA) através do lançamento de etiquetas eletrônicas de Identificação por Radiofrequência (do inglês *Radio Frequency Identification*, RFID). São descritos, também, os resultados apresentados no relatório técnico: *Relatório de experimentos de campo na Mina do Salobo* (RESENDE FILHO *et al.*, 2020) e no pedido de patente de invenção: *Dispositivo e método para lançamento de etiquetas eletrônicas sobre rocha desmontada a partir de um veículo aéreo não tripulado* (RESENDE FILHO *et al.*, 2021), frutos de trabalhos em colaboração com os coautores indicados nos documentos citados. Este Capítulo, diferentemente dos demais capítulos dessa dissertação, possui viés de inovação tecnológica, portanto, em seu decorrer são descritos o protótipo desenvolvido e a metodologia de operacionalização da atividade.

Salobo é o segundo projeto de cobre desenvolvido pela Vale no Brasil. A mina está localizada em Marabá, sudeste paraense, e entrou em operação em novembro de 2012. O empreendimento tem capacidade nominal estimada de 100 mil toneladas anuais de cobre em concentrado (VALE, 2020).

Em termos gerais, o fluxo de produção (Figura 3.1) de cobre em Salobo pode ser descrito em: o minério é lavrado e transportado por caminhões fora-de-estrada até a britagem, onde tem o seu tamanho reduzido. Em seguida, esse minério chega ao *roller press*, um equipamento formado por dois rolos que giram em sentidos opostos, fragmentando o produto graças à ação de rotação e pressão do equipamento. Logo após, o minério passa por moinhos e uma bateria de ciclones até chegar às áreas de flotação e filtragem, etapa final do processo que resulta em um concentrado que varia de 36% a 40% de cobre (VALE, 2020). Dentre esses processos, um dos mais importantes da cadeia de produção do cobre é a flotação, devido ao seu impacto direto na concentração de saída. Segundo os relatórios gerenciais de produção da planta, o minério de cobre em Salobo é extraído com um teor médio de 0,8% e, ao final do processo do beneficiamento, seu teor aumenta entre 45 e 50 vezes.

Para garantir que o processo de flotação atinja o teor adequado, é crucial que se conheça a composição química do minério de entrada, assim como é importante que se faça a escolha adequada dos reagentes do processo. Quaisquer variações inesperadas podem impactar na eficiência do beneficiamento, resultando em um concentrado com teor inferior ao esperado. Ressalta-se, ainda, que o minério de cobre extraído em Salobo contém grande presença de substâncias deletérias, contaminantes presentes no sulfeto, e estas, por sua vez, representam um risco no processo de flotação.

Visando minimizar esse risco de processo, foi proposto pelo Departamento de Operações Cobre Norte o rastreamento do fluxo de massa de cada polígono alimentado no britador, de

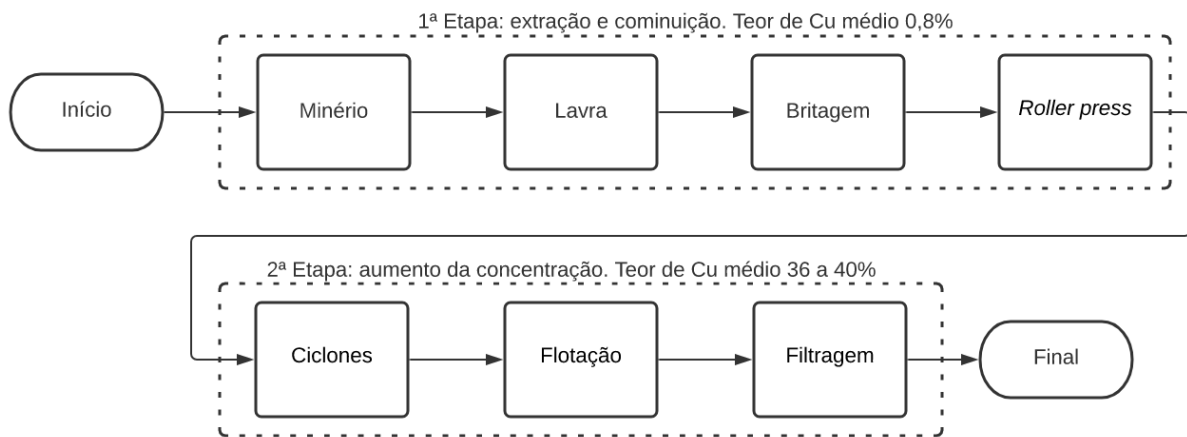


Figura 3.1: Fluxo de produção de Salobo.

Fonte: O autor.

forma a permitir a antecipação de ajustes na flotação antes da entrada do minério no processo, garantindo que o produto seja concentrado no teor desejado. Para o rastreamento, foi proposta a utilização de etiquetas eletrônicas RFIDs Dienamics (Metso, Helsinque) apresentadas na Figura 3.2. Nas etiquetas são carregadas um código identificador, o qual contém as relações de composições químicas para cada região dentro do polígono.



Figura 3.2: Exemplo das etiquetas eletrônicas Dienamics.

Fonte: Serisier (2020).

Inicialmente, as etiquetas RFID eram colocadas nas regiões de interesse antes mesmo da detonação. Contudo, observou-se que grande parte delas, cerca de 75 a 80%, era destruída no momento da explosão. Em seguida, foi proposta a colocação das etiquetas pós detonação de forma manual, com um funcionário se deslocando na região do detonado e deixando os dispositivos manualmente. Esta última atividade foi suspensa após serem detectados riscos de acidentes.

Neste contexto, viu-se a oportunidade de realizar esta atividade com o auxílio de RPA. Uma RPA pode sobrevoar a região do detonado e lançar as etiquetas sem expor funcionários. Portanto, este trabalho consiste em desenvolver um dispositivo para armazenamento das etiquetas eletrônicas, controlado remotamente, e que seja anexo a uma RPA, substituindo a atividade

que hoje é manual. Além de desenvolver o dispositivo, espera-se deste trabalho definir a metodologia de operação da RPA, garantindo que esta atividade seja realizada com segurança e eficiência.

### 3.1. Trabalhos relacionados

Segundo Tang e Shao (2015), a disponibilidade de RPAs com múltiplos tamanhos, formatos e aplicações aumentou significativamente nas últimas décadas, assim como seu uso se popularizou para civis. As RPAs têm, principalmente, substituído aplicações de sensoriamento remoto que no passado eram feitas por satélites e pequenos aviões, tais como: pesquisas em florestas, mapeamento de lacunas dossel, fotogrametrias, rastreamento de queimadas e desmatamento.

Nas áreas de ecologia e agricultura, consideradas uma das precursoras na utilização de RPAs, atividades mais complexas têm sido desenvolvidas. Por exemplo, Freitas *et al.* (2020b) apresentam metodologia que utilizam RPAs como uma plataforma de apoio ao controle biológico de pragas. Neste caso, o RPA é responsável por fazer uma varredura em áreas de diversos formatos, lançando cápsulas com inimigos naturais em pontos estratégicos. O uso do RPA proporcionou maior eficiência no controle de pragas e economia na utilização das cápsulas.

Existem estudos com a aplicação de RPAs também no setor da mineração. Lee e Choi (2016) apresentam o conjunto de aplicações desenvolvidas subdividindo-as em pesquisas de mineração, operação, perfuração e detonação, segurança, construção e outras, demonstrando que as RPAs estão se tornando cada vez mais utilizadas também nesse ramo. Shahmoradi *et al.* (2020) apresentam uma classificação para as aplicações de RPAs, subdividindo-as em três grandes áreas: minas a céu aberto, minas subterrâneas e minas abandonadas. Em seguida, os autores apresentam as RPAs e sensores embarcados mais adequados para cada tipo de operação, bem como os desafios associados à operação na mineração, tais como poeira, umidade, luminosidade, entre outros.

Nascimento *et al.* (2017) apresentam um exemplo de RPA aplicado à inspeção de transportadores de correia. Graças à extensão dos transportadores de correia e o grande impacto que eles têm na cadeia produtiva do minério, os autores propuseram realizar a inspeção de forma automatizada, embarcando alguns sensores em uma RPA que, por sua vez, voaria sobre a correia para monitorá-la e encontrar defeitos.

Azpúrua *et al.* (2019) apresentam um desenvolvimento aplicado que utiliza RPA para criar mapas digitais de elevação magnética, com o objetivo de detectar corpos metálicos soterrados, ou até mesmo para investigação mineral. Os mapas são obtidos a partir de voos autônomos e cooperativos entre diferentes dispositivos. A metodologia proposta em comparação com métodos tradicionais (feitos em aeronaves tripuladas) é mais barata e menos perigosa.

Neste trabalho, é proposto o desenvolvimento de um dispositivo para armazenamento de etiquetas eletrônicas RFID que seja acoplado a uma RPA capaz sobrevoar os materiais detona-



dos e de lançá-las em locais específicos. A realização desta atividade garante maior estabilidade do processo de flotação da Usina do Salobo, bem como a eliminação de uma atividade com risco de acidentes.

## 3.2. Desenvolvimento do protótipo

O desenvolvimento do protótipo pode ser dividido em duas partes: criação da estrutura mecânica do lançador de etiquetas eletrônicas e a implementação da eletrônica neste. É importante ressaltar que o protótipo foi projetado para ser uma prova de conceito. A Figura 3.3 apresenta visão geral da estrutura proposta. Nas Subseções a seguir são apresentados mais informações a respeito dos componentes utilizados e das etapas de desenvolvimento.

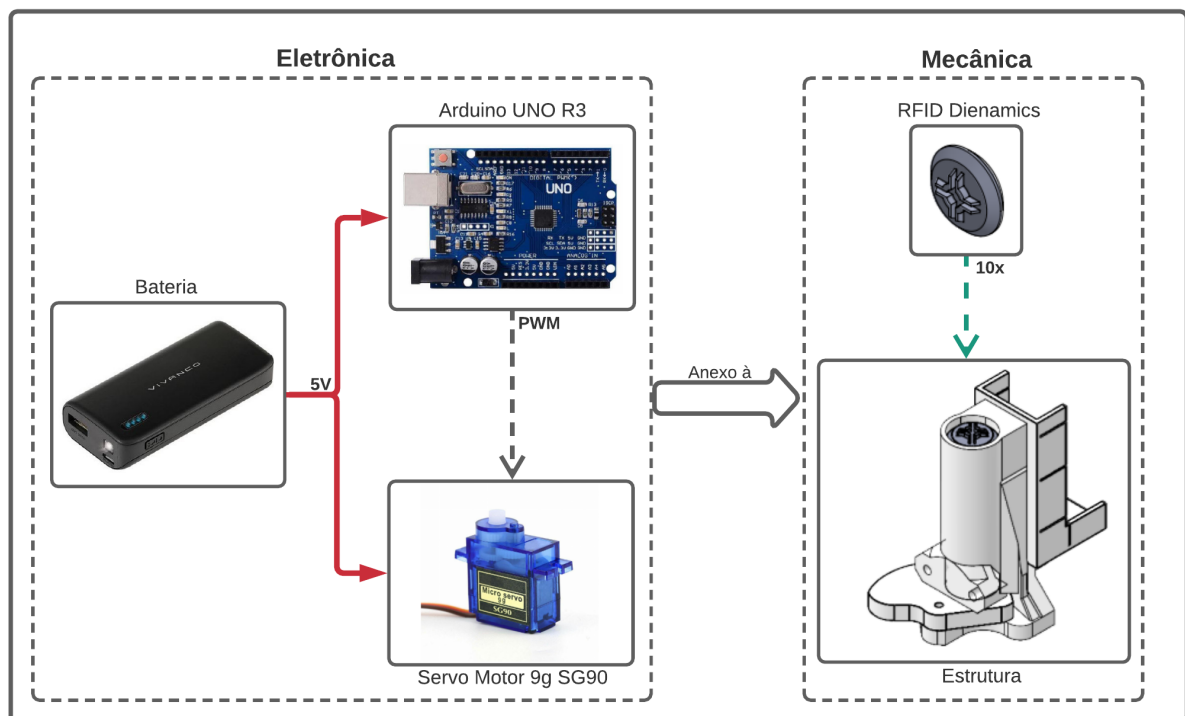


Figura 3.3: Visão geral do protótipo desenvolvido.

Fonte: O autor.

### 3.2.1. Estrutura mecânica

A estrutura mecânica foi desenvolvida nos laboratórios do Instituto Tecnológico Vale (ITV). Os requisitos de projeto para esta etapa foram: ter a capacidade de voar com 10 etiquetas eletrônicas e ser o mais leve possível para ser embarcada em um drone.

Como as etiquetas eletrônicas apresentam formato de um disco, optou-se por desenvolver um reservatório com formato de um cilindro, pois este formato permite que as etiquetas sejam empilhadas. Na parte inferior do cilindro foi instalada uma junta rotativa, que ao ser movimentada possibilita o lançamento de uma etiqueta por vez. Além disso, foi desenvolvida uma

peça para acoplar este cilindro com as etiquetas eletrônicas ao drone. A Figura 3.4 apresenta as visões isométricas da estrutura. No Apêndice A - Figura A1 são expostas todas visões e dimensões da estrutura mecânica.




Figura 3.4: Projeto do lançador de etiquetas eletrônicas.

Fonte: Adaptado de acervo ITV.

Após finalizado o projeto, a peça foi impressa em náilon por uma impressora 3D e acoplada ao Inspire 1, RPA descrita na Subseção 2.1.3 e apresentada na Figura 2.3. Este drone foi selecionado devido a sua capacidade de voar com cargas externas e por ser o mais robusto dentre os disponíveis no ITV. A Figura 3.5 demonstra o lançador de etiquetas acoplado a parte traseira do Inspire 1, bem como, indica os locais de entrada e saída das etiquetas.




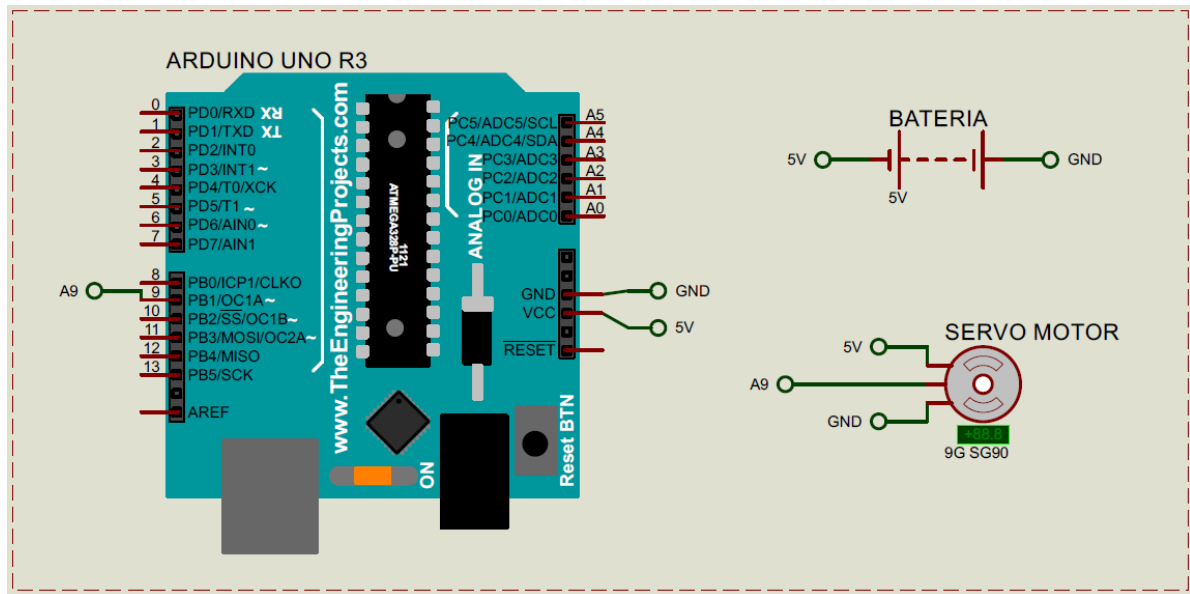
Figura 3.5: Lançador de etiquetas acoplado a traseira do Inspire 1.

Fonte: O autor.


### 3.2.2. Desenvolvimento e implementação da eletrônica

A implementação da eletrônica tem como objetivo promover a movimentação da parte inferior do lançador de etiquetas, permitindo que estas sejam disparadas sempre que necessário.

Como forma de estabelecer a prova de conceito para o desenvolvimento, priorizou-se a aplicação de um acionamento simples. Neste módulo eletrônico foram utilizados uma placa Arduino UNO R3 (Arduino, Somerville) e um servo motor, modelo 9g SG90 (TowerPro, Ponte Vedra), ambos alimentados por uma bateria portátil, que fornece 5 V de tensão e 1 A de corrente. A Figura 3.6a apresenta diagrama elétrico do protótipo e a Figura 3.6b apresenta o módulo eletrônico acoplado ao drone.



(a) Diagrama elétrico do protótipo desenvolvido



(b) Módulo eletrônico acoplado ao drone

Figura 3.6: Implementação eletrônica do dispersor de etiquetas eletrônicas.

Fonte: O autor.

O movimento do lançador, a princípio, foi programado para ser repetido a cada 20 segundos, tempo considerado suficiente para que o drone se desloque entre as posições de interesse.

### 3.3. Validações do dispositivo

Esta Seção apresenta os procedimentos realizados durante os testes e validações do dispositivo lançador de etiquetas.

#### 3.3.1. Validações em ambiente representativo

Inicialmente, foram realizados testes em um ambiente representativo para analisar o comportamento do drone, tanto em voos manuais, como em voos automatizados, após embarcar o protótipo com os seus itens.

Primeiramente, voou-se o drone em manual, a fim de analisar a sua estabilidade estática e dinâmica, isto é, foi verificado se o Inspire 1 conseguiria se manter parado quando estivesse pairando e se sua manobrabilidade se manteria ao realizar movimentos no ar. Para esta validação, os voos foram realizados em Ouro Preto em um campo aberto. A Figura 3.7 apresenta local de voo e destaque amarelo no drone durante voo. A RPA não apresentou dificuldades para voar com o carregamento.



Figura 3.7: Validação em ambiente representativo.

Fonte: O autor.

Em seguida, voos automatizados em modo *waypoint* foram realizados. Nesta modalidade, o drone voa sobre uma área parando em alguns pontos-chaves, os quais foram escolhidos de forma a simular um polígono de detonação. A programação da rota foi feita através do software Litchi<sup>1</sup>. Estes testes também foram bem sucedidos, validando a operação do drone na mina.

Com o sucesso dos voos manuais e automatizados no ambiente representativo foi possível obter 5 no Nível de Maturidade Tecnológica (do inglês *Technology Readiness Level*, TRL) proposto pela Empresa Brasileira de Pesquisa e Inovação Industrial (EMBRAPII)<sup>2</sup>.

<sup>1</sup><https://flylitchi.com/>

<sup>2</sup>[https://embrapii.org.br/wp-content/images/2019/05/0705\\_Orientacao\\_Operacional.02-19.pdf](https://embrapii.org.br/wp-content/images/2019/05/0705_Orientacao_Operacional.02-19.pdf)

### 3.3.2. Validações em ambiente de mina

A validação em ambiente de mina foi realizada na Mina do Salobo. No primeiro momento, seguiu-se a mesma metodologia dos testes realizados previamente com a execução de voos manuais e em seguida voos automatizados em modo *waypoint*, programados pelo software Litchi.

Devido à grande diferença entre os ambiente e aos riscos da operação em ambiente de mina, as validações na Mina do Salobo foram divididas em duas etapas: i) revalidação do dispositivo lançador de etiquetas em voo sobre área aberta e ii) voo sobre materiais detonados.

#### 3.3.2.1. Revalidação do dispositivo lançador de etiquetas

A revalidação em área aberta foi realizada para garantir que tudo estaria funcionando conforme os testes e validações anteriores. Para a execução desta atividade, seguiu-se a mesma metodologia dos testes anteriores: voos manuais seguidos de voos automatizados em modo *waypoint*.

No voo manual (Figura 3.8) o drone não apresentou nenhum problema com relação a sua estabilidade dinâmica, permitindo a execução do voo automatizado. Ao iniciar o voo programado, observou-se uma variação entre as coordenadas do GPS fornecido pela equipe de topografia da mina com as coordenadas do GPS do drone. Essa diferença é explicada pelo fato dos sistemas de coordenadas utilizados serem diferentes, enquanto a mina utiliza o sistema de GPS com Posicionamento Cinemático em Tempo Real (do inglês *Real Time Kinematic*, RTK), o drone utiliza o GPS convencional. Como os sistemas RTK são mais precisos, precisão na ordem de centímetros, eles foram adotados como referência.



Figura 3.8: Revalidação do dispositivo lançador de etiquetas em campo aberto. Caixa amarela apresentando foco no drone em voo.

Fonte: O autor.

Portanto, para dar sequência aos testes, foi necessário analisar a diferença entre os sistemas de coordenadas do GPS da mina e da RPA. Para tal, foram comparadas coordenadas entre

os dois sistemas, conforme pode ser verificado na Tabela 3.1.

Tabela 3.1: Diferença de posição entre os sistemas de coordenadas da mina e do drone.

Ponto medido	Drone		RTK		Diferença	
	Latitude [m]	Longitude [m]	Latitude [m]	Longitude [m]	Latitude [m]	Longitude [m]
1	551.953	9.360.704	552.007,432	9.360.735,578	54,432	31,578
2	551.956	9.360.705	552.010,647	9.360.735,890	54,647	30,890
3	551.959	9.360.705	552.013,436	9.360.736,162	54,436	31,162
4	551.963	9.360.706	552.017,626	9.360.736,595	54,626	30,595
5	551.967	9.360.707	552.021,786	9.360.737,001	54,786	30,001
6	551.971	9.360.708	552.026,000	9.360.737,412	55,000	29,412
7	551.975	9.360.707	552.030,058	9.360.737,848	55,058	30,848

Fonte: O autor.

A partir dos valores da Tabela 3.1, nota-se um padrão no erro entre os sistemas de coordenadas. Os valores obtidos para a diferença tanto da latitude como da longitude podem ser caracterizados como erros sistemáticos, uma vez que estes dados apresentam baixa dispersão. Para atuar na correção do erro, calculou-se os valores médios da diferença para a latitude e longitude, que foram, respectivamente,  $54,712 \pm 0,249$  m e  $30,641 \pm 0,727$  m. Na sequência, os valores médios das diferenças foram somados para cada par de coordenadas da RPA, a fim de minimizar o impacto do erro com o GPS RTK.

Em seguida, foi realizado um teste em campo aberto para analisar as correções efetuadas. No teste observou-se que o erro de posicionamento do GPS da RPA com relação as coordenadas do GPS RTK reduziu consideravelmente, atingindo valores médios inferiores a 1 m de raio, validando o voo automatizado na mina. Ainda neste teste, avaliou-se a área de dispersão que a etiqueta eletrônica atingia ao ser lançada, variando-se a altura. Foram testadas as alturas de 5, 10 e 15 m e observou-se, para todas alturas, que o raio de dispersão foi inferior a 50 cm. Segundo a equipe técnica responsável pela mineralogia da Mina do Salobo, o minério de cobre apresenta características semelhantes em um raio de até 2 m e, portanto, um raio de dispersão apresentado nas alturas analisadas atendem as necessidades para o rastreamento do minério. Após estas constatações, a revalidação foi considerada como concluída, habilitando a RPA para a execução de voos sobre material detonado.

### 3.3.2.2. Voo sobre material detonado

A realização do voo sobre materiais detonados é a etapa mais importante neste processo, pois ela é responsável pela validação desta prova de conceito e também pela definição de parâmetros de operacionalização.

Para a criação da rota de voo, foi realizada uma visita às pilhas de materiais detonados (Figura 3.9a). Durante a visita, observou-se que o pico do material detonado atinge, no máximo, a altura de 15 m, portanto, por questões de segurança adotou-se voar 10 m acima do material



detonado, ou seja, a 25 m de altura. Para cobrir toda a área do polígono (aproximadamente 2500 m<sup>2</sup>) e garantir a rastreabilidade do minério, a distância dos *waypoints* foi configurada para 20 m. Por fim, a velocidade de voo foi ajustada para 3 m/s de forma a manter a estabilidade dinâmica da RPA. Considerando a distância entre os pontos-chaves e a velocidade configurada, a RPA pode executar a rota em tempos inferiores a 4 minutos. Em seguida, o plano de voo (Figura 3.9b) foi configurado considerando estes parâmetros.

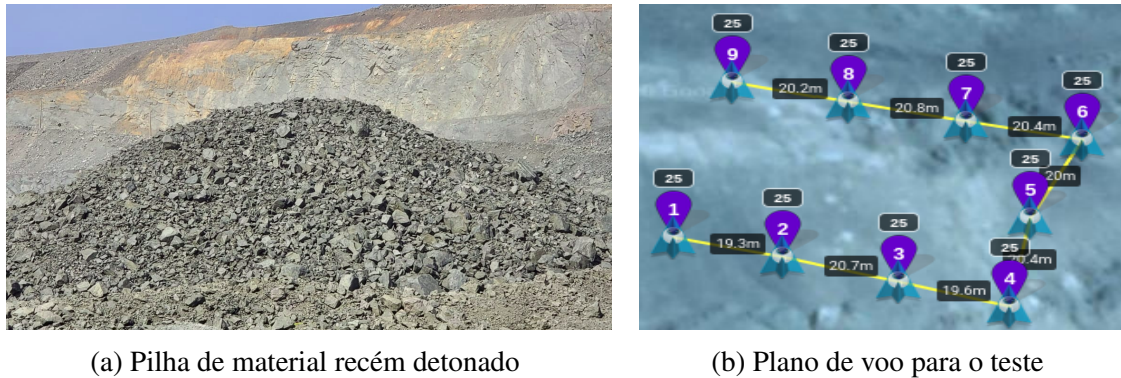


Figura 3.9: Visita à área da mina e criação de rota.

Fonte: O autor.

Antes da realização do voo automatizado, um voo em modo manual foi realizado para se analisar o comportamento do drone dentro da mina. Observou-se neste teste que o magnetômetro do drone estava instável devido à grande interferência eletromagnética do minério de cobre, que é um material ferromagnético.

Tendo ciência desta condição, considerou-se realizar o voo em modo automático, quando a medida do magnetômetro estabilizasse. Porém, caso algum distúrbio, tal como instabilidade durante o voo, perda de rota ou intermitência do sinal de comunicação fosse detectado, a RPA teria o seu modo de voo alterado para manual e os testes seriam abortados.

Sendo assim, a rota foi transferida à RPA. Apesar das interferências eletromagnéticas, o voo automatizado (Figura 3.10) foi realizado com sucesso. A atividade foi repetida mais três vezes para garantir robustez e validar os padrões estipulados. Uma vez que a atividade obteve êxito em sua realização, o protótipo desenvolvido atingiu o nível 7 na escala TRL ao atuar em ambientes operacionais.

### 3.4. Considerações sobre a Dispersão de Etiquetas Eletrônicas

A partir da necessidade de manter o processo de flotação estável, foi observado que a realização da rastreabilidade da composição do minério desde o processo de desmonte poderia ter papel determinante. Tal atividade já havia passado por duas metodologias diferentes, uma que perdia as etiquetas no desmonte e outra que gerava condições inseguras aos funcionários.

Neste contexto, foi sugerida a realização do lançamento das etiquetas via RPA. O desenvolvimento foi realizado em duas etapas: i) criação do protótipo e testes em ambiente repre-



Figura 3.10: Voo automatizado sobre material detonado. Caixa amarela apresentando foco no drone em voo.

Fonte: O autor.

sentativo e ii) validação em área, na Mina do Salobo, bem como a definição de parâmetros para operacionalização. As sequências de testes permitiram a realização da prova de conceito: foi possível validar a execução desta atividade por RPA com dispositivo desenvolvido e, também, foi feita a definição de parâmetros de trabalho (altura de 25 m, distância dos *waypoints* de 20 m e velocidade de 3 m/s).

Por fim, com os resultados obtidos foi possível atingir o nível 7 da escala TRL e além disso foi possível solicitar um pedido de patente de invenção para o protótipo e metodologia desenvolvidos neste trabalho.

### 3.5. Trabalhos futuros

Como trabalhos futuros, são sugeridos:

- Embarcar outros sensores no protótipo desenvolvido como acelerômetros, giroscópios ou IMU para automatizar o gatilho do dispersor de etiquetas eletrônicas por meio de um movimento pré-programado sempre que a RPA estiver na posição de interesse.
- Utilização de modelos de RPA com GPS RTK, pois assim é possível eliminar o *offset* de coordenadas realizado no planejamento da rota e, caso o magnetômetro apresente algum defeito ou ruído, a RPA pode manter seu referencial no GPS com precisão de posicionamento na ordem de centímetros.
- Integração do Kit de Desenvolvimento de Software (do inglês *Software Development Kit*, SDK) da DJI. Assim, o gatilho do dispositivo dispersor de etiquetas deve ser realizado



de forma diferente e a rota pode ser feita de forma manual. Com a integração do SDK pode-se configurar um botão do controle da RPA para efetuar o gatilho do servo motor, de forma que, sempre que o botão for pressionado, uma etiqueta deva ser lançada. Ainda na configuração deste botão, deve-se salvar as coordenadas do GPS da RPA sempre que ele for pressionado, garantindo a rastreabilidade do local. Aconselha-se a utilização de uma RPA que possua GPS RTK para minimizar o erro de posição entre os sistemas de coordenadas. Em termos operacionais, a execução desta atividade promove mais flexibilidade e apresenta uma redução no tempo em comparação com a metodologia demonstrada anteriormente, pois as distâncias entre os pontos para o lançamento de etiquetas não precisam ser fixas e nem sequer em função do tempo.

## 4. INVESTIGAÇÃO EM FOTOGRAMETRIA PARA A RECONSTRUÇÃO 3D DE AMBIENTES NA MINERAÇÃO


Este Capítulo apresenta a investigação desenvolvida no método da fotogrametria para a execução de reconstrução 3D em ambientes hostis, tais como cavernas, galerias e espaços confinados aplicados à mineração. São descritos, também, os resultados apresentados no resumo: *Investigation on Photogrammetry and LiDAR Models for Caves/Mines 3D Reconstruction* (RESENDE FILHO *et al.*, 2019), no relatório técnico: *Dispositivo robótico para inspeção de ambientes restritos e confinados* (FREITAS *et al.*, 2020a) e no artigo de período: *Towards semi-autonomous robotic inspection and mapping in confined spaces with the Espeleo-Robô* (AZPÚRUA *et al.*, 2021), frutos de trabalhos em colaboração com os coautores indicados nos documentos citados.

Devido à necessidade de adequar às normas ambientais de Legislação de Proteção ao Patrimônio Cultural Nacional e Ambiental por meio do Decreto<sup>1</sup> n° 99.556 de 01/10/1990, à Portaria<sup>2</sup> do Instituto Brasileiro do Meio Ambiente (IBAMA) n° 887/90 de 15/06/1990, às resoluções do Conselho Nacional do Meio Ambiente (CONAMA) e à necessidade de buscar maior eficiência no processo de extração, as mineradoras estão procurando determinar se um local pode ser explorado ou não utilizando as técnicas de espeleologia. Entende-se espeleologia como a ciência que realiza estudos das cavidades naturais quanto à sua origem e evolução, ao meio físico que elas representam, ao seu ecossistema atual ou passado e aos meios e técnicas que são próprias do seu estudo (MONTEIRO, 2011).

Contudo, a realização do estudo de espeleologia em cavernas e dutos nem sempre é uma tarefa fácil, deixando o responsável pela atividade exposto a riscos ergonômicos, físicos, biológicos e até químicos (gases), conforme pode ser observado na Figura 4.1.



(a) Espeleólogo em ambiente de difícil acesso



(b) Caverna com a presença de morcegos

Figura 4.1: Ambientes típicos para a realização da espeleologia.

Fonte: (a) Figueiroa (2004), (b) Costa (2012).


<sup>1</sup>[http://www.planalto.gov.br/ccivil\\_03/decreto/1990-1994/D99556.htm](http://www.planalto.gov.br/ccivil_03/decreto/1990-1994/D99556.htm)

<sup>2</sup><https://www.ibama.gov.br/component/legislacao/?view=legislacao&legislacao=94232>

Nos últimos anos, graças aos avanços tecnológicos, uma alternativa que tem sido adotada para realização de tarefas que podem ser nocivas às pessoas, é fazê-la com a aplicação de robôs móveis. Robôs móveis são dispositivos teleoperados, semi ou completamente autônomos, desenvolvidos para atividades específicas em que a mobilidade é necessária (COTA, 2019). Seguindo essa tendência, a Vale, em 2014, adquiriu seu primeiro robô móvel para realizar espeleologia, o EspeleoRobô, que foi descrito na Subseção 2.1.4 e apresentado nas Figuras 1.5 e 2.5. Não restrito apenas a espeleologia, este robô é também utilizado em inspeções em espaços confinados, conforme pode ser verificado na Figura 4.2.



(a) Inspeção de tubulação da barragem de água da Mina do Fazendão



(b) Inspeção em moinho de bolas na Usina Conceição 2

Figura 4.2: EspeleoRobô em trabalhos de campo.

Fonte: Acervo ITV.

Para que a espeleologia do local de interesse seja realizada, é necessário, primeiramente, que o ambiente seja modelado, de forma a obter a sua reconstrução 3D. O estudo e a reconstrução 3D de superfícies e objetos, por sua vez, podem ser realizados utilizando diferentes tipos de sensores, cada um com um método específico.

Neste contexto, surge a necessidade de se investigar uma metodologia para se realizar a reconstrução 3D de um ambiente hostil, como cavernas e minas subterrâneas, utilizando as técnicas de fotogrametria a partir do EspeleoRobô ou até mesmo outras plataformas móveis.

## 4.1. Trabalhos relacionados

Thrun *et al.* (2004) apresentam o GroundHog, um robô utilizado para a exploração e mapeamento de minas abandonadas de forma autônoma. O robô, que pesa 680 kg, é equipado

com computador embarcado, LiDAR, sensores a gás e de afundamento e câmeras. Os autores apresentam as técnicas e os desafios para realizar o mapeamento e localização simultaneamente.

Li *et al.* (2020) apresentam o desenvolvimento do CUMT-B, um robô utilizado para aplicações de resgate em minas de carvão na China. Este robô apresenta câmeras, sensores de gases, microfones e alto falante, que o permitem analisar o ambiente e comunicar com pessoas, caso necessário. Além disso, o CUMT-B pode-se deslocar até 7 km, a uma velocidade máxima de 1,3 m/s e com inclinação máxima de 32°.

Não restrito apenas a robôs terrestres, Freire e Cota (2017) apresentam alternativas para acessar e obter informações dentro de minas subterrâneas utilizando RPAs. Nesta produção, os autores demonstram as operações com um drone e com um balão a gás e afirmam ser possível manusear os equipamentos mesmo sem o uso de GPS, desde que eles estejam em visada direta e haja iluminação.

Mascarich *et al.* (2018) demonstram uma aplicação utilizando uma RPA equipada com uma Unidade Multi Modal de Mapeamento (do inglês *Multi-Modal Mapping Unit*), que consiste de dois leds ultra claros, uma unidade inercial de medida, um par estéreo de câmeras e um sensor de profundidade. Com este sistema, os autores mostram que é possível fazer missões autônomas e mapeamentos de ambientes fechados.

Nesse contexto, a Agência de Projetos de Pesquisa Avançada de Defesa (do inglês *Defense Advanced Research Projects Agency*, DARPA) propôs o DARPA *Subterranean* ou “*SubT*” *Challenge*, que busca novas abordagens para mapear, navegar e pesquisar ambientes subterrâneos e de difícil acesso, uma vez que trabalhar nesses locais sempre foi considerado uma atividade desafiadora, tanto para aplicações militares, como para civis. Variando-se a complexidade do ambiente, diferentes tipos de perigos e dificuldades podem estar presentes (DARPA, 2020).

Dessa forma, o objetivo deste trabalho é investigar um método de fotogrametria para a realização de reconstrução 3D em ambientes subterrâneos e com pouca iluminação, definindo uma metodologia que apresente resultados satisfatórios, que permitam extrair informações e dar suporte na tomada de decisões. Além disso, deseja-se comparar a fotogrametria com outros métodos ativos, LiDAR-SLAM e Visual-SLAM, a fim de validar o quão precisos foram os resultados obtidos por ela.

## 4.2. Metodologia

Esta Seção apresenta os procedimentos executados para a definição da metodologia utilizada na fotogrametria para os ambientes definidos pelo escopo deste trabalho.



### 4.2.1. Análise de software para realização da fotogrametria

A investigação na realização da reconstrução 3D a partir da fotogrametria iniciou-se pela definição de um software. Neste aspecto, foram selecionados cinco softwares que fossem *open source*, para iniciar os trabalhos. A Tabela 4.1 apresenta os softwares selecionados para a análise, bem como algumas de suas características.

Tabela 4.1: Lista de softwares selecionados para análise de fotogrametria e algumas de suas características.


Software	Versão	Nuvem de pontos	Nuvem densa	Superfície	Textura
OpenSfM	v0.2.0	Sim	Sim	Não	Não
AliceVision - Meshroom	2019.2.0	Sim	Sim	Sim	Sim
COLMAP	3.6-dev.2	Sim	Sim	Sim	Não
Mesh Reconstruction Software	1.0	Não	Não	Sim	Não
Meshlab	20190129-beta	Não	Não	Sim	Sim

Fonte: O autor.

Em seguida, para cada um deles, foram realizadas três reconstruções 3D de ambientes internos e estruturados com 30, 40 e 50 fotos. Nessas reconstruções, comparou-se o tempo necessário para o processamento e também a sua qualidade. A qualidade, nesse momento, foi analisada de forma qualitativa: avaliou-se a representatividade do ambiente e a presença de falhas na reconstrução.

As fotos utilizadas neste teste foram obtidas através de uma câmera GoPro 5 Hero (GoPro, San Mateo) e as reconstruções foram realizadas em um computador equipado com processador Xeon (R) W-2123 (Intel, Santa Clara), com 64GB de RAM e com placa de vídeo TITAN Xp/PCIe/SSE2 (NVIDIA, Santa Clara).

Da lista citada na Tabela 4.1, para os softwares Mesh Reconstruction Software e Meshlab, não foi possível obter reconstruções 3D diretamente. Para os demais, as Figuras 4.3 e 4.4 apresentam os resultados obtidos com 30, 40 e 50 fotos. É importante ressaltar que as reconstruções foram executadas utilizando os parâmetros padrão de cada software.



(a) Resultado do software OpenSfM



(b) Resultado do software AliceVision - Meshroom

Figura 4.3: Fotogrametrias realizadas com 30 fotos.

Fonte: O autor.




Figura 4.4: Fotogrametrias realizadas com 40 e 50 fotos. A primeira linha apresenta os resultados com 40 fotos e a segunda com 50 fotos.

Fonte: O autor.

Note que na Figura 4.3 não é apresentado o resultado obtido pelo COLMAP, uma vez que o software não convergiu para uma solução. A Tabela 4.2 apresenta os tempos aproximados para as reconstruções 3D obtidas.

Tabela 4.2: Tempos aproximados nas reconstruções 3D.

Software	Tempo aproximado de execução [min]		
	30 fotos	40 fotos	50 fotos
OpenSfM	4	5	17
AliceVision - Meshroom	14	21	18
COLMAP	-	55	74

Fonte: O autor.

Analisando-se os resultados obtidos, observa-se que o software OpenSfM apresenta os melhores resultados, uma vez que é o mais rápido. Já analisando as Figuras 4.3 e 4.4, pode-se dizer que, qualitativamente, os resultados obtidos pelo software AliceVision - Meshroom são melhores, uma vez que conseguem representar melhor o ambiente e apresentam menos buracos/falhas que os demais. Como um dos objetivos deste trabalho é a avaliação de ambientes, considerou-se mais importante a qualidade em detrimento do tempo. Portanto, o software AliceVision - Meshroom foi selecionado para dar continuidade nesta investigação.

#### 4.2.2. Fluxo de reconstrução 3D no software escolhido

Uma vez definido o software para a realização da fotogrametria, analisou-se como a reconstrução é realizada nele. O AliceVision - Meshroom, é um *framework* desenvolvido para realizar reconstruções 3D e rastreamento de câmeras, é composto por algoritmos de visão computacional estado-da-arte que já foram exaustivamente testados/analísados e que podem ser extrapolados. Este software é resultado de uma colaboração entre a academia e a indústria para fornecer algoritmos com qualidade e robustez para as mais diversas aplicações (ALICEVISION, 2021). O AliceVision - Meshroom é um software de fácil utilização e apresenta uma interface amigável.

Ao executar o software, o fluxo básico da fotogrametria é exibido no campo *Graph Editor* (consulte Apêndice B - Figura B1). Neste fluxo, as etapas do processo de reconstrução são carregadas e dispostas como entradas/saídas. Cada bloco é responsável pela execução de uma atividade e apresenta configurações que, se ajustadas da maneira adequada, podem melhorar os resultados da fotogrametria. Também é possível adicionar, excluir e reordenar os blocos de forma a alterar a reconstrução 3D. Abaixo é apresentada breve descrição de cada um dos blocos padrão (ALICEVISION, 2021):

- *CameraInit*: responsável por extrair os metadados das imagens. O objetivo deste bloco é obter as informações intrínsecas da câmera utilizada;
- *FeatureExtraction*: responsável por identificar grupos de pixels que são invariantes no tempo, também conhecidos como *features*, à medida que a câmera é deslocada;
- *ImageMatching*: responsável por selecionar pares de imagens correspondentes, de forma a encontrar as imagens que se enquadram nas mesmas cenas;
- *FeatureMatching*: responsável por executar a correspondência de todos *features* entre os pares de imagens candidatas;
- *StructureFromMotion*: responsável por analisar as correspondências dos *features* para entender a relação geométrica por trás de todas observações 2D e inferir a estrutura rígida em 3D com a pose;
- *PrepareDenseScene*: responsável por exportar imagens não distorcidas, para que o mapa de profundidade e texturização sejam calculados em imagens sem distorção;
- *DepthMap*: responsável por estimar o valor de profundidade para cada pixel que foi estimado no *StructureFromMotion*;
- *DepthMapFilter*: responsável por filtrar os valores de profundidade do mapa de profundidade que não são coerentes;

- *Meshing*: responsável por criar uma representação geométrica densa da superfície da cena;
- *MeshingFiltering*: responsável por aplicar um filtro laplaciano para remover os defeitos locais do *Meshing*;
- *Texturing*: responsável por calcular a texturização na representação geométrica.

### 4.2.3. Proposta de fluxo de reconstrução 3D

Como o objetivo deste trabalho é realizar a fotogrametria em ambientes subterrâneos e com pouca iluminação, foram propostas três modificações no fluxo padrão de reconstrução do AliceVision - Meshroom para minimizar as limitações impostas pelos locais em questão.

A primeira alteração no fluxo de reconstrução 3D foi a inclusão de um bloco *StructureFromMotion*, de forma que o fluxo apresentasse dois blocos *StructureFromMotion* em série. Além disso, no primeiro bloco o parâmetro *minInputTrackLength* foi alterado para 4, enquanto no segundo se manteve o padrão, que é 2. Essas alterações melhoram a robustez da seleção/reconstrução do par inicial de imagens e são úteis quando se trabalha com um maior volume de imagens.

A segunda alteração foi no bloco *FeatureMatching*. Neste bloco, foi ativada a opção *Guided Matching*. Esta opção habilita um segundo estágio no procedimento de correspondência dos *features*, o que minimiza a rejeição precoce e, conseqüentemente, melhora o número das correspondências, em particular para estruturas repetitivas.

E a última alteração realizada foi a inclusão do recurso *Augment Reconstruction*. Esta operação permite a inclusão de diferentes imagens ao fluxo padrão, de maneira adicional, e é adequada para análise de cenas mais complexas. O fluxo de operações, após adicionar o recurso *Augment Reconstruction*, é ligeiramente alterado e o bloco *ImageMatchingMultiSfM*, que permite a fusão dos grupos em uma única reconstrução é adicionado automaticamente.

No Apêndice B - Figura B2 é demonstrado o fluxo de reconstrução 3D, após a realização das alterações acima citadas.

### 4.2.4. Comparação dos fluxos de reconstrução 3D

Para validar o fluxo de reconstrução 3D proposto na Subseção anterior e compará-lo com o fluxo padrão do AliceVision - Meshroom, Subseção 4.2.2, foram realizadas fotogrametrias seguindo os dois métodos. As reconstruções foram feitas em dois cenários distintos, sendo um simulado e outro real. As comparações dos resultados obtidos foram analisadas qualitativamente, observando-se a representatividade do ambiente e a presença de falhas e quantitativamente através do tempo decorrido.

O primeiro cenário analisado foi a caverna subterrânea do DARPA *Subterranean*<sup>3</sup>. Este

<sup>3</sup>“cave\_02” acessado em <https://github.com/osrf/subt>



ambiente tem obstáculos, terreno irregular e geometria realista de cavernas subterrâneas (Figura 4.5). Todos os experimentos foram realizados utilizando a versão virtual do EspeleoRobô dentro do simulador CoppeliaSim<sup>4</sup>, executado com o Sistema Operacional de Robôs (do inglês *Robot Operating System*, ROS) na versão Kinetic e Ubuntu 16.04.




Figura 4.5: Cenário experimental no simulador CoppeliaSim.

Fonte: O autor.

Já o segundo cenário foi a mina de ouro subterrânea conhecida como Mina do Veloso, localizada em Ouro Preto - MG, Brasil (coordenadas: 20°22'34.9" sul, 43°30'57.7" oeste). Na Figura 4.6 pode-se observar o EspeleoRobô dentro deste local. A Mina do Veloso é caracterizada por possuir um corredor estreito, de aproximadamente 200 metros, com vários níveis e terreno acidentado.



Figura 4.6: Cenário experimental na Mina do Veloso.

Fonte: O autor.

Para o cenário da caverna subterrânea do DARPA *Subterranean*, o EspeleoRobô foi montado com uma câmera RGB-D, um LiDAR e uma IMU. Já para o cenário da Mina du

---

<sup>4</sup><http://www.coppeliarobotics.com>

Veloso, ele foi montado com a câmera RealSense D435i (Intel, Santa Clara), o LiDAR OS 1 (Ouster, São Francisco), a IMU MTI-G-710 (Xsens, Enschede) e um módulo de led de 100W (StratusLEDS, Seattle). Os dados coletados foram armazenados utilizando o ROS.

#### 4.2.5. Comparação com outros métodos de reconstrução 3D

Como forma de analisar o quão preciso foram os resultados obtidos pela fotogrametria, realizou-se uma comparação dela com outras duas metodologias de reconstrução 3D: o LiDAR-SLAM através da técnica do LeGO-LOAM<sup>5</sup> e o Visual-SLAM através da técnica RTAB-MAP<sup>6</sup>. Estas técnicas, que são realizadas a partir de sensores ativos, são aplicadas em atividades de Localização e Mapeamento Simultâneos (do inglês *Simultaneous Localization and Mapping*, SLAM).

A comparação entre as três metodologias foi feita a partir de suas respectivas nuvens de pontos. Após realizar as reconstruções 3D dos ambientes, foram comparados os erros ponto a ponto, para cada um dos métodos, com o *ground truth*, que é considerado como a referência para reconstrução e que pode ser traduzido para o português como “verdade fundamental”. As comparações foram realizadas nos dois cenários já apresentados neste trabalho. Sendo assim, para o cenário da caverna do *DARPA Subterranean*, como o ambiente é simulado, a própria caverna foi selecionada como *ground truth*. Agora, para o cenário da Mina do Veloso, uma referência foi determinado a partir dos resultados obtidos pela simulação: àquele método que apresentou o menor erro, considerando toda a distribuição dos dados, foi o selecionado. Desta forma, as outras duas metodologias foram comparadas com a referência definida.

Nestas análises, também foi considerado o tempo de processamento, a fim de se conhecer melhor as aplicações e limitações de cada método.

### 4.3. Resultados e discussões

Esta Seção apresenta os resultados obtidos para cada um dos testes propostos anteriormente.

#### 4.3.1. Reconstruções 3D por fotogrametrias


Utilizando os dados previamente gravados pelo ROS para cada um dos cenários, as reconstruções sucederam-se de forma offline. As imagens utilizadas nas fotogrametrias foram extraídas das informações gravadas pelas câmeras RGB-D, as quais foram usadas imagens RGB com resolução de  $640 \times 480$  pixels. Para executar as reconstruções foi utilizado um computador equipado com uma CPU i5-9300H (Intel, Santa Clara), 16GB de RAM e placa de vídeo RTX 1050 (NVIDIA, Santa Clara).

---

<sup>5</sup><https://github.com/RobustFieldAutonomyLab/LeGO-LOAM>

<sup>6</sup><http://introlab.github.io/rtabmap/>

Para o cenário do DARPA *Subterranean*, foram extraídas 365 imagens, considerando um trecho da caverna. Aplicando-se o fluxo padrão de reconstrução 3D, que é direto, todas as imagens foram adicionadas a ele e a fotogrametria foi realizada. Após o processamento, obteve-se uma reconstrução 3D do ambiente com 399.946 vértices (Figura 4.7a). O tempo de reconstrução foi de aproximadamente 1 hora e 17 minutos. Em seguida, fora aplicado o fluxo de reconstrução proposto na Subseção 4.2.3. Apesar de utilizar as mesmas 365 imagens, a inclusão delas foi realizada de forma diferente. Nesta metodologia, três grupos foram criados seguindo a divisão: no primeiro utilizou-se 105 imagens, enquanto que no segundo e terceiro foram utilizadas 130 em cada um. As 105 imagens utilizadas no primeiro grupo foram selecionadas de forma a permitir identificar todo o trajeto percorrido pelo EspeleoRobô, enquanto que, nos demais grupos, as imagens foram utilizadas para fornecer informações adicionais. Ao final, obteve-se uma reconstrução 3D do ambiente com 106.332 vértices (Figura 4.7b). O tempo de reconstrução foi de aproximadamente 1 hora e 45 minutos.



(a) Resultado da fotogrametria seguindo fluxo padrão AliceVision - Meshroom



(b) Resultado da fotogrametria seguindo fluxo proposto no trabalho

Figura 4.7: Fotogrametria aplicada a caverna do DARPA *Subterranean*.


Fonte: O autor.

Utilizando-se o fluxo padrão do AliceVision - Meshroom, notou-se que o software, apesar de convergir a um resultado, não conseguiu criar uma malha que se correlacionasse ao ambiente analisado. Tal fato pode ser explicado pela dificuldade que essa metodologia apresentou para identificar um SfM que fosse coerente com a rota realizada pelo EspeleoRobô na simulação. Em contrapartida, no outro método, as alterações realizadas fortaleceram a definição do SfM: foram utilizados dois blocos *StructureFromMotion* em série com parâmetros diferentes e, além disso, a opção *Guided Matching* fora habilitada, permitindo melhora na correspondência de *features*. O resultado dessas operações foi uma definição robusta do SfM. E uma vez que o SfM foi bem definido, obteve-se êxito ao adicionar novas informações à reconstrução através do recurso *Augment Reconstruction*. Por isso, analisando-se a Figura 4.7, pode-se dizer, qualitativamente, que a reconstrução 3D utilizando o segundo método foi melhor que a primeira.


Com relação ao tempo de processamento pode-se observar que as alterações realizadas no fluxo proposto aumentaram o tempo de processamento em 28 minutos, o que representa um

acréscimo de aproximadamente 27% no tempo para a obtenção do resultado. Esse aumento pode ser explicado pelo fato do fluxo proposto possuir três blocos de *DepthMap*, conforme demonstrado na Figura B2, nos Apêndices B. Este bloco que é responsável por estimar o valor de profundidade de cada pixel da reconstrução, geralmente, consome 70% do tempo de uma fotogrametria. Neste caso, o aumento do tempo se limitou a 28 minutos porque as imagens no fluxo proposto foram incluídas em grupos menores do que no fluxo padrão.

Para o cenário da Mina do Veloso foram extraídas 333 imagens de um trecho do corredor. Assim como na caverna do DARPA *Subterranean*, para a metodologia padrão do AliceVision - Meshroom, todas as imagens foram adicionadas diretamente ao fluxo e a fotogrametria foi realizada. Após o processamento, obteve-se uma reconstrução 3D do ambiente com 63.624 vértices (Figura 4.8a). O tempo de reconstrução foi de aproximadamente 1 hora e 6 minutos. Na mesma linha de raciocínio anterior, para o outro fluxo de reconstrução 3D, as imagens foram divididas em três grupos. O primeiro grupo ficou com 133 imagens, enquanto que o segundo e terceiro grupos ficaram com 100 imagens cada um. Ao final, obteve-se uma reconstrução 3D do ambiente<sup>7</sup> com 139.326 vértices (Figura 4.8b). O tempo de reconstrução foi de aproximadamente 1 hora e 28 minutos.



(a) Resultado da fotogrametria seguindo fluxo padrão AliceVision - Meshroom



(b) Resultado da fotogrametria seguindo fluxo proposto no trabalho

Figura 4.8: Fotogrametria aplicada a Mina do Veloso.

Fonte: O autor.

Conforme apresentado na Figura 4.8, nota-se que ambas reconstruções conseguiram representar o ambiente de maneira realista e com alta qualidade. Contudo, pode-se observar também que o trecho reconstruído pelo fluxo padrão foi menor e apresentou mais falhas em comparação com o outro fluxo. Neste caso em específico, ambas reconstruções definiram bem o SfM, mas a segunda conseguiu detalhar melhor o ambiente, o que pode ser explicado pela opção *Guided Matching* que foi ativada e ao uso do recurso *Augment Reconstruction*. Portanto, considera-se que a segunda metodologia apresentou um resultado qualitativamente melhor.

Assim como na simulação, observa-se que o fluxo proposto demorou mais tempo para obter a reconstrução do que o fluxo padrão, apresentando um aumento de 22 minutos, o que

<sup>7</sup><https://skfb.ly/6SLSV>

representa um acréscimo de 33% no tempo.

Neste cenário foi possível observar duas particularidades para a realização da fotogrametria que ainda não haviam sido percebidas. Primeiramente, notou-se que para melhor definição do SfM, quanto menos o EspeleoRobô rotacionasse em torno do seu eixo, mais fácil era a extração da trajetória percorrida por ele. Como o robô se deslocou a uma baixa velocidade, inferior a 1 m/s, e a câmera gravou a uma taxa de 15 quadros/segundo, notou-se que haviam muitas imagens com cenas repetidas e borradas quando ele fazia os movimentos de rotação. A inclusão dessas imagens no fluxo de reconstrução 3D, quando processadas pelo software, provocava um erro na estimativa da pose em questão afetava as seguintes. Mesmo que essas imagens fossem filtradas ou retiradas do banco de imagens, notou-se que havia impacto no restante do processamento. Consequentemente, para se maximizar a definição do SfM, é aconselhável que o robô evite rotações no próprio eixo.

A segunda observação realizada durante os procedimentos foi em relação ao campo de visão da câmera utilizada. Notou-se que nas regiões mais próximas da câmera, isto é, o chão e alturas de até 1,0 m, a reconstrução 3D apresentou menos buracos em comparação com alturas superiores e ao teto. Consultando as especificações técnicas da câmera, é possível verificar que seu campo de visão na vertical é de  $42,5^\circ$ , o que representa uma abertura relativamente pequena. Sendo assim, para se potencializar a reconstrução 3D e evitar a presença indesejável de buracos causados pelo campo de visão, sugere-se a utilização de câmeras com maior abertura vertical.

### **4.3.2. Comparação de métodos de reconstrução 3D**

Para a comparação, foram selecionados dados de uma mesma base de informações. Na fotogrametria foram utilizadas imagens RGB gravadas pelas câmeras RGB-D. No LiDAR-SLAM, as nuvens de pontos foram coletadas pelos LiDARs. Por fim, no Visual-SLAM, foram utilizadas imagens RGB-D gravadas pelas câmeras RGB-D.

A fotogrametria, nesta comparação, foi realizada considerando o fluxo de reconstrução proposto na Subseção 4.2.3, cujos resultados na Subseção 4.3.1 demonstraram melhor desempenho comparado com o fluxo padrão. Portanto, para simplificar a nomenclatura, nesta Subseção o fluxo proposto é apresentado simplesmente como fotogrametria. De maneira análoga, as técnicas LeGO-LOAM e RTAB-MAP, são identificadas, respectivamente, por suas metodologias: LiDAR-SLAM e Visual-SLAM.

#### **4.3.2.1. Caverna do DARPA *Subterranean***

Foram realizadas as reconstruções 3D para cada um dos métodos para uma seção da caverna. A Figura 4.9 apresenta a comparação das nuvens de pontos geradas, na qual a primeira linha representa as nuvens de pontos obtidas por cada metodologia, a segunda linha a comparação entre as nuvens e o *ground truth* (região cinza da imagem), e a terceira linha o histograma dos erros.



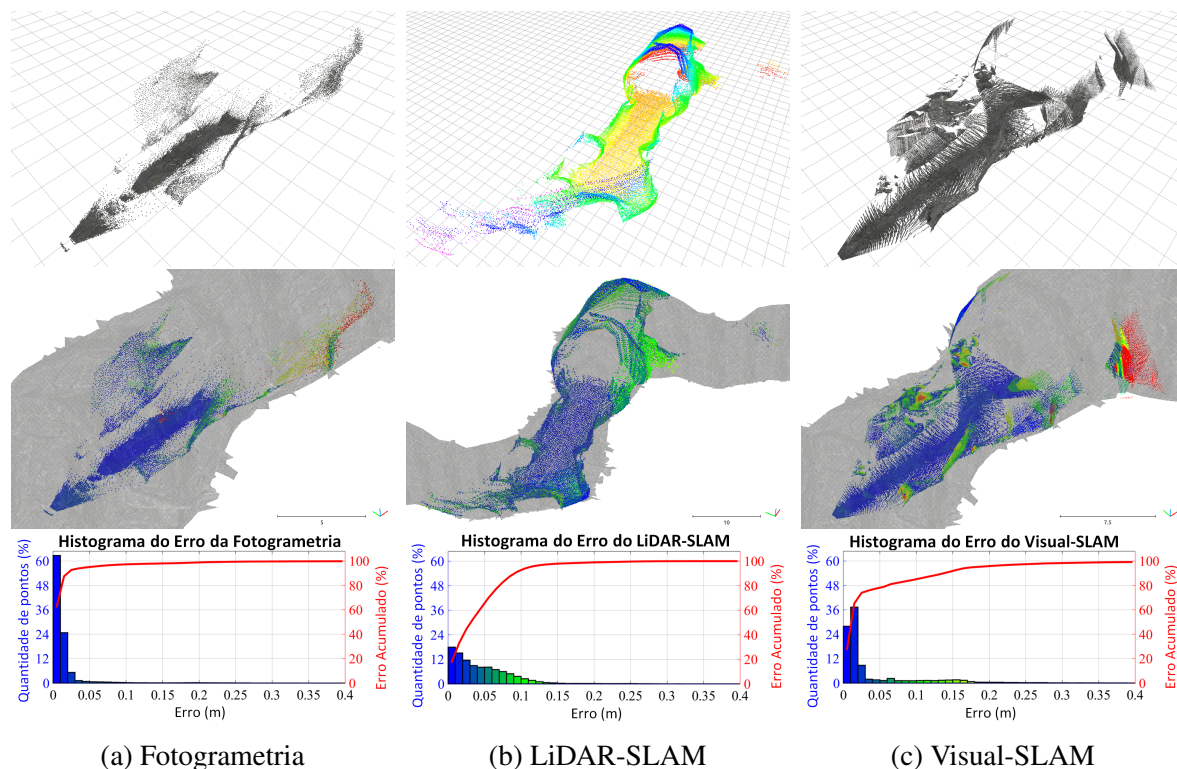


Figura 4.9: Análise de erro das nuvens de pontos aplicadas aos três métodos de reconstrução 3D para a caverna do DARPA *Subterranean*.

Fonte: Azpúrua *et al.* (2021).

A Tabela 4.3 apresenta quantos pontos foram representados por cada nuvem de pontos, e os erros máximos em  $2\sigma$  (distribuição de 95% dos pontos),  $3\sigma$  (distribuição de 99,7% dos pontos) e em toda amostra.

Tabela 4.3: Análise das nuvens de pontos para as reconstruções 3D realizadas na caverna do DARPA *Subterranean*.

Método de reconstrução	Número de pontos da nuvem	Erro máximo em $2\sigma$ [m]	Erro máximo em $3\sigma$ [m]	Erro máximo [m]
Fotogrametria	79.404	0,054	0,332	1,85
LiDAR-SLAM	31.239	0,115	0,258	0,33
Visual-SLAM	383.862	0,128	0,480	0,80

Fonte: Azpúrua *et al.* (2021).

Analisando a Tabela 4.3 pode-se observar que as nuvens de pontos para cada método apresentam dimensões diferentes, sendo que a nuvem de pontos do LiDAR-SLAM foi a mais esparsa e a do Visual-SLAM a mais densa. Ainda na Tabela 4.3 observa-se que o menor erro máximo em  $2\sigma$  foi obtido pela fotogrametria seguido do LiDAR-SLAM, enquanto em  $3\sigma$  o LiDAR-SLAM obteve o melhor resultado seguido da fotogrametria. Quando se analisa toda a amostra de dados, nota-se que a fotogrametria teve o maior erro máximo e o LiDAR-SLAM os menores resultados. Apesar da fotogrametria apresentar o maior erro máximo, este método

é o que converge mais rapidamente quando comparado aos demais, conforme demonstrado no histograma de erros, na terceira linha da Figura 4.9.

Com relação ao tempo de processamento, a reconstrução realizada pela fotogrametria foi feita utilizando 405, imagens de tamanho  $640 \times 480$  pixels, e levou 1 hora e 10 minutos em um computador equipado com CPU i7-10875H (Intel, Santa Clara), 32GB de RAM e placa de vídeo RTX 2070 (NVIDIA, Santa Clara). O método LiDAR-SLAM, que é um método online, levou  $1239 \pm 226$  ms para efetuar a varredura do ambiente e atualizar a reconstrução. Já o método Visual-SLAM, que também é online, levou  $56 \pm 12$  ms por quadro e  $486 \pm 123$  ms por quadro-chave para atualizar a reconstrução.

#### 4.3.2.2. Mina do Veloso

Para a reconstrução da Mina do Veloso, o método LiDAR-SLAM foi selecionado como referência pelo fato de ter obtido o menor erro máximo em toda amostra na análise das nuvens de pontos apresentadas na Tabela 4.3. Portanto, as nuvens de pontos da fotogrametria e do Visual-SLAM foram comparadas à ela. A Figura 4.10 apresenta a análise do erro das nuvens de pontos para este cenário, na qual a primeira linha representa a nuvem de pontos obtidas para cada método, a segunda linha a sobreposição da nuvem de pontos com a referência e a terceira o histograma de erros.

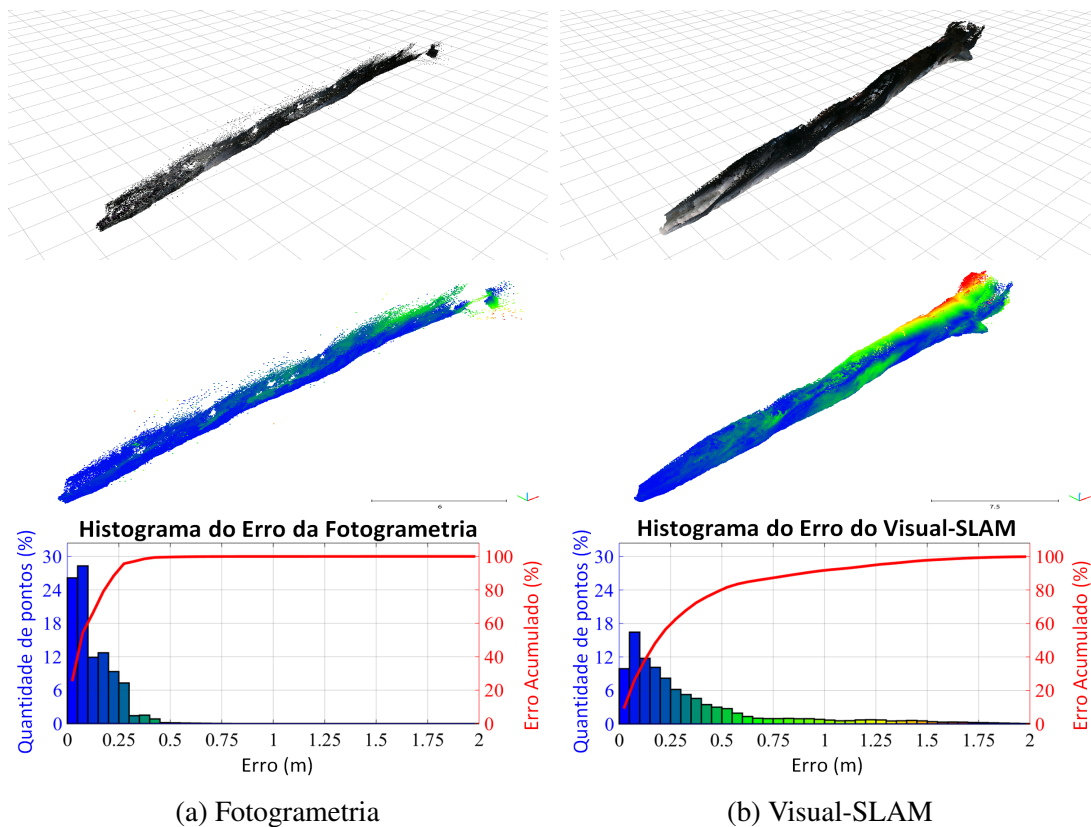


Figura 4.10: Análise de erro das nuvens de pontos obtidas pela fotogrametria e Visual-SLAM da Mina do Veloso, utilizando LiDAR-SLAM como referência.

Fonte: Azpúrua *et al.* (2021).

A Tabela 4.4 apresenta quantos pontos foram representados por cada nuvem de pontos, e os erros máximos em  $2\sigma$  (distribuição de 95% dos pontos),  $3\sigma$  (distribuição de 99,7% dos pontos) e em toda amostra.

Tabela 4.4: Análise das nuvens de pontos para as reconstruções 3D realizadas na Mina do Veloso.

Método de reconstrução	Número de pontos da nuvem	Erro máximo em $2\sigma$ [m]	Erro máximo em $3\sigma$ [m]	Erro máximo [m]
Fotogrametria	154.881	0,290	0,500	2,06
Visual-SLAM	1.235.708	1,276	1,896	2,56

Fonte: Azpúrua *et al.* (2021).

A Tabela 4.4 demonstra novamente que as dimensões das nuvens de pontos foram diferentes, sendo que a nuvem de pontos produzida pelo Visual-SLAM foi a mais densa, de novo. Observa-se também pela Tabela 4.4 que a fotogrametria apresentou menores erros em relação ao Visual-SLAM em todas as distribuições, bem como, convergiu mais rapidamente conforme demonstrado na terceira linha da Figura 4.10. É importante ressaltar que a nuvem de pontos gerada pela fotogrametria passou por operações manuais de rotação e escala para coincidir com a nuvem de pontos da referência e, em seguida, os erros foram estimados. Essas operações foram realizadas porque a fotogrametria é mais sujeita a erros rotacionais e de escala, uma vez que utiliza apenas de recursos visuais para efetuar a reconstrução.

Com relação ao tempo de processamento, a reconstrução realizada pela fotogrametria foi feita utilizando 103 imagens de tamanho  $640 \times 480$  pixels, e levou 22 minutos e 18 segundos, enquanto o método Visual-SLAM, levou  $59 \pm 49$  ms por quadro e  $763 \pm 200$  ms por quadro-chave para atualizar a reconstrução.

## 4.4. Considerações sobre a Investigação em Fotogrametria

Partindo da necessidade de adequação às vigentes normas e resoluções ambientais para a exploração de cavernas e minas subterrâneas, a Vale desenvolveu o EspeleoRobô, um dispositivo robótico reduzido e com arquitetura modular capaz de realizar missões teleoperadas. Este robô foi concebido para dar suporte as atividades de espeleologia, cujo objetivo é extrair informações do local de interesse, tais como a modelagem 3D. Baseado nessa necessidade, este trabalho apresentou uma investigação sobre reconstruções 3D para estes ambientes através das técnicas da fotogrametria.

O trabalho iniciou-se com a investigação de um software *open source* que fosse capaz não só de fazer a fotogrametria, mas que também, apresentasse recursos suficientes para a realização de reconstruções 3D em ambientes subterrâneos. O software AliceVision - Meshroom apresentou os melhores resultados na análise e, por isso, deu sequência a este trabalho.



Em seguida, foi proposto um fluxo de reconstrução, cujo objetivo era ser capaz de superar algumas das limitações dos ambientes analisados. Esse fluxo, por sua vez, foi comparado ao fluxo padrão do software como forma de validação. Na sequência, foram realizadas as fotogrametrias de dois ambientes representativos, sendo um deles simulado e o outro real. Com o resultado das reconstruções, observou-se que a alteração proposta apresentou benefícios na qualidade da fotogrametria e promoveu aumento no tempo de processamento de aproximadamente 30%. Ainda nessas reconstruções, notou-se duas particularidades que afetaram diretamente nos resultados: a relação da estimativa do SfM com a rotação sobre o eixo do robô, e a relação do campo de visão da câmera com a presença de buracos. Por fim, a fotogrametria foi comparada a outros dois métodos, LiDAR-SLAM e Visual-SLAM, como forma de analisar o erro ponto a ponto e o tempo necessário para realizar a reconstrução. Nesta comparação foi possível notar que a fotogrametria apresenta boa precisão quando comparada a métodos ativos.

Com base nas informações acima expostas, pode-se concluir que este trabalho conseguiu investigar as técnicas de fotogrametria, bem como suas limitações aplicadas nos ambientes definidos pelo escopo do trabalho. Apoiado nestes resultados, acredita-se que estas técnicas podem ser reproduzidas e extrapoladas para quaisquer outros tipos de ambientes aplicados à mineração e com menos limitações, tais como frente de mina, pátio de estoque de produtos, entre outros.

## **4.5. Trabalhos futuros**

Como trabalhos futuros, são sugeridos:

- Realização de testes em ambientes reais com os atuais parâmetros;
- Avaliação da utilização de outras câmeras com campo de visão, na vertical, superior ao utilizado neste trabalho ( $42,5^\circ$ );
- Utilização de referências externas na fotogrametria para reduzir os problemas de escala e rotação;
- Combinar a fotogrametria com informações de odometria do robô, a fim de minimizar os problemas de escala na reconstrução. Essa informação pode ser útil também na navegação e pode até ser utilizada como técnica de pré-mapeamento para as metodologias SLAM.

## 5. DETECÇÃO DE POTENCIAIS FALHAS PRECOSES EM DUTO DE REJEITOS COM DISPOSITIVO ROBÓTICO E APRENDIZADO DE MÁQUINA

Este Capítulo apresenta uma proposta, construção e avaliação de um sistema de visão computacional de *deep learning* para a identificação de potenciais falhas precoces na tubulação de rejeitos da Usina do Salobo. São descritos, também, os resultados apresentados no relatório técnico: *Inspecção da tubulação de rejeitos das usinas de Salobo* (MAGNO *et al.*, 2019) e no artigo de conferência: *Deep Learning for Early Damage Detection of Tailing Pipes Joints with a Robotic Device* (RESENDE FILHO *et al.*, 2020), frutos de trabalhos em colaboração com os coautores indicados nos documentos citados.

Na indústria da mineração é comum a utilização de grandes distâncias de tubos, sendo eles de tamanhos e materiais variados. Somente nas instalações da Mina do Salobo, mina de cobre localizada no interior da Floresta Amazônica, existem mais de três quilômetros e meio de tubos de rejeitos. O rejeito gerado após o processamento do minério de cobre nessa mina é enviado para uma barragem através de um tubo, que possui um diâmetro de 1200 mm, feito de Polietileno de Alta Densidade (do inglês *High-Density Polyethylene*, HDPE).

O rejeito devido à sua alta velocidade e ao atrito, provoca efeito de abrasão no revestimento interno ao passar pelo tubo, proporcionando o desenvolvimento de anomalias na tubulação em forma de rasgos, buracos e superfícies irregulares. Por esse motivo, a cada seis meses, é necessário inspecionar as condições da tubulação. Uma rotina de inspeção regular é baseada na abertura de “janelas” (cortes com um tamanho aproximado de 80 x 60 cm) no tubo e, em seguida, na execução de uma inspeção visual no local, feita por um mantenedor. Esse processo é caro, lento e trabalhoso, pois a inspeção é restrita a uma região curta perto da janela. Uma falha na detecção de danos ou anomalias na inspeção pode permitir vazamentos, sendo capaz de interromper todo o complexo produtivo por várias horas ou dias, gerando perdas econômicas significativas e aumentando os riscos operacionais para os trabalhadores.

Embora a equipe de manutenção realize uma inspeção visual cuidadosa em toda a infraestrutura e equipamentos da planta para evitar possíveis irregularidades, a extensão dos tubos e os perigos como gás tóxico, calor, entre outros, exigem um mecanismo de inspeção autônomo. Nesse sentido, o uso de um dispositivo robótico remoto que possa entrar nos dutos para inspeção de maneira simples e confiável é uma solução desejável.

Para a execução desta atividade foi proposta a utilização do EspeleoRobô, dispositivo descrito na Subseção 2.1.4 e apresentado nas Figuras 1.5, 2.5, 4.2 e 4.6. O robô possui uma grande variedade de sensores para executar missões autônomas e teleoperadas, como LiDAR, câmeras de imagens digitais (RGB) e de profundidade (RGB-D) e sensores de gás, tornando-o adequado para a atividade.

Para a atividade de inspeção, três câmeras RGB de alta definição localizadas em dife-

rentes posições no robô foram utilizadas para gravar vídeos que, posteriormente, poderiam ser utilizados pelos operadores de manutenção para detectar remotamente os potenciais danos dentro dos tubos. A inspeção se concentrou principalmente nas juntas dos tubos que, em geral, são as áreas mais impactadas. A captura de vídeo é útil e aumenta a segurança nas operações de inspeção, entretanto, a detecção automática de potenciais falhas precoces, proposta neste trabalho, permite a verificação e tomada de decisão mais ágil pelas equipes de manutenção.

## 5.1. Trabalhos relacionados

Kakogawa *et al.* (2018) apresentam AIRo3, um robô desenvolvido para a inspeção de tubos com diâmetro inferior a 100 mm. O AIRo3 apresenta um design compacto, podendo avançar/retroceder e se mover helicoidalmente dentro das tubulações. O robô pode, também, apresentar diferentes configurações em suas juntas, alterando o seu formato para melhor se adaptar ao ambiente inspecionado.

Wahed e Arshad (2017) desenvolvem um robô do tipo prensa de parede para inspeção de tubos. Este robô é composto por três seções: câmera, módulo de direção frontal e módulo de direção traseira, apresentando comprimento total de 542 mm e diâmetro de 230 mm. Segundo os autores, esta configuração, é mais barata e necessita de menos manutenção comparado com os robôs de múltiplas rodas.

Para tentar contornar problemas de deslocamento de robôs nas ramificações em oleodutos, Masuta *et al.* (2013) apresentam o Pipe Inspection Robot, um robô de inspeção de tubos que pode operar em uma ampla gama de diâmetros e contornar as curvas. No trabalho, os autores propõem o reconhecimento do tubo de derivação usando um sensor de visão de grade de fibra, capaz de reconhecer a posição e a direção da flexão para executar o movimento de rotação.

Para identificar defeitos que podem causar danos ao sistema de tubos, Ganegedara *et al.* (2012) afirmam que a abordagem popular tem sido enviar robôs com controle remoto para fotografar e processar as imagens. Dessa forma, os autores apresentam uma abordagem baseada em mapas auto-organizados que tem como objetivo isolar regiões de interesse que possam conter defeitos. Com um algoritmo que consiste em três fases, eles restringem a área de busca para detecção de defeitos e demonstram a eficácia da abordagem proposta para um conjunto de dados de imagem de tubo real.

Chen *et al.* (2018) apresentam uma abordagem de aprendizado de ponta a ponta, baseada em aplicações com CNN e TL para realizar uma detecção, baseada em visão, de tubulação de esgoto. A estrutura de detecção foi dividida em detecção de movimento da câmera, detecção anormal de quadros de vídeo e classificação de defeitos de quadros anormais. Para melhorar a precisão da detecção, foi adotada a estratégia de TL utilizando o conjunto de modelos múltiplos, os quais atingiram precisão de 81%. No entanto, o método proposto pode ser aplicado apenas para detectar defeitos com características óbvias e apresenta baixo desempenho na detecção de defeitos com características não significativas.

Para obter alta precisão e classificação robusta para a detecção de vazamento em tubos de transmissão de petróleo bruto, Li *et al.* (2019) fundiram imagens RGB com imagens térmicas usando uma CNN. A aplicação da fusão na CNN superou em 10% a precisão alcançada por algumas redes estado da arte (LeNet5, AlexNet, VGGNet16 e ResNet50).

Neste trabalho combina-se robótica e *deep learning* para uso em uma aplicação que exige uma inspeção eficaz para manter a produção de uma planta de mineração e também a segurança do meio ambiente. É proposto um serviço capaz de realizar a inspeção de maneira simples, rápida e confiável.

## 5.2. Métodos e procedimentos

Esta Seção apresenta os procedimentos realizados durante a coleta de dados e as etapas de construção do detector de juntas de rejeito.

### 5.2.1. Coleta de dados

O conjunto de dados utilizado neste trabalho foi obtido por meio de uma inspeção realizada em setembro de 2019 no duto de rejeitos da Usina do Salobo (coordenadas: 5°47'05.6" sul, 50°31'29.1" oeste). A tubulação tem extensão aproximada de 3,5 km, consistindo de trechos de 12 m conectados. A Figura 5.1 mostra uma vista superior da planta e da tubulação.



Figura 5.1: Vista superior da Mina do Salobo. A linha em amarelo destaca a tubulação.

Fonte: Adaptado de Google Earth (2020).

Dentre as câmeras embarcadas no EspeleoRobô, a filmagem escolhida para ser usada neste trabalho foi a realizada pela câmera digital B06W-1080P-HX (SV3C, Longgang District),

que possui campo de visão de 70° e, consequentemente, facilita a detecção das potenciais falhas. A inspeção foi realizada apenas nas regiões mais críticas do complexo de tubulações e o robô entrou nos tubos a partir das janelas usadas para inspeção visual, conforme exposto na Figura 5.2.



(a) Janela aberta na tubulação



(b) EspeleoRobô sendo inserido pela janela

Figura 5.2: Inspeção dos tubos de rejeito.

Fonte: Resende Filho *et al.* (2020).

Nos vídeos analisados, pode-se verificar que uma das situações mais recorrentes na tubulação é o dano precoce nas juntas entre os trechos. Esses defeitos são caracterizados por descontinuidade/orifícios na parte inferior da junta. A Figura 5.3 mostra um exemplo de uma junta em boas condições e outra com um defeito inicial.



(a) Junta em bom estado



(b) Junta com potencial defeito precoce, devido à descontinuidade na parte inferior

Figura 5.3: Exemplos de juntas.

Fonte: Adaptado de Resende Filho *et al.* (2020).

Com base nestas características, este trabalho pode ser visto como tendo duas classes a serem categorizadas: boas e ruins, onde o bom é representado pelas juntas em bom estado e o ruim por aquelas com potenciais defeitos precoces.

A obtenção das imagens para o conjunto de dados foi realizada com um algoritmo em Python a partir da biblioteca OpenCV (BRADSKI, 2000). Sendo assim, a partir dos vídeos foram extraídas 187 imagens de cada classe. Os conjuntos de treinamento e teste utilizam 70 e 30% do conjunto de dados, respectivamente, o que representa 130 imagens para o conjunto de treinamento e 57 para o conjunto de teste. As imagens utilizadas nos testes foram retiradas de trechos de tubulação diferentes daqueles do treinamento, garantindo assim que a capacidade de generalização da rede fosse testada.

### 5.2.2. Desenvolvimento da rede neural convolucional

Uma Rede Neural Convolucional é uma rede multicamada projetada especificamente para reconhecer formas bidimensionais com um alto grau de translação, escala, inclinação e outras formas de distorção, sendo capaz de extrair automaticamente suas próprias características de um conjunto de dados (HAYKIN, 2009). Para construir e treinar as redes, utilizou-se o PyTorch (PASZKE *et al.*, 2019), uma biblioteca de ML de código aberto. Todo o código foi desenvolvido na linguagem Python.

Como o conjunto de dados usado foi limitado, treinar uma rede desde o início de sua concepção não era uma opção viável. Para superar esta dificuldade, utilizou-se técnicas de TL nos modelos, ou seja, inicialmente considerou os pesos dos modelos já treinados e consolidados em grandes conjuntos de dados e depois eles foram ajustados para este caso, em específico. Portanto, os testes foram feitos com AlexNet (KRIZHEVSKY, 2020), DenseNet (HUANG *et al.*, 2017), GoogLeNet (SZEGEDY *et al.*, 2015), Inception V3 (SZEGEDY *et al.*, 2016), MnasNet (SZEGEDY *et al.*, 2016), MobileNet V2 (SANDLER *et al.*, 2018), ResNet (HE *et al.*, 2016), ResNeXt (XIE *et al.*, 2017), ShuffleNet V2 (MA *et al.*, 2018), SqueezeNet (IANDOLA *et al.*, 2020), VGG (SIMONYAN e ZISSERMAN, 2020) e Wide ResNet (ZAGORUYKO e KOMODAKIS, 2020).

Antes de treinar as redes, foi realizado um DA, produzindo as seguintes operações:

- ajuste de saturação e matiz de com um fator 0,5;
- rotação horizontal aleatória, com 60% de probabilidade de ocorrência;
- rotação vertical aleatória, com 60% de probabilidade de ocorrência;
- distorção na escala de 0,3, com uma probabilidade de 30% de ocorrer;
- rotação aleatória no eixo de  $-45^\circ$  até  $+45^\circ$ .

Para cada rede, o treinamento foi feito com 20 épocas e os testes de validação foram repetidos 3 vezes, a fim de se obter a média dos melhores resultados.



### 5.2.3. Mapas de ativação de classe

Para validação da rede, os CAM foram realizados para analisar a região com maior relevância em sua classificação. O CAM é mecanismo usado para destacar qual região chamou mais atenção na imagem para definir a classe, mas ele não representa diferentes classes. A sua representação é feita através de um mapa de calor sobre as imagens testadas. Após o CAM, uma caixa delimitadora foi criada em cima dele, com objetivo de enquadrar o local mais quente, reforçando o seu resultado.

### 5.2.4. Tempo de execução

Para os modelos que apresentaram as melhores precisões, foi realizado um teste de tempo de execução em diferentes tipos de hardware. Com esses resultados, é possível verificar qual rede é mais eficiente e a necessidade de se utilizar GPU no computador embarcado no robô.

### 5.2.5. Rede neural convolucional de disparo único

Como forma de automatizar a detecção de potenciais falhas precoces e usar o processamento apenas quando necessário, uma rede no YOLOv3 foi treinada para detectar as juntas na tubulação. O treinamento da rede foi feito com base no modelo Darknet-53, aplicando as imagens de treinamento do conjunto de dados como entradas. Em seguida, testes de validação foram realizados para avaliar as saídas obtidas pela rede através do mAP e das previsões realizadas.

### 5.2.6. Fluxo esquemático do software proposto

Considerando as etapas apresentadas nas Subseções anteriores, pode-se representar este sistema de detecção e classificação conforme a Figura 5.4. A CNN utilizada para o disparo único é responsável pela detecção das juntas, são classificadas pelas demais CNNs em seguida. Os outros testes descritos foram utilizados para validar visualmente e temporalmente a viabilidade do sistema.




Figura 5.4: Esquemático do fluxo de software proposto para detecção e classificação das juntas.

Fonte: O autor.

## 5.3. Resultados e discussões

Esta Seção apresenta os resultados obtidos para cada um dos testes propostos anteriormente.

### 5.3.1. Treinamento da rede neural convolucional

Para os modelos mencionados na Subseção 5.2.2, testes de treinamento e validação foram realizados. A Tabela 5.1 mostra a média dos melhores resultados obtidos para cada rede.

Tabela 5.1: Resultados de acurácia para cada rede neural convolucional testada.

Modelo	Média da melhor acurácia no teste [%]
AlexNet	100,0 $\pm$ 0,0
DenseNet	100,0 $\pm$ 0,0
GoogLeNet	100,0 $\pm$ 0,0
Inception V3	100,0 $\pm$ 0,0
MnasNet	89,2 $\pm$ 7,1
MobileNet V2	100,0 $\pm$ 0,0
ResNet	100,0 $\pm$ 0,0
ResNeXt	100,0 $\pm$ 0,0
ShuffleNet V2	90,9 $\pm$ 9,8
SqueezeNet	83,9 $\pm$ 27,9
VGG	100,0 $\pm$ 0,0
Wide ResNet	100,0 $\pm$ 0,0

Fonte: Resende Filho *et al.* (2020).

De acordo com a Tabela 5.1, é possível verificar que a maioria dos modelos apresentou 100% de acurácia. Isso pode ser explicado pelo fato da junta ter características semelhantes a uma borda, o que é facilmente detectável pelas CNNs. Tomando como exemplo a rede ResNet, na Figura 5.5 é possível observar o comportamento da acurácia nas etapas de treinamento e validação ao longo das épocas.

Os modelos de redes MnasNet, ShuffleNet V2 e SqueezeNet não apresentaram média de 100% na acurácia (Tabela 5.1), portanto, eles não serão considerados para as próximas análises realizadas para este trabalho.






Figura 5.5: Curvas de acurácia das etapas de treinamento e validação para a rede ResNet.

Fonte: O autor.

### 5.3.2. Mapas de ativação de classe

Como a maioria dos modelos apresentou acurácia de 100%, o CAM foi utilizado como forma de validação visual dos resultados. Esta técnica foi aplicada ao modelo ResNet para todo o conjunto de dados de teste. A arquitetura desta rede facilita a extração de sua última camada de convolução e, como os resultados de sua acurácia foram 100%, permite inferir que as regiões mais quentes tendem a ser aproximadamente as mesmas para todas as redes. Na Figura 5.6 é possível observar o CAM aplicado à duas juntas: uma boa e uma ruim. Nota-se que, indiferente da classe, o nível de calor é semelhante.




Figura 5.6: Resultados do mapa de ativação de classe.

Fonte: Resende Filho *et al.* (2020).

Nas imagens obtidas pelo CAM, uma caixa delimitadora foi criada para destacar a região mais quente/ativa da imagem (Figura 5.7). Esta caixa foi estimada por meio de um fator de 0,8 sobre o CAM. Este valor foi definido empiricamente por meio de experimentos, como sendo um bom compromisso entre a boa precisão da localização e o tamanho real da anomalia projetada nas imagens.

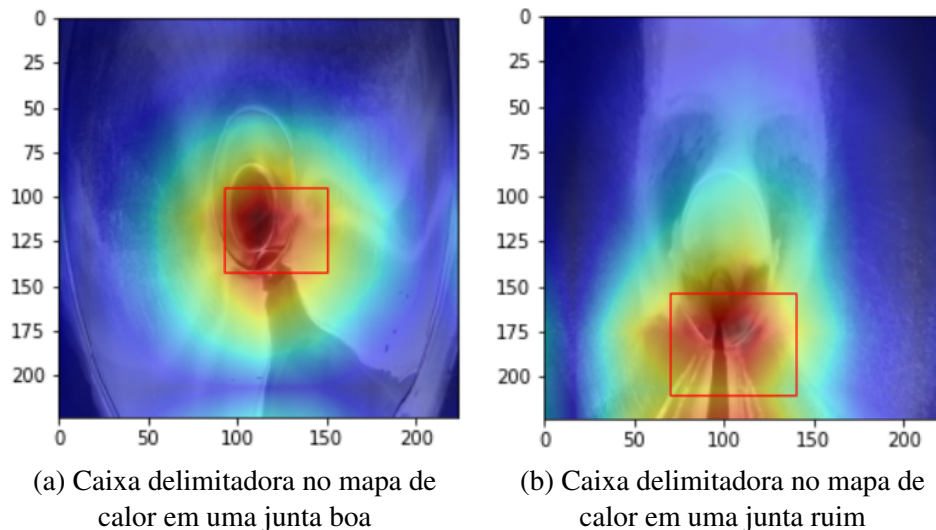


Figura 5.7: Caixa delimitadora aplicado ao mapa de ativação de classe.

Fonte: Resende Filho *et al.* (2020).

Uma vez que a caixa delimitadora foca onde estão as anomalias, fica claro que a área com maior influência na classificação é a parte inferior da junta do tubo, as quais representam a maioria dos defeitos anteriormente caracterizados, manualmente, pelo operadores.

### 5.3.3. Tempo de execução

O teste de tempo de execução foi aplicado apenas às redes que mostraram 100% de precisão (consultar Tabela 5.1). Três diferentes hardware foram usados: Google Colab - Tesla T4, NVIDIA - GeForce 930M e Intel Core i5-8250. Nos testes, foi calculado o tempo necessário para que cada modelo realizasse uma classificação de todo o grupo de teste (114 imagens). A Tabela 5.2 apresenta os resultados.

Considerando que a velocidade de deslocamento do robô na tubulação é de 0,3 m/s e sabendo que a distância entre as juntas é de 12 m, pode-se dizer que o intervalo de tempo entre as juntas é de aproximadamente 40 s. Para este período de tempo, desconsiderando o processamento de outras atividades realizadas pelo robô, conforme Tabela 5.2, apenas o uso de uma CPU é suficiente para qualquer modelo testado. No entanto, sugere-se utilizar aqueles que possuem maior velocidade de processamento: AlexNet, MobileNet V2 e ResNet.

Tabela 5.2: Resultados do tempo de execução para as redes neurais convolucionais em diferentes tipos de hardware.

Modelo	Google Colab - TESLA T4		NVIDIA - GeForce 930M		Intel Core i5-8250	
	Tempo [ms]	Frequência [Hz]	Tempo [ms]	Frequência [Hz]	Tempo [ms]	Frequência [Hz]
AlexNet	65 ± 4	15,38	52 ± 2	19,23	83 ± 7	12,05
DenseNet	96 ± 5	10,42	124 ± 10	8,06	236 ± 9	4,24
GoogLeNet	63 ± 5	15,87	60 ± 2	16,67	118 ± 3	8,47
Inception V3	70 ± 6	14,29	66 ± 3	15,15	128 ± 4	7,81
MobileNet V2	70 ± 4	14,29	57 ± 2	17,54	86 ± 6	11,63
ResNet	65 ± 4	15,38	54 ± 2	18,52	89 ± 6	11,24
ResNeXt	68 ± 4	14,71	76 ± 1	13,16	156 ± 5	6,41
VGG	56 ± 6	17,86	167 ± 10	5,99	267 ± 12	3,75
Wide ResNet	70 ± 4	14,29	138 ± 7	7,25	138 ± 16	4,00

Fonte: Adaptado de Resende Filho *et al.* (2020).

### 5.3.4. Rede neural convolucional de disparo único

O treinamento da YOLO foi feito com o objetivo de encontrar as juntas dentro do tubo. A Figura 5.8 mostra o gráfico da evolução das respostas após 4000 épocas. Em azul são apresentados os valores de perda e em vermelho os valores da precisão média ponderada.





Figura 5.8: Valores resultantes do treinamento do detector YOLOv3 no conjunto de dados.

Fonte: Resende Filho *et al.* (2020).

Como pode ser visto na Figura 5.8, entre 250 e 500 épocas, o resultado da perda já é inferior a 1,0. Ao final, obteve-se um mAP de 94,4%, demonstrando que a rede é capaz de encontrar a junta. Em seguida, o conjunto de dados de teste foi aplicado à rede treinada para analisar o resultado (Figura 5.9). A YOLO, neste caso, foi utilizada apenas para detectar a junta (destaque em roxo), não sendo responsável por sua classificação.



(a) Exemplo de detecção aplicado a uma junta boa

(b) Exemplo de detecção aplicado a uma junta ruim

Figura 5.9: Detecções de juntas realizada pela rede YOLOv3.

Fonte: Resende Filho *et al.* (2020).

## 5.4. Considerações sobre a Inspeção Automatizada de Dutos

A partir da necessidade de acompanhar as condições da tubulação de rejeitos, a atividade de inspeção da tubulação é realizada periodicamente na Usina do Salobo, minimizando o risco de vazamentos ou quaisquer outros problemas. O processo é realizado atualmente de forma manual e, por conta da extensão da tubulação (aproximadamente três quilômetros e meio), é caro, lento e trabalhoso. Neste contexto, viu-se a possibilidade de usar um dispositivo robótico que fosse capaz de entrar na tubulação e realizar a inspeção de trechos mais longos de maneira rápida e confiável. Para a execução desta atividade, foi proposta a utilização do EspeleoRobô com uma abordagem *deep learning* para dar suporte à decisão sobre as atividades de manutenção.

Durante os procedimentos, observou-se que os modelos AlexNet, DenseNet, GoogLeNet, Inception V3, MobileNet V2, ResNet, ResNeXt, VGG e Wide ResNet foram mais eficientes, atingindo 100% de acurácia, enquanto os modelos MnasNet, ShuffleNet V2 e SqueezeNet apresentaram resultados mais baixos para a aplicação. Como forma de validar visualmente as redes, o CAM foi implementado e demonstrou que a região mais ativa da imagem coincide com a região em que os defeitos estão concentrados. Nos testes de tempo de execução, pode-se constatar que as redes AlexNet, MobileNet V2 e ResNet tiveram performance melhor que as demais, uma vez que tiveram os menores tempos de processamento. Por fim, através do YOLOv3 foi possível detectar a junta com alto grau de precisão: mAP de 94,4%.

Uma vez que todos os resultados apresentaram desempenho satisfatório, essas estruturas podem ser conectadas em um único serviço, a fim de auxiliar na inspeção das tubulações. Assim, pode-se concluir que a hipótese inicial de trabalhar com ML na detecção de potenciais defeitos nas juntas dos rejeitos é viável, podendo ser aplicada nos desenvolvimentos posteriores do software do EspeleoRobô.

## 5.5. Trabalhos futuros

Como trabalhos futuros, são sugeridos:

- Realização de testes para validação do sistema proposto e também para coletar mais dados, de forma a melhorar sua robustez;
- Uma vez que as juntas apresentam distribuição uniforme no tubo, propõe-se combinar a detecção das juntas com as informações de odometria do EspeleoRobô, utilizando a detecção como mais uma variável para minimizar os erros associados à posição;
- Utilização do YOLOv3 como detector de juntas ruins, focando apenas no defeito. Esta operação reduz o número de atividades do sistema atual e permite mais uma comparação, o que favorece na definição do melhor sistema a ser utilizado.

## 6. CONSIDERAÇÕES FINAIS

Este Capítulo apresenta as considerações finais e as contribuições desta dissertação, com viés de revisão e fechamento, uma vez que as informações já foram apresentadas para cada estudo de caso.

Graças à sua popularização e crescente demanda, a robótica está cada vez mais presente em nossas vidas. A partir do momento que os robôs ganharam mobilidade e passaram a interagir com as pessoas, novas perspectivas de desenvolvimentos surgiram, permitindo a sua utilização em tarefas repetitivas, perigosas ou naquelas que as pessoas não querem fazer. Desde a última década, que foi marcada pela digitalização e a transformação digital, a robótica móvel se aproximou da indústria. Dentre os setores da indústria em que isso ocorreu, pode-se destacar a mineração, por apresentar forte impacto na economia e por ser um ambiente desafiador. Apesar das aplicações robóticas se tornarem mais frequentes na mineração, investimentos e pesquisas ainda devem ser feitas para o aperfeiçoamento de mecanismos robóticos e sistemas de localização, navegação, e controle, buscando atingir o pleno desenvolvimento. É importante destacar que a mineração apresenta particularidades relacionadas ao seu ambiente, tais como presença de poeira, alta umidade e locais com baixa luminosidade que dificultam e impossibilitam algumas aplicações.

Nesta perspectiva, encontra-se esse trabalho com a proposta de realizar o desenvolvimento de serviços robóticos para atuação na mineração, sendo feita a apresentação de três estudos de caso aplicados: (i) **Dispersão de Etiquetas Eletrônicas**, (ii) **Investigação em Fotogrametria**, e (iii) **Inspeção Automatizada de Dutos**.

O primeiro estudo de caso, **Dispersão de Etiquetas Eletrônicas**, foi motivado pela necessidade de manter estável o processo de flotação da Usina do Salobo. Foi observado que conhecer a composição do minério desde o processo de desmonte é importante na estabilização do processo de flotação e, conseqüentemente, na qualidade final do produto. A atividade de rastreabilidade do minério já havia sido realizada por duas metodologias diferentes, contudo sem sucesso. Neste contexto, foi proposto o desenvolvimento de um dispositivo eletromecânico para ser acoplado a uma RPA com o objetivo de realizar dispersões tele-operadas que fossem capazes de auxiliar na atividade de rastreio. O Capítulo 3 apresenta o passo a passo deste desenvolvimento. Ao final deste estudo de caso, validou-se o dispositivo utilizado em ambiente real atingindo um nível 7 na escala TRL, determinou-se os parâmetros de execução da atividade (altura de 25 m, distância dos *waypoints* de 20 m e velocidade de 3 m/s) e solicitou-se um pedido de patente de invenção para o dispositivo e o método desenvolvido.

O segundo estudo de caso, **Investigação em Fotogrametria**, foi motivado pela necessidade de adequação às vigentes normas e resoluções ambientais para a exploração de cavernas e minas subterrâneas. Para tal, é necessária a realização da espeleologia do local de interesse, a fim de se obter informações a respeito das cavidades, antes de se iniciar quaisquer atividades de extração. Sabendo que uma das atividades da espeleologia é a modelagem 3D do ambiente,

viu-se a oportunidade de utilizar robôs móveis na execução da atividade. Neste contexto, foi proposta a realização de uma investigação quanto à técnica de fotogrametria, a partir de imagens obtidas pelo EspeleoRobô. O Capítulo 4 apresenta o passo a passo desta investigação. Primeiramente, o software AliceVision - Meshroom foi selecionado para este trabalho a partir de uma comparação com outros software. Em seguida, validou-se um fluxo alternativo de reconstrução 3D, com alterações nas operações de *FeatureMatching* e *StructureFromMotion*, e, também, utilizou-se o recurso *Augment Reconstruction*. Durante os procedimentos, observou-se duas particularidades quanto a execução da fotogrametria em ambientes com pouca iluminação: relação inversamente proporcional entre a rotação do robô e a definição do SfM e a relação diretamente proporcional entre o campo de visão e a qualidade da reconstrução. Por fim, através da comparação da fotogrametria com outros métodos de reconstrução 3D, foi possível notar que 99,7% dos pontos da nuvem de pontos da fotogrametria apresentam erros inferiores a 50 cm. Estes resultados demonstraram que a fotogrametria pode ser utilizada em ambientes subterrâneos e pode ser extrapolada a outros locais na mineração, que apresentam menos restrições.

O terceiro estudo de caso, **Inspecção Automatizada de Dutos**, foi motivado pela necessidade da realização de inspeção da tubulação de rejeitos da Mina do Salobo, que fica no interior da Floresta Amazônica. Quaisquer problemas nesta tubulação são capazes de interromper o complexo produtivo por horas e, até mesmo, dias. Atualmente, a atividade de inspeção é realizada de maneira manual e é limitada por conta dos perigos e da dificuldade de realizá-la em toda a sua extensão. Neste contexto, foi proposta a utilização do EspeleoRobô para a realização desta atividade, já que o robô poderia entrar na tubulação e inspecionar trechos maiores. O Capítulo 5 apresenta a proposta de um sistema para realizar a detecção automática de potenciais falhas precoces. Primeiramente, diferentes tipos de redes neurais foram testadas na detecção, das quais os modelos AlexNet, DenseNet, GoogLeNet, Inception V3, MobileNet V2, ResNet, ResNeXt, VGG e Wide ResNet apresentaram 100% de acurácia. Em seguida, foi realizada a validação visual dos resultados obtidos através do CAM. Nestes testes, a região com maior ativação coincidiu com a região do potencial defeito precoce. Na sequência, através de testes de tempo de execução, validou-se que as redes AlexNet, MobileNet V2 e ResNet apresentaram os menores tempos de processamento. E, para finalizar, foi aplicado o YOLOv3 sobre as juntas e obteve-se a detecção delas com alto grau de precisão, mAP de 94,4%. Estes resultados demonstram que é possível desenvolver um sistema automático para suporte à decisões na inspeções das tubulações.

Os trabalhos futuros são apresentados nos devidos capítulos autocontidos. Notadamente, as sugestões sobre o tema **Dispersão de Etiquetas Eletrônicas** podem ser vistos na Seção 3.5, sobre o tema **Investigação em Fotogrametria** na Seção 4.5, e sobre o tema **Inspecção Automatizada de Dutos** na Seção 5.5.



## 6.1. Contribuições

Durante o desenvolvimento das pesquisas relacionadas a dissertação, foi possível realizar contribuições para os eixos científicos, tecnológicos, industriais e sociais, das quais destacam-se:

### 6.1.1. Contribuições científicas

- Publicação de **artigo em periódico** (co-autoria): *Towards semi-autonomous robotic inspection and mapping in confined spaces with the EspeleoRobô* no *Journal of Intelligent and Robotic Systems*. Resultados deste artigo são parte do Capítulo 4;
- Publicação de **artigo de conferência** e apresentação: *Deep Learning for Early Damage Detection of Tailing Pipes Joints with a Robotic Device* no *CASE 2020 - International Conference on Automation Science and Engineering*. Resultados desta publicação são parte do Capítulo 5;
- Publicação de **artigo de conferência** (co-autoria): *Visão Computacional e Redes Neurais Convolucionais aplicadas à Detecção de Vazamentos de Óleo* no Congresso Brasileiro de Automática (CBA) 2020.
- Publicação e apresentação do **resumo**: *Investigation on Photogrammetry and LiDAR Models for Caves/Mines 3D Reconstruction* no *Fall Meeting 2019 - AGU* (União de Geofísica dos Estados Unidos). Resultados desta publicação são parte do Capítulo 4;

### 6.1.2. Contribuições tecnológicas

- Inventor no pedido de **patente da invenção**: *Dispositivo e método para lançamento de etiquetas eletrônicas sobre rocha desmontada a partir de um veículo aéreo não tripulado*. Resultados deste trabalho são parte do Capítulo 3;
- Autoria do **relatório técnico**: *Relatório de experimentos de campo na Mina do Salobo (2020)*. Resultados desta publicação são parte do Capítulo 3;
- Co-autoria do **relatório técnico**: *Dispositivo robótico para inspeção de ambientes restritos e confinados (2020)*. Parte dos conhecimentos adquiridos no relatório são utilizados Capítulo 4.
- Co-autoria do **relatório técnico**: *Inspeção da tubulação de rejeitos das usinas de Salobo (2019)*. Parte dos conhecimentos adquiridos no relatório são utilizados nos Capítulos 4 e 5;

### 6.1.3. Contribuições industriais

- Participação em operações de inspeção em Nova Lima e Brumadinho. Inspeções realizadas com EspeloRobô de forma teleoperada para captura de vídeos para análise de estrutura de galerias de barragens. Parte dos conhecimentos adquiridos na tarefa são utilizados no Capítulo 4.
- Participação em operação de inspeção em Salobo. Inspeção realizada com o Espeleo-Robô de forma teleoperada para captura de vídeos para análise de interior de tubulação de rejeitos da usina. Parte dos conhecimentos adquiridos nas tarefas são utilizados no Capítulo 5;
- Participação em operação com drone em Salobo. Atividade foi realizada com drone sobre materiais detonadas de forma manual e automatizada para validações do dispositivo lançador de etiquetas eletrônicas. Parte dos conhecimentos adquiridos nas tarefas são utilizados no Capítulo 3;
- Participação em operação com drone no Complexo Mineral de Mariana. Operação com drone sobre correias transportadoras para captura de vídeos termais dos rolos e correias transportadoras. Parte dos conhecimentos adquiridos na tarefa são utilizados no Capítulo 3;
- Treinamento de Operação de Drones para funcionários do ITV e Vale, abordando os seguintes temas: conceitos básicos, equipamentos embarcados, aplicações, legislação brasileira, planejamento e execução de voos manuais e automatizados. Parte dos conhecimentos adquiridos na tarefa são utilizados no Capítulo 3;
- Treinamento de Técnicas de Reconstrução 3D para turma Vale (Mina de Sossego, Canaã dos Carajás - PA) sobre aspectos teóricos e práticos para a reconstrução 3D de ambientes. Parte dos conhecimentos adquiridos na tarefa são utilizados no Capítulo 4.

### 6.1.4. Contribuições sociais

- Reconstrução 3D da Mina do Veloso<sup>1</sup> e disponibilização dos resultados aos proprietários da mina. Esta mina é uma atração turística na cidade de Ouro Preto - Minas Gerais;
- Palestra no Workshop de Sensoriamento Remoto realizado pelo ITV - 2019, com o tema de *Visão Computacional e Técnicas de Reconstrução 3D na Mineração*;
- Revisor de artigos e voluntário no 14º Simpósio Brasileiro de Automação Inteligente (SBAI) 2019;
- Revisor de artigos no VIII Simpósio Brasileiro de Sistemas Elétricos (SBSE) 2020.

---

<sup>1</sup><https://skfb.ly/6SLSV>

## REFERÊNCIAS BIBLIOGRÁFICAS

- AGHDAM, H. H.; HERAVI, E. J. **Guide to convolutional neural networks: a practical application to traffic-sign detection and classification** . Springer, 2017.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL - ANAC. Drones - Agência Nacional de Aviação Civil ANAC. Agosto 2020. Disponível em: <<https://www.anac.gov.br/assuntos/paginas-tematicas/drones>>.
- AGÊNCIA NACIONAL DE MINERAÇÃO - ANM. **Principais substâncias metálicas - Ano base 2019** . Brasília, Ministério de Minas e Energia, 2020.
- ALICEVISION. Meshroom: A 3D reconstruction software. Agosto 2020. Disponível em: <<https://github.com/alicevision/meshroom>>.
- ALICEVISION. Meshroom Manual. Março 2021. Disponível em: <<https://meshroom-manual.readthedocs.io/en/latest/>>.
- ALICEVISION MESHROOM. Photogrammetry Pipeline. 2019. Disponível em: <<https://alicevision.github.io/>>.
- ATTARAN, M. The rise of 3-D printing: The advantages of additive manufacturing over traditional manufacturing. **Business Horizons**, v. 60, n. 5, pp. 677 – 688, 2017. ISSN: 0007-6813. doi: <https://doi.org/10.1016/j.bushor.2017.05.011>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0007681317300897>>.
- AZPÚRUA, H.; POTJE, G. A.; REZECK, P. A.; FREITAS, G. M.; UZEDA GARCIA, L. G.; NASCIMENTO, E. R.; MACHARET, D. G.; CAMPOS, M. F. Cooperative digital magnetic-elevation maps by small autonomous aerial robots. **Journal of Field Robotics**, v. 36, n. 8, pp. 1378–1398, 2019. ISSN: 15564967. doi: 10.1002/rob.21909.
- AZPÚRUA, H.; REZENDE, A.; POTJE, G.; JUNIOR, G. P. D. C.; FERNANDES, R.; MIRANDA, V.; RESENDE FILHO, L. W. D.; DOMINGUES, J.; ROCHA, F.; MARTINS DE SOUZA, F. L.; DIAS DE BARROS, L. G.; NASCIMENTO, E. R.; MACHARET, D. G.; PESSIN, G.; FREITAS, G. M. Towards Semi-autonomous Robotic Inspection and Mapping in Confined Spaces with the EspeleoRobô. **Journal of**

**Intelligent & Robotic Systems**, v. 101, n. 4, pp. 69, abr. 2021. ISSN: 0921-0296, 1573-0409. doi: 10.1007/s10846-021-01321-5.

BASLER, Agosto 2020. Disponível em: <<https://www.baslerweb.com/en/company/news-press/news/tof-cameras-in-logistics-robotics-and-medicine/25154/>>.

BAZZANI, L.; BERGAMO, A.; ANGUELOV, D.; TORRESANI, L. Self-taught object localization with deep networks. Em: **2016 IEEE winter conference on applications of computer vision (WACV)**, pp. 1–9. IEEE, 2016.

BERMAN, B. 3-D printing: The new industrial revolution. **Business Horizons**, v. 55, n. 2, pp. 155 – 162, 2012. ISSN: 0007-6813. doi: <https://doi.org/10.1016/j.bushor.2011.11.003>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0007681311001790>>.

BESL, P. J. **Surfaces in Range Image Understanding** . Springer Series in Perception Engineering. 1 ed. , Springer-Verlag New York, 1988. ISBN: 978-1-4612-8396-6, 978-1-4612-3906-2.

BIANCO, G.; GALLO, A.; BRUNO, F.; MUZZUPAPPA, M. A Comparative Analysis between Active and Passive Techniques for Underwater 3D Reconstruction of Close-Range Objects. **Sensors**, v. 13, n. 8, pp. 11007–11031, ago. 2013. doi: 10.3390/s130811007. Disponível em: <<https://doi.org/10.3390/s130811007>>.

BILJECKI, F.; STOTER, J.; LEDOUX, H.; ZLATANOVA, S.; ÇÖLTEKIN, A. Applications of 3D city models: State of the art review. **ISPRS International Journal of Geo-Information**, v. 4, n. 4, pp. 2842–2889, 2015. ISSN: 22209964. doi: 10.3390/ijgi4042842.

BOGUE, R. 3D printing: the dawn of a new era in manufacturing? **Assembly Automation**, v. 33, n. 4, pp. 307–311, Jan 2013. ISSN: 0144-5154. doi: 10.1108/AA-06-2013-055. Disponível em: <<https://doi.org/10.1108/AA-06-2013-055>>.

BRADSKI, G. The OpenCV Library. **Dr. Dobb's Journal of Software Tools**, 2000.

BROWNLEE, J. A Gentle Introduction to Transfer Learning for Deep Learning. 2017. Disponível em: <<https://machinelearningmastery.com/transfer-learning-for-deep-learning/>>.

BUDUMA, N.; LOCASCIO, N. **Fundamentals of deep learning: Designing next-generation machine intelligence algorithms** . “O'Reilly Media, Inc.”, 2017.

- BURGARD, W.; HEBERT, M.; BENNEWITZ, M. World Modeling. Em: Bruno Siciliano, O. K. (Ed.), **Springer Handbook of Robotics**, 2 ed., Springer International Publishing, cap. 45, pp. 1135–1152, Heidelberg, 2016.
- CARTOLA V. Laser Scanner vs Structured Light. Setembro 2020. Disponível em: <[https://www.3dnatives.com/en/laser-3d-scanner-vs-structured-light-3d-scanner-080820194/#!](https://www.3dnatives.com/en/laser-3d-scanner-vs-structured-light-3d-scanner-080820194/#!>)>.
- CHEN, K.; HU, H.; CHEN, C.; CHEN, L.; HE, C. An Intelligent Sewer Defect Detection Method Based on Convolutional Neural Network. Em: **2018 IEEE International Conference on Information and Automation (ICIA)**, pp. 1301–1306, Aug 2018. doi: 10.1109/ICInfA.2018.8812445.
- CHOLLET, F. **Deep Learning with Python**. USA, Manning, 2018. ISBN: 9781617294433.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, pp. 79 – 97, 2014. ISSN: 0924-2716. doi: <https://doi.org/10.1016/j.isprsjprs.2014.02.013>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0924271614000501>>.
- COSTA, Y. D. Morcego. 2012. Disponível em: <<https://www.infoescola.com/animais/morcego/>>.
- COTA, E. **Implementação e Avaliação de Técnicas de Odometria Aplicadas a um Dispositivo Robótico Móvel**. Dissertação de Mestrado, Universidade Federal de Ouro Preto, Ouro Preto, Abril 2019.
- COXWORTH, B., Outubro 2020. Disponível em: <<https://newatlas.com/robotics/anymal-quadruped-robot-wheels/>>.
- DARPA. Subterranean Challenge. Agosto 2020. Disponível em: <<https://www.subtchallenge.com/#top>>.
- DE SOUZA, D. Sistema desenvolvido pela coppe/ufRJ para detectar manchas de óleo será testado no mar em dezembro. Setembro 2020. Disponível em: <<https://petronoticias.com.br/sistema-desenvolvido-pela-coppeufRJ-para-detectar-manchas-de-oleo-sera-testado-no-mar-em-dezembro/>>.
- DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO - DECEA. DRONE (RPAS) - Departamento de Controle do Espaço Aéreo. Agosto 2020. Disponível em: <<https://www.decea.gov.br/drone/>>.
- DJI. Inspire 1 - Specs. Agosto 2020a. Disponível em: <<https://www.dji.com/br/inspire-1/info>>.

- DJI. Matrice 300 RTK. Agosto 2020b. Disponível em: <<https://www.dji.com/br/matrice-300>>.
- DJI. Inspire 1 - User Manual. Junho 2021. Disponível em: <[https://dl.djicdn.com/downloads/inspire\\_1/en/Inspire\\_1\\_User\\_Manual\\_en\\_v2.0\\_1218.pdf](https://dl.djicdn.com/downloads/inspire_1/en/Inspire_1_User_Manual_en_v2.0_1218.pdf)>.
- DRING, B. Uma impressora 3D ORDbot Quantum. Fevereiro 2021. Disponível em: <[https://pt.wikipedia.org/wiki/Impress%C3%A3o\\_3D#/media/Ficheiro:ORDbot\\_quantum.jpg](https://pt.wikipedia.org/wiki/Impress%C3%A3o_3D#/media/Ficheiro:ORDbot_quantum.jpg)>.
- EDWARDS, D. Robotic lawn mower market forecast to grow to \$1.3 billion. Agosto 2020. Disponível em: <<https://roboticsandautomationnews.com/2019/04/29/robotic-lawn-mower-market-forecast-to-grow-to-1-3-billion/22080/>>.
- ELIJAH, O.; RAHMAN, T. A.; ORIKUMHI, I.; LEOW, C. Y.; HINDIA, M. N. An Overview of Internet of Things (IoT) and Data Analytics in Agriculture: Benefits and Challenges. **IEEE Internet of Things Journal**, v. 5, n. 5, pp. 3758–3773, 2018.
- EULITZ, M.; REISS, G. 3D reconstruction of SEM images by use of optical photogrammetry software. **Journal of Structural Biology**, v. 191, n. 2, pp. 190–196, 2015. ISSN: 10958657. doi: 10.1016/j.jsb.2015.06.010. Disponível em: <<http://dx.doi.org/10.1016/j.jsb.2015.06.010>>.
- FIGUEIROA, W. G. Espeleologia. Julho 2004. Disponível em: <<https://www.infoescola.com/animais/morcego/>>.
- FREIRE, G.; COTA, R. Capture of images in inaccessible areas in an underground mine using an unmanned aerial vehicle. Em: **Proceedings of the First International Conference on Underground Mining Technology**. Australian Centre for Geomechanics, 2017. ISBN: 9780992481070. doi: 10.36487/acg\_rep/1710\_54\_freire.
- FREITAS, G.; MARTINS, A.; MIRANDA, V. R. F.; CRUZ JUNIOR, G. P.; SILVA, R. F. G.; FANY, C.; AMARAL, I.; MARQUES, S. D.; MATOS, L. V. C.; ARAUJO, A. R.; AZPURUA, H.; ROCHA, F.; GARCIA, G.; SANTOS, A. S.; MAGNO, A.; RESENDE FILHO, L. W.; DOMINGUES, J.; SOUZA, F. L. M.; PESSIN, G. **Dispositivo robótico para inspeção de ambientes restritos e confinados**. Relatório técnico, Instituto Tecnológico Vale, 2020a. doi: DOI:10.29223/PROD.TEC.ITV.MI.2020.2.FREITAS.
- FREITAS, H.; FAIÇAL, B. S.; CARDOSO E SILVA, A. V.; UEYAMA, J. Use of UAVs for an efficient capsule distribution and smart path planning for biological pest control. **Computers and Electronics in Agriculture**, v. 173, pp. 105387,

- 2020b. ISSN: 0168-1699. doi: <https://doi.org/10.1016/j.compag.2020.105387>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0168169919323488>>.
- GANEGEDARA, H.; ALAHAKOON, D.; MASHFORD, J.; PAPLINSKI, A.; MÜLLER, K.; DESERNO, T. M. Self organising map based region of interest labelling for automated defect identification in large sewer pipe image collections. Em: **The 2012 International Joint Conference on Neural Networks (IJCNN)**, pp. 1–8, June 2012. doi: 10.1109/IJCNN.2012.6252482.
- GONZÁLEZ, I.; CALDERÓN, A. J. Integration of open source hardware Arduino platform in automation systems applied to Smart Grids/Micro-Grids. **Sustainable Energy Technologies and Assessments**, v. 36, n. July, pp. 100557, 2019. ISSN: 22131388. doi: 10.1016/j.seta.2019.100557. Disponível em: <https://doi.org/10.1016/j.seta.2019.100557>>.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning** . MIT press, 2016.
- GOOGLE EARTH, Setembro 2020. Disponível em: <https://www.google.com/earth/>>.
- GUIZZO, E. Your Next Salad Could Be Grown by a Robot. Setembro 2020. Disponível em: <https://spectrum.ieee.org/robotics/industrial-robots/your-next-salad-could-be-grown-by-a-robot>>.
- HAYKIN, S. S. **Neural networks and learning machines** , v. 3. Pearson Upper Saddle River, 2009.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. Em: **Proceedings of the IEEE conference on computer vision and pattern recognition**, pp. 770–778, 2016.
- HIRSCHMULLER, H. Accurate and efficient stereo processing by semi-global matching and mutual information. Em: **2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**, v. 2, pp. 807–814 vol. 2, 2005.
- HUANG, G.; LIU, Z.; VAN DER MAATEN, L.; WEINBERGER, K. Q. Densely connected convolutional networks. Em: **Proceedings of the IEEE conference on computer vision and pattern recognition**, pp. 4700–4708, 2017.
- IANZOLA, F. N.; HAN, S.; MOSKEWICZ, M. W.; ASHRAF, K.; DALLY, W. J.; KEUTZER, K. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. Janeiro 2020. Disponível em: <https://arxiv.org/abs/1602.07360>>.



- JANCOSEK, M.; PAJDLA, T. Exploiting Visibility Information in Surface Reconstruction to Preserve Weakly Supported Surfaces. **International Scholarly Research Notices**, v. 2014, pp. 1–20, 2014. ISSN: 2356-7872. doi: 10.1155/2014/798595.
- JAULIN, L. **Mobile Robotics**. Hoboken, NJ, Wiley, set. 2019. doi: 10.1002/9781119663546. Disponível em: <<https://doi.org/10.1002/9781119663546>>.
- KAKOGAWA, A.; OKA, Y.; MA, S. Multi-link Articulated Wheeled In-pipe Robot with Underactuated Twisting Joints. Em: **2018 IEEE International Conference on Mechatronics and Automation (ICMA)**, pp. 942–947. IEEE, 2018.
- KHARCHENKO, V.; CHYRKA, I. Detection of Airplanes on the Ground Using YOLO Neural Network. Em: **2018 IEEE 17th International Conference on Mathematical Methods in Electromagnetic Theory (MMET)**, pp. 294–297, July 2018. doi: 10.1109/MMET.2018.8460392.
- KRIZHEVSKY, A. One weird trick for parallelizing convolutional neural networks. Fevereiro 2020. Disponível em: <<https://www.infoescola.com/animais/morcego/>>.
- LAI, K.; BO, L.; REN, X.; FOX, D. RGB-D (Kinect) Object Dataset. Setembro 2020. Disponível em: <<https://rgbd-dataset.cs.washington.edu/>>.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, pp. 2278–2324, 1998.
- LEE, S.; CHOI, Y. Reviews of unmanned aerial vehicle (drone) technology trends and its applications in the mining industry. **Geosystem Engineering**, v. 19, n. 4, pp. 197–204, 2016. doi: 10.1080/12269328.2016.1162115. Disponível em: <<https://doi.org/10.1080/12269328.2016.1162115>>.
- LÉVY, B.; PETITJEAN, S.; RAY, N.; MAILLOT, J. Least squares conformal maps for automatic texture atlas generation. **Proceedings of the 29th Annual Conference on Computer Graphics and Interactive Techniques, SIGGRAPH '02**, pp. 362–371, 2002. doi: 10.1145/566570.566590.
- LI, A.; YE, D.; LYU, E.; SONG, S.; MENG, M. Q.; DE SILVA, C. W. RGB-Thermal Fusion Network for Leakage Detection of Crude Oil Transmission Pipes. Em: **2019 IEEE International Conference on Robotics and Biomimetics (ROBIO)**, pp. 883–888, Dec 2019.
- LI, T.; ASPLER, J.; KINGSLAND, A.; CORMIER, L. M.; ZOU, X. 3D Printing – A Review Of Technologies, Markets, And Opportunities For The Forest Industry. **Journal of Science & Technology for Forest Products and Processes**, v. 5, n. 2, 2016.

- LI, Y.; LI, M.; ZHU, H.; HU, E.; TANG, C.; LI, P.; YOU, S. Development and applications of rescue robots for explosion accidents in coal mines. **Journal of Field Robotics**, v. 37, n. 3, pp. 466–489, 2020. ISSN: 15564967. doi: 10.1002/rob.21920.
- LIANQIAO, L.; XIAI, C.; HUILI, Z.; LING, W. Recognition and Application of Infrared Thermal Image Among Power Facilities Based on YOLO. Em: **2019 Chinese Control And Decision Conference (CCDC)**, pp. 5939–5943. IEEE, 2019.
- LOJA DRONE MANIA. Inspire 1 Pro. Agosto 2020. Disponível em: <<https://lojadronemania.com.br/produto/drone-dji-inspire-1-pro/>>.
- LOW, D. G. Distinctive image features from scale-invariant keypoints. **International Journal of Computer Vision**, pp. 91–110, 2004. Disponível em: <<https://www.cs.ubc.ca/{~}lowe/papers/ijcv04.pdf>>.
- MA, N.; ZHANG, X.; ZHENG, H.-T.; SUN, J. Shufflenet v2: Practical guidelines for efficient cnn architecture design. Em: **Proceedings of the European Conference on Computer Vision (ECCV)**, pp. 116–131, 2018.
- MAGNO, A.; THIAGO, N. C. S.; CID, A. M.; SATHLER, M. S.; RESENDE FILHO, L. W.; NAZÁRIO, M.; TORRES, M. C. D.; AZPURUA, H.; PESSIN, G. **Inspeção da Tubulação de Rejeitos das Usinas de Salobo Set/2019**. Relatório técnico, Instituto Tecnológico Vale, 2019. doi: DOI:10.29223/PROD.TEC.ITV.MI.2019.50.Magno.
- MAIMONE, M. W.; MATTHIES, L. Visual odometry on the Mars exploration rovers - a tool to ensure accurate driving and science imaging. **IEEE Robotics Automation Magazine**, v. 13, n. 2, pp. 54–62, June 2006. ISSN: 1070-9932. doi: 10.1109/MRA.2006.1638016.
- MASCARICH, F.; KHATTAK, S.; PAPACHRISTOS, C.; ALEXIS, K. A multi-modal mapping unit for autonomous exploration and mapping of underground tunnels. Em: **2018 IEEE Aerospace Conference**, pp. 1–7, 2018.
- MASUTA, H.; WATANABE, H.; SATO, K.; LIM, H. Recognition of branch pipe for pipe inspection robot using fiber grating vision sensor. Em: **2013 10th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)**, pp. 633–638, Oct 2013. doi: 10.1109/URAI.2013.6677411.
- MCGILL, S. G.; YI, S. J.; YI, H.; AHN, M. S.; CHO, S.; LIU, K.; SUN, D.; LEE, B.; JEONG, H.; HUH, J.; HONG, D.; LEE, D. D. Team THOR’s Entry in the DARPA Robotics Challenge Finals 2015. **Journal of Field Robotics**, v. 34, n. 4, pp. 775–801, 2017. ISSN: 15564967. doi: 10.1002/rob.21672.

- MINISTÉRIO DE MINAS E ENERGIA. Novas regras para o setor de mineração vão estimular investimentos e reduzir impactos ambientais. Junho 2018. Disponível em: <[http://www.mme.gov.br/web/guest/pagina-inicial/outras-noticias/-/asset\\_publisher/32hLr0zMKwWb/content/novas-regras-para-o-setor-de-mineracao-vao-estimular-investimentos-e-reduzir-impactos-ambientais](http://www.mme.gov.br/web/guest/pagina-inicial/outras-noticias/-/asset_publisher/32hLr0zMKwWb/content/novas-regras-para-o-setor-de-mineracao-vao-estimular-investimentos-e-reduzir-impactos-ambientais)>.
- MONTEIRO, F. A. D. Projeto de implantação de conhecimentos, práticas e legislação pertinentes à espeleologia na Superintendência Estadual do Meio Ambiente – SEMACE. **Anais do 31º Congresso Brasileiro de Espeleologia**, pp. 263–267, Junho 2011.
- MOULON, P.; MONASSE, P.; MARLET, R. Global Fusion of Relative Motions for Robust, Accurate and Scalable Structure from Motion. Em: **2013 IEEE International Conference on Computer Vision**, pp. 3248–3255, 2013.
- NASCIMENTO, R.; CARVALHO, R.; DELABRIDA, S.; BIANCHI, A.; OLIVEIRA, R. A. R.; GARCIA, L. G. U. An Integrated Inspection System for Belt Conveyor Rollers - Advancing in an Enterprise Architecture. Em: **Proceedings of the 19th International Conference on Enterprise Information Systems - Volume 2: ICEIS**, pp. 190–200. INSTICC, SciTePress, 2017. ISBN: 978-989-758-248-6. doi: 10.5220/0006369101900200.
- NET COMPUTADORES. Arduino UNO-R3. Agosto 2020. Disponível em: <<https://netcomputadores.com.br/p/aunor3-arduino-uno-r3-/14715>>.
- NISTER, D.; STEWENIUS, H. Scalable Recognition with a Vocabulary Tree. Em: **2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)**, v. 2, pp. 2161–2168, 2006.
- NUSSEY, J. **Arduino For Dummies**. For Dummies (Computer/Tech). West Sussex, For Dummies, 2013. ISBN: 1118446372, 9781118446379.
- OHSNMAN, A. Tesla Has a Little to Show in California Autonomous Car Data Tally. Setembro 2020. Disponível em: <<https://www.forbes.com/sites/alanohnsman/2017/02/01/tesla-has-little-to-show-in-californias-tally-of-autonomous-car-test-data/#6df0afcd6a48>>.
- PASZKE, A.; GROSS, S.; MASSA, F.; LERER, A.; BRADBURY, J.; CHANAN, G.; KILLEEN, T.; LIN, Z.; GIMELSHEIN, N.; ANTIGA, L.; DESMAISON, A.; KOPF, A.; YANG, E.; DEVITO, Z.; RAISON, M.; TEJANI, A.; CHILAMKURTHY, S.; STEINER, B.; FANG, L.; BAI, J.; CHINTALA, S. PyTorch: An Imperative Style, High-Performance Deep Learning Library. Em: Wallach, H.; Larochelle, H.;

- Beygelzimer, A.; d'Alché-Buc, F.; Fox, E.; Garnett, R. (Eds.), **Advances in Neural Information Processing Systems 32**, pp. 8024–8035. Curran Associates, Inc., 2019. Disponível em: <<http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-library.pdf>>.
- PÉREZ D.; ALARCÓN F.; BOZA A. Industry 4.0: A classification. **International Joint Conference - (IJC 2016)**, pp. 161–168, 2016. doi: 10.1007/978-3-319-58409-6. Disponível em: <<http://link.springer.com/10.1007/978-3-319-58409-6>>.
- RECTRIX DRONE SERVICES. Flyability Elios. Setembro 2020. Disponível em: <<https://rectrixdrones.com/product/flyability-elios/>>.
- REDMON, J.; FARHADI, A. YOLOv3: An Incremental Improvement. Janeiro 2020. Disponível em: <<https://arxiv.org/abs/1804.02767>>.
- REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. Em: **Proceedings of the IEEE conference on computer vision and pattern recognition**, pp. 779–788, 2016.
- RESENDE FILHO, L. W.; DOMINGUES, J. D.; AZPÚRUA, H.; CORREA PABÓN, R. E.; PESSIN, G.; PRZEWODOWSKI, A.; OSÓRIO, F. S. Investigation on Photogrammetry and LiDAR Models for Caves/Mines 3D Reconstruction. Em: **AGU Fall Meeting Abstracts**, v. 2019, pp. P41C–3475, dez. 2019.
- RESENDE FILHO, L. W.; DIAS BARROS, L. G.; ALVES, P. H. T. F.; PESSIN, G.; GARCIA, G.; NASCIMENTO, R. G.; TORRES, A.; LIMA, M.; ALMEIDA, L.; SANTOS, I.; MAGNA, M. **Relatório de experimentos de campo na Mina do Salobo**. Relatório técnico, Instituto Tecnológico Vale, 2020. doi: DOI:10.29223/PROD.TEC.ITV.MI.2020.14.ResendeFilho.
- RESENDE FILHO, L. W.; SANTOS, A. A.; AZPÚRUA, H.; GARCIA, G. C.; PESSIN, G. Deep Learning for Early Damage Detection of Tailing Pipes Joints with a Robotic Device. Em: **2020 IEEE 16th International Conference on Automation Science and Engineering (CASE)**, pp. 1441–1446, 2020. doi: 10.1109/CASE48305.2020.9216881.
- RESENDE FILHO, L. W.; DIAS BARROS, L. G.; ALVES, P. H. T. F.; ROCHA, F.; PESSIN, G.; GARCIA, G.; NASCIMENTO, R. G.; TORRES, A.; LIMA, M.; ALMEIDA, L.; SANTOS, I.; MAGNA, M. **Dispositivo e método para lançamento de etiquetas eletrônicas sobre rocha desmontada a partir de um veículo aéreo não tripulado** Pedido de Invenção BR 10 2021 005143 4, Março 2021. Disponível em: <<https://busca.inpi.gov.br/pePI/servlet/PatenteServletController?Action=>

detail&CodPedido=1606523&SearchParameter=BR%2010%202021%  
20005143%204%20%20%20%20%20%20%20&Resumo=&Titulo=>.

SANDLER, M.; HOWARD, A.; ZHU, M.; ZHMOGINOV, A.; CHEN, L.-C. Mobilenetv2: Inverted residuals and linear bottlenecks. Em: **Proceedings of the IEEE conference on computer vision and pattern recognition**, pp. 4510–4520, 2018.

SERISIER, M. Case Study: Metso Minerals RFID Tags. Agosto 2020. Disponível em: <<https://dienamics.com.au/blog/case-study-metso-minerals-rfid-tags/>>.

SHAHMORADI, J.; TALEBI, E.; ROGHANCHI, P.; HASSANALIAN, M. A Comprehensive Review of Applications of Drone Technology in the Mining Industry. **Drones**, v. 4, n. 3, pp. 34, 2020. ISSN: 2504-446X. doi: 10.3390/drones4030034.

SHIBATA, T. An overview of human interactive robots for psychological enrichment. **Proceedings of the IEEE**, v. 92, n. 11, pp. 1749–1758, 2004. ISSN: 00189219. doi: 10.1109/JPROC.2004.835383.

SIEGWART, R.; NOURBAKHSH, I. R.; SCARAMUZZA, D. **Introduction to autonomous mobile robots**. Intelligent Robotics and Autonomous Agents. 2nd ed. , MIT Press, 2011. ISBN: 9780262295321,0262295326.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. Janeiro 2020. Disponível em: <<https://arxiv.org/abs/1409.1556>>.

SNEHA S. 3D Measure UP. Dezembro 2019. Disponível em: <<https://www.prototechsolutions.com/blog/point-cloud-visualization/>>.

STEREO LABS. ZED Stereo Camera. Setembro 2020. Disponível em: <<https://www.stereolabs.com/zed/>>.

SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCKE, V.; RABINOVICH, A. Going deeper with convolutions. Em: **Proceedings of the IEEE conference on computer vision and pattern recognition**, pp. 1–9, 2015.

SZEGEDY, C.; VANHOUCKE, V.; IOFFE, S.; SHLENS, J.; WOJNA, Z. Rethinking the inception architecture for computer vision. Em: **Proceedings of the IEEE conference on computer vision and pattern recognition**, pp. 2818–2826, 2016.

TANG, L.; SHAO, G. Drone remote sensing for forestry research and practices. **Journal of Forestry Research**, v. 26, n. 4, pp. 791–797, Dec 2015. ISSN: 1993-0607.

doi: 10.1007/s11676-015-0088-y. Disponível em: <<https://doi.org/10.1007/s11676-015-0088-y>>.

TARDELLA, N. Earthbound Robots Today Need to Take Flight. Setembro 2020. Disponível em: <<https://spectrum.ieee.org/automaton/robotics/industrial-robots/earthbound-robots-today-need-to-take-flight>>.

THRUN, S.; THAYER, S.; WHITTAKER, W.; BAKER, C.; BURGARD, W.; FERGUSON, D.; HAHNEL, D.; MONTEMERLO, D.; MORRIS, A.; OMOHUNDRO, Z.; REVERTE, C.; WHITTAKER W. Autonomous exploration and mapping of abandoned mines. **IEEE Robotics Automation Magazine**, v. 11, n. 4, pp. 79–91, 2004.

TOPSKY. Robô de desarmamento da bomba de ER3 EOD, bomba explosiva flexível que difunde o robô. Agosto 2020. Disponível em: <<http://portuguese.counterterrorismequipment.com/sale-9800278-er3-eod-bomb-disarming-robot-flexible-explosive-bomb-diffusing-robot.html>>.

TORREY, L.; SHAVLIK, J. Transfer learning. Em: **Handbook Of Research On Machine Learning Applications and Trends: Algorithms, Methods and Techniques - 2 Volumes**, Information Science Reference - Imprint of: IGI Publishing, Hershey, PA, 2009. ISBN: 1605667668.

TRIEBEL, R.; PFAFF, P.; BURGARD, W. Multi-Level Surface Maps for Outdoor Terrain Mapping and Loop Closing. Em: **International Conference on Intelligent Robots and Systems, IROS**, Beijing, China, 2006.

VAIDYA, S.; AMBAD, P.; BHOSLE, S. Industry 4.0 - A Glimpse. **Procedia Manufacturing**, v. 20, pp. 233–238, 2018. ISSN: 23519789. doi: 10.1016/j.promfg.2018.02.034. Disponível em: <<https://doi.org/10.1016/j.promfg.2018.02.034>>.

VALE. Vale terá a primeira mina operando somente com caminhões autônomos no Brasil. Setembro 2020. Disponível em: <<http://www.vale.com/brasil/PT/aboutvale/news/Paginas/vale-tera-a-primeira-mina-operando-somente-com-caminhoes-autonomos-no-brasil.aspx>>.

VALE. Conheça Salobo, o maior projeto de cobre da Vale. Agosto 2020. Disponível em: <<http://www.vale.com/brasil/PT/aboutvale/news/Paginas/conheca-salobo-maior-projeto-cobre-vale.aspx>>.

VELODYNE, Agosto 2020. Disponível em: <<https://velodynelidar.com/products/puck/>>.

- WAHED, M. A. A.; ARSHAD, M. R. Wall-press type pipe inspection robot. Em: **2017 IEEE 2nd International Conference on Automatic Control and Intelligent Systems (I2CACIS)**, pp. 185–190. IEEE, 2017.
- XIE, S.; GIRSHICK, R.; DOLLÁR, P.; TU, Z.; HE, K. Aggregated residual transformations for deep neural networks. Em: **Proceedings of the IEEE conference on computer vision and pattern recognition**, pp. 1492–1500, 2017.
- 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. ISSN: 2363-6912. doi: 10.1007/s40903-015-0032-7.
- ZAGORUYKO, S.; KOMODAKIS, N. Wide residual networks. Janeiro 2020. Disponível em: <https://arxiv.org/abs/1605.07146>.
- ZANUTTIGH, P.; MARIN, G.; DAL MUTTO, C.; DOMINIO, F.; MINTO, L.; CORTELAZZO, G. M. **Time-of-Flight and Structured Light Depth Cameras: Technology and Applications**. 1 ed., Springer International Publishing, 2016. ISBN: 978-3-319-30971-2, 978-3-319-30973-6.
- ZHANG, J. Deep Transfer Learning via Restricted Boltzmann Machine for Document Classification. Em: **2011 10th International Conference on Machine Learning and Applications and Workshops**, v. 1, pp. 323–326, Dec 2011. doi: 10.1109/ICMLA.2011.51.
- ZHOU, B.; KHOSLA, A.; A., L.; OLIVA, A.; TORRALBA, A. Learning Deep Features for Discriminative Localization. **CVPR**, 2016.



# APÊNDICE A: ESTRUTURA MECÂNICA DO DISPOSITIVO LANÇADOR DE ETIQUETAS ELETRÔNICAS RFID




Figura A1: Principais vistas da estrutura mecânica do dispositivo lançador de etiquetas eletrônicas RFID.

Fonte: adaptado de acervo ITV.

# APÊNDICE B: FLUXOS DE RECONSTRUÇÕES 3D

## Fluxo padrão de reconstrução 3D por AliceVision - Meshroom




Figura B1: Fluxo de reconstrução 3D no software AliceVision - Meshroom.

Fonte: AliceVision (2020).

## Fluxo de reconstrução 3D proposto

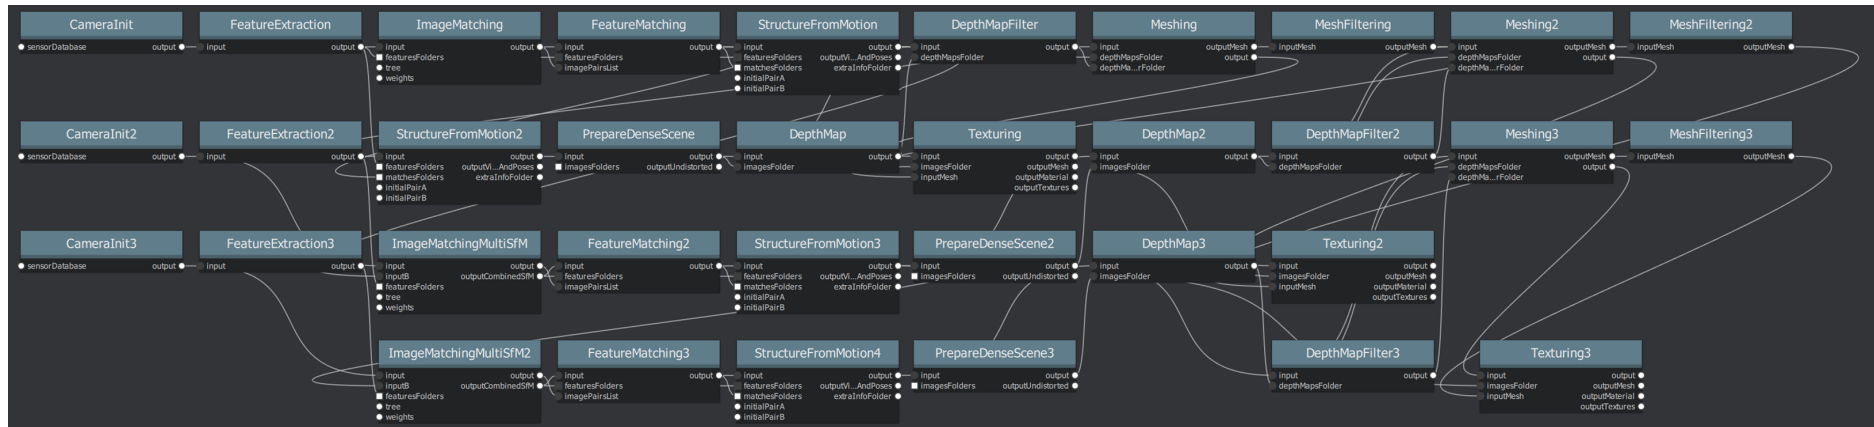


Figura B2: Fluxo de reconstrução 3D proposto para minimizar limitações do ambiente.

Fonte: adaptado de AliceVision (2020).