


UNIVERSIDADE DE LISBOA
FACULDADE DE CIÊNCIAS



Ciências
ULisboa

**Métodos de classificação de nuvens de pontos recolhidas por sistemas LiDAR
móveis, para a geração de modelos digitais de terreno, a grandes escalas**

“ Documento Definitivo ”

Doutoramento em Ciências Geofísicas e da Geoinformação

Especialidade em Engenharia Geográfica

Luis Filipe Júlio Gézero

Tese orientada por:

Doutor Carlos Manuel Correia Antunes

Documento especialmente elaborado para a obtenção do grau de doutor

2020

UNIVERSIDADE DE LISBOA

FACULDADE DE CIÊNCIAS



**Ciências
ULisboa**

**Métodos de classificação de nuvens de pontos recolhidas por sistemas LiDAR móveis,
para a geração de modelos digitais de terreno, a grandes escalas**

Doutoramento em Ciências Geofísicas e da Geoinformação

Especialidade em Engenharia Geográfica

Luis Filipe Júlio Gézero

Tese orientada por:

Doutor Carlos Manuel Correia Antunes

Júri:

Presidente:

- Doutor João Manuel de Almeida Serra, Professor Catedrático e Presidente do Departamento de Engenharia Geográfica, Geofísica e Energia da Faculdade de Ciências da Universidade de Lisboa;

Vogais:

- Doutora Cidália Maria Parreira da Costa Fonte, Professora Auxiliar da Faculdade de Ciências e Tecnologia da Universidade de Coimbra;
- Doutor José Alberto Álvares Pereira Gonçalves, Professor Auxiliar da Faculdade de Ciências da Universidade do Porto;
- Doutor João Carlos da Costa Catalão Fernandes, Professor Associado com Agregação da Faculdade de Ciências da Universidade de Lisboa;
- Doutora Paula Maria Ferreira de Sousa Cruz Redweik, Professora Auxiliar da Faculdade de Ciências da Universidade de Lisboa;
- Doutor Carlos Manuel Correia Antunes, Professor Auxiliar da Faculdade de Ciências da Universidade de Lisboa;

Documento especialmente elaborado para a obtenção do grau de doutor

Resumo

A tecnologia LiDAR (*Light Detection And Ranging*) tem-se revelado nos últimos anos como sendo uma técnica bastante eficaz na aquisição de dados geoespaciais. A instalação destes sistemas em plataformas sobre veículos terrestres permite uma elevada rapidez na recolha de nuvens de pontos, por vezes limitada apenas pela velocidade do próprio veículo.

A obtenção de dados de base (pontos de cota e linhas de quebra), para a geração de MDT (Modelos Digitais do Terreno) a grandes escalas é normalmente um processo bastante moroso e conseqüentemente dispendioso. A utilização das nuvens de pontos recolhidas por sistemas LiDAR moveis terrestre surge assim, naturalmente, como uma possível solução eficiente para a obtenção desse tipo de dados. No entanto, as nuvens de pontos recolhidas por estes sistemas, são não-seletivas, sendo necessário efetuar a classificação e segmentação desses dados. A classificação dos pontos da nuvem que representam a superfície do terreno e a sua segmentação de forma a identificar e restituir as linhas de quebra é um desafio em aberto que continua a despertar o interesse dos investigadores. Ao longo deste trabalho pretende-se contribuir para a resposta a esse desafio, propondo e testando diversos métodos inovadores para a classificação e extração de pontos das nuvens recolhidas por sistemas LiDAR móveis terrestres, com o objetivo de geração de MDT a grandes escalas. Ao contrário da maioria dos algoritmos existentes na literatura, em que apenas são utilizadas as coordenadas tridimensionais dos pontos, a maioria dos algoritmos aqui propostos tiraram partido dos princípios de funcionamento dos sistemas e dos dados associados a cada um dos pontos da nuvem. Os algoritmos propostos, têm ainda em consideração a eficiência na obtenção dos dados mínimos e suficientes para a representação da forma do terreno a uma determinada escala. Sendo mantido o paradigma estabelecido pela maioria dos utilizadores e produtores de informação geográfica, na utilização de pontos de cota e linhas de quebra, para a geração de MDT a grandes escalas. É ainda proposto um método para a extração de linhas tridimensionais a partir de nuvens de pontos obtidas ao longo de infraestruturas ferroviárias. Finalmente, tendo em conta que, os perfis transversais a grandes escalas representam o atual paradigma para a modelação do terreno como base para projetos de execução de vias lineares, nomeadamente, rodoviárias e ferroviárias. É apresentado um estudo comparativo de várias estratégias propostas para o agrupamento dos pontos das nuvens com vista à criação desses perfis transversais.

Palavras-chave: Sistemas LiDAR móveis terrestres, Modelos digitais do terreno, Nuvens de pontos, Linhas de quebra, Secções transversais.

Abstract

LiDAR (Light Detection And Ranging) technology, revealed in recent years, to be a very effective technique in the acquisition of geospatial information. The installation of these systems on land vehicles allows a high information collection speed of point clouds, often limited only by the speed of the vehicle itself.

Obtaining basic information (height points and break lines) for digital terrain models generation, is usually a very time-consuming task and consequently an expensive process. The use of point clouds collected by terrestrial mobile LiDAR systems, naturally emerges as a possible efficient solution to obtain this type of information.

However, the point clouds collected by these systems are non-selective, and it is necessary to classify and segment this information. The classification of cloud points representing the surface of the terrain and the segmentation of information in order to identify and restore their break lines is an open challenge that continues to stimulate the researcher's interest.

Throughout this work, its intended to contribute to answer to this challenge, by proposing and testing several innovative methods, for the classification and extraction of information from point clouds collected by terrestrial mobile LiDAR systems, for digital terrain models creation

Most of the proposed algorithms take advantage of the principles of system operation and the information stored for each cloud point. Instead of most existing algorithms in the literature, where only the points three-dimensional coordinates are used.

The proposed algorithms also consider the efficiency in obtain, the minimum and necessary information, to represent the terrain shape at a given scale. Being maintained the paradigm established by the majority of users and producers of geographic information, in the use of height points and break lines, for digital terrain models representation.

A method is also presented for the particular case of the use of these systems on railway lines. Finally, considering, that the use of cross sections represents the terrain modelling, current paradigm, for linear infrastructures projects, namely roads and railways. A comparative study of several strategies proposed for cloud points group, is presented, in way to create these cross sections.

Keywords: Terrestrial mobile LiDAR Systems, Digital Terrain Models, Point Clouds, Break Lines, Terrain cross sections.

Agradecimentos

Em primeiro lugar gostaria de deixar um agradecimento especial ao meu orientador, Professor Doutor Carlos Antunes, que me deu apoio na realização deste trabalho desde o primeiro ao último minuto. Um agradecimento especial à Sara Ribeiro, por todo o apoio, conselhos e paciência para a revisão dos textos. Um agradecimento adicional à Professora Doutora Paula Redweik pelos comentários construtivos ao longo dos seminários e pelas correções à versão provisória que permitiram a melhoria da versão definitiva deste trabalho.

Finalmente, agradeço à minha família, pelo apoio ao longo de toda a vida e particularmente me acompanharem nesta jornada de 4 anos.

Índice

Resumo.....	ii
Abstract	iii
Agradecimentos.....	iv
Índice.....	v
Índice de tabelas	viii
Índice de figuras	ix
Lista de acrónimos.....	xv
CAPÍTULO 1. INTRODUÇÃO	1
1.1. MOTIVAÇÃO	1
1.2. OBJETIVOS.....	3
1.3. ENQUADRAMENTO.....	4
1.4. ESTRUTURA DA DISSERTAÇÃO	5
CAPÍTULO 2. ESTADO DO CONHECIMENTO.....	7
2.1. DEFINIÇÕES E CLASSIFICAÇÃO DOS SISTEMAS LIDAR	7
2.2. VARRIMENTO LASER	8
2.3. PRINCIPAIS COMPONENTES DE UM SLMT	10
2.3.1. <i>Sensor LASER</i>	11
2.3.1.1. Método de medição de distâncias baseado no tempo de percurso	12
2.3.1.2. Método de medição de distâncias baseado na diferença de fase da onda eletromagnética	13
2.3.1.3. Método de medição da distância através de triangulação ótica	14
2.4. SISTEMA GNSS	14
2.5. UNIDADE DE MEDIÇÃO INERCIAL	15
2.6. PRINCÍPIOS DE FUNCIONAMENTO DE UM SLMT.....	18
2.7. PLANEAMENTO E RECOLHA DOS DADOS.....	20
2.8. PROCESSAMENTO DOS DADOS.....	23
2.8.1. <i>Processamento da trajetória</i>	23
2.8.2. <i>Sistema de navegação inercial</i>	25
2.8.3. <i>Filtro de Kalman</i>	26
2.8.4. <i>Controlador de erros nos ciclos fechados</i>	26
2.8.5. <i>Módulo de suavização</i>	26
2.8.6. <i>Módulo de criação da trajetória</i>	27
2.9. PROCESSAMENTO DAS NUVENS DE PONTOS GEORREFERENCIADAS	28
2.10. FORMATOS DE ARMAZENAMENTO DE NUVENS DE PONTOS.....	31
2.10.1. <i>Estrutura do formato LAS</i>	33
2.11. EXEMPLO PRÁTICO DE RECOLHA E PROCESSAMENTO DE DADOS RECOLHIDOS POR SLMT	36
2.12. ESTADO DE ARTE DOS MÉTODOS DE AJUSTAMENTO DE NUVENS DE PONTOS SOBREPOSTAS	40
2.12.1. <i>Métodos baseados em estruturas</i>	41

2.12.2.	<i>Métodos baseados em superfícies</i>	42
2.12.3.	<i>Métodos locais</i>	43
2.13.	CLASSIFICAÇÃO DE PONTOS DE NUVENS RECOLHIDAS POR SLMT PARA A GERAÇÃO DE MDT	47
2.14.	ESTADO DA ARTE DOS MÉTODOS DE CLASSIFICAÇÃO DOS PONTOS DE NUVENS PARA GERAÇÃO DE MDT	48
2.14.1.	<i>Métodos baseados nas diferenças de altitude</i>	48
2.14.2.	<i>Métodos baseados na variação de declive</i>	49
2.14.3.	<i>Métodos morfológicos</i>	50
2.14.4.	<i>Métodos Escalares</i>	50
2.14.5.	<i>Métodos que utilizam dados auxiliares</i>	51
2.15.	EXTRAÇÃO DE LINHAS DE QUEBRA A PARTIR DE NUVENS DE PONTOS	52
2.15.1.	<i>Estado da arte da extração de linhas de quebra de nuvens de pontos</i>	53
2.16.	GERAÇÃO DE MDT COM BASE EM NUVENS ESPECIFICAMENTE RECOLHIDAS POR SLMT	55
CAPÍTULO 3. MÉTODOS E RESULTADOS		57
3.1.	NOÇÕES TEÓRICAS E MÉTODOS AUXILIARES	57
3.1.1.	<i>O método RANSAC</i>	57
3.1.2.	<i>Equação do plano</i>	58
3.1.3.	<i>Distância entre um ponto e um plano</i>	59
3.2.	MÉTODO PROPOSTO PARA AJUSTAMENTO DE NUVENS DE PONTOS SOBREPOSTAS	60
3.2.1.	<i>Definição dos pontos para ajustamento ao longo da trajetória.</i>	61
3.2.2.	<i>Determinação das correções a serem aplicadas.</i>	64
3.2.3.	<i>Criação de uma nova nuvem ajustada através da trajetória corrigida.</i>	66
3.2.4.	<i>Implementação e resultados obtidos</i>	66
3.3.	MÉTODO PROPOSTO PARA A CLASSIFICAÇÃO E EXTRAÇÃO DE PONTOS DO TERRENO	73
3.3.1.	<i>Filtragem dos dados.</i>	73
3.3.2.	<i>Pré-processamento dos dados.</i>	78
3.3.3.	<i>Interpolação e eliminação de pontos conspícuos à superfície do terreno.</i>	79
3.3.4.	<i>Resultados obtidos</i>	82
3.3.5.	<i>Coordenadas-grelha e análise de sensibilidade à forma das células utilizadas</i>	87
3.3.5.1.	<i>Células quadradas</i>	88
3.3.5.2.	<i>Células hexagonais</i>	89
3.3.5.3.	<i>Células triangulares</i>	91
3.3.5.4.	<i>Grelhas irregulares</i>	93
3.3.5.5.	<i>Implementação e funcionamento dos algoritmos</i>	96
3.3.5.6.	<i>Análise comparativa dos resultados.</i>	98
3.4.	MÉTODOS DE EXTRAÇÃO DE LINHAS DE QUEBRA DE NUVENS DE PONTOS RECOLHIDAS POR SLMT	107
3.4.1.	<i>Método manual.</i>	108
3.4.2.	<i>Método semiautomático</i>	108
3.4.2.1.	<i>Estabelecimento das posições ao longo da linha de quebra</i>	109

3.4.2.2.	Definição dos perfis transversais e dos pontos de base e crista da linha de quebra	110
3.4.2.3.	Correção do rumo e definição da distância de recuo	111
3.4.2.4.	Implementação e resultados.....	113
3.5.	MÉTODO AUTOMÁTICO.....	117
3.5.1.	<i>Decomposição em secções transversais temporais</i>	117
3.5.2.	<i>Filtro baseado na época GPS versus distância à trajetória</i>	120
3.5.3.	<i>Decomposição em cadeias monótonas</i>	125
3.5.4.	<i>Identificação dos pares de pontos candidatos</i>	127
3.5.5.	<i>Matrizes de pares de pontos candidatos</i>	128
3.5.6.	<i>Reconstrução das linhas de quebra</i>	129
3.5.7.	<i>Resultados</i>	131
3.6.	CASO PARTICULAR DAS LINHAS FERROVIÁRIAS	137
3.6.1.	<i>Descrição do método proposto</i>	139
3.6.2.	<i>Linha central do topo dos carris</i>	142
3.6.3.	<i>Linhas de quebra da crista e base do balastro</i>	144
3.6.4.	<i>Resultados</i>	145
3.7.	criação DE PERFIS TRANSVERSAIS COM BASE EM NUVENS DE PONTOS RECOLHIDAS POR SLMT	148
3.7.1.	<i>Estratégias para a criação dos pontos das secções transversais</i>	150
3.7.1.1.	Pontos projetados na linha da secção transversal	150
3.7.1.2.	Agregação dos pontos da nuvem através da média das coordenadas planimétricas	152
3.7.1.3.	Perfil original do sensor.....	154
3.7.1.4.	Agregação dos pontos com base no perfil original do sensor	155
3.7.2.	<i>Resultados</i>	157
3.8.	INTEGRAÇÃO DOS MÉTODOS PROPOSTOS PARA GERAÇÃO DO MDT	160
	CAPÍTULO 4 DISCUSSÃO E CONCLUSÕES	163
4.1.	PERSPETIVAS E DESENVOLVIMENTO DE TRABALHOS FUTUROS	165
	REFERÊNCIAS BIBLIOGRÁFICAS.....	166

Índice de tabelas

Tabela 2.1 - Valores máximos recomendados (Optech,2008).....	30
Tabela 2.2 - Formatos mais comuns de armazenamento das nuvens de pontos.....	32
Tabela 2.3 - Versões publicadas do formato LAS e respectivos formatos de pontos suportados.....	34
Tabela 2.4 - Estrutura do cabeçalho do ficheiro LAS	34
Tabela 2.5 - Estrutura do formato 3 de registo de pontos.	35
Tabela 2.6 - Valores estatísticos referentes às diferenças entre os pontos de controlo e as nuvens de pontos.	39
Tabela 3.1 - Valores estatísticos referentes às diferenças entre os pontos de controlo e as nuvens de pontos, após a aplicação do método.	67
Tabela 3.2 - Resíduos dos pontos de controlo, antes e depois da aplicação do método de ajustamento. Todos os valores apresentados, são valores absolutos.	71
Tabela 3.3 - Estatísticas obtidas da aplicação do método.	72
Tabela 3.4 - Comparação estatística dos diferentes métodos.	107
Tabela 3.5 - Valores estatísticos comparativos entre o método manual e semiautomático.....	116
Tabela 3.6 - Características do sensor utilizado (VQ.250).....	131
Tabela 3.7 - Parâmetros utilizados na aplicação do método proposto.....	132
Tabela 3.8 - Valores comparativos dos métodos propostos.	134
Tabela 3.9 - Valores estatísticos das diferenças obtidas entre métodos.	135
Tabela 3.10 – Valores de completude, exatidão e qualidade.....	136
Tabela 3.11 - Estatísticas das linhas extraídas.....	147
Tabela 3.12 - Valores do CDR medidos em campo.	157
Tabela 3.13 – Valores esquerdos e direitos obtidos para cada estratégia.....	158
Tabela 3.14 - Valores de EMQ relativamente aos valores de referência.	159

Índice de figuras

Figura 2.1 - Esquema simplificado do espelho rotativo do sensor.	9
Figura 2.2 - Esquema do movimento de rotação em torno do. a) Vista superior. b) Vista da retaguarda sensor (pulsos vermelhos refletidos, pulsos cinza não refletidos).....	9
Figura 2.3 - Movimentos associados ao processo de recolha das nuvens. a) Estático, b) Móvel.....	10
Figura 2.4 - Esquema dos componentes de um SLMT.	11
Figura 2.5 - Esquema do cálculo da distância através da medição do tempo de percurso.	12
Figura 2.6 - Cálculo da distância através da medição da diferença de fase.....	13
Figura 2.7 - Princípio de funcionamento do sensor por triangulação ótica.	14
Figura 2.8 - Sistema de eixos ortogonais e respetivos ângulos <i>Heading</i> , <i>Roll</i> e <i>Pitch</i> , definido o sistema de coordenadas da plataforma.	18
Figura 2.9 - Esquema do posicionamento dos componentes de um SLMT.	19
Figura 2.10 - Sistema LiDAR móvel terrestre <i>Lynx</i>	20
Figura 2.11 - Interface de visualização do LV-POS View.	22
Figura 2.12 - Arquitetura do sistema Applanix. Adaptado de Scherzinger & Hutton, (2006).	24
Figura 2.13 - Sistemas de referência do sistema inercial (adaptado de Mustafa & Huton, 2001).	26
Figura 2.14 - Trajetória antes (a roxo) e depois (a verde) do processamento.	27
Figura 2.15 - Efeito dos erros de calibração em cada um dos ângulos a) <i>Heading</i> . b) <i>Roll</i> . c) <i>Pitch</i> . (Fonte: Optech, 2008).....	29
Figura 2.16 - Esquema de recolha de dados para calibração (adaptado de Montour & Parry, 2013). ..	30
Figura 2.17 - Exemplo dos dados associados aos pontos que definem a trajetória.	31
Figura 2.18- Caracterização da área do levantamento.....	36
Figura 2.19 - Resultados do processo de calibração.....	37
Figura 2.20 - Exemplo de uma nuvem de pontos final.....	37
Figura 2.21 - Distribuição dos pontos de controlo ao longo da área de trabalho.	38
Figura 2.22 - Exemplo de ponto de controlo em campo e a medição sobre as nuvens.	38
Figura 2.23 - Diferença entre nuvens sobre um ponto de controlo.	39
Figura 2.24 - Diferenças entre duas nuvens ao longo do mesmo perfil transversal, junto ao solo e no topo de um edifício.....	40
Figura 3.1 - Definição da equação do plano.....	59
Figura 3.2 - Distância entre um ponto e um plano.	60
Figura 3.3 - Origem do ângulo de varrimento.	62

Figura 3.4 - Origem do ângulo de varrimento.....	62
Figura 3.5 - Classificação dos pontos por intervalo de época GPS (pontos vermelhos).....	63
Figura 3.6 - Exemplo do estabelecimento de pontos ao longo da trajetória.....	63
Figura 3.7 - Estabelecimento dos círculos de raio r centrados nos pontos da trajetória.....	64
Figura 3.8 - Diferenças altimétricas entre os planos nos pontos da trajetória.....	65
Figura 3.9 - Exemplo da distribuição dos pontos da trajetória na zona de sobreposição das nuvens. ..	68
Figura 3.10 - Evolução dos valores de correção altimétrica aplicada aos pontos da Figura 3.9.....	68
Figura 3.11 - Perfil transversal, antes (esquerda) e depois (direita) de aplicação do método.....	69
Figura 3.12 - Exemplo de um perfil antes e depois do ajustamento da trajetória.....	69
Figura 3.13 - Definição dos pontos auxiliares.....	70
Figura 3.14 - Exemplo de nuvem antes e depois de aplicação do método.....	71
Figura 3.15 - Definição dos pontos de controlo.....	72
Figura 3.16 Esquema da divisão iterativa das células.....	74
Figura 3.17 - Exemplificação do funcionamento do método proposto.....	75
Figura 3.18 - Ilustração da distribuição espacial dos pontos por iteração.....	76
Figura 3.19 - Efeito de erosão provocada por um ponto <i>outlier</i> com elevação inferior ao terreno.....	77
Figura 3.20 - Esquema da função quadrática com variação do valor a . a) $a = 0$; b) $a > 0$; c) $a < 0$	79
Figura 3.21 - Vizinhança baseada nas arestas comuns dos triângulos.....	80
Figura 3.22 - Distância ao plano definido por três vizinhos.....	80
Figura 3.23 - Distâncias máxima e mínima aos planos gerados pelos pontos vizinhos.....	81
Figura 3.24 - a) Exemplo de nuvem de ponto colorido por altura b) Pontos resultantes obtidos da aplicação do Passo 1 após quatro iterações, onde $D_{mi} = 1$ m, $L_{Min} = 0.04$ m, $L_{Max} = 0.08$ m.....	82
Figura 3.25 - Análise comparativa com base na variação de dimensão da célula inicial. a) Nuvem de pontos colorida por elevação b) Resultado obtido com $D_{Ini} = 4$ m c) Resultado obtido com $D_{Ini} = 2$ m d) Resultado obtido com $D_{Ini} = 1$ m.....	83
Figura 3.26 - Exemplos de resultados da aplicação do método proposto.....	83
Figura 3.27 - Esquema de uma secção transversal cruzando uma linha de quebra do terreno. a) Resultado obtido após uma iteração b) Resultado obtido após duas iterações c) Resultado do obtido após três iterações.....	84
Figura 3.28 - Exemplo de aplicação do método em zonas com veículos estacionados b) Resultado do processo de filtragem com $L_{Max} = 0.40$ m c) Resultado do processo de filtragem com $L_{Max} = 0.15$ m.....	85
Figura 3.29 - Análise do resultado do método proposto. a) Triangulação de Delaunay dos pontos da Figura a. b)Ampliação da zona marcada a vermelho na Figura a. c)Resultado obtido após aplicação do filtro com base no operador Laplaciano.....	86

Figura 3.30 - Análise do resultado do método proposto. a) Triangulação de Delaunay dos pontos da Figura 3.29c b) Resultado obtido após redução dos pontos	87
Figura 3.31 - Esquema das coordenadas-grelha para as células hexagonais.....	89
Figura 3.32 - Relação altura largura das células hexagonais.....	90
Figura 3.33 - Definição das áreas auxiliares, para estabelecimento das coordenadas-grelha em células hexagonais.....	90
Figura 3.34 - Coordenadas-grelhas triangulares.....	92
Figura 3.35 - Definição das áreas auxiliares para o cálculo das coordenadas auxiliares.	92
Figura 3.36 - Esquema da triangulação recursiva irregular.....	94
Figura 3.37 - Definição de ponto no interior do triângulo.....	95
Figura 3.38 - Processo de divisão das células regulares.....	98
Figura 3.39 - Lado do triângulo tridimensional.....	98
Figura 3.40 - Resultados obtidos com diferentes células regulares.....	99
Figura 3.41 - Extrato dos resultados obtidos com células com 1 m ²	100
Figura 3.42 - Resultados obtidos em zonas de vegetação.	101
Figura 3.43 - Resultados obtidos em zonas urbanas. Resultado obtido com células quadradas a verde, hexagonais a vermelho e triangulares a azul.	102
Figura 3.44 - Triangulação de Delaunay.....	103
Figura 3.45 - Triangulação baseada na reconstrução da superfície de Poisson.....	103
Figura 3.46 - Resultado obtido utilizando grelhas triangulares irregulares em zonas de vegetação. ..	104
Figura 3.47 - Comparação entre os resultados obtidos em zonas planas inclinadas, utilizando células triangulares regulares e irregulares. a) Nuvem de pontos original; b) Resultado obtido utilizando células triangulares regulares. c) Resultado obtido utilizando células triangulares irregulares.	105
Figura 3.48 - Comparação dos resultados obtidos com grelhas regulares e irregulares em zonas urbanas.	106
Figura 3.49 - Método manual de extração das linhas de quebra; a) Faixas sequenciais ao longo da linha de quebra. b) Vista de perfil e respetivos pontos de crista e base.	108
Figura 3.50 - Fluxograma do método semiautomático proposto para extração das linhas de quebra.	109
Figura 3.51 - Esquema do estabelecimento das posições ao longo da linha de quebra.....	110
Figura 3.52 - Esquema de funcionamento do algoritmo semiautomático; a) Estabelecimento dos perfis transversais; b) Pontos resultantes do perfil transversal e estabelecimento da janela móvel	111
Figura 3.53 - Correção do rumo e distância de recuo; a) Esquema da correção do rumo entre posições; b) Aplicação da distância de recuo.	113
Figura 3.54 - Pontos resultantes do processo semiautomático. a) Nuvem de pontos colorida por cota b) Par de pontos ao longo da linha de quebra (base a vermelho e crista a azul).....	114

Figura 3.55 - Linhas de quebra extraídas (base a vermelho e crista a azul) (a) Resultado do processo manual b) Resultado do processo semiautomático proposto.....	116
Figura 3.56 - Fluxograma dos passos do método automático proposto para extração das linhas de quebra.	117
Figura 3.57 - Esquema da recolha de dados por um SLMT.	118
Figura 3.58 - Decomposição das nuvens em STT. a) Nuvem de pontos original. b) Resultado da decomposição em STT esquerda (azul) e direita (vermelho).	119
Figura 3.59 - Vista isométrica do resultado de aplicação do método de Douglas- Peucker. a) STT originais. b) Resultado de aplicação do método.	120
Figura 3.60 - Efeito da intersecção das STT com as linhas de quebra do terreno. a) Vista horizontal do terreno. b) Vista isométrica do terreno.	121
Figura 3.61 - Distância perpendicular à trajetória.	121
Figura 3.62 - Detalhe das iterações do filtro baseado na época GPS <i>versus</i> distância à trajetória. a) STT original. b) Primeira iteração. c) Segunda iteração. d) Terceira iteração. e) Quarta iteração. f) STT final.	123
Figura 3.63 - Filtro época GPS <i>versus</i> distância à trajetória; a) STT originais; b) Resultado da aplicação do filtro.	124
Figura 3.64 Vista de perfil do esquema de variação vertical da calçada da estrada. A linha vermelha representa a situação da calçada de infraescavação.	124
Figura 3.65 - Exemplo do efeito em zonas de infraescavação, STT original (magenta) resultado após aplicação do filtro(azul) a) Vista de topo da linha de quebra do lancil; b) Vista de perfil da linha de quebra do lancil.	125
Figura 3.66 - Decomposição em cadeias monótonas: a) Exemplo de uma cadeia C1 monótona e uma C2 não monótona; b) Decomposição em cadeias monótonas de C2.....	126
Figura 3.67 - Cadeias monótonas coloridas.	127
Figura 3.68 - Resultado após aplicação das restrições.	127
Figura 3.69 - Pares de pontos candidatos base (azul) e crista (vermelho).....	128
Figura 3.70 - Esquema de inicialização das matrizes na primeira STT.	128
Figura 3.71 - Resultado do processo de construção das matrizes de pares de pontos.	129
Figura 3.72 - Resultado do processo de agregação de matrizes consecutivas.....	130
Figura 3.73 - Pares de pontos resultantes do processo.	130
Figura 3.74 - Exemplo do resultado da extração das linhas de quebra.	131
Figura 3.75 - Nuvem de pontos da área de teste.....	131
Figura 3.76 - Linhas de quebra obtidas pelo método proposto.	132
Figura 3.77 - Análise da triangulação dos resultados obtidos pelas diferentes metodologias; a) Método proposto; b) Método manual; c) Levantamento de campo.	133

Figura 3.78 - Distribuição espacial das diferenças obtidas; a) Método proposto versus levantamento manual; b) Método proposto versus levantamento campo.	134
Figura 3.79 - Nuvem de pontos recolhida por um SLMT instalado num comboio. a) Representação em valores de cinzento; b) Nuvem de pontos colorida por ângulo de varrimento.	138
Figura 3.80 - Perfil da nuvem de pontos colorida por ângulo de varrimento.	139
Figura 3.81 - Pontos da nuvem com ângulo de varrimento zero.	139
Figura 3.82 - Esquema de criação das linhas tridimensionais.	140
Figura 3.83 - Resultado obtido para a linha tridimensional representado a trajetória do sensor.	141
Figura 3.84 - Classificação dos ângulos de varrimento dos pontos que representam os carris.	142
Figura 3.85 - Classificação dos pontos que representam os carris; a) Classificação dos pontos da nuvem que representam os carris; b) Detalhe dos pontos que representam os carris.	143
Figura 3.86 - Exemplo de linhas de topo do carril extraídas. Pontos da nuvem que representam o carril (vermelho) e linhas de topo dos carris (azul) resultantes da união dos pontos obtidos (verde).	143
Figura 3.87 - Ângulos de varrimento dos pontos da crista e base das linhas de quebra do balastro. ...	144
Figura 3.88 - Classificação dos pontos da crista e base das linhas de quebra do balastro.	144
Figura 3.89 - Resultado obtido para as linhas de crista e base do balastro.	145
Figura 3.90 - Nuvem da área de teste colorida por elevação.	145
Figura 3.91 - Ampliação das linhas obtidas.	146
Figura 3.92 - Extrato da modelação tridimensional das linhas obtidas.	146
Figura 3.93 - Esquemático dos métodos de medição do CDR. a) Método manual usando uma régua transversal; b) Sistema laser terrestre. c) Sistema laser contínuo.	149
Figura 3.94 - Nuvem de pontos e exemplo de linha transversal.	150
Figura 3.95 - Esquema da primeira estratégia proposta.	150
Figura 3.96 - Resultados obtidos da primeira estratégia proposta.	152
Figura 3.97 - Esquema da segunda estratégia proposta.	152
Figura 3.98 - Resultados obtidos da segunda estratégia proposta.	153
Figura 3.99 - Esquema da terceira estratégia proposta.	154
Figura 3.100 - Resultados obtidos da terceira estratégia proposta.	155
Figura 3.101 - Esquema da quarta estratégia proposta.	155
Figura 3.102 - Resultados obtidos da quarta estratégia proposta.	156
Figura 3.103 - Exemplo da distribuição das linhas transversais ao longo da estrada.	157
Figura 3.104 - Representação longitudinal dos valores esquerdos do CDR.	158
Figura 3.105 - Representação longitudinal dos valores direitos do CDR.	159

Figura 3.106 - Representação longitudinal dos valores máximos do CDR.....	159
Figura 3.107 - Fluxograma dos métodos integrados.	161
Figura 3.108 - Aplicação do método auxiliar, para remoção dos pontos cotados próximos das linhas de quebra. a) Exemplo da linha de quebra antes de aplicação do método. b) Resultado após aplicação do método auxiliar.....	162
Figura 3.109 - Método auxiliar de interpolação dos vértices de linha de quebra. a) Exemplo antes da aplicação do método. b) Resultado após a aplicação do método.....	162

Lista de acrónimos

ASCII - *American Standard Code for Information Interchange*
ASPRS - *American Society for Photogrammetry & Remote Sensing*
CDR - Cavado de rodeiras
ECEF - *Earth Centered Earth Fixed*
EMQ - Erro médio quadrático
EVLR - *Extended Variable Length Records*
FOG - *Fiber Optic Gyros*
GAMS - *GNSS Azimuth Measurement Subsystem*
GNSS - *Global Navigation Satellite System*
GPS - *Global Positioning System*
ICP - *Iterative Closest Point*
ICPatch - *Iterative Closest Patch*
ICPP - *Iterative Closest Projected Point*
KAR - *Kinematic Ambiguity Resolution*
LASER - *Light Amplification by Stimulated Emission of Radiation*
LiDAR - *Light Detection And Ranging*
LMS - *LiDAR Mapping Suite*
MDT – Modelo Digital do Terreno
MEMS – *Micro Electro Mechanical Systems*
MHT - *Multiscale Hermite Transform*
PPK - *Post Processed Kinematic*
RANSAC - *Random Sample Consensus*
RIT - Rede Irregular de Triângulos
RLG - *Ring Laser Gyros*
RTK - *Real Time Kinematic*
SBET - *Smoothed Best Estimate of Trajectory*
SLA - Sistema LiDAR Aéreo
SLAM - *Simultaneous Localization And Mapping*
SLFT - Sistema LiDAR Fixo Terrestre
SLMT - Sistema LiDAR Móvel Terrestres
SMRMSG - *Smoother Root Mean Square Estimation*
SNI - Sistema de Navegação Inercial

STT - Secção Transversal Temporal

SURF - *Speeded Up Robust Features*

UCP - Unidade Central de Processamento

UMI - Unidade de Medição Inercial

VLR - *Variable Length Records*

Capítulo 1.

Introdução

1.1. Motivação

O Modelo Digital do Terreno (MDT) é possivelmente o conjunto de dados mais transversalmente utilizado por todo o tipo de projetos que utilizam informação geográfica. A definição e representação da forma do relevo é uma peça essencial em todos os estudos ambientais, hidráulicos, de construção civil, geotécnicos, de planeamento do território, etc.

O nível de detalhe necessário para a informação geográfica de base e, conseqüentemente, para a escala associada ao MDT, é definida pelo tipo e fase do projeto. Projetos de construção e manutenção de estradas, redes de distribuição de águas e de saneamento requerem um MDT com um nível de detalhe de acordo com especificações das escalas 1:500, 1:200 e até superior, em situações específicas. Tipicamente a obtenção dos dados de base para a criação desses MDT a grandes escalas é efetuada através da coordenação de pontos obtidos através de estações totais topográficas e recetores GNSS de dupla frequência. Este processo é normalmente moroso e dispendioso, especialmente no caso dos países em vias de desenvolvimento, onde a necessidade deste tipo de projetos é maior e os recursos disponíveis são menores, escassos ou mesmo inexistentes. A falta de mão-de-obra especializada e a necessidade de informação em áreas remotas aumenta significativamente o custo associado à recolha dos dados, representando muitas vezes um entrave à execução dos projetos.

A utilização das nuvens de pontos recolhidas por sistemas que utilizam a tecnologia *Light Detection And Ranging* (LiDAR), para a geração de MDT é algo que ocupa os investigadores desde o aparecimento dos primeiros sistemas. Enquanto os dados recolhidos por sistemas LiDAR instalados em plataformas aéreas, designados por Sistemas LiDAR Aéreos (SLA)¹, são utilizados em estudos globais, normalmente em grandes áreas e a escalas mais pequenas, os sensores LiDAR instalados em plataformas terrestres permitem a recolha de nuvens de pontos mais densas e conseqüentemente a geração de informação a escalas maiores. Os sistemas terrestres podem ser classificados em fixos e móveis, de acordo com a dinâmica da plataforma

¹ Tradução da designação anglo-saxónica *Airborne Laser Scanning* (ALS)

em que se encontram instalados. Enquanto que os Sistemas LiDAR Fixos Terrestres (SLFT)² permitem a obtenção de uma nuvem de pontos em torno de um sensor estático, sendo a área coberta pela nuvem limitada ao alcance do sistema em cada estação, os Sistemas LiDAR Móveis Terrestres (SLMT)³ cujos sensores são instalados sobre um veículo terrestre, permitem a recolha de nuvens de pontos, ao longo da via em que o veículo circula. Apesar dos princípios de funcionamento serem muito semelhantes no que concerne aos sensores, o facto dos SLMT estarem em movimento, no momento da recolha dos dados, aumenta a complexidade do processo de georreferenciação dos dados. Por outro lado, esse movimento permite diminuir o tempo de aquisição dos dados, possibilitando a sua recolha ao longo de uma área muito mais extensa de forma mais eficiente. A utilização de SLMT para a obtenção de nuvens de pontos que sirvam de base à criação de MDT a grandes escalas, surge assim como uma metodologia promissora como forma de aumentar a velocidade e facilidade de recolha dos dados. No entanto, os SLMT representam uma técnica de recolha de dados georreferenciados não seletiva, ou seja, os dados recolhidos sob a forma de nuvem de pontos espaciais representam a realidade espacial da superfície no momento da recolha, de forma indiscriminada sem qualquer classificação, incluindo: solo, vegetação, edificações, veículos, pessoas, ou qualquer outro objeto dentro do alcance do sistema. Torna-se assim necessário efetuar a classificação e segmentação dos dados que representam a superfície do terreno.

Considerando o aumento significativo de disseminação dos SLMT e a sua grande facilidade na recolha de grandes quantidades de nuvens de pontos, facilmente se compreende o estrangulamento no fluxo de trabalho resultante da morosidade de processos manuais de classificação e extração dos pontos. Torna-se assim necessária a implementação de algoritmos otimizados que efetuem a classificação dos pontos dessas nuvens, de forma eficiente, possibilitando a geração de MDT a grandes escalas.

Apesar de existirem vários estudos para a geração de MDT com base em nuvens de pontos recolhidas por SLA, a diferente densidade e ângulo de aquisição das nuvens recolhidas pelos sistemas terrestres faz com que a maioria desses algoritmos não seja eficiente no processamento das nuvens recolhidas por SLMT. Assim, a inexistência de algoritmos eficientes de classificação e segmentação dos pontos das nuvens, que permitam tirar partido da velocidade da recolha dos SLMT, surge como um entrave à utilização destes sistemas como solução para

² Tradução da designação anglo-saxónica *Terrestrial Laser Scanning* (TLS)

³ Tradução da designação anglo-saxónica *Mobile Laser Scanning* (MLS)

a obtenção de dados para a geração de MDT a grandes escalas de forma eficiente, rápida e, conseqüentemente, mais barata.

Para além disso, a elevada densidade das nuvens de pontos recolhidos por SLMT representa um novo paradigma na utilização e armazenamento de dados, não sendo assim, compatível com os atuais recursos computacionais da maioria dos utilizadores. Essa é muitas vezes a razão apontada por muitos utilizadores como o entrave à utilização deste tipo de produtos. Torna-se, portanto, necessário a dizimação e otimização espacial da distribuição dos dados, de forma a aproximar o resultado ao paradigma a que esses utilizadores estão habituados.

Finalmente, quando sobre a mesma área geográfica são adquiridas diferentes nuvens, em diferentes momentos temporais e/ou a partir de diferentes pontos de vista, surgem diferenças no alinhamento entre as nuvens (Gressin *et al.*, 2013). Estes erros têm uma influência direta na implementação dos algoritmos de classificação dos pontos do terreno. Apesar de existirem muitos artigos científicos descrevendo diversas técnicas de ajustamento das nuvens de pontos sobrepostas, este é ainda um desafio em aberto que se apresenta à comunidade civil que utiliza de forma comercial as nuvens de pontos recolhidas por SLMT (González *et al.*, 2016). É na sequência das limitações existentes e desafios descritos anteriormente, e na tentativa de contribuir para a solução dos mesmos, que reside a motivação para este trabalho.

1.2. Objetivos

Ao longo deste trabalho apresenta-se um conjunto de algoritmos para a classificação e segmentação dos pontos das nuvens, especificamente obtidas por sistemas LiDAR terrestres, de forma a permitir a geração automática de MDT a grandes escalas. São apresentados e testados algoritmos inovadores e eficientes que contribuem para a eliminação do estrangulamento referido atrás e que atualmente se verifica nos processos de geração de MDT com base nas nuvens de pontos recolhidas por SLMT.

O objetivo é, por um lado, a separação correta entre os pontos da nuvem que representam o terreno dos restantes. Por outro lado, pretende-se que os algoritmos apresentados, atentem à obtenção dos dados mínimos e suficientes para a representação da forma mais exata do terreno a uma determinada escala. Pretende-se que com estes objetivos se mantenha o paradigma estabelecido pela maioria dos utilizadores e produtores de informação geográfica, definido pela utilização de pontos de cota e linhas de quebra para a geração de MDT a grandes escalas. Para

além da classificação dos pontos, pretende-se apresentar métodos inovadores para a extração semiautomática e automática de extração de linhas de quebra das nuvens de pontos.

Tendo em conta que as plataformas dos SLMT estão essencialmente instaladas sobre veículos rodoviários e ferroviários, é natural que os dados por eles recolhidos sirvam de base maioritariamente a projetos ao longo dessas vias. Considerando o papel crucial que os perfis transversais têm na representação do terreno para a execução e manutenção desse tipo de infraestruturas de vias lineares, pretende-se avaliar a eficiência de diferentes estratégias de agregação dos pontos das nuvens para a geração desses perfis transversais.

Dada a grande quantidade de pontos inerente ao tipo de dados utilizados, a redução do tempo de execução é um requisito transversal e fundamental a todos os métodos propostos ao longo deste trabalho.

Tendo em conta que, entre nuvens sobrepostas, obtidas de diferentes ângulos e/ou em diferentes épocas, surgem normalmente diferenças, que dificultam ou impossibilitam a aplicação de muitos métodos de classificação automática de pontos das nuvens, a temática do ajustamento das nuvens de pontos ganha uma importância significativa ao longo deste trabalho, pretendendo-se efetuar um estudo detalhado sobre os métodos de ajustamento e propor um algoritmo eficiente de ajustamento altimétrico de nuvens sobrepostas.

1.3. Enquadramento

Nesta secção é apresentado um resumo das principais tarefas e respetivas publicações de resultados, efetuadas para atingir os objetivos propostos nesta dissertação.

Este trabalho surge de uma necessidade profissional do autor, que trabalhando diretamente com dados recolhidos por diferentes SLMT em vários países e diferentes ambientes teve a necessidade recorrente de gerar MDT a grandes escalas com base nesses dados. Não existindo soluções eficientes por parte dos softwares comerciais existentes, surgiu a necessidade de conceção e implementação de soluções que permitam a geração de MDT com base nas nuvens de pontos recolhidas por SLMT.

Durante o ano de 2016 foi efetuada uma revisão bibliográfica dos diferentes métodos existentes para a classificação e ajustamento de nuvens pontos recolhidas por SLMT. Foi desenvolvido o estudo dos princípios teóricos e fundamentos do funcionamento dos diferentes SLMT, assim como, dos formatos de armazenamento e processamento dos dados recolhidos. Ao longo de 2017 foi proposto um método de classificação dos pontos de terreno, baseado num processo

iterativo e na divisão do espaço em grelhas (Gézero & Antunes, 2017a). Ainda durante o ano de 2017 foi proposto um método de ajustamento altimétrico de nuvens sobrepostas, tirando partido dos dados associados a cada um dos pontos da nuvem (Gézero & Antunes, 2017b).

Durante o ano de 2018, foi aprofundado o estudo do método de classificação proposto no ano anterior, tendo sido publicado um estudo de sensibilidade à forma das células (Gézero & Antunes, 2018a). Iniciou-se igualmente o estudo da problemática de extração de linhas de quebra das nuvens de pontos recolhidas por SLMT, que resultou na proposta de um método semiautomático de extração dessas linhas (Gézero & Antunes, 2018b).

Em 2019 foi aprofundado o estudo do processo de extração de elementos lineares, tendo sido proposto um método genérico e completamente automático de restituição das linhas de quebra. Neste caso, tirando partido dos dados associados a cada um dos pontos da nuvem (Gézero e Antunes, 2019a), foi ainda publicado um método específico para extração desse tipo de linhas, a partir de nuvens de pontos recolhidas especificamente ao longo de linhas ferroviárias (Gézero & Antunes, 2019b). Finalmente, foi desenvolvido um estudo comparativo de diversas estratégias de agrupamento dos pontos das nuvens para a criação de perfis transversais, como forma de representação do terreno ao longo de estruturas lineares (Gézero & Antunes, 2019c). Todos os métodos apresentados ao longo deste trabalho foram implementados através de rotinas programadas em linguagem C# .NET.

1.4. Estrutura da dissertação

De forma a permitir um entendimento mais detalhado do funcionamento dos sistemas LiDAR terrestres, no Capítulo 2 são apresentados os princípios teóricos de funcionamento destes sistemas. Ao invés de apresentar uma enumeração sistemática de componentes ou sistemas, que rapidamente ficaria desatualizada, optou-se por apresentar uma explicação teórica do funcionamento dos sistemas mais comuns. Uma descrição mais pormenorizada das componentes e tipo de dados envolvidos na recolha e processamento das nuvens permite uma visão do funcionamento e dos erros inerentes ao processo. Para além da descrição teórica dos processos de recolha e processamento dos dados, é apresentado um caso prático, de forma a enfatizar as diferenças obtidas entre as nuvens sobrepostas. Finalmente apresenta-se uma descrição do estado da arte das diferentes problemáticas associadas ao processo de geração de MDT com base em nuvens de pontos, nomeadamente: ajustamento de nuvens de pontos sobrepostas, classificação dos pontos do terreno e extração de linhas de quebra.

No Capítulo 3 são descritos os métodos propostos para a geração de MDT a grandes escalas com base em nuvens de pontos recolhidas por SLMT, iniciando-se com um método proposto para o ajustamento altimétrico entre nuvens de pontos sobrepostas, com base nos princípios de funcionamento dos SLMT e da estrutura *standard* de armazenamento das nuvens. Em seguida é descrito um método inovador de classificação dos pontos do terreno, que permite uma variação de densidade dos pontos proporcional à variação do terreno. Seguem-se os métodos de extração de linhas de quebra das nuvens de pontos, com maior destaque para um método totalmente automático, baseado na decomposição da nuvem nos perfis originais dos sensor.

Tendo em conta a especificidade das nuvens de pontos obtidas por SLMT instalados em comboios, é proposto um método de extração de linhas tridimensionais ao longo de linhas ferroviárias. O Capítulo 3, termina com um estudo comparativo de várias estratégias propostas para o agrupamento dos pontos das nuvens com vista à criação de perfis transversais, já que estes perfis representam o atual paradigma para a modelação do terreno a grandes escalas, necessária para a execução e manutenção de vias lineares, nomeadamente, rodoviárias e ferroviárias.

Finalmente no Capítulo 4, são apresentadas as conclusões deste trabalho, bem como uma discussão sobre a maior valia dos métodos propostos, face aos métodos existentes.

Capítulo 2.

Estado do conhecimento

Ao longo desta secção é apresentada uma visão geral do funcionamento dos SLMT, assim como, o estado da arte dos temas desenvolvidos no trabalho.

Na primeira parte desta secção, descrevem-se as principais componentes e princípios teóricos de funcionamento dos SLMT. A compreensão desses princípios e dos principais erros inerentes ao seu funcionamento é fundamental para o posterior desenvolvimento e implementação dos algoritmos propostos. Dada a grande quantidade de sistemas comerciais existentes, optou-se por não efetuar qualquer enumeração exaustiva dos sistemas existentes, já que dada a dinâmica do mercado, essa listagem corria o risco de estar rapidamente desatualizada. Ao invés disso, optou-se por apresentar uma descrição de um processo de recolha e processamento dos dados, incluindo os resultados de um exemplo prático. Para além disso, apresenta-se uma descrição do estado da arte dos diferentes processos, associados à criação de MDT a grandes escalas, nomeadamente, métodos de ajustamento das nuvens, métodos de classificação e extração de pontos de cota e extração de linhas de quebra

2.1. Definições e classificação dos sistemas LiDAR

A expressão inglesa *Light Detection And Ranging* da qual LiDAR é acrónimo resume muito bem o funcionamento desta tecnologia. Na prática é uma forma de emissão e deteção baseada num feixe de luz, através do qual é possível medir distâncias. Este processo é tipicamente efetuado através da emissão e receção após reflexão de um pulso criado através de um sensor *Light Amplification by Stimulated Emission of Radiation* (LASER), permitindo assim a medição da distância entre o sensor e o ponto de reflexão. Na literatura os termos LASER e LiDAR confundem-se, surgindo ambos como designação da tecnologia, do sensor e/ou do processo de medição. Dada a continua variação de direção associada ao pulso laser emitido, o termo inglês *LASER Scanning* surge igualmente em muita literatura como designação desta tecnologia. Ao longo deste trabalho optou-se por utilizar sempre o termo LiDAR para designar a tecnologia associada ao processo de medição das distâncias, utilizando-se sensores LASER, para o instrumento que efetua o processo de medição. Considerando a definição de um sistema, como um conjunto de elementos e as relações entre si, a designação sistema LiDAR é utilizada

ao longo deste trabalho para designar para além do sensor que permite medir as distâncias, também os restantes sensores e instrumentos ligados entre si que permitem o registo, georreferenciação e armazenamento dos pontos recolhidos. Na sua classificação mais óbvia, os sistemas LIDAR podem ser divididos em terrestres e aéreos, consoante a plataforma que os suporta estar instalada sobre a superfície terrestre (viatura ou comboio) ou instalada acima dela em uma aeronave. Os sistemas terrestres são por sua vez classificados em fixos ou móveis, dependendo se a plataforma é estática ou está instalada sobre um veículo em movimento. Para além do movimento, os sistemas móveis e fixos também se distinguem por outras características, nomeadamente, no tipo de sensores auxiliares, forma de rotação do sensor e método de georreferenciação dos dados recolhidos. Ao longo deste trabalho todos os métodos propostos foram desenvolvidos e testados especificamente sobre nuvens recolhidas por SLMT. Apesar de em alguns casos não existir nenhuma restrição ao facto de serem aplicados a nuvens recolhidas por SLFT ou SLA, não foram feitos testes sobre esse tipo de nuvens.

2.2. Varrimento LASER

O termo “varrimento LASER”, resultado da tradução do inglês *LASER scanning*, é utilizado em muita literatura como designação do sistema LIDAR ou genericamente da própria tecnologia LIDAR. No entanto, a sua utilização ao longo do presente documento refere-se estritamente ao processo de recolha contínua dos pontos para posterior geração das nuvens de pontos tridimensionais. Este processo surge também designado por *3D scanning* na literatura, por analogia ao processo que os scanners 2D efetuam numa imagem bidimensional.

Os dados resultantes de um SLMT são essencialmente uma nuvem de pontos tridimensionais georreferenciados. Para obter essa nuvem, que apesar de discreta permite uma cobertura quase contínua das superfícies ao longo da trajetória do veículo, é necessário que a direção do pulso de radiação emitido mude continuamente de direção. Essa mudança sistemática permite criar o efeito de nuvem de pontos, ou seja, uma representação tridimensional da realidade em torno do sensor num determinado instante. Para obter esse efeito, são impostos dois tipos de movimentos aos pulsos emitidos, que em simultâneo permitem uma cobertura contínua da superfície envolvente ao sensor.

O primeiro movimento está associado à rotação do sensor. Apesar de em alguns SLMT o próprio sensor, ou parte dele, rodar fisicamente em torno do seu eixo, o método mais comum é a simulação desse movimento, através de um espelho rotativo (Figura 2.1).




Figura 2.1 - Esquema simplificado do espelho rotativo do sensor.

Neste caso, o sensor está continuamente a emitir pulsos numa direção fixa (na direção do espelho), sendo estes refletidos no espelho rotativo, alterando a sua direção. O movimento de rotação descrito associado ao espelho, apenas permite o registo de um perfil, ou seja, emissão de pulsos 360 graus em torno do sensor e o registo dos seus reflexos, sempre que existam objetos físicos na direção emitida com características refletoras (Figura 2.2).

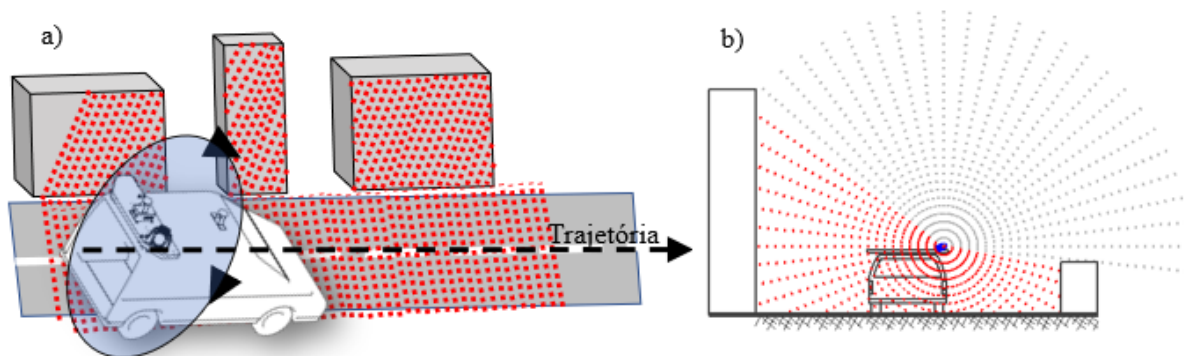


Figura 2.2 - Esquema do movimento de rotação em torno do. a) Vista superior. b) Vista da retaguarda sensor (pulsos vermelhos refletidos, pulsos cinza não refletidos).

Para obter a totalidade da geometria do espaço envolvente ao SLMT, é necessário um segundo movimento. Enquanto que no caso dos sistemas terrestres estáticos, o segundo movimento é provocado pela rotação do sensor em torno do eixo, nos SLMT este segundo movimento resulta do próprio movimento do veículo que transporta a plataforma (Figura 2.3).




Figura 2.3 - Movimentos associados ao processo de recolha das nuvens. a) Estático, b) Móvel.

Apesar de, para evitar “sombras” e cobrir uma maior área os SLMT terem muitas vezes mais do que um sensor LASER (Shan & Toth, 2008), todos os métodos propostos ao longo deste trabalho se baseiam nas nuvens resultantes de apenas um sensor LASER.

2.3. Principais componentes de um SLMT

Uma diferença significativa entre os SLFT e SLMT, resulta da forma de georreferenciação dos dados recolhidos. No caso dos SLFT a georreferenciação é feita de forma indireta, ou seja, as coordenadas absolutas dos dados recolhidos são obtidas através de pontos coordenados por métodos exteriores ao sistema, tipicamente estações totais ou recetores GNSS. A georreferenciação dos dados recolhidos por SLMT é designada por direta, ou seja, em teoria, não necessita de dados exteriores ao sistema para georreferenciar os pontos recolhidos. Esta diferença associada ao movimento do sistema faz com que o sistema móvel necessite de mais sensores para manter a qualidade da georreferenciação dos dados recolhidos.

Um SLMT é constituído essencialmente por 3 componentes principais, a Unidade de Medição Inercial (UMI)⁴, o sistema de posicionamento GNSS e um ou mais sensores LASER (Figura 2.4). Para além destes componentes principais, consoante os sistemas, poderão existir ainda alguns componentes auxiliares, nomeadamente, uma Unidade Central de Processamento (UCP), uma unidade externa para armazenamento dos dados, um computador portátil como interface para acompanhamento do levantamento, câmaras para registo fotográfico e um odómetro de precisão.

⁴ Tradução da designação anglo-saxónica *Inertial Measuring Unit* (IMU)

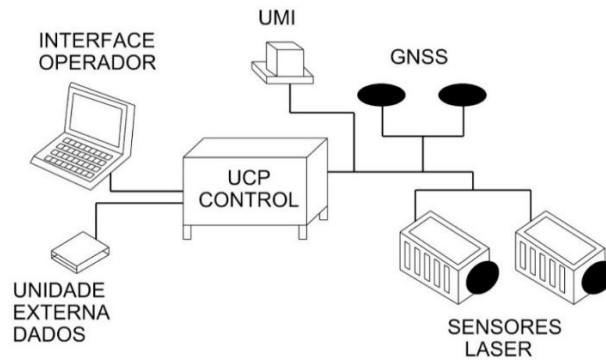


Figura 2.4 - Esquema dos componentes de um SLMT.

O sensor LASER é o elemento comum a todos os sistemas que define a tecnologia e cuja qualidade e método de funcionamento define em grande parte a eficiência dos sistemas, justificando-se assim uma descrição mais pormenorizada.

2.3.1. Sensor LASER

Sendo o método de medição de distância aos objetos baseado na radiação eletromagnética emitida pelo sensor LASER, torna-se importante a compreensão do comportamento e características desta radiação. A radiação eletromagnética pode ser conceptualizada de duas formas (Schuckman & Renslow, 2014):

- Ondas de energia elétrica e magnética (comprimento de onda inversamente proporcional à frequência);
- Pequenas partículas (fotões) que se deslocam com uma determinada energia e momento linear.

Ambos os modelos são usados no estudo e desenvolvimento da tecnologia LiDAR de acordo com o tipo de sensor.

Em termos genéricos, um sensor LASER é um dispositivo cuja radiação eletromagnética emitida tem três características bem definidas:

- ✓ Monocromática - ou seja, tem um único comprimento de onda;
- ✓ Coerente - o que significa que todas as ondas de fotões que compõem o feixe estão em fase;
- ✓ Colimada - fazendo a sua propagação como um feixe de ondas praticamente paralelas;

A principal função do sensor LASER é determinar a distância entre o sensor e os pontos que definem a superfície dos objetos. De acordo com a utilização que o sensor faz das características da radiação eletromagnética emitida, existem três abordagens distintas para a medição da

distância entre o sensor e os pontos da superfície de um objeto: os métodos baseados no tempo de percurso; os que utilizam a diferença de fase; e os que calculam a distância através da triangulação ótica.

2.3.1.1. Método de medição de distâncias baseado no tempo de percurso

Este método consiste na medição precisa do tempo do percurso realizado por um pulso de radiação emitido pelo sensor LASER, desde que é emitido até ao seu retorno ao sensor, após ter sido refletido no objeto (Figura 2.5). O cálculo da distância é então calculada através de:

$$R = v \cdot \frac{t}{2} \quad (2.1)$$

onde, R é a distância medida entre o sensor e o objeto, v é a velocidade da radiação eletromagnética e t é o intervalo de tempo medido.




Figura 2.5 - Esquema do cálculo da distância através da medição do tempo de percurso.

Na sequência da Equação 2.1 é possível formular a variância associada à medição da distância (R) através da relação expressa na Equação (2.2), a partir da qual se obtém a respetiva incerteza através da sua raiz quadrada.

$$\sigma_R^2 = \left(\sigma_v \cdot \frac{t}{2} \right)^2 + \left(\sigma_t \cdot \frac{v}{2} \right)^2 \quad (2.2)$$

onde, σ_R é a incerteza associada à distância calculada, σ_v é a incerteza associada à precisão da velocidade da radiação eletromagnética e σ_t representa a incerteza associada à medição do intervalo de tempo.

Tendo em conta que a velocidade de propagação da radiação eletromagnética é conhecida com bastante rigor, na prática, a exatidão da distância calculada está diretamente dependente da precisão com que o intervalo de tempo é determinado (Shan & Toth, 2008).

2.3.1.2. Método de medição de distâncias baseado na diferença de fase da onda eletromagnética

Neste método, o emissor do sensor LASER emite um feixe contínuo de radiação em vez da emissão de pulsos. A distância é obtida através da medição da diferença de fase da onda sinusoidal entre as fases de emissão e receção. Assim, a amplitude (ou intensidade) da radiação é obtida através do sinal sinusoidal, que tem um determinado período e um comprimento de onda. O cálculo da distância é efetuado através da medição da diferença de fase (ou ângulo de fase) entre o sinal emitido pelo sensor e o sinal recebido no sensor, após a reflexão no solo ou em qualquer outro objeto (Figura 2.6). Esta técnica permite obter a parte fracionária do comprimento de onda incompleto que perfaz a distância total percorrida, à qual acresce o número inteiro de ciclos completos, a multiplicar pelo comprimento de onda conhecido (Shan & Toth, 2008). O cálculo da distância pode ser formulado através de:

$$R = \frac{(M \cdot \lambda + \Delta\lambda)}{2} \quad (2.3)$$

onde, M é o número inteiro de ciclos completos da onda (determinado através da modulação do comprimento de onda), λ é o comprimento de onda conhecido, $\Delta\lambda$ representa a parte fracionária do comprimento de onda incompleto $(\alpha/2\pi) \cdot \lambda$, onde α é o ângulo de fase.

Este método de medição da diferença de fase é mais preciso que o método de medição do tempo de percurso, no entanto, tem um alcance mais curto (Puente *et al.*, 2013).




Figura 2.6 - Cálculo da distância através da medição da diferença de fase.

2.3.1.3. Método de medição da distância através de triangulação ótica

Apesar da quase totalidade dos mais recentes sistemas, existentes no mercado, utilizarem um dos dois métodos referidos anteriormente, existem alguns sistemas mais antigos que utilizam um processo de triangulação ótica para a medição das distâncias. Este tipo de método utiliza uma lente que desvia lateralmente o pulso emitido pelo sensor LASER, sendo o pulso novamente registado após a reflexão no objeto. A distância ao objeto pode ser obtida através da resolução do sistema de triângulos similares apresentados na Figura 2.7.




Figura 2.7 - Princípio de funcionamento do sensor por triangulação ótica.

A distância desconhecida D é determinada através da resolução da Equação 2.4, com base nas distâncias conhecidas E e F (constantes do sistema), e a medição do valor G que representa a distância medida no sensor com base na imagem refletida do objeto (Berkovic & Shafir, 2012).

$$\frac{D}{E} = \frac{F}{G} \quad (2.4)$$

2.4. Sistema GNSS

O sistema GNSS é utilizado como sistema auxiliar, permitindo a georreferenciação dos dados recolhidos pelo SLMT, num referencial absoluto ou inercial,. É utilizado para determinar a posição e velocidade do sistema através do registo e processamento das pseudo-distâncias e medições de fase da onda portadora a partir de cada satélite observado. São utilizadas técnicas de processamento diferencial, baseadas na medição da diferença de fase de mais de uma onda portadora, seja em tempo real, designadas por *Real Time Kinematic* (RTK), seja em pós-processamento, designadas por *Kinematic Ambiguity Resolution*⁵ (KAR). Tanto o RTK como

⁵ Em alguma literatura designado por PPK (*Post Processed Kinematic*)

o KAR necessitam de resolver as ambiguidades iniciais de fase das ondas portadoras para obter precisões na ordem de poucos centímetros. No entanto existem algumas diferenças entre as duas técnicas. A técnica RTK, por ser uma técnica em tempo real, depende da ligação contínua com a estação de referência para a transmissão de correções. Na técnica KAR, os dados são guardados e posteriormente processados em combinação com os dados de uma estação de referência próxima.

A técnica KAR apresenta algumas vantagens relativamente à RTK. A principal vantagem consiste no facto de, geralmente, permitir obter resultados mais precisos, devido à maior flexibilidade na edição e limpeza dos dados GNSS e devido à ausência de degradação da precisão devido à latência dos dados. Outra vantagem importante é a inexistência de limitações relacionadas com as falhas de cobertura e obstruções que causam interrupções de comunicação com a estação de referência (El-Rabbany, 2002).

O processo de resolução de ambiguidades demora tipicamente entre 30 e 120 segundos, dependendo do número visível, da distribuição dos satélites e da distância à estação de referência.

Poderão existir interrupções frequentes do sinal, durante o movimento do veículo, tipicamente devido à presença de edifícios e árvores que obstruem o sinal GNSS e, conseqüentemente, podem degradar a precisão do posicionamento tanto em modo RTK como em KAR (El-Rabbany, 2002). Tendo em conta que a exatidão do SLMT depende da precisão das coordenadas obtidas pelo sistema GNSS, em teoria, seriam necessárias restrições ao ambiente em que o veículo poderia operar de forma a obter uma exatidão mais elevada. No entanto, existem técnicas para atenuar a perda de precisão associada às obstruções de sinal GNSS, nomeadamente, recorrendo à utilização dos dados recolhidos pela UMI. Para além do cálculo da posição e velocidade, o sistema GNSS é também utilizado em alguns SLMT para cálculo da correção contínua do azimute através da utilização simultânea de duas antenas.

2.5. Unidade de medição inercial

Tipicamente a recolha e processamento dos dados posicionais da trajetória de um SLMT é designada por inercial ou seja, acelerómetros e giroscópios (sensores inerciais) são utilizados para calcular a posição e orientação de um corpo em relação a um determinado sistema de coordenadas. Esta técnica permite calcular as variações relativas da posição, necessitando de

coordenadas iniciais (fornecidas pelo sistema GNSS) e orientação previamente conhecidas (Le Scouarnec *et al.*, 2014).

De uma forma geral, os sensores inerciais são convenientemente agrupados e controlados por uma UCP, formando uma UMI. A UMI contém uma tríade ortogonal de giroscópios e outra de acelerómetros, os quais fornecem valores de velocidades angulares e acelerações lineares, respetivamente. A navegação inercial é amplamente utilizada na navegação de aeronaves, mísseis, submarinos, navios, robótica, entre outros (Puente *et al.*, 2013). A ampla maioria das UMI destinadas a estas aplicações não é muito compacta e possui um custo elevado. No entanto, os recentes avanços na construção de dispositivos semicondutores têm possibilitado o fabrico de sistemas de navegação inerciais mais leves, compactos, baratos e relativamente precisos.

Os sistemas associados às UMI podem ser classificados em duas categorias: os sistemas de navegação de plataforma estável (também conhecidos como sistemas isolados de rotação ou *gimbaled systems*) e os sistemas de navegação de plataforma analítica, conhecidos como *strapdown systems* (Titterton & Weston, 2004). Uma das vantagens dos sistemas do tipo *strapdown* é a redução do custo, tamanho e complexidade mecânica, em contrapartida requerem um aumento do esforço computacional (Woodman, 2007).

De uma forma geral, as UMI utilizadas pelos SLMT são do tipo *strapdown*, justificando-se assim uma explicação mais detalhada destes sistemas. *Strapdown*, é o nome atribuído a um sistema de medição inercial integrado, onde três acelerómetros e três giroscópios são montados sobre eixos ortogonais coincidentes, fixados sobre uma base rígida. Ao fixar-se esta UMI na plataforma do SLMT, forma-se um sistema de coordenadas denominado sistema de coordenadas da plataforma (Titterton & Weston, 2004).

Os erros atribuídos à UMI resultam essencialmente de imperfeições dos sensores e de fontes de erro aleatórias. Os erros devido à imperfeição dos sensores podem ser determinados com elevada precisão, por um processo denominado calibração. São classificados como erros determinísticos, ou seja, podem ser expressos por uma função matemática bem determinada. Já as fontes de erros de natureza aleatória não possuem uma função matemática que as descreva, podendo apenas ser descritas através da teoria de processos estocásticos. Os erros associados às medições da UMI resultam essencialmente em deriva dos sensores que introduzem um erro cumulativo, sendo a sua magnitude proporcional à magnitude da velocidade angular dos giroscópios e do intervalo de tempo de duração do movimento (Woodman, 2007). O processo protagonizado pela UMI, em que cada nova posição é calculada apenas com base na posição anterior (através das medidas dos sensores inerciais), designado por *dead reckoning*, não pode

ser mantido durante grandes períodos, devido ao acumular contínuo dos erros anteriormente referidos.

As UMI do tipo *strapdown* comerciais são divididas, de acordo com a sua qualidade, em três categorias: alta, média e baixa qualidade. As de alta qualidade referem-se a sistemas inerciais capazes de navegar e detetar as mudanças de orientação e velocidade do SLMT com elevada precisão durante longos períodos (horas). As UMI de média qualidade, apenas conseguem manter uma navegação autónoma de qualidade por alguns minutos. Finalmente, as UMI de baixa qualidade, apenas durante alguns segundos são capazes de navegar com precisão, utilizando apenas com os sensores da UMI, necessitando de sensores auxiliares para prolongar esse tempo.

A cada uma das classificações anteriores correspondem diferentes tipos construtivos dos seus giroscópios (Kavanagh, 2007), nomeadamente: micro eletromecânicos designados por *Micro Electro Mechanical Systems* (MEMS), fibra ótica, *Fiber Optic Gyros* (FOG) e LASER, *Ring Laser Gyros* (RLG). Nos sistemas MEMS, os giroscópios utilizam como sensores pequenos componentes de quartzo integrados em circuitos de silicone. Estes sistemas são os menos precisos, e tornaram-se populares nos sistemas de recolha de imagens, mas são também os mais baratos e devido a esse facto têm vindo a ser cada vez mais utilizados nos SLMT. Os sistemas FOG baseiam-se na interferência da luz que passa por um cabo de fibra ótica. Estes sistemas são mais caros que os MEMS, mas permitem obter uma precisão que satisfaz muitas das aplicações dos SLMT, correspondendo a sistemas de média qualidade. Os RLG são os mais precisos e como o nome indica utilizam tecnologia LASER. Devido às suas exigências construtivas são também os mais caros, o que limita a sua utilização pelos SLMT. A configuração mais comum das UMI, representada na Figura 2.8, resulta da integração de três giroscópios colocados sobre um sistema de eixos ortogonais, permitindo detetar as variações nos três ângulos associados ao movimento da plataforma, *Heading*⁶, *Pitch* e *Roll*.

⁶ Também designado por *Yaw*.




Figura 2.8 - Sistema de eixos ortogonais e respectivos ângulos *Heading*, *Roll* e *Pitch*, definido o sistema de coordenadas da plataforma.

2.6. Princípios de funcionamento de um SLMT

O principal objetivo dos SLMT é a aquisição de dados que permita a criação de uma nuvem de pontos coordenados (X, Y, Z), num referencial absoluto ou inercial. Podendo-se resumir o seu funcionamento em duas fases distintas:

- Determinação da posição e orientação absoluta do sensor no espaço;
- Cálculo da posição relativa dos pontos em relação à posição do sensor.

A posição e orientação absoluta do sensor ao longo da trajetória são determinadas através das coordenadas iniciais fornecidas pelo sistema GNSS e das correções calculadas através da UMI. Dada a deriva associada aos sensores da UMI, torna-se necessário efetuar uma reinicialização dos valores das coordenadas absolutas, em curtos intervalos de tempo, para evitar o aumento das derivas. Ou seja, é necessário fornecer novos valores de posição à UMI para que esta, por integração, reinicie o processo de cálculo das variações de posição e orientação dos seus eixos até ao fornecimento de novas coordenadas pelo sistema GNSS. É neste ciclo, designado por *closed loop* (Mostafa *et al.*, 2001), que se baseia todo o cálculo das posições ao longo da trajetória do sistema. A qualidade posicional absoluta da trajetória está assim diretamente relacionada com a precisão das coordenadas fornecidas pelo sistema GNSS (que depende da disponibilidade e qualidade do sinal GNSS) e da qualidade da UMI do sistema. A fim de melhorar a posição da trajetória em ambientes com frequentes obstruções ao sinal GNSS, existem diversas estratégias, resultantes de algoritmos de processamento e de acordo

com cada um dos produtores de SLMT. Vários estudos apresentam exemplos da investigação na melhoria da qualidade posicional, nomeadamente, em ambientes com obstruções ao sinal GNSS (Haala *et al.*, 2008; Narayana, 2011; Navidi & Landry, 2015; Tang *et al.*, 2015).

O sistema de coordenadas solidário com a plataforma no qual o sistema se encontra integrado (Figura 2.8), tem a sua origem no centro da UMI, e todas as medidas recolhidas pelos outros componentes são referenciadas a esse ponto. Para isso, as distâncias relativas entre esses componentes e o centro do sistema de coordenadas (*lever arms*), devem ser medidos com bastante rigor, sendo muitas vezes utilizado para esse efeito uma estação total ou distanciómetro LASER (Puente *et al.*, 2013). A orientação do sensor LASER em relação aos eixos do sistema de coordenadas da plataforma é tipicamente determinada através de um processo de calibração do sistema (*boresight*).

Todos estes valores necessitam de ser integrados no início do processamento da trajetória. Na Figura 2.9 apresenta-se um esquema com a configuração mais comum dos componentes dum SLMT.




Figura 2.9 - Esquema do posicionamento dos componentes de um SLMT.

Para além do processo de cálculo da trajetória, é necessário determinar a posição dos pontos em relação à posição do sensor. Este cálculo é efetuado utilizando as distâncias e os ângulos obtidos pela reflexão do pulso LASER nos objetos, registados ao longo da trajetória. O cálculo das coordenadas (X,Y,Z) de cada um dos pontos da nuvem final é o resultado da integração das posições absolutas do sensor ao longo da trajetória e as distâncias e ângulos registados pelo

sensor, podendo existir variações nos algoritmos e nos sensores auxiliares associados a cada um dos SLMT.

2.7. Planeamento e recolha dos dados

De forma a enquadrar todo o processo prático de recolha e processamento dos dados, optou-se por explicitar os passos a efetuar diretamente nos softwares de processamento. Para uma comparação dos diferentes sistemas, sugere-se a leitura de El-Sheimy (2005), Petrie (2010) e Puente *et al.* (2013).

Para ilustrar o processo de recolha de dados foi utilizado como exemplo o SLMT, *Lynx M1* da Optech (Figura 2.10), estando os passos e recomendações aqui apresentadas de acordo com as indicações desse fabricante. Genericamente, o sistema é constituído, apenas por um sensor LASER. Os dados foram recolhidos com a frequência máxima (500000 pontos por segundo) e velocidade de rotação de 200 Hz. A navegação inercial é assegurada pelo sistema *Applanix LV 520*.



Figura 2.10 - Sistema LiDAR móvel terrestre *Lynx*.

O sistema de navegação é apresentado pelo fabricante, como tendo as seguintes precisões: 0.020 m em XY, 0.050 m em Z, 0.005 ° nos ângulos *Roll* e *Pitch* e 0.015 ° no ângulo *Heading* (com disponibilidade do sinal GNSS). O sensor LiDAR tem um alcance máximo de 200 m. No entanto, devido à sua posição na plataforma apresentar uma orientação em relação à direção do veículo de cerca de 45°, esse alcance é reduzido para aproximadamente 120 m. A exatidão para essa distância é de 5 cm.

A precisão das nuvens finais obtidas pelo sistema está condicionada pelas condições de recolha, nomeadamente, as obstruções de sinal GNSS, a qualidade da calibração do sistema e as corretas metodologias no processo de recolha dos dados.

Relativamente aos dados GNSS, o sistema LYNX está preparado para funcionar através da técnica de processamento KAR. O sistema é baseado em pós-processamento dos dados GNSS, adquiridos ao longo da trajetória em simultâneo com os dados adquiridos por uma estação base de referência. A base é colocada sobre um ponto de coordenadas conhecidas e todos os dados são processados com base nessas coordenadas. O comprimento da linha de base deverá ser mantido dentro dos valores recomendados para uma base curta (distância inferior a 20 km). É importante salientar que, na definição do comprimento da linha de base, para além das questões relacionadas com a precisão dos dados GNSS, deverá igualmente ter-se em consideração as variações da ondulação do geoide nos casos em que se pretenda utilizar cotas ortométricas com boa exatidão em vez das elipsoidais.

De acordo com o fabricante, com um comprimento de linha de base inferior a 8 km e uma trajetória sem obstáculos significativos (mantendo entre 7 e 10 satélites visíveis tanto na base como nos recetores do veículo), é possível obter para os pontos ao longo da trajetória uma exatidão aproximada de 10 milímetros (Clay & Wygant, 2009). A velocidade do veículo é outro fator a ter em consideração, dado que influencia diretamente a densidade dos pontos das nuvens obtidas.

Depois de devidamente instalado e ligado o recetor GNSS da estação base, deverá proceder-se à inicialização do sistema na viatura. De uma forma resumida, esta inicialização passa por ligar todos os seus componentes, nomeadamente, o sensor LASER, o UMI e o recetor GNSS. No veículo, o estado de cada um dos sensores, assim como, os erros momentâneos associados a cada um deles, podem ser acompanhados pelo operador a partir da interface. Neste caso apresenta-se o *software* LV-POS View da Applanix (Figura 2.11), normalmente instalado num computador portátil ao qual todos os componentes estão ligados. Dada a complexidade de parâmetros específicos e tolerâncias, relacionados com todos os componentes, não se enquadra neste trabalho fazer a descrição exaustiva de todos. No entanto, todos os valores e verificações são disponibilizadas pelo fabricante (Optech, 2011).

Após a inicialização do sistema, é recomendado conduzir-se a viatura durante alguns minutos (particularmente em curva), para a ativação dos acelerómetros e giroscópios da UMI, baixando assim a sua deriva. Imediatamente antes do início da recolha dos dados, o veículo deverá ser

estacionado durante alguns minutos para permitir a obtenção de um ponto em modo estático para garantir a resolução das ambiguidades de fase do GNSS.

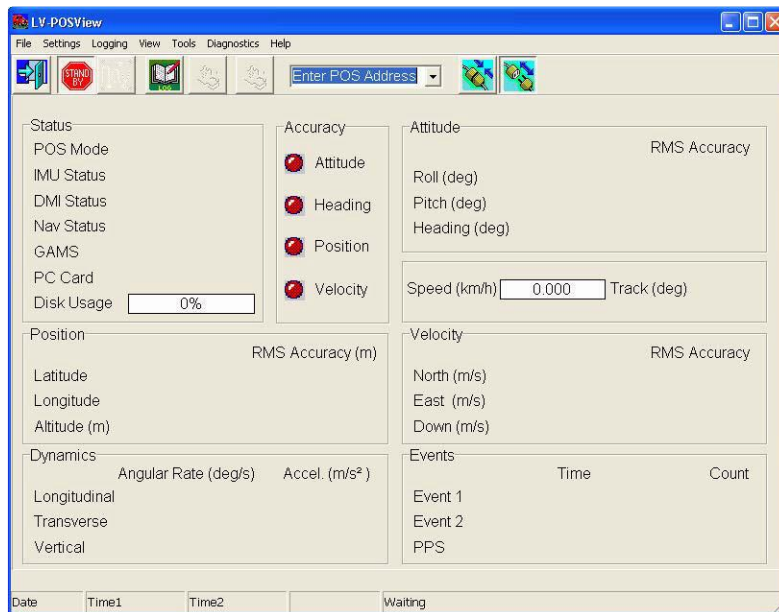


Figura 2.11 - Interface de visualização do LV-POS View.

Ao longo do processo de recolha dos dados, é espectável uma degradação momentânea dos parâmetros, nomeadamente, as coordenadas adquiridas pelo sistema GNSS. Esta degradação é tipicamente de curta duração, verificando-se normalmente uma melhoria após alguns segundos. Isto deve-se essencialmente às obstruções do sinal GNSS, ou de multitrajeto, que ocorrem naturalmente ao longo do percurso do veículo, nomeadamente, em ambientes urbanos ou com vegetação densa. Em situações mais extremas, onde o sinal se mantém degradado por mais tempo (normalmente, superior a 1 minuto), torna-se necessário tomar medidas para evitar a degradação da precisão final da trajetória. A medida mais comum passa pela interrupção da recolha dos dados e a imobilização do veículo por alguns minutos, numa zona sem obstrução ao sinal GNSS, para permitir a reiniciação do processo da fixação de ambiguidades de fase.

Na prática, ao longo do percurso são registados dois tipos de dados, correspondentes às duas fases de processamento dos mesmos:

- Dados posicionais, que são utilizados no posterior processamento da posição e orientação do sensor ao longo da trajetória;
- Dados LASER, que compõem um conjunto de tempos de retorno e ângulos do pulso que após a integração com os dados posicionais processados, permitirão a criação das nuvens de pontos georreferenciadas.

Apesar do sistema estar preparado para registar os dados LASER continuamente, torna-se necessário interromper, manualmente ou automaticamente esse registo de forma a gerar ficheiros com os diferentes tipos de dados ao longo da trajetória. Este procedimento evita a criação de ficheiros demasiado grandes, facilitando o subsequente processamento dos dados.

No final da recolha deverá proceder-se à imobilização do veículo por alguns minutos, numa zona sem obstrução ao sinal GNSS, para permitir terminar a recolha de dados da trajetória com um ponto estático com fixação de ambiguidades. Este procedimento deverá ser igualmente efetuado ao longo da recolha dos dados, sempre que se preveja existirem obstáculos que obstruam o sinal GNSS, por exemplo, antes e depois de uma passagem superior ou túnel.

Após a recolha da área pretendida e o encerramento do sistema, procede-se à transferência dos dados para uma unidade de armazenamento externa de forma a facilitar o seu processamento em gabinete.

São transferidos dois tipos de dados: os ficheiros POS, ficheiros binários onde estão contidos todos os parâmetros recolhidos ao longo da trajetória para o cálculo do posicionamento e os ficheiros que contêm os dados registados pelo sensor LASER. São igualmente descarregados os ficheiros GNSS do recetor da base.

2.8. Processamento dos dados

O processamento dos dados é efetuado em duas fases distintas de acordo com o tipo de dados recolhidos. Em primeiro lugar, é efetuado o processamento da trajetória (ficheiros POS) de forma a obter a respetiva correção posicional da trajetória. Em seguida esses dados são integrados com os dados contidos nos ficheiros do sensor LASER (ficheiros RANGE) de forma a obter as nuvens de pontos georreferenciadas.

2.8.1. Processamento da trajetória

O *software* mais comum para efetuar o processamento das trajetórias é o *software* POSPAC *Mobile Mapping Suite* (MMS) produzido pela empresa APPLANIX. A transversalidade do uso deste *software*, justifica a descrição mais detalhada do seu funcionamento, apresentada de seguida.

A Figura 2.12 apresenta um esquema da arquitetura dos componentes, dados recolhidos e módulos de processamento utilizado pela APPLANIX.

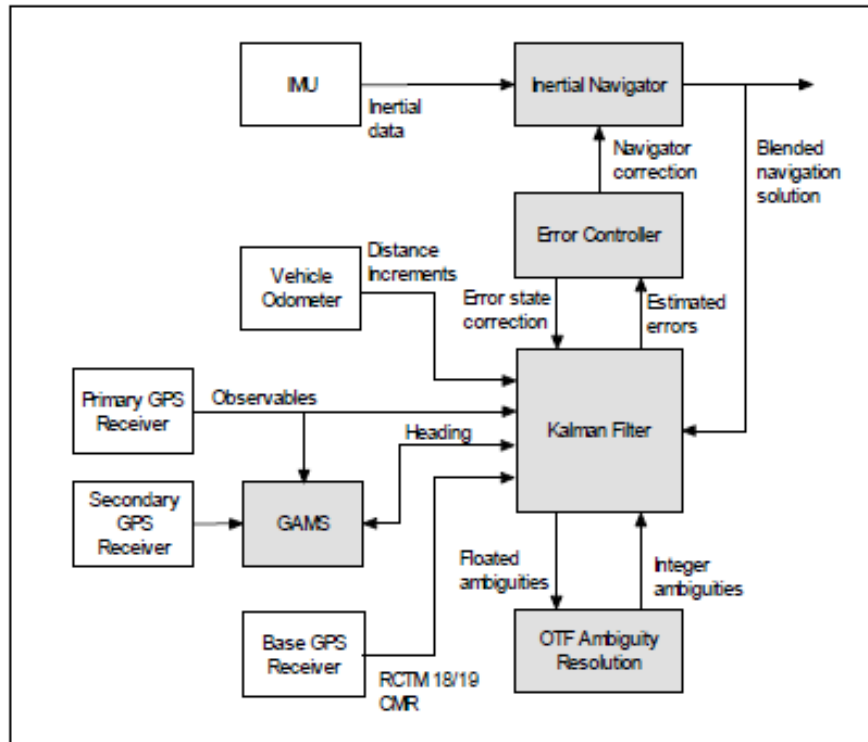


Figura 2.12 - Arquitetura do sistema Applanix. Adaptado de Scherzinger & Hutton, (2006).

Uma grande limitação da navegação inercial está relacionada com a precisão do ângulo *Heading*, parte da trilogia de ângulos associados à UMI (Figura 2.8).

A precisão de determinação do ângulo *Heading*, depende, para além da qualidade do giroscópio, da latitude de lugar. Esta dependência decorre do facto do sistema utilizar a projeção do norte geográfico no plano horizontal local para determinar a direção norte e utilizar o giroscópio para medir a variação dessa direção. A divergência diminui de magnitude com o aumento do valor da latitude para norte e sul. Nos polos norte e sul, o vetor assume o valor zero para a magnitude, sendo a magnitude desse vetor inversamente proporcional ao erro introduzido nas medições do giroscópio (Scherzinger & Hutton, 2006). De forma a contornar esta limitação sem um aumento significativo de custos (giroscópio de alta precisão), a Applanix incorporou no sistema um método designado por *GNSS Azimuth Measurement Subsystem* (GAMS).

O GAMS consiste na colocação de duas antenas GNSS no sistema. A configuração das duas antenas colocadas no sentido longitudinal do veículo permite a determinação rigorosa do azimute, possibilitando uma forma alternativa ao giroscópio UMI na determinação do ângulo *Heading*. Os dados recolhidos pelo subsistema GAMS são processados em conjunto pelo *software*, sendo integrados num filtro de *Kalman*, o que permite uma melhoria significativa na posição e orientação ao longo da trajetória. Por outro lado, os valores de *Heading* medidos pelo

giroscópio da UMI são usados para melhorar os resultados em momentos de obstrução do sinal GNSS. Assim, o GAMS tem a capacidade de calcular dados precisos para o ângulo *Heading*, independentemente dos valores de latitude e da dinâmica do veículo, permitindo utilizar uma UMI mais barata. A importância deste subsistema revela-se particularmente importante em zonas urbanas com bastantes obstáculos ao sinal GNSS e multitrajeto (Scherzinger & Hutton, 2006).

Outro subsistema instalado no veículo, cujos dados são igualmente integrados pelo POSPAC, permitindo melhorar a precisão da trajetória, é o *Distance Measurement Indicator* (DMI). Na realidade, este subsistema consiste num odómetro bastante preciso. O aparelho é instalado numa das rodas do carro permitindo, com base nas rotações da roda, medir a distância percorrida pelo veículo de forma precisa. Esta é outra fonte de dados alternativa para as situações em que o sinal GNSS sofre alguma obstrução.

Os dados destes dois subsistemas GAMS e DMI são integrados pelo POSPAC com os dados fornecidos pelo sistema GNSS e pela UMI, permitindo através de diversos módulos de processamento obter a posição e orientação do sensor ao longo da trajetória do veículo.

Os principais componentes do POSPAC, correspondentes às diferentes fases do processamento descritas sucintamente em seguida, são: Sistema de Navegação Inercial - *Strapdown*; Filtro de *Kalman*; Controlador de erros em ciclos fechados; Módulo de suavização e Módulo de criação da trajetória.

2.8.2. Sistema de navegação inercial

O SNI (sistema de navegação inercial) permite resolver as equações de movimento por aplicação da segunda lei de Newton do movimento, através da integração dos valores de aceleração e variações angulares medidas pela UMI. Tendo em conta que se trata de um processo de integração matemática, o sistema tem de ser inicializado com valores de posição e velocidade conhecidos (fornecidos pelo sistema GNSS), posicionado verticalmente sobre a origem do referencial do sistema e orientado relativamente ao norte geográfico. Uma vez alinhado, o SNI estabelece um sistema de referência local, cuja posição e orientação são conhecidas relativamente ao referencial terrestre, de acordo com o esquematizado na Figura 2.13.

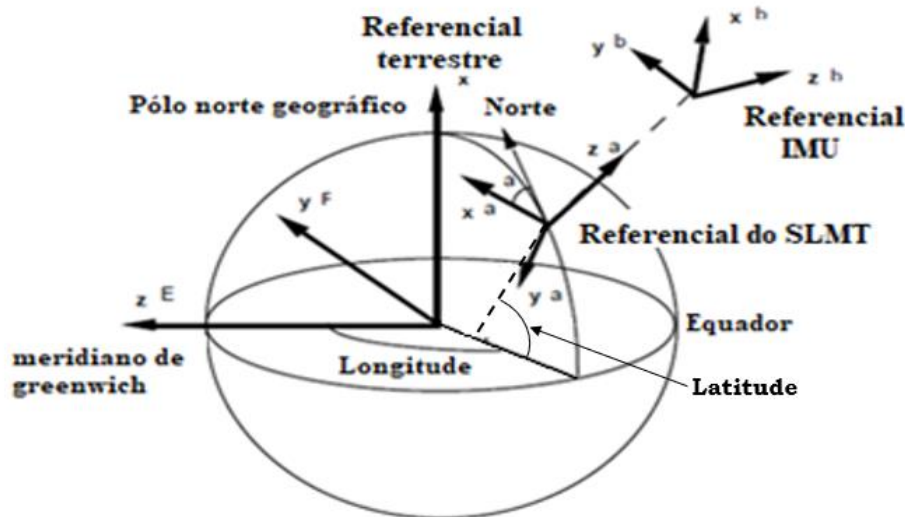


Figura 2.13 - Sistemas de referência do sistema inercial (adaptado de Mustafa & Huton, 2001).

2.8.3. Filtro de Kalman

De forma a utilizar os dados GNSS para estimar os erros da navegação inercial, é utilizado um filtro de *Kalman*. Este filtro implementa um conjunto de equações diferenciais que modelam os erros associados aos sensores da UMI e, conseqüentemente, da navegação inercial. As diferenças entre a posição calculada pelo sistema GNSS e pelos sensores da UMI são processadas pelo filtro de *Kalman* (tipicamente a 1 Hz), para estimar a deriva crescente da UMI, permitindo a estimação implícita dos valores de posição e orientação.

2.8.4. Controlador de erros nos ciclos fechados

O algoritmo designado por controlador de erros em ciclos fechados (*closed-loop error*) é usado para reiniciar o sistema de navegação utilizando os valores estimados pelo filtro de *Kalman*. Os valores das correções aos erros dos sensores inerciais são igualmente aplicados antes de serem integrados. A solução resultante da navegação inercial integrada tem a sua posição e velocidade diretamente asseguradas pela posição absoluta fornecida pelo sistema GNSS, e a sua precisão na orientação indiretamente melhorada pela calibração dos erros dos sensores inerciais.

2.8.5. Módulo de suavização

O módulo de suavização estima os erros associados ao sistema, processando os dados de forma cronológica inversa, e em seguida combinando-os com os valores estimados pelo filtro de *Kalman*. As estimativas dos erros resultantes são assim baseadas nos dados disponíveis antes e

depois do instante de ocorrência, e portanto, mais precisas. É devido à utilização deste filtro que é importante imobilizar o veículo (numa zona sem obstruções ao sinal GNSS) quando existir degradação do sinal GNSS durante um intervalo de tempo considerável, uma vez que permitirá melhorar os dados que foram recolhidos anteriormente (processamento da frente para trás no tempo).

2.8.6. Módulo de criação da trajetória

Este módulo utiliza os valores estimados pelo módulo de suavização e aplica-os na solução integrada de navegação inercial com a frequência da UMI, gerando a trajetória final que é designada por *Smoothed Best Estimate of Trajectory* (SBET).

Todos os módulos e processos aqui referidos são executados sequencialmente pelo software (Figura 14) ao longo do processamento dos dados sem qualquer interferência do utilizador. Em termos de utilização, o POSPAC MMS é muito semelhante a um software de processamento de dados diferenciais GNSS, em que são importados os dados da estação de referência do recetor móvel, juntamente com os dados POS, recolhidos pelo sistema ao longo da trajetória. Após a conclusão do processamento é possível observar a diferença entre a trajetória original antes do processamento e a trajetória corrigida (Figura 2.14).



Figura 2.14 - Trajetória antes (a roxo) e depois (a verde) do processamento.

Para além de todos dados complementares, no final do processamento são gerados os ficheiros SBET e *SMoother Root Mean Square Estimation* (SMRMSG) que serão utilizados na fase seguinte, para geração das nuvens de pontos georreferenciadas. O ficheiro SBET contendo

todos os dados necessários para o estabelecimento da posição e orientação do sensor ao longo da trajetória, é um ficheiro binário em que todos os valores têm precisão dupla (codificados a 8 Bytes). O ficheiro SMRMSG, contém os erros associados a cada uma das medidas incluídas no SBET.

2.9. Processamento das nuvens de pontos georreferenciadas

Para a descrição do processamento das nuvens utilizou-se como referência o software *LiDAR Mapping Suite* (LMS) da Optech. É possível efetuar a esquematização do processo de georreferenciação das nuvens de pontos, através da Equação (2.5) (Le Scouarnec *et al.*, 2014):

$$X_{LIDAR}^{ECEF} = X_{GNSS}^{ECEF} + C_n^{ECEF} C_{SNI}^n (b^{SNI} + (C_{LIDAR}^{SNI}) X_{LIDAR}^{LIDAR}) \quad (2.5)$$

onde, X_{LIDAR}^{ECEF} representa as coordenadas dos pontos da nuvem no sistema *Earth Centered Earth Fixed* (ECEF), X_{GNSS}^{ECEF} representa as coordenadas da antena GNSS, no sistema *Earth Centered Earth Fixed* (ECEF), C_n^{ECEF} é a matriz de rotação que permite a conversão entre o SNI e o sistema ECEF, C_{SNI}^n é a matriz de rotação obtida pelo SNI, b^{SNI} representa o vetor translação entre a antena GNSS e o LiDAR (*lever arms*), C_{LIDAR}^{SNI} representa a matriz de rotação de conversão entre o sistema [LiDAR] e o SNI, finalmente X_{LIDAR}^{LIDAR} é a distância medida pelo sensor LiDAR.

O processo de calibração do sistema consiste em determinar a orientação relativa do sistema LiDAR em relação ao sistema de coordenadas da plataforma, descrita como C_{LIDAR}^{SNI} (Le Scouarnec *et al.*, 2014). Mecanicamente, é muito difícil determinar essa orientação de forma precisa, assim é necessário estimá-la computacionalmente através do procedimento de calibração. Matematicamente, a falta de alinhamento dos eixos pode ser modelada através de uma matriz de rotação designada por matriz de calibração. Esta matriz de rotação é constituída pelos três ângulos de rotação, anteriormente referidos, *Heading*, *Roll* e *Pitch*. De acordo com o erro em cada ângulo, surgem diferentes incongruências e deformações associadas às nuvens de pontos finais. Na Figura 2.15 apresentam-se os três tipos de erros associados a cada um dos ângulos.




Figura 2.15 - Efeito dos erros de calibração em cada um dos ângulos a) *Heading*. b) *Roll*. c) *Pitch*. (Fonte: Optech, 2008).

Existem essencialmente duas abordagens para efetuar a calibração: os processos baseados apenas nos pontos das nuvens recolhidas e os processos baseados no modelo matemático do sistema. Os primeiros são provavelmente os mais populares porque não requerem acesso aos dados GNSS e da UMI. No entanto, são também os menos precisos. Consistem em estimar uma matriz de rotação e um vetor de translação que minimiza a distância entre pontos recolhidos pelo LiDAR em momentos diferentes, ou seja, diferentes nuvens que se sobrepõem parcialmente. Estes processos necessitam que um operador identifique e meça diversos pontos comuns em diferentes nuvens. A segunda abordagem não é baseada nas nuvens, mas sim no modelo matemático descrito na Equação (2.5) (Le Scouarnec *et al.*, 2014). Apesar de mais precisa que a primeira, esta tem algumas limitações, nomeadamente, o facto de ser sensível aos erros GNSS. A Optech apresenta soluções para a execução das duas abordagens. O primeiro é um processo manual apresentado na versão *standard* do LMS. Na prática, passa pela recolha de dados sobre uma parede lisa de um edifício, fazendo-se várias passagens em ambos os sentidos da mesma direção. Em seguida, os dados são processados e manualmente um operador vai eliminando as diferenças entre as diferentes nuvens obtidas. Este é um processo iterativo e requer um operador com bastante experiência de forma a garantir que os ficheiros de calibração finais representem a melhor transformação do sistema de coordenadas da plataforma para o sistema de coordenadas absolutas.

A segunda abordagem está integrada na versão LMS Pro. É um processo de auto calibração utilizando o método de ajustamento por mínimos quadrados, que permite determinar um conjunto de parâmetros desconhecidos com base em observações redundantes (Montour & Parry, 2013). As observações utilizadas correspondem às distâncias e ângulos dos pontos

medidos pelo LASER, a posição do sensor e os ângulos *Heading*, *Roll*, e *Pitch*. A todas as observações são associados pesos de acordo com os valores de desvio padrão *a priori*. Os parâmetros a determinar e respetivos limites para os desvios padrão recomendados no processo de calibração são os apresentados na Tabela 2.1.

Tabela 2.1 - Valores máximos recomendados (Optech,2008).

Designação no LMS	Parâmetro de calibração	Valores de desvio. padrão Max. Recomendados
Boresight angle Ex	Roll	0.005°
Boresight angle Ey	Pitch	0.005°
Boresight angle Ez	Heading	0.005°
Shift in X-coordinate	X Lever Arm	0.0009 m
Shift in Y-coordinate	Y Lever Arm	0.0009 m
Shift in Z-coordinate	Z Lever Arm	0.0009 m

Tendo em conta que o processo de ajustamento é efetuado através do cálculo de planos verticais e horizontais sobre as nuvens de pontos, de forma a obter a redundância necessária, a zona de recolha dos dados deverá obedecer a alguns critérios. Nomeadamente, ser efetuada de preferência nas direções norte-sul e este-oeste (em ambos os sentidos) e na zona de cruzamento de duas vias. Idealmente, deverão existir edifícios e/ou muros ao longo de ambos os lados das vias (planos). A constante sobreposição das nuvens de pontos obtidas ajuda a criar a redundância e a melhorar a eficiência do ajustamento (Figura 2.16).




Figura 2.16 - Esquema de recolha de dados para calibração (adaptado de Montour & Parry, 2013).

Na prática o processo de calibração é iterativo, ou seja, são processados os dados, obtidos novos valores para os parâmetros, sendo o processo, sucessivamente, repetido com os novos parâmetros, até serem atingidos valores de diferenças entre iterações, inferiores aos apresentados na Tabela 2.1. O número de iterações necessárias para atingir os valores das

diferenças entre iterações pretendidos, depende da qualidade dos valores iniciais e da redundância obtida na área de recolha escolhida. Deve salientar-se que o processo de calibração deverá ser repetido sempre que o sistema seja retirado do veículo ou quando exista suspeita de pequenos deslocamentos da plataforma, nomeadamente, em viagens longas. A melhoria do processo de calibração tem despertado o interesse da comunidade científica, como provam os diversos trabalhos publicados sobre este assunto, Le Scouarnec *et al.* (2014), Mao *et al.* (2015) e Nolan *et al.*, (2015).

Todos os dados são processados em conjunto, incluindo os ficheiros SBET, SMRMSG e os ficheiros RANGE contendo os dados recolhidos pelo sensor LASER. Na Figura 2.17 apresenta-se um exemplo dos pontos da trajetória, aos quais são aplicadas as distâncias e ângulos recolhidos pelo sensor, possibilitando a geração das nuvens de pontos georreferenciadas.

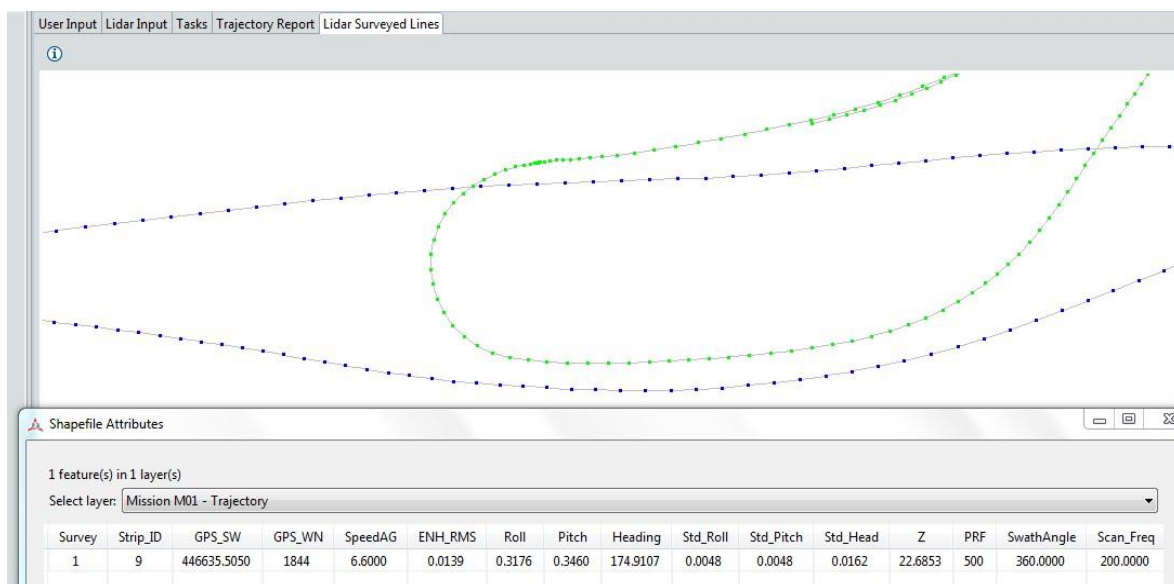


Figura 2.17 - Exemplo dos dados associados aos pontos que definem a trajetória.

Dada a grande variedade dos formatos de armazenamento das nuvens de pontos e do tipo de dados passível de serem associados a cada um dos pontos, na secção seguinte apresenta-se um estudo mais detalhado dos diferentes tipos de formatos de armazenamento existentes.

2.10. Formatos de armazenamento de nuvens de pontos

Os ficheiros de armazenamento das nuvens de pontos podem ser classificados de acordo com a sua forma de codificação, em dois tipos, os *American Standard Code for Information Interchange* (ASCII), vulgarmente designados por ficheiros de texto e, os ficheiros binários com codificação não diretamente inteligível (Samberg, 2007).

Os formatos de armazenamento de nuvens ASCII, mais simples, têm extensão XYZ e contêm apenas os dados referentes à posição dos pontos, nomeadamente, as suas 3 coordenadas tridimensionais. Outros exemplos de ficheiros ASCII são os ficheiros PTS que para além das coordenadas, permitem armazenar o valor de intensidade e os três valores RGB e, os ficheiros PTX propriedade da *Leica Geosystems*, que permitem armazenar várias nuvens de pontos num só ficheiro.

Os formatos de ficheiros binários para armazenamento das nuvens distinguem-se, não só pelo tipo de dados codificados, mas também pela forma como esses dados são codificados. Essa diversidade de formatos resulta, por um lado, de estratégias comerciais dos fabricantes dos sistemas e *software* e, por outro lado, da busca por parte dessas empresas na diminuição do espaço ocupado pelos ficheiros, otimização da velocidade de acesso e visualização das nuvens de pontos. A maioria destes formatos binários têm direitos de autor, por esse motivo na sua maioria a sua estrutura não é conhecida. Sem se pretender efetuar uma lista exaustiva e sem nenhuma ordem específica, na Tabela 2.2 apresenta-se uma listagem dos formatos mais comuns utilizados para o armazenamento das nuvens de pontos.

Tabela 2.2 - Formatos mais comuns de armazenamento das nuvens de pontos.

Extensão	Formato	Empresa/Software
.CMP	Binário	Optech REALM
.DVZ	Binário	FUSION/LDV
.E57	Binário	ASTM
.FLS	Binário	FARO
.LAS	Binário	ASPRS LAS
.POD	Binário	Bentley
.PTX	ASCII	Leica Geosystems
.QTC	Binário	QT Modeler
.RCP	Binário	Autodesk
.SDF	Binário	Riegl
.TS	Binário	TerraScan
.XYZ	ASCII	Ficheiro texto

A maior limitação na utilização dos formatos de propriedade comercial, é que pelo facto de não ser divulgada a sua estrutura, não permitem a interoperabilidade entre sistemas, nem a sua implementação em aplicações de código aberto.

A utilização do formato ASCII apresenta uma limitação relacionada com a baixa performance e eficiência na leitura dos dados. O passo extra da conversão do texto para binário (*parsing*), de forma a permitir a sua interpretação pelos *softwares*, torna necessariamente o processo de leitura

dos dados mais lento. Para além disso, o espaço em disco ocupado por um ficheiro ASCII é substancialmente superior ao ocupado por um ficheiro binário que contenha a mesma quantidade de dados. De forma a contornar estas limitações, a *American Society for Photogrammetry & Remote Sensing* (ASPRS) através do seu comité *File Format Exchange Activities*, criou o formato LAS. O LAS é um formato público, de código aberto, que permite a interoperabilidade de nuvens de pontos tridimensionais e cuja estrutura permite armazenar os dados associados ao processo de recolha. O objetivo desta iniciativa é disponibilizar um formato aberto, que contenha aos dados referentes a uma nuvem de pontos (gerada por um sistema LIDAR ou de qualquer outra fonte), tendo opção de exportação nos diferentes *softwares* comerciais e armazenando os dados recolhidos pelo sistema GNSS, UMI e sensor LASER que originou cada um dos pontos registados (ASPRS, 2020).

Tendo em conta a necessidade, ao longo deste trabalho, de implementação de algoritmos de leitura de nuvens de pontos, o formato LAS surge naturalmente como o formato por excelência para o armazenamento dessas nuvens. Assim, todos os algoritmos propostos ao longo deste documento são baseados em nuvens de pontos armazenadas em formato LAS. Por esse motivo, torna-se essencial uma descrição detalhada desse formato.

2.10.1. Estrutura do formato LAS

À data deste documento, a versão mais atual do formato LAS é a 1.4 e revisão 15. A estrutura deste formato está dividida em 4 blocos principais de dados: um cabeçalho, um número de *Variable Length Records (VLR)*, o registo individual de cada um dos pontos e finalmente, um número variável de *Extended Variable Length Records (EVLN)*. Todos os dados têm codificação binária em *little-endian* (ASPRS, 2020).

A manutenção e atualização do formato LAS tem sido efetuada através do comité interno da ASPRS, designado por *LAS File Format Exchange*. Na Tabela 2.3 são enumeradas as diferentes versões publicadas até à data do formato LAS, incluindo o formato de pontos suportada por cada uma delas.

Tabela 2.3 - Versões publicadas do formato LAS e respetivos formatos de pontos suportados.

Versão	Data de publicação	Formatos de pontos suportados
1	9 Maio de 2003	0-1
1.1	7 Maio de 2005	0-1
1.2	2 Setembro de 2008	0-3
1.3	24 Outubro de 2010	0-5
1.4	14 de Novembro de 2011	0-10
1.4 - R15	9 de Julho de 2019	0-10

O cabeçalho contém dados genéricos do ficheiro, como o número de pontos, os limites geográficos, etc. Na Tabela 2.4 é apresentada a totalidade do cabeçalho de um ficheiro LAS na versão 1.4.

Tabela 2.4 - Estrutura do cabeçalho do ficheiro LAS

Variável	Formato	Dimensão	Descrição
Assinatura	Char [4]	4 Bytes	Assinatura do formato, "LASF" (LAS File)
Identificador	unsigned short	2 Bytes	Identificador do ficheiro
Codificação global	unsigned short	2 Bytes	Tipo de codificação do ficheiro
Id. do projeto (1 a 4)	unsigned long	4 Bytes	Quatro campos livres
Versão	unsigned char	1 byte	Dois campos (parte inteira e decimal)
Id. do sistema	Char [32]	32 bytes	SLMT utilizado para a recolha dos dados
Software	Char [32]	32 bytes	<i>Software</i> utilizado
Dia e ano	unsigned short	2 bytes	Dia e ano de criação do ficheiro
Dimensão do cabeçalho	unsigned short	2 bytes	Dimensão em bytes do cabeçalho
N.º bytes 1º ponto	unsigned long	4 bytes	Byte em que se inicia o primeiro ponto
Número de VLR	unsigned long	4 bytes	Número de VLR contidas no ficheiro
Formato dos pontos	unsigned char	1 byte	Formato dos pontos (0-10 na versão 1.4)
Nº Bytes dos pontos	unsigned short	2 bytes	Número de bytes do registo de cada ponto
Nº de pontos	unsigned long	4 bytes	Número total de pontos
Nº por retorno	unsigned long	20 bytes	Número de pontos de cada retorno
Fator de escala X,Y e Z	Double	8 bytes	Fator de escala associada às coordenadas
Translação X,Y e Z	Double	8 bytes	Translação aplicada às coordenadas
X,Y e Z Máx. e Mín.	Double	8 bytes	Coordenadas da área coberta

Dado o seu carácter opcional e com pouca contribuição para a descrição dos dados, não é apresentada a descrição das VLR e EVLR, podendo, no entanto, ser consultada em ASPRS (2020).

Para os registos individuais de cada ponto existem para a versão 1.4, 11 formatos numerados de 0-10. Estes formatos resultam da evolução das versões do LAS baseadas nas necessidades detetadas, permitindo aumentar o número de dados associados a cada ponto ou aumentar o número de bytes disponíveis para o seu registo. Para cada ponto, para além das suas

coordenadas, o formato LAS permite que sejam guardados específicos, nomeadamente, os valores de RGB, intensidade de retorno, número de retornos, etc.

Na Tabela 2.5 é apresentado o formato de ponto 3, uma vez que será o formato mais utilizado ao longo deste trabalho, no entanto, a totalidade dos formatos de pontos poderá ser consultada em ASPRS (2020).

Tabela 2.5 - Estrutura do formato 3 de registo de pontos.

Item	Formato	Tamanho	Descrição
X	Long	4 bytes	Coordenada X do ponto
Y	Long	4 bytes	Coordenada Y do ponto
Z	Long	4 bytes	Coordenada Z do ponto
Intensidade	unsigned short	2 bytes	Valor inteiro da magnitude do retorno
Número de retorno	3 bits (bits 0 – 2)	3 bits	Número de retorno do pulso emitido
Número de retornos	3 bits (bits 3 – 5)	3 bits	Número de retornos do ponto
Direção de varrimento	1 bit (bit 6)	1 bit	Direção do perfil
Limite de perfil	1 bit (bit 7)	1 bit	1 no limite e 0 nos restantes casos
Classificação do ponto	unsigned char	1 byte	Valor da classe do ponto
Ângulo de varrimento	Char	1 byte	Valor do ângulo de varrimento
Dados utilizador	unsigned char	1 byte	Campo livre
Origem do ponto	unsigned short	2 bytes	Ficheiro de origem do ponto
Época GPS	Double	8 bytes	Valor da época GPS
Vermelho	unsigned short	2 bytes	Valor de vermelho (RGB)
Verde	unsigned short	2 bytes	Valor de verde (RGB)
Azul	unsigned short	2 bytes	Valor de azul (RGB)

De notar que de forma a diminuir o número de algarismos das coordenadas e, conseqüentemente, diminuir o tamanho do ficheiro é aplicada uma translação e um fator de escala, que poderá ser diferente para cada uma das coordenadas (X,Y,Z) dos pontos. Assim, as coordenadas absolutas de cada ponto podem ser calculadas através das seguintes equações:

$$\begin{cases} X_p = X_t + X * X_s \\ Y_p = Y_t + Y * Y_s \\ Z_p = Z_t + Z * Z_s \end{cases} \quad (2.6)$$

onde, X_p , Y_p e Z_p , são as coordenadas absolutas do ponto, X_t , Y_t e Z_t , são as coordenadas do ponto da translação, X , Y , Z são as coordenadas do ponto armazenadas e X_s , Y_s e Z_s , representam os fatores de escala em cada componente.

2.11. Exemplo prático de recolha e processamento de dados recolhidos por SLMT

De forma a validar os processos descritos anteriormente, utilizou-se um levantamento ilustrado na Figura 2.18, efetuado na Avenida 22 de Maio, município de Itaboraí, estado do Rio de Janeiro, Brasil, com comprimento aproximado de 12 km. Pretende-se neste caso obter as nuvens de pontos que sirvam de base à produção de cartografia à escala 1:500, de toda a área pública ao longo da via.

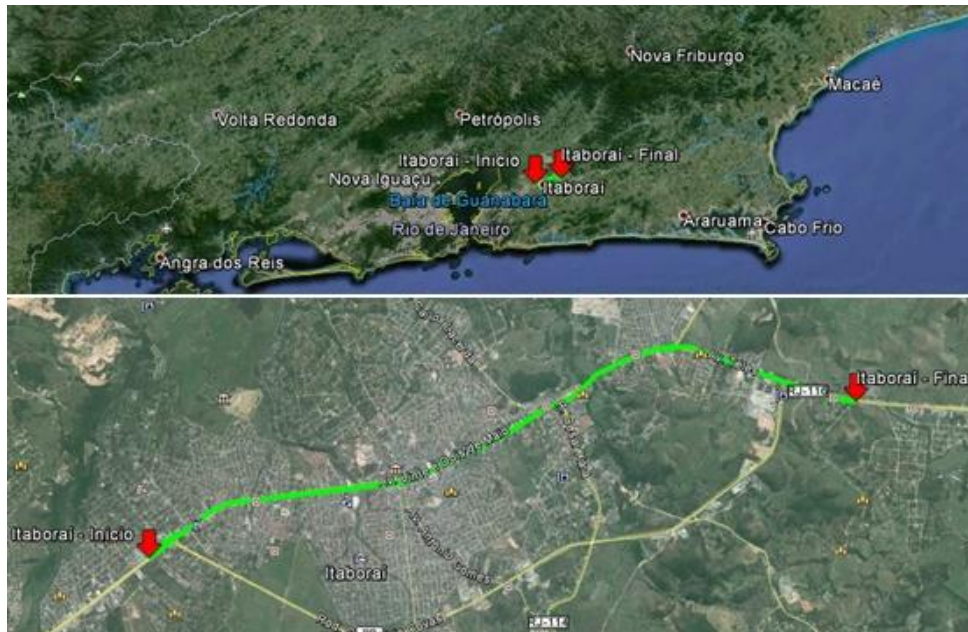


Figura 2.18- Caracterização da área do levantamento.

Neste exemplo, o sistema LiDAR utilizado para a recolha dos dados foi o *Lynx M1* da Optech, sendo a recolha efetuada de acordo com as recomendações do fabricante, seguindo todos os passos descritos nas secções anteriores. A zona escolhida é uma zona urbana com edifícios altos e árvores ao longo do percurso, apresentando dificuldades na receção do sinal GNSS.

Para efetuar a calibração, foram realizadas 8 passagens numa zona de cruzamento de duas vias (4 em cada direcção) de forma a obter a redundância pretendida. O processo de calibração foi realizado através do processo automático, por ajustamento de mínimos quadrados, descrito na Secção 2.8.2. Na Figura 2.19 são apresentados os resultados obtidos ao fim de 5 iterações do processo de ajustamento, podendo verificar-se que os valores de desvio padrão estão abaixo das tolerâncias definidas na Tabela 2.1.

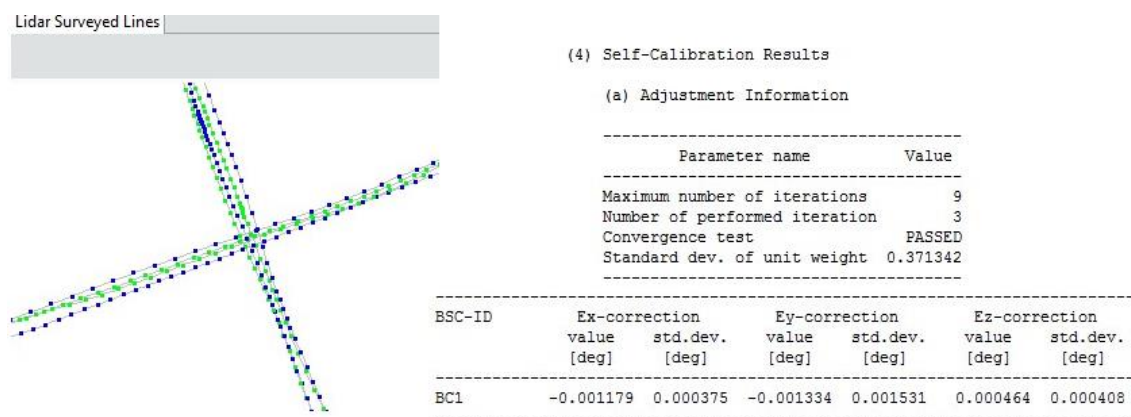


Figura 2.19 - Resultados do processo de calibração.

Após efetuado todo o processo, obtiveram-se 18 nuvens de pontos, como resultado da recolha de dados ao longo da área de trabalho nos dois sentidos. Na Figura 2.20, apresenta-se o exemplo de uma nuvem obtida, colorida por elevação e intensidade.



Figura 2.20 - Exemplo de uma nuvem de pontos final.

Para efetuar a verificação da exatidão das nuvens foram medidos 25 pontos pré-sinalizados ao longo da área de trabalho, de forma a serem identificáveis nas respetivas nuvens de pontos (Figura 2.21).




Figura 2.21 - Distribuição dos pontos de controlo ao longo da área de trabalho.

Os pontos de controlo foram medidos através de recetores GNSS (dupla frequência), em pós-processamento, com um mínimo de 20 minutos de observação. De forma a serem mais facilmente identificados nas nuvens, a materialização destes pontos foi feita através de dois quadrados pintados com tinta branca. Na Figura 2.22 é exemplificada a medição de um ponto de controlo e a sua visualização na nuvem de pontos.

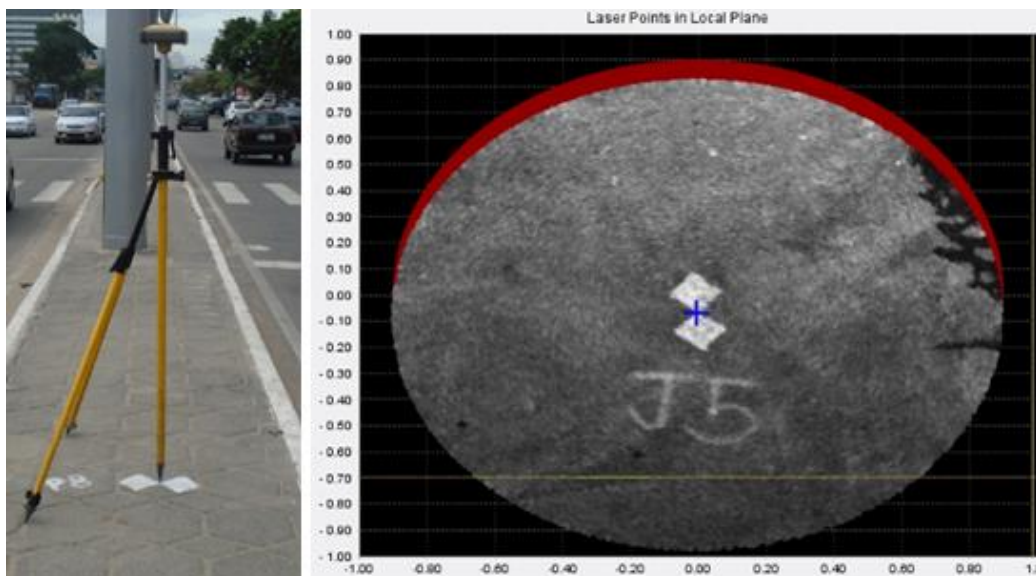


Figura 2.22 - Exemplo de ponto de controlo em campo e a medição sobre as nuvens.

Na Figura 2.23 é representado um exemplo de uma secção transversal de duas nuvens A e B sobre um ponto de controlo. É possível verificar a diferença altimétrica entre as duas nuvens e o ponto de controlo.




Figura 2.23 - Diferença entre nuvens sobre um ponto de controlo.

Todos estes pontos foram medidos sobre as nuvens em planimetria e altimetria apresentando-se na Tabela 2.6 os dados estatísticos referentes às diferenças medidas.

Tabela 2.6 - Valores estatísticos referentes às diferenças entre os pontos de controlo e as nuvens de pontos.

	Diferenças (m)	
	Planimetria	Altimetria
Média	0.025	0.049
Valor máximo	0.055	0.068
Valor mínimo	0.003	0.022
Desvio padrão	0.015	0.013

Muitos dos pontos de controlo foram capturados por mais de uma nuvem, verificando-se existirem diferentes valores para diferentes nuvens, o que demonstra a inconsistência entre as nuvens sobrepostas. De forma a uniformizar as medidas para todos os pontos de controlo, utilizou-se o critério de apenas considerar os valores relativos à nuvem que apresentou maior diferença em cada um dos pontos de controlo.

Verificou-se, como exemplificado na Figura 2.24, que em zonas muito acima do solo, nomeadamente em prédios e vegetação, a diferença entre nuvens é maior, atingindo, em alguns casos, valores próximos de 20 cm.

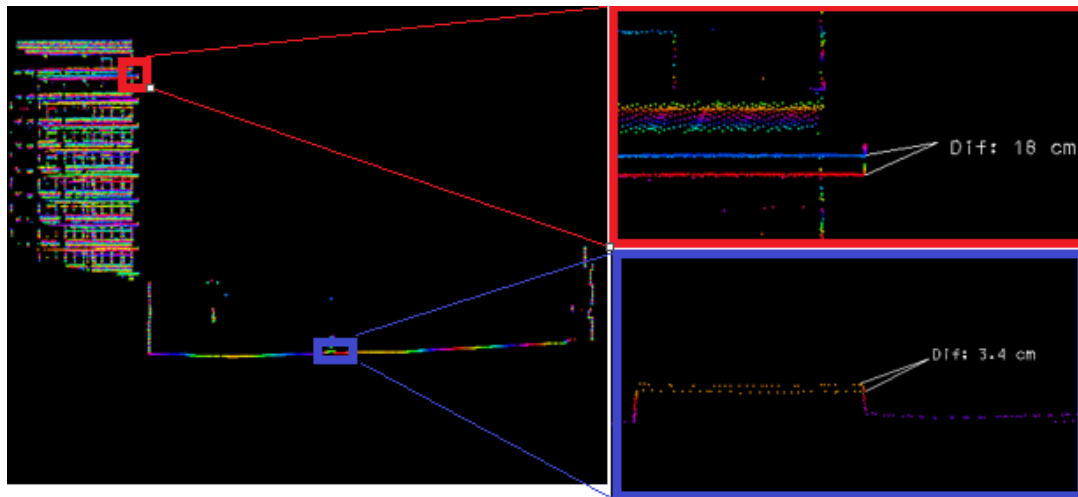


Figura 2.24 - Diferenças entre duas nuvens ao longo do mesmo perfil transversal, junto ao solo e no topo de um edifício.

Com base na inconsistência entre nuvens sobrepostas verificada nos pontos de controle, e nas diversas medições efetuadas, é possível concluir que as diferenças altimétricas entre nuvens sobrepostas não são resultantes apenas de uma translação. Verifica-se que existe uma rotação entre as nuvens, como é observável nas medições apresentadas na Figura 2.24.

Tendo em conta que estas diferenças têm um impacto direto na implementação dos algoritmos de classificação e segmentação das nuvens de pontos, para a geração de MDT, e que este continua a ser uma problemática em aberto, justifica-se um estudo mais detalhado dos tipos de métodos de ajustamento de nuvens de pontos sobrepostas existentes.

2.12. Estado de arte dos métodos de ajustamento de nuvens de pontos sobrepostas

Sempre que são recolhidas duas ou mais nuvens sobre a mesma área geográfica, de diferentes pontos de vista ou em diferentes épocas, existem inevitavelmente diferenças relativas de posicionamento entre essas nuvens. Essas diferenças poderão ir de alguns milímetros até dezenas de centímetros e resultam dos erros associados à recolha e processamento das nuvens (Gao *et al.*, 2015; Gressin *et al.*, 2012). Apesar da diversidade das fontes dessas diferenças, a principal fonte de erro resulta das obstruções ao sinal GNSS durante o processo de recolha dos dados e assume um maior valor na sua componente altimétrica.

Considerando duas nuvens de pontos total ou parcialmente sobrepostas, representando a mesma área de terreno, se existirem diferenças altimétricas entre elas, serão geradas duas superfícies representativas do terreno, paralelas ou não. Esta ambiguidade impossibilita a aplicação de métodos para a classificação de pontos para geração de MDT. Justifica-se assim um olhar mais detalhado sobre a temática do ajustamento de nuvens com sobreposição. Ao longo desta secção,

apresenta-se um estudo aprofundado do processo de ajustamento de nuvens de pontos obtidas por SLMT. Para além do estado da arte, propõe-se um método inovador eficiente para efetuar o processo de ajustamento de nuvens obtidas por SLMT.

A grande quantidade e atualidade dos estudos publicados sobre o ajustamento de nuvens de pontos recolhidas por sistemas LiDAR demonstra bem a relevância e o interesse científico deste assunto. Os métodos existentes podem ser classificados de diversas formas, dependendo da aproximação ao problema e do tipo de estruturas geométricas utilizadas no ajustamento. Os métodos de ajustamento podem ser classificados em 3 grandes famílias (Gressin *et al.*, 2013): métodos baseados em estruturas, métodos baseados em superfícies e métodos locais. As principais características destas três famílias são descritas nas subsecções seguintes.

2.12.1. Métodos baseados em estruturas

Neste tipo de métodos, o ajustamento é efetuado com base na correspondência entre pontos, linhas, planos ou outras estruturas identificadas como correspondentes nas duas nuvens de pontos. Estes métodos baseiam-se essencialmente em dois passos, identificação das estruturas correspondentes em cada uma das nuvens e o subsequente ajustamento. As estruturas a identificar em cada uma das nuvens poderão ser pontos-chave (Barnea & Filin, 2008; Gao *et al.*, 2015; Wang & Brenner, 2008; Weinmann *et al.*, 2011), cantos de estruturas existentes (Cheng, *et al.*, 2013), estruturas básicas específicas (esferas, cilindros) ou estruturas mais complexas (Jaw & Chuang, 2008; Kitamura *et al.*, 2012; Thapa *et al.*, 2009).

Wu *et al.* (2013) apresentam um trabalho interessante da utilização de pontos, linhas e planos para ajustar modelos topográficos da lua obtidos por diferentes sensores. Este trabalho realça de forma clara as dificuldades de integração de MDT gerados por diferentes sensores e a necessidade do seu ajustamento. Han & Jaw (2013) utilizam estruturas geométricas híbridas para resolver a transformação 3D e estabelecer similaridades entre os dois sistemas de referência. Além disso, esta abordagem fornece uma solução automática para a transformação e, conseqüentemente, não requer um valor inicial específico para iniciar o processo de estimação dos parâmetros de transformação. Chuang & Jaw (2015) apresentam um operador que inclui as principais transformações entre geometrias, nomeadamente rotação, mudança de escala e translação, conseguindo definir correspondências entre múltiplos tipos de estruturas e parâmetros de transformação 3D, permitindo assim, um maior automatismo do processo. Hänsch *et al.* (2014) apresentam um estudo comparativo entre diversos métodos de

identificação e operadores com base em pontos. Este estudo expõe as limitações de alguns métodos e realça a necessidade da adequação do método a cada tipo de dados.

Uma outra abordagem ao problema é a do reconhecimento de formas e objetos 3D. Bronstein *et al.* (2010) apresentam um conjunto de resultados de diferentes métodos de detecção de formas, concluindo claramente que os melhores resultados são obtidos por métodos baseados no algoritmo de *Kernel*. Na detecção de formas realça-se ainda diferentes técnicas tais como histograma das formas (Gelfand *et al.*, 2005), operadores escala-espaco-vetor (Li & Guskov, 2005), e operadores locais de superfície baseados em estruturas conspícuas (Gal & Cohen-Or, 2006). Mais recentemente Chen *et al.* (2017) referem que o ajustamento automático de nuvens de pontos obtidos por sistema LiDAR terrestre é um tópico crucial, mas ainda não totalmente resolvido, e de grande interesse em muitos domínios. Este estudo combina nuvens de pontos recolhidas com um SLT, com dados recolhidos de um *smartphone* para um ajustamento grosseiro baseado em variações dos ângulos *roll e pitch*, e diferenças de altitude. A distância aproximada entre duas nuvens de pontos vizinhas é calculada em primeiro lugar com coordenadas GNSS do *smartphone*. Em seguida, é utilizado um método designado por entropia iterativa mínima, de forma a calcular a distribuição das diferenças entre as nuvens e estabelecer os parâmetros de transformação iniciais. Chuang & Jaw (2017) apresentam um esquema de ajustamento baseado na extração de pontos, linhas e planos das nuvens de pontos para realizar o ajustamento das nuvens adquiridas pela mesma plataforma LiDAR. Uma mais-valia desse estudo é apresentar resultados para ajustamento entre nuvens de pontos obtidas por diferentes plataformas, SLT, SLMT e SLA.

2.12.2. Métodos baseados em superfícies

Este tipo de métodos faz a abordagem ao problema através da correspondência entre superfícies. Neste caso os modelos utilizam a representação vulgarmente designada por *mesh*, que são representações das superfícies através da triangulação irregular de pontos (TIN), sendo o ajustamento efetuado diretamente entre as representações das superfícies.

Teo & Huang (2014) apresentam uma solução para o ajustamento entre nuvens de pontos obtidas através de SLA e SLMT, utilizando superfícies geradas com base nas nuvens e o método de ajustamento de mínimos quadrados para minimizar a diferença entre as nuvens. Esta é uma tarefa que se revelou desafiante para os autores, devido à variação da densidade e direção de obtenção de pontos das nuvens obtidas pelos dois tipos de sistemas. Holz & Behnke (2014)

apresentam igualmente um método baseado no ajustamento de superfícies, de forma a contornar a dificuldade inerente à diferença de densidade entre nuvens.

2.12.3. Métodos locais

Estes métodos utilizam diretamente os pontos das nuvens e não se baseiam na deteção de estruturas, nem necessitam de prévia modelação da superfície. Os métodos podem ser aplicados em toda a nuvem, ou apenas a um subconjunto de pontos da mesma. O objetivo passa por encontrar correspondências entre as duas nuvens de pontos, e em seguida, estimar a transformação a aplicar. Estes métodos podem ser classificados pela forma como os dois processos são efetuados em simultâneo ou em sequência.

Os métodos em simultâneo são reconhecidos como sendo bastante robustos, uma vez que os erros são distribuídos por todos os pontos de forma a limitar a distorção e preservar a geometria. Myronenko & Song (2010) propõem um método probabilístico, denominado algoritmo de derivação de ponto coerente, tanto para o registo de conjuntos de pontos rígidos como não-rígidos. Neste caso, assumem o alinhamento de duas nuvens de pontos como um problema de probabilidade de estimativa de densidade. As maiores fragilidades deste tipo de métodos estão relacionadas com o tempo de computação e a perda potencial de pequenos detalhes ou pormenores na nuvem devido à acumulação dos erros (Gressin *et al.*, 2013). Os métodos sequenciais podem apresentar resultados imprecisos, uma vez que os erros poderão ser facilmente propagados, a menos que exista a garantia de um alinhamento inicial correto. O tipo de otimização do método pode ser global ou local, tendo alguns autores tentado um método que mistura os dois níveis (Breitenreicher, 2010; Papazov & Burschka, 2011).

As otimizações globais ou estocásticas usando, por exemplo, métodos *branch-and bound*, *simulated annealing*, algoritmos genéticos, ou métodos evolucionários são normalmente caracterizados por grandes tempos de computação e cálculos muito complexos (particularmente os determinísticos, apesar da garantia de convergência) e são geralmente vistos como um ajustamento grosseiro das nuvens (Silva *et al.*, 2005). Estes podem ser conjugados com métodos locais, mesmo que alguns autores consigam chegar a um ajustamento mínimo sem qualquer inicialização. Li & Hartley (2007) apresentam exatamente um método baseado na teoria de otimização de *Lipschitz*, que permite garantir uma otimização global sem qualquer inicialização.

Existem ainda outros métodos locais, baseados em ajustamento por mínimos quadrados (Grant *et al.*, 2012; Gruen & Akca, 2005), correlação de *Kernel* (Tsin & Kanade, 2004) ou transformação através de uma distribuição normal (Ripperda & Brenner, 2005).

Apesar de alguns destes métodos apresentarem resultados bastante interessantes, o método mais divulgado e reconhecidamente mais eficaz na família dos métodos locais é o algoritmo designado por *Iterative Closest Point* (ICP) (Gressin *et al.*, 2013). A simplicidade deste método introduzido por Chen & Medioni (1991) e Besl & McKay (1992) é a razão do seu uso extensivo em nuvens de pontos com diferentes densidades e contextos. O método ICP minimiza iterativamente o erro médio quadrático entre um conjunto de pontos pertencente a uma determinada nuvem e o ponto mais próximo numa outra nuvem. Na prática, o ICP é constituído por cinco passos: seleção; identificação de correspondências; rejeição; definição de pesos; e, identificação das zonas onde a transformação estimada minimiza uma determinada função.

Devido à sensibilidade do método iterativo ao ruído, muitas variantes foram desenvolvidas para melhorar os 5 passos consecutivos que constituem o ICP, com vários graus de sucesso e em muitos casos focados em contextos específicos.

Rusinkiewicz & Levoy (2001) enumeram e classificam muitas variantes do método ICP e avaliam o seu efeito na velocidade com a qual o ajustamento correto é alcançado. Concluem propondo uma combinação de variantes ICP otimizadas, demonstrando que a sua implementação é capaz de alinhar duas nuvens em algumas dezenas de milissegundos, assumindo uma boa posição inicial. A qualidade do ajustamento obtida por este algoritmo depende muito da escolha dos pares de pontos correspondentes nas duas nuvens. Se forem escolhidos muitos pontos de regiões sem características distintas, o algoritmo converge lentamente, efetua o ajustamento errado, ou pode até divergir, especialmente na presença de ruído ou de erros de calibração dos sistemas de recolha dos dados. Gelfand *et al.* (2003) descrevem um método para detetar a incerteza associada à posição inicial e propõem uma estratégia de seleção de pontos para aplicação do ICP que minimiza essa incerteza. Segal *et al.* (2009) combinam os algoritmos ICP e ponto-plano num único quadro probabilístico. O método ponto-plano minimiza a distância entre um ponto de uma nuvem e o plano tangente ao seu ponto correspondente na outra nuvem (Chen & Medioni, 1991).

Em seguida, usam essa estrutura para modelar a superfície localmente plana de ambas as nuvens, em vez de apenas a nuvem “modelo”, como normalmente é feito com o método ponto-plano. A nova abordagem é testada com dados simulados e reais e é mostrado que supera tanto o ICP padrão quanto o método ponto-plano.

Bae (2010) defende um método baseado em primitivas geométricas e pesquisa de vizinhança. A mudança de curvatura geométrica e o vetor normal aproximado da superfície formada por um ponto e a sua vizinhança são usados para determinar a possível correspondência entre nuvens de pontos. O trabalho apresentado por Gressin *et al.* (2013) pretende demonstrar como o conhecimento da forma que melhor se adapta à geometria local de cada ponto da nuvem pode melhorar a velocidade e a precisão de cada um dos cinco passos do método ICP. Várias variações de cada um desses passos são propostas e analisadas, pelos autores, sendo no final verificadas melhorias em dois dos cinco passos do ICP.

Entretanto outros métodos surgiram com base no ICP, por exemplo o *Iterative Closest Patch* (ICPatch) apresentado por Habib *et al.* (2010), um método derivado do ICP utilizando a relação ponto-plano em vez de ponto-ponto. A vantagem do ICPatch relativamente ao ICP é o facto de no caso do ICP o estabelecimento da correspondência ser baseada num único ponto, podendo facilmente ser mal estabelecida e levar a erros no ajustamento. Enquanto que, utilizando o ICPatch são estabelecidos planos numa das nuvens permitindo estabelecer a relação ponto-plano.

Al-Durgham & Habib (2013) apresentam outra evolução baseada no ICP, o *Iterative Closest Projected Point* (ICPP). A criação deste método propõe-se por um lado suprir a limitação do ICP referida anteriormente, por outro lado, os planos necessários para o ICPatch requerem um passo adicional para a sua criação, nomeadamente através da triangulação de Delaunay.

A triangulação de Delaunay de um conjunto de pontos S , introduzida pelo russo Boris Nikolaevich Delaunay (Delaunay, 1934), é caracterizada pela propriedade de circunscrição vazia, ou seja, nenhum ponto de S reside no interior do círculo circunscrito de qualquer triângulo formado pelos restantes pontos. A triangulação de Delaunay caracteriza-se por maximizar o ângulo mínimo e otimiza vários outros critérios geométricos relacionados com a precisão da interpolação (Cheng *et al.*, 2012).

No ICPP propõe-se eliminar as limitações decorrentes do uso do ICP e do ICPatch. Num primeiro passo, as nuvens individuais são segmentadas para identificar pontos que pertencem a superfícies planas. Nesta etapa, estima-se a densidade, a rugosidade da superfície e as direções normais da superfície. Num segundo passo é estabelecido o ICPP, cujo conceito se baseia em estabelecer um ponto físico de uma das nuvens baseado na projeção dos pontos correspondentes entre duas nuvens ao longo da zona de sobreposição, e em diminuir a distância euclidiana entre esse ponto e a segunda nuvem (Gressin *et al.*, 2012).

Alguns processos utilizam dados auxiliares exteriores à nuvem de pontos, é o caso da utilização das imagens obtidas por câmaras acopladas aos sistemas LiDAR. Um exemplo disso é o estudo apresentado por Han & Jaw (2013), onde numa primeira fase são estabelecidas correspondências entre pontos sobre as imagens e posteriormente são calculados parâmetros de transformação e aplicados às nuvens de forma a permitir o seu ajustamento. Chien-Chou *et al.* (2017) apresentam um estudo semelhante com algumas variações que permite a otimização do processo, nomeadamente, ordenando os pares de pontos correspondentes por distância e utilizando apenas a metade desses pares com maior valor para efetuar o ajustamento. Outros estudos, não usando diretamente as imagens, fazem uso dos valores RGB extraído das imagens e associados a cada ponto das nuvens (Kim, 2016).

Lei *et al.* (2017) descrevem as áreas de aplicação das nuvens de pontos e chamam a atenção para o facto de as nuvens recolhidas por sistemas LiDAR poderem sofrer muitas torções, que juntamente com o ruído e as sombras causadas por objetos, tornam o processo de ajustamento das nuvens num problema bastante desafiante. A sua abordagem ao problema é feita através do cálculo de valores e vetores normais a diversas escalas, permitindo em seguida a extração de diferentes estruturas. Ji *et al.* (2017) apresentam um novo método híbrido de mínimos quadrados para o registo de nuvens de pontos.

Com base na descrição do estado de arte dos métodos de ajustamento de nuvens de pontos recolhidas por sistemas LiDAR, descritos anteriormente, constata-se que este continua a ser um tema científico atual em aberto, e continua a despertar o interesse dos investigadores. A dinâmica atual e diversa de abordagens é demonstrativa da atualidade e interesse científico deste tema. Apesar de já existirem vários estudos que tentam efetuar o ajustamento entre nuvens recolhidas de diferentes plataformas SLA, SLT e SLMT (Chuang & Jaw, 2017), é claramente menor o número de estudos específicos para o ajustamento de nuvens obtidas por SLMT. Uma explicação para tal, é o facto de a tecnologia ser mais recente, existindo um número menor de sistemas.

Considerando o processo de recolha e processamento dos dados, em conjunto com o estado da arte descrito anteriormente, a abordagem proposta neste trabalho, descrita no Capítulo 3, baseia-se na eliminação das diferenças entre as nuvens apoiada no estudo das fontes desses erros.

2.13. Classificação de pontos de nuvens recolhidas por SLMT para a geração de MDT

A tecnologia LiDAR é uma técnica não seletiva, ou seja, as nuvens de pontos georreferenciadas representam a realidade física circundante no momento da aquisição, indiscriminadamente, sem classificação, incluindo: terreno, vegetação, edifícios ou qualquer outro objeto dentro do alcance do sistema. Assim, para usar esse tipo de dados na geração de MDT, é necessário identificar e classificar os pontos da nuvem que representam a forma do terreno.

A obtenção do MDT ao longo de uma via e da sua área circundante, com grande detalhe e precisão, é uma necessidade em muitas áreas, como por exemplo, em projetos de redes de água e saneamento, colocação de asfalto ou melhoria da infraestrutura rodoviária, etc. Esta necessidade é ainda mais significativa nos países em vias de desenvolvimento. No entanto, a recolha dos dados para gerar o MDT é tipicamente mais difícil nesses países, seja pela falta de mão-de-obra qualificada, seja por questões de segurança, ou pelo facto desses projetos estarem localizados em áreas remotas onde os custos de produção não são compatíveis com os recursos disponíveis. Os SLMT permitem uma rápida recolha de grandes quantidades de dados ao longo de vias, reduzindo o tempo de trabalho de campo, em comparação com os métodos topográficos clássicos, facto que resulta na redução dos custos de aquisição e no aumento da segurança (em países de instabilidade e de baixos níveis de segurança, como são muitos dos países em vias de desenvolvimento).

O objetivo central deste estudo resulta da necessidade de obter um método eficiente para gerar o MDT a partir de nuvens de pontos recolhidas por SLMT, permitindo tirar partido da eficiência desses sistemas na recolha de dados. O objetivo é obter dados com elevada precisão e, ao mesmo tempo, eliminar o estrangulamento no fluxo de processamento dos dados, que se verifica na atualidade com elevada frequência devido ao volume de dados. Dada a densidade das nuvens de pontos (na ordem dos milhares por m²) e a velocidade de aquisição, o volume de dados armazenados, atinge valores na ordem dos terabytes, dificultando o acesso e aplicação de algoritmos de extração.

O conceito de armazenamento, análise e identificação de padrões em grande volume de dados é atualmente designado por *Big data*, no âmbito do qual as nuvens de pontos foram incluídas recentemente (Soilán *et al.* 2019). Devido às suas características, as nuvens de pontos não são classificadas como dados vetor ou matriciais, não sendo possível usar as técnicas implementadas para o processamento desse tipo de dados (Pajić *et al.*, 2018). No entanto, existem alguns estudos na adaptação de técnicas *Big data*, nomeadamente, na extração de copas

de árvores (Liu & Boehm, 2015). Contudo, a maioria dos estudos centram-se nos métodos de armazenamento e consulta de grandes quantidades de pontos resultantes de sistemas LiDAR. Por exemplo, em Zhou *et al.* (2017) é proposta uma estrutura *GeoSpark SQL* que fornece uma interface conveniente para consultas *SQL* geoespaciais, com recurso ao *Apache Spark*, permitindo o armazenamento de nuvens de pontos e consultas espaciais. Outra abordagem, centrada em ficheiros para armazenamento de grandes nuvens de pontos recolhidos por LiDAR, é descrita em Boehm (2014). As nuvens de ponto são divididas por regiões retangulares e em cada região é armazenada um ficheiro. As regiões são indexadas utilizando o sistema *Geohash* e armazenadas na base de dados MongoDB, juntamente com a localização do ficheiro correspondente. No que diz respeito à utilização de técnicas *Big data*, aplicadas especificamente a nuvens de pontos recolhidas por SLMT, há um pequeno número de artigos relevantes. Boehm *et al.* (2016) apresentam um projeto designado *FP7 IQmulus*, que consiste numa infraestrutura para armazenamento, processamento e visualização, de grandes quantidades nuvens de pontos recolhidas por SLMT, sendo, no entanto, apenas implementado um algoritmo para a extração de árvores. Para além destes estudos, não se conhecem até ao momento algoritmos associados ao conceito *Big data*, para a classificação de nuvens de pontos recolhidas por sistemas LiDAR móveis para a geração de MDT a grandes escalas.

2.14. Estado da arte dos métodos de classificação dos pontos de nuvens para geração de MDT

Os métodos geométricos de classificação dos pontos de nuvens para a geração de MDT, podem ser agrupados em 4 grandes grupos, consoante as características e as relações entre os pontos utilizadas. Nomeadamente, os métodos baseados nas diferenças de altitude, os métodos que utilizam a variação de declive, os métodos morfológicos e os métodos escalares. Para além destes, existem outros métodos que utilizam dados não geométricos associados aos pontos da nuvem e/ou dados auxiliares.

2.14.1. Métodos baseados nas diferenças de altitude

Estes métodos funcionam com base nas diferenças altimétricas definidas entre uma superfície pré-estabelecida e os pontos da nuvem. A cada ponto da nuvem é atribuído um peso baseado na distância à superfície e com base nesses valores é criada uma nova superfície. Em Kraus & Pfeifer (2001), os pontos são comparados com uma superfície gerada por um processo de *Kriging*, em que os resíduos calculados (distância entre a superfície e os pontos LiDAR) são

aplicados através de uma função de pesos. Aos pontos com resíduos negativos é atribuído maior peso, assumindo-se que têm maior probabilidade de serem pontos do terreno, enquanto que aos pontos com resíduos positivos é atribuído menor peso. Uma nova superfície é gerada com base nesses pesos associados a cada ponto. O processo de associar pesos aos pontos e gerar uma nova superfície é efetuado de forma iterativa até se atingir um dado limiar para todos os pontos ou, em alternativa, um número máximo de iterações. Zhang & Cui (2007) apresentaram uma solução baseada em dois filtros polinomiais de forma a melhorar os resultados das superfícies interpoladas. O primeiro filtro polinomial é aplicado de forma a identificar pontos no terreno, comparando as diferenças de elevação dos pontos da nuvem com a superfície interpolada. Os pontos candidatos são selecionados com base nessas variações de elevação e incorporados na nova superfície. O segundo filtro polinomial compara a nova superfície gerada com a anterior, de forma a estimar a curva que melhor se ajusta entre as duas superfícies.

2.14.2. Métodos baseados na variação de declive

Este tipo de métodos utilizam filtros baseados no declive entre os pontos da nuvem, resultante da relação entre a diferença de altitude e a distância entre os pontos. Grandes desníveis locais implicam que o ponto mais alto tem maior probabilidade de não pertencer ao terreno. Vosselman (2000) utiliza a função de declive entre pontos numa determinada vizinhança para classificar os pontos do terreno. Em Roggero (2001), a superfície do terreno é criada calculando valores de declives locais de forma a permitir a classificação dos pontos do terreno. Sithole (2001) compara os declives entre pontos vizinhos da nuvem através de um mapa de declives, criado previamente pelos pontos que apresentam valores de altitude menor. Este filtro é uma modificação do método apresentado por Vosselman (2000), onde o limiar máximo do declive para classificação dos pontos exteriores ao terreno, não é fixo para toda a área, mas variável de acordo com os valores circundantes. Outros filtros baseados na variação do declive, em vez de utilizarem uma Rede Irregular de Triângulos (RIT), aplicam à nuvem de pontos uma grelha regular de células, sendo o algoritmo baseado na variação de declive entre células vizinhas dessa grelha. Para a definição de altitude de cada célula é utilizado o ponto com altitude menor que se encontra no seu interior (Wack & Wimmer, 2001). É então gerada uma superfície e, iterativamente, cada um dos pontos da nuvem é testado em relação a essa superfície e classificado como ponto exterior ao terreno sempre que os valores de declive ultrapassem os valores limiares máximos definidos para o declive. O processo poderá ser repetido aumentando

progressivamente a dimensão das células da grelha, até todos os pontos serem classificados (Zhang & Whitman, 2005).

2.14.3. Métodos morfológicos

Os métodos morfológicos foram inicialmente aplicados sobre imagens em tons de cinzento, processando as imagens com base na identificação de estruturas espaciais e não nos valores numéricos das células. Os principais operadores utilizados, são a dilatação e a erosão que utilizados em conjunto podem ser classificados em fecho e abertura. No contexto do processamento de nuvens de pontos, Zhang *et al.* (2003) apresentam um filtro morfológico que aplica um processo iterativo, aumentando gradualmente a dimensão da janela do filtro de forma a detetar objetos pelas suas dimensões. Um limiar de elevação definido com base nas dimensões da janela é introduzido no processo de forma a lidar com classificações incorretas na crista de zonas escarpadas. De forma a melhorar a performance do filtro, foram mais tarde introduzidos parâmetros relativos à rotação e o número de rotações por Zhang & Cui (2007). Um filtro similar foi desenvolvido por Chen *et al.* (2007). Esta aproximação inclui processos para preencher valores nulos (*no data*) e remover pontos conspícuos (*outliers*) em conjunto com a classificação dos pontos do terreno. Outra aproximação foi ainda desenvolvida por Zaksek & Pfeifer (2006) que calcula inclinações da superfície, estimadas com base no primeiro e último retorno do LiDAR.

2.14.4. Métodos Escalares

Os filtros escalares (*multi-scale*) funcionam com base nas propriedades da superfície, sendo utilizadas varias resoluções para analisar as variações do terreno. Silvan-Cardenas & Wang (2006) apresentam uma investigação baseada no uso da MHT (*Multiscale Hermite Transform*) como uma técnica para separar os pontos do terreno dos restantes. A nuvem de pontos é interpolada utilizando grelhas com várias resoluções, sendo aplicado o MHT com valores limiares de acordo com diferentes escalas, o que permite remover os pontos exteriores ao terreno através do operador de erosão. O MHT é um filtro baseado numa pirâmide de Gauss, com as propriedades da teoria de ondas. O *Multiscale Curvature Classification* é outro algoritmo escalar iterativo para classificação das nuvens recolhidas por sistemas LiDAR (Evans & Hudak, 2007). O algoritmo efetua o filtro dos pontos com base numa curva com um determinado fator de escala e curvatura. É interpolada uma superfície com diferentes resoluções utilizando a técnica de *thin-plate spline*, sendo os pontos classificados com base num valor

limiar da curvatura progressiva. Axelsson (2000) utiliza uma RIT densificada progressivamente de forma a filtrar a nuvem de pontos. Este filtro foi implementado pelo *software* comercial Terrasolid, que permite modelar descontinuidades do terreno, especialmente em zonas urbanas (Guan *et al.*, 2014). Este processo parte do princípio de que os pontos que representam o terreno têm elevação menor que os restantes. O primeiro passo consiste no cálculo dos parâmetros iniciais e a identificação dos pontos mais baixos numa grelha de dimensão previamente definida (esta dimensão deverá ser maior que os objetos existentes no terreno), designados por *seed points*. Em paralelo, alguns *seed points* são removidos, ajustando o valor da mediana determinada com base nos histogramas, de forma a minimizar a dimensão da grelha.

2.14.5. Métodos que utilizam dados auxiliares

Todos os métodos anteriormente descritos utilizam apenas a geometria dos pontos para a separação entre os pontos do terreno e os restantes. Alguns trabalhos introduzem outros parâmetros para a melhoria do desempenho dos filtros. Schickler & Thorpe (2001) incluem linhas de quebra desenhadas de forma independente e tipo de uso do solo para obter o MDT com base em nuvens de pontos. Para além do terreno, Raber *et al.* (2002) classificam a vegetação baseada na distribuição vertical da elevação dos pontos LiDAR, utilizando os múltiplos retornos do sistema LiDAR. Goepfert *et al.* (2008) acrescentam a intensidade de retorno associada a cada ponto para apoio à classificação. Bretar & Chehata (2007) utilizam igualmente dados referentes à vegetação. Os valores de intensidade são combinados com a cor das imagens de forma a criar um parâmetro, designado por *Normal Difference Vegetation Index*, e dessa forma obter a classificação da vegetação. Outro estudo que utiliza uma distribuição de Gauss de duas classes de vegetação derivadas da intensidade é apresentado em Wang & Glenn (2009). Outros estudos utilizam os coeficientes de *skewness* e *kurtosis* associados aos valores de intensidade dos pontos para classificar os pontos do terreno (Crosilla *et al.*, 2011; Crosilla *et al.*, 2013; Liu *et al.*, 2009). Pfeifer *et al.* (2001) apresentaram um método robusto de interpolação hierárquica que permite lidar com edifícios de maior dimensão e reduzir o tempo computacional. Em Elmqvist (2001), a iteração inicia-se sobre uma superfície horizontal com uma elevação inferior a todos os pontos e vai aumentando a elevação até atingir os pontos seguindo o sentido negativo da gravidade.

Outros algoritmos centram-se na segmentação de dados e métodos de *clustering*, processos muito populares na classificação do uso do solo. Essa classificação é adaptada em alguns estudos à identificação dos pontos do terreno (Filin & Pfeifer, 2006, Sithole & Vosselman,

2005). Estes métodos de segmentação utilizam normalmente uma rasterização dos dados em vez da utilização dos pontos individualmente, sendo este processo menos afetado pelo ruído (Mandlbürger *et al.*, 2007).

Apesar da grande quantidade e diversidade dos métodos existentes, resultado do interesse dos investigadores desde o aparecimento dos primeiros sistemas LiDAR, a maioria do trabalho publicado neste campo de estudo é baseada em nuvens recolhidas por SLA (Özcan & Ünsalan, 2017). As nuvens de pontos recolhidas através de SLMT apresentam características muito diferentes das recolhidas por SLA. O ângulo diferente de recolha, a maior densidade de pontos e a complexidade do ambiente envolvente da via, fazem com que a maioria das técnicas de criação de MDT a partir de dados recolhidos por SLA não funcione, ou não seja muito eficiente com os dados recolhidos por SLMT.

Um grande desafio associado aos métodos de geração de MDT é a sua capacidade de adaptação a diferentes ambientes (rurais, urbanos e mistos), onde as características e as formas do terreno são muito diferentes e com grandes variações. Por outro lado, a grande quantidade de pontos no MDT final é geralmente apontado pelos utilizadores como uma limitação para um uso mais amplo deste tipo de dados. Os pontos incluídos no MDT devem ser o mínimo possível, mas, ao mesmo tempo, suficientes para garantir a representação da forma do terreno a uma determinada escala, o que implica uma escolha criteriosa do número mínimo de pontos que seja representativo do terreno à escala da sua representação, com o rigor posicional necessário. É com base nas necessidades e restrições anteriores, que é proposto o método para classificação dos pontos que representam o terreno, descrito no Capítulo 3.

A representação das zonas de rutura do terreno apenas com recurso a pontos de cota, obriga ao uso de um número muito elevado de pontos. Assim, desde há muitos anos que o paradigma para representação dessas zonas é através das designadas linhas de quebra ou rutura. Na secção seguinte apresentam-se o estado da arte e as noções teóricas associadas à extração dessas linhas a partir de nuvens de pontos.

2.15. Extração de linhas de quebra a partir de nuvens de pontos

Li *et al.* (2005) classifica os pontos que representam o terreno em dois grupos, os PE (pontos específicos que representam características da superfície do terreno) e os restantes que são pontos aleatórios. Os PE representam extremos locais como picos e depressões, e ao ligarem-se dão

origem às linhas de quebra. Essas linhas de quebra não contêm apenas dados sobre si mesmas, mas representam implicitamente algumas informações sobre o seu meio envolvente.

Podem ser encontradas na literatura diferentes classificações de linhas de quebra, "artificiais" ou "naturais", dependendo se resultam ou não da intervenção humana. Suaves (*soft*) ou abruptas (*hard*) de acordo com o seu grau de rutura ou quebra mais suave ou mais acentuado. Além disso, podem ser dados diferentes pesos às linhas de rutura relativamente aos restantes pontos aleatórios, de acordo com a sua precisão (Lichtenstein & Doytsher, 2004). Independentemente da designação e classificação, existe uma ideia generalizada da integração das linhas de rutura no MDT serem essenciais para a fiabilidade da representação morfológica do terreno a grandes escalas (Li *et al.*, 2005; Lichtenstein & Doytsher, 2004; Little e Shi, 2001; Liu & Zhang, 2008; Yang *et al.*, 2016, Hingee *et al.* 2019).

2.15.1. Estado da arte da extração de linhas de quebra de nuvens de pontos

Nas últimas décadas, foram publicadas várias técnicas de extração de linhas de quebra de nuvens de pontos. Brugelmann (2000) apresenta um método de extração de linhas de quebra de nuvens de pontos obtidas por SLA, com base numa abordagem para extração de estruturas de imagens, proposta por Forstner (1998). Nesta abordagem, a nuvem é transformada em píxeis e todos os píxeis com uma medida significativa de homogeneidade do ruído são assinalados como potenciais valores extremos. A variação quadrática, utilizada como medida de homogeneidade, indica a extensão da curvatura. Embora as linhas resultantes tenham baixa qualidade quando comparadas com as linhas de quebra obtidas fotogrametricamente, o autor mostrou que é viável a extração automática da linha de quebra a partir de dados LiDAR obtidos a partir de plataformas aerotransportadas.

Uma outra abordagem baseada na intersecção de dois planos é proposta por Kraus & Pfeifer (2001), permite extrair algumas linhas 3D apesar de necessitar de uma aproximação 2D da posição das linhas de quebra. Em Briese (2004) é descrito o uso de pares de pontos correspondentes, robustamente estimados ao longo da linha de quebra. A eliminação da influência dos pontos fora de terreno neste processo de estimativa funciona de forma totalmente automatizada, adaptando-se aos dados. Esta modelação também se inicia a partir de uma aproximação 2D da linha de quebra, que é iterativamente refinada. Com base nesse trabalho Briese *et al.* (2009) apresentaram um método dividido em dois passos. Num primeiro passo, a nuvem de pontos é convertida para uma grelha 2D, donde é obtida uma aproximação das linhas de quebra. No segundo passo, um modelo da superfície é aplicado de forma a obter os dados tridimensionais das linhas.

Este método foi melhorado por Yang *et al.* (2016), tendo introduzido uma nova aproximação que permite a determinação do início de segmentos e, conseqüentemente, múltiplas inicializações para cada uma das linhas de quebra. Este método permite obter resultados satisfatórios em linhas de quebra longas e com pouca curvatura, no entanto em linhas curvas e aproximadamente paralelas entre si, o resultado não é satisfatório.

Existem alguns trabalhos publicados para extração de linhas ao longo de vias rodoviárias. Zhou & Vosselman (2012) testaram um método baseado em três passos para extração das linhas de lancil, em ambos os tipos de dados recolhidos por SLA e SLMT. Este método revelou ser muito sensível aos carros parados ao longo das vias, o que baixa consideravelmente os seus valores de completude.

Um outro método que identifica os pontos da linha de lancil através de três indicadores espaciais: diferença de elevação, gradiente e normal é proposto por Zhao & Yuan (2012). Este método, como outros que utilizam as diferenças de elevação, é condicionado pela definição dos limites dos intervalos que inviabilizam a deteção de lancis com alturas muito variáveis. Tipicamente, não funcionam em zonas de inclinação acentuada das vias.

Kumar *et al.* (2013) apresentam um estudo baseado na rasterização dos valores de inclinação, reflexão e intensidade de retorno do pulso. O fluxo de vetores gradientes e um modelo de balão são combinados para criar um modelo paramétrico de curvas de nível, que permite determinar os limites da estrada.

Rodríguez-Cuenca *et al.* (2016) testaram o trabalho de Kumar *et al.* (2013) e concluíram que “em secções retas apresentaram bons resultados, mas o seu desempenho em secções curvas é desconhecido. O procedimento é computacionalmente complexo, o que pode tornar o processo de deteção demasiado lento”. Rodríguez-Cuenca *et al.* (2016), também apresentam um método focado na segmentação de curvas e fronteiras de rua. A solução baseia-se na projeção da nuvem de pontos medida no plano XY. Os limites da via resultam de um algoritmo de segmentação baseado em operações morfológicas.

Soilán *et al.* (2018) optaram por uma abordagem baseada na construção de um mapa de restrições, que é calculado através de um algoritmo de aprendizagem não supervisionado. Apesar da robustez dos resultados reivindicada, as linhas de lancil resultantes dos métodos anteriores são representadas apenas por uma linha 2D, com total ausência de dados sobre a altura do passeio, o que desqualifica a sua integração no MDT.

Xu *et al.* (2017) apresentam uma solução em dois passos para extrair as linhas tridimensionais do lancil com base na definição de um parâmetro de rugosidade dos pontos da nuvem. No primeiro passo, identificam-se os pontos candidatos para representar os lancis, utilizando uma

nova função energia proposta. No segundo passo, os pontos candidatos são escolhidos usando um modelo de grafos baseado no caminho menos dispendioso. Através deste método foi alcançada uma completude de 78.62% e uma correção de 83.29%.

O interesse pela detecção das linhas de lancil aumentou recentemente devido à investigação em veículos autónomos. As características dessas linhas são utilizadas para a perceção do ambiente (limite de estrada, áreas restritas) e para ajudar os veículos autónomos em zonas de obstrução ao sinal GNSS. Os dados do LiDAR têm vindo a ser utilizados pelas comunidades de investigação de veículos autónomos para a extração das linhas de lancil, devido à precisão das informações recolhidas e pelo facto de não serem afetados pelas condições de luz (Verghese 2017; Maalej, 2018).

Zhang *et al.* (2019) apresentam um método de detecção do lancil em tempo real através da segmentação automática da estrada. O método requer um pré-processamento de nuvem de pontos para classificar as áreas interiores e exteriores à estrada. Após a aplicação de um algoritmo baseado numa janela móvel, para segmentação da estrada, o método de detecção dos lancis é finalmente aplicado.

Zai (2018) propõe a utilização da divisão do espaço em cubos (*super voxels*), que são usados para obter pontos candidatos, sendo os dados da trajetória usados para classificar esses pontos em esquerda e direita.

Guojun *et al.* (2019) apresentam um método robusto para a detecção de lancis num ambiente estruturado. Utiliza um método de detecção de estruturas baseado em camadas, para a extração de pontos candidatos e, posteriormente, é usado um método para a separação dos pontos candidatos em esquerda e direita, baseado na densidade. Finalmente, é aplicado um filtro de *Kalman* para eliminar falsas detecções. Este método foi construído para ser usado em tempo real, não utilizando quaisquer dados em pós processamento.

Com base na descrição dos trabalhos publicados, facilmente se percebe que, apesar de alguns trabalhos serem passíveis de ser usados com esse fim, não existe uma solução eficiente para a extração de linhas de quebra de nuvens de pontos recolhidas por SLMT, especificamente para a criação de MDT a grandes escalas. Nas secções seguintes, é proposto um conjunto de métodos com vista a contribuir para a solução deste problema em aberto.

2.16. Geração de MDT com base em nuvens especificamente recolhidas por SLMT

A maioria dos estudos e métodos propostos existentes na literatura, para geração de MDT, utilizam nuvens de pontos recolhidas por SLA (Chen *et al.*, 2017; Özcan & Ünsalan, 2017). No

entanto, o diferente ângulo de incidência, a densidade muito superior e a complexidade do ambiente em torno do sensor ao longo da sua trajetória, fazem com que estas técnicas não funcionem ou tenham uma eficiência muito baixa em dados recolhidos por SLMT.

Apesar de alguns estudos recentes, para classificação de extração dos pontos das nuvens recolhidas por SLMT, para a geração de MDT, continua a ser um desafio em aberto (Chen *et al.*, 2017). Recentemente começaram a surgir alguns estudos focados especificamente em dados recolhidos por SLMT. Yuan *et al.* (2010) propõem um método do tipo *fuzzy cluster* para detetar os pontos que representam a superfície da rodovia, baseado na segmentação dos pontos e num algoritmo de ajustamento de mínimos quadrados ponderados. Diversos trabalhos (Guan, 2013; Guan 2015a; Guan, 2015b; Smadja *et al.*, 2010) apresentam métodos baseados na deteção da quebra do lancil ao longo da rodovia, de forma a identificar os pontos que representam a superfície da via. Contudo estes métodos precisam de dados auxiliares, tal como um mapa de acumulação *multi-frame* e pontos da trajetória efetuada pelo sistema. Todos estes métodos concentram-se apenas na deteção da superfície da via e não em toda a faixa coberta pelas nuvens recolhidas pelo sistema. O ângulo diferente de recolha, a elevada densidade dos dados e a complexidade do ambiente em torno da via, faz com que a maioria das técnicas utilizadas para a geração de MDT com base em nuvens recolhidas por SLA, não sejam eficientes com os dados recolhidos por SLMT. Apesar de existirem alguns estudos que adaptam algumas técnicas, inicialmente aplicadas a nuvens obtidas por SLA, a nuvens obtidas por SLMT (Fellendorf, 2013; Tyagur & Hollaus, 2016; Vallet & Papelard, 2015), não existe nenhum estudo detalhado para a geração de MDT a grandes escalas, incluindo pontos e linhas de quebra, especificamente baseado em nuvens recolhidas por SLMT.

Capítulo 3.

Métodos e resultados

Ao longo deste capítulo descreve-se um conjunto de métodos, com o objetivo de ajustar, classificar e segmentar os dados armazenados nas nuvens de pontos recolhidas por SLMT, com vista à geração de MDT a grandes escalas. Em primeiro lugar, propõe-se um método de ajustamento altimétrico de nuvens de pontos sobrepostas. Depois, é proposto um método de classificação de pontos do terreno, seguindo-se a descrição dos métodos de extração de linhas de quebra de nuvens de pontos recolhidas por SLMT. Tendo em conta a especificidade do uso dos SLMT ao longo de linhas ferroviárias, é apresentado um método específico de extração de linhas tridimensionais nesse ambiente, incluindo linhas de quebra. Dado que os dados recolhidos pelos SLMT se adequa essencialmente a obras lineares, nomeadamente rodovias e ferrovias, e que para a sua execução e manutenção, os perfis transversais têm um papel essencial na geração do MDT, é apresentado um estudo comparativo de diferentes estratégias de agregação dos pontos das nuvens com vista à criação de perfis transversais. Finalmente é apresentado o resultado da junção dos métodos de extração de pontos e linhas para a geração do MDT.

Antes da exposição do método, apresentam-se algumas noções teóricas e métodos auxiliares, utilizados ao longo dos diferentes métodos.

3.1. Noções teóricas e métodos auxiliares

3.1.1. O método RANSAC

O *Random Sample Consensus* (RANSAC) publicado por Fischer & Bolles (1981) é um dos algoritmos mais utilizados para o processamento de dados associados às nuvens de pontos. O RANSAC é um algoritmo que permite a convergência de modelos na presença de *outliers*. A sua natureza genérica permite aplicá-lo a diferentes modelos, nomeadamente planos, linhas, etc. O algoritmo baseia-se numa técnica de amostragem que gera soluções candidatas, utilizando um conjunto de observações (pontos) necessárias para estimar os parâmetros subjacentes ao modelo. Como referido por Fischler & Bolles (1981), ao contrário das técnicas de amostragem mais convencionais, que utilizam o número máximo de pontos possível para obter uma solução inicial para a eliminação dos pontos que não pertencem ao modelo teórico

(*outliers*), o algoritmo RANSAC, inicia o processo com um conjunto mínimo e vai aumentando com novos pontos consistentes com o modelo (*inliers*).

É possível sumarizar o algoritmo em 4 passos:

1. Selecionar de forma aleatória o número mínimo de pontos para calcular os parâmetros do modelo;
2. Calcular a solução dos parâmetros do modelo com os pontos anteriores;
3. Determinar quantos pontos do conjunto inicial são solução do modelo dentro de uma tolerância previamente definida;
4. Verificar se a fração do número de *inliers* sobre a totalidade dos pontos excede o valor limite predefinido T e calcula novamente os parâmetros do modelo utilizando todos os *inliers* identificados. Se exceder o limite T termina o processo, caso contrário, repete os passos de 1 até 4 (num máximo de N iterações).

O número máximo de iterações, N, é um valor escolhido suficientemente alto para garantir que pelo menos um dos conjuntos aleatórios não inclua nenhum *outlier* para uma probabilidade p (normalmente definida com o valor máximo de 0.99). Assumindo que u representa a probabilidade de qualquer ponto ser um *inlier* e $v=1-u$, a probabilidade de ser observado um *outlier*, utilizando N iterações com o mínimo de m pontos, obtém-se através de:

$$1 - p = (1 - u^m)^N \quad (3.1)$$

logo,

$$N = \frac{\log(1-p)}{\log(1-(1-v)^m)} \quad (3.2)$$

3.1.2. Equação do plano

Uma forma possível de representar um plano no espaço é através de um ponto pertencente ao plano e o vetor normal a esse plano que passe pelo ponto. Como ilustrado na Figura 3.1, sendo \vec{n} o vetor normal ao plano, P_1 o ponto de intersecção de \vec{n} com o plano e P um ponto conhecido do plano, o vetor entre os pontos P e P_1 é definido através de:

$$\vec{p} - \vec{p}_1 = (x - x_1, y - y_1, z - z_1) \quad (3.3)$$




Figura 3.1 - Definição da equação do plano.

Tendo em conta que o vetor $\vec{p} \rightarrow \vec{p}_1$ e o vetor \vec{n} são perpendiculares entre si, o produto escalar entre os dois vetores é nulo.

$$\vec{n} \cdot (\vec{p} - \vec{p}_1) = 0 \quad (3.4)$$

Com base no produto escalar entre os dois vetores é então possível deduzir a equação do plano considerando a, b, c as componentes do vetor \vec{n} .

$$(a, b, c)(x - x_1, y - y_1, z - z_1) = 0 \quad (3.5)$$

$$a(x - x_1) + b(y - y_1) + c(z - z_1) = 0 \quad (3.6)$$

$$ax + by + cz - (ax_1 + by_1 + cz_1) = 0 \quad (3.7)$$

Substituindo os termos constantes por $d = -(ax_1 + by_1 + cz_1)$, a Equação (3.7) passa a ter seguinte forma:

$$ax + by + cz + d = 0 \quad (3.8)$$

3.1.3. Distância entre um ponto e um plano

A distância mais curta entre um ponto no espaço P_2 e o plano definido anteriormente, esquematizada na Figura 3.2, pode ser calculada através do produto escalar entre o vetor \vec{n} e a projeção do vetor $(\vec{p}_2 - \vec{p}_1)$ segundo a normal ao plano n .




Figura 3.2 - Distância entre um ponto e um plano.

Assim a distância D entre o plano $ax + by + cz + d = 0$ e o ponto P_2 , pode ser calculada por:

$$D = |\vec{p}_2 - \vec{p}_1| \cos \theta = \frac{\vec{n} \cdot (\vec{p}_2 - \vec{p}_1)}{|\vec{n}|} = \frac{\vec{n} \cdot (\vec{p}_2 - \vec{p}_1)}{\sqrt{a^2 + b^2 + c^2}} \quad (3.9)$$

Desenvolvendo o numerador da equação anterior obtém-se:

$$\vec{n} \cdot (\vec{p}_2 - \vec{p}_1) = (a, b, c) \cdot (x_2 - x_1, y_2 - y_1, z_2 - z_1) = ax_2 + by_2 + cz_2 - (ax_1 + by_1 + cz_1) \quad (3.10)$$

Finalmente é possível definir a distância entre um ponto e um plano através da Equação 3.11.

$$D = \frac{ax_2 + by_2 + cz_2 - (ax_1 + by_1 + cz_1)}{\sqrt{a^2 + b^2 + c^2}} \quad (3.11)$$

De notar que a distância pode ter um sinal negativo, dependendo da direção do ponto em relação ao plano. O sinal é positivo se o ponto se encontra do mesmo lado do plano do sentido da normal e será negativo se se encontrar no lado oposto.

3.2. Método proposto para ajustamento de nuvens de pontos sobrepostas

Analisando os três grandes grupos de métodos descritos no estado de arte, conclui-se que a maioria se baseia em transformações rígidas. Tendo em conta os princípios de funcionamento dos SLMT, as nuvens recolhidas, são obtidas com base em intervalos de acordo com a frequência da UMI. Logo, em cada momento de registo da UMI, existem erros diferentes associados à posição registada, consequentemente, o erro de uma nuvem recolhida por SLMT está continuamente a mudar, invalidando a aplicação de métodos rígidos. Assim, optou-se por uma abordagem, baseada na eliminação das diferenças entre as nuvens, variáveis ao longo do processo de recolha. Esta abordagem, é baseada na correção da trajetória, reescrevendo uma ou

mais nuvens com base numa nova trajetória ajustada, em vez da aplicação de uma transformação única entre as nuvens. No entanto, de forma a tornar o processo completamente automático, é necessário a deteção de estruturas nas nuvens de forma a calcular as diferenças entre as mesmas.

Tipicamente, a maior componente do erro associado à precisão da trajetória de um SLMT é a componente altimétrica. Isso resulta do facto do sensor GNSS ser o sensor principal do sistema de georreferenciação do SLMT. Por essa razão, apenas se exemplifica a aplicação do método proposto para ajustamento altimétrico das nuvens de pontos recolhidas por SLMT. No entanto, como se poderá verificar ao longo da sua descrição, o método pode facilmente ser expandido ao ajustamento da componente planimétrica das nuvens.

Ao longo da descrição do método proposto irão ser consideradas duas nuvens ou blocos de nuvens, com uma área de sobreposição entre elas. Assume-se uma das nuvens como tendo coordenadas absolutas fixas (nuvem de âncora) e uma outra nuvem relativamente à qual existem diferenças verticais variáveis. O objetivo do método é eliminar as diferenças altimétricas entre as duas nuvens, ajustando a segunda nuvem à nuvem de âncora.

O método proposto é dividido em três passos principais: 1) definição dos pontos de ajustamento ao longo da trajetória; 2) determinação das correções a aplicar; 3) criação de uma nova nuvem ajustada, com base na trajetória corrigida. Todos os passos no algoritmo do método são executados automaticamente, com base em parâmetros previamente definidos, e apenas utilizam as nuvens armazenadas em formato LAS, sem recorrerem a quaisquer ficheiros de trajetória auxiliares.

3.2.1. Definição dos pontos para ajustamento ao longo da trajetória.

A trajetória do veículo que transporta o SLMT pode ser representada por uma sequência de pontos representando a posição do sistema ao longo do tempo. Nesta fase, pretende-se reconstruir não exatamente a posição tridimensional da trajetória da plataforma no espaço, mas a projeção vertical dos pontos de trajetória no solo (ou seja sobre a nuvem de pontos). Para obter os pontos da trajetória, é necessário conhecer o ângulo de varredura (α) de cada ponto. Tendo em conta que a origem do ângulo de varredura é a direção nadir, todos os pontos que têm $\alpha = 0$ encontram-se nessa direção em relação ao sensor, como ilustrado na Figura 3.3.

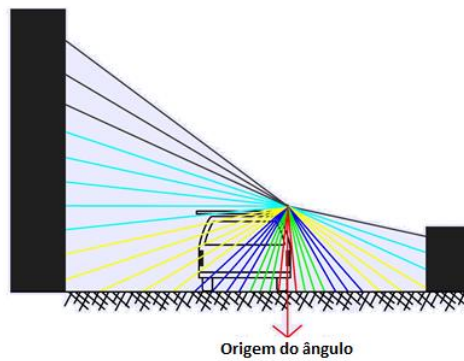


Figura 3.3 - Origem do ângulo de varrimento.

Associando a cada intervalo angular uma cor diferente relativamente à origem da contagem dos ângulos (Figura 3.4), verifica-se que as áreas correspondentes a cada intervalo angular são simétricas relativamente à trajetória do veículo.




Figura 3.4 - Origem do ângulo de varrimento.

Para reconstruir a trajetória do veículo, além do ângulo de varredura, é necessário conhecer a época GPS⁷ de cada ponto da nuvem, de forma a estabelecer o intervalo de tempo para os pontos da trajetória. Na Figura 3.5 são representados a vermelho os pontos resultantes de um intervalo de tempo pré-estabelecido (τ).

⁷ Assume-se que o GNSS utiliza o tempo difundido pelo GPS. Inclusive, essa é a designação utilizada nas especificações dos ficheiros LAS. Por essa razão, ao longo deste trabalho é utilizado sempre o termo GPS, associado à designação da época dos pontos recolhidos por SLMT.




Figura 3.5 - Classificação dos pontos por intervalo de época GPS (pontos vermelhos).

A partir da interseção das duas variáveis (α , τ), para $\alpha = 0$, é possível estabelecer um conjunto de pontos com um determinado intervalo de tempo (Figura 3.6), que representam a projeção da trajetória realizada pelo SLMT na nuvem de pontos.




Figura 3.6 - Exemplo do estabelecimento de pontos ao longo da trajetória.

De acordo com o descrito na Secção 2.9.1, os valores do ângulo de varrimento e do tempo GPS de cada ponto podem ser obtidos diretamente dos ficheiros *standard LAS*. Dado que nas versões LAS 1.1 a 1.3, o campo de ângulo de varrimento é limitado a 1 byte, o seu valor máximo é 255, o que significa que para armazenar 360° de varrimento, a resolução de intervalo armazenado corresponde a $360^\circ/255$. A variável de ângulo de varrimento é do tipo *signed short*, e representa a posição rotacional do pulso LASER emitido em relação à vertical do sistema de coordenadas dos dados, cuja origem é a direção nadir do sensor.

A época GPS foi incluída desde a primeira versão do LAS, do tipo *double* com 8 bytes de comprimento. O valor pode estar representado relativamente à semana GPS ou tempo GPS standard, sendo a distinção feita através da variável *Global Encoding* disponível no cabeçalho do ficheiro.

Uma vez que, para o mesmo intervalo de tempo, a distância euclidiana entre pontos consecutivos depende da velocidade do veículo, optou-se por aplicar uma terceira restrição de distância mínima entre pontos consecutivos (Δ). Essa restrição garante que em situações em que a velocidade do veículo é baixa, ou se encontra mesmo parado, a distância aproximada entre pontos da trajetória seja mantida. O resultado dos pontos de trajetória pode ser representado por uma conjunção lógica das três restrições descritas em (3.12).

$$T = \begin{cases} P(\tau)_i, P(\tau + 1)_{i+1}, P(\tau + 2)_{i+2}, \dots, P(\tau + N)_{i+N} \\ P(\alpha)_i, P(\alpha)_{i+1}, P(\alpha)_{i+2}, \dots, P(\alpha)_{i+N}, \alpha = 0 \\ |P_i - P_{i-1}| \geq \Delta \end{cases} \quad (3.12)$$

onde, T representa a listagem dos pontos estabelecidos ao longo da trajetória, P_i representa os pontos da nuvem, τ é o intervalo de tempo previamente definido, α é o ângulo de varrimento ($\alpha=0^\circ$ sobre a trajetória) e Δ é a distância mínima entre pontos consecutivos

Através da aplicação das condições descritas em (3.12) para uma determinada nuvem recolhida por um SLMT, é possível obter um conjunto de pontos que representam a projeção da posição da plataforma no solo ao longo do tempo, ou seja, a trajetória do SLMT ao longo do intervalo de tempo em que a nuvem foi recolhida.

3.2.2. Determinação das correções a serem aplicadas

De forma a determinar as diferenças entre as nuvens, em cada um dos pontos da trajetória, são estabelecidos círculos de raio r centrados em cada um dos seus pontos (Figura 3.7). Esses círculos são usados para identificar os pontos de ambas as nuvens na vizinhança dos pontos da trajetória.

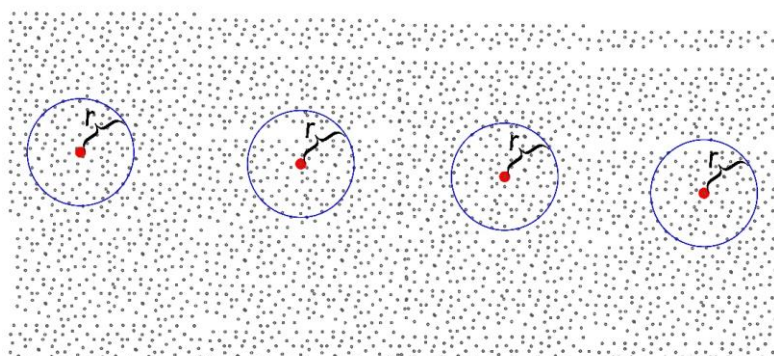


Figura 3.7 - Estabelecimento dos círculos de raio r centrados nos pontos da trajetória.

Uma vantagem da utilização dos pontos ao longo da trajetória é o facto dos dados da nuvem utilizados para estabelecer a comparação entre elas, estar no meio da estrada e imediatamente sob o sensor, sendo improvável que qualquer objeto ou anomalia possa causar uma deformação na nuvem. Sendo assim, é de esperar que tendencialmente os pontos identificados dentro do círculo estejam aproximadamente sobre o mesmo plano (da estrada). Apesar disso, de forma a eliminar o ruído causado por alguma vegetação rasteira ou qualquer outro pequeno objeto sob o veículo no momento da captura, o método RANSAC foi utilizado para garantir o estabelecimento dos planos nas nuvens. Assume-se que esses planos formados em cada uma das nuvens são paralelos. Usando o método RANSAC com a equação do plano, é possível definir planos em ambas as nuvens (Figura 3.8), correspondendo a diferença entre esses dois planos à diferença entre as duas nuvens em cada ponto da trajetória.




Figura 3.8 - Diferenças altimétricas entre os planos nos pontos da trajetória.

No passo seguinte, é efetuada a interpolação dos valores de diferença entre os planos em cada um dos pontos, de forma a associar valores de diferença altimétrica a todas as épocas de GPS existentes na nuvem (valores de registo UMI) e, conseqüentemente, a todos os pontos da nuvem. De notar que esta interpolação é possível devido ao facto de aos dados GNSS obtidos ao longo da trajetória, ser aplicado um filtro *Kalman*, o que permite suavizar e otimizar a estimativa das posições (Gressin *et al.*, 2012).

Foram comparados os resultados obtidos, em várias nuvens, utilizando um interpolador linear e outro quadrático. Verificou-se que a diferença entre ambos é inferior a 0.1 milímetro. Esta reduzida diferença resulta do facto da distância Euclidiana entre os pontos utilizados para medir as diferenças verticais entre as nuvens ser pequena e a trajetória resultante estar suavizada

devido ao filtro de *Kalman*. Dada a pequena diferença, optou-se então por utilizar ao longo do trabalho uma interpolação linear com base na diferença temporal entre os pontos. Assim, considerando dois pontos consecutivos da trajetória P_i e P_{i+1} , cujos valores das diferenças entre as duas nuvens nesses pontos são respetivamente v_i e v_{i+1} , sendo conhecidas as respetivas épocas GPS (E_i , E_{i+1}), o valor da correção altimétrica (C) a aplicar a qualquer ponto da nuvem com época GPS E_j pode ser obtido através da seguinte interpolação linear.

$$v_{E_j} = v_i + \frac{(v_{i+1}-v_i)}{(E_{i+1}-E_i)}(E_j - E_i), E_i < E_j < E_{i+1} \quad (3.13)$$

onde, v_{E_j} é o valor da correção a aplicar, E_j é a época GPS para a qual se pretende obter a correção, E_i e E_{i+1} são respetivamente as épocas GPS dos pontos inicial e final do intervalo, v_i e v_{i+1} , são respetivamente a diferença altimétrica dos pontos inicial e final do intervalo. Através da Equação (3.13) é possível determinar as correções a aplicar a todo os pontos da nuvem, utilizando apenas os dados do ficheiro LAS.

3.2.3. Criação de uma nova nuvem ajustada através da trajetória corrigida.

No final do passo anterior, todos os pontos na nuvem têm um valor de diferença vertical associado. Após esse passo é possível gerar uma nova nuvem de pontos, aplicando a correção com base nos valores da diferença às coordenadas de cada ponto da nuvem. A nova nuvem de pontos será ajustada à nuvem de âncora em todas as épocas do GPS, eliminando as diferenças verticais ao longo da trajetória original.

3.2.4. Implementação e resultados obtidos

De forma a testar o método apresentado foram utilizados os dados descritos na Secção 2.10. Os dados foram separados em dois blocos, a via principal (Bloco A) e as 106 vias transversais (Bloco B).

O objetivo é utilizar as nuvens do Bloco A como âncora e fazer o ajustamento das nuvens do Bloco B utilizando o método proposto, de forma a eliminar as diferenças entre as nuvens. Tendo em conta que o método apenas pretende efetuar o ajustamento relativo das nuvens, é efetuado em primeiro lugar um ajustamento absoluto da nuvem âncora.

Para efetuar o ajustamento absoluto do Bloco A utilizou-se o conjunto de 25 pontos de controlo, referidos na Tabela 2.6. Sendo o ajustamento das nuvens do Bloco A absoluto, ele é realizado através do ajustamento das trajetórias que lhe deram origem, sendo adicionados os dados do

pontos de controlo no momento do processamento da trajetória. Para efetuar este ajustamento foi utilizado o *software* POSPAC MMS. A introdução dos pontos de controlo como posições fixas foi integrado com os dados dos sensores, o que permitiu o ajustamento da trajetória.

Na Tabela 3.1, são apresentadas as diferenças calculadas entre as nuvens do Bloco A (medidas manualmente) e os pontos de controlo utilizados para o cálculo dos resíduos da Tabela 2.6.

Tabela 3.1 - Valores estatísticos referentes às diferenças entre os pontos de controlo e as nuvens de pontos, após a aplicação do método.

	Diferenças (m)	
	Planimetria	Altimetria
Média	0.013	0.025
Valor máximo	0.029	0.034
Valor mínimo	0.001	0.011
Desvio padrão	0.008	0.007

Verificou-se, que após o ajustamento, os valores das diferenças planimétricas e altimétricas são substancialmente inferiores (Tabela 2.6). Como resultado do ajustamento absoluto foi criado um novo conjunto de nuvens referentes ao Bloco A. Pretende-se, em seguida, aplicar o método de ajustamento proposto, de forma a ajustar altimetricamente as nuvens das vias transversais do Bloco B, relativamente às nuvens do Bloco A.

Parte-se do pressuposto que todas as nuvens referentes às vias transversais (Bloco B) têm uma área de sobreposição com pelo menos parte de uma nuvem da via principal (Bloco A).

Os módulos correspondentes a cada um dos passos do método proposto, descritos anteriormente, foram implementados em C#. Foi utilizada a Equação (3.12), com um intervalo de tempo $\tau = 0.25$ segundos e uma distância mínima de 2 m entre pontos consecutivos, obtendo-se os pontos ao longo da trajetória de cada uma das nuvens do Bloco B. Foi estabelecido um valor de 15 centímetros para o raio r dos círculos utilizados, sendo aplicados nas nuvens de ambos os blocos de forma a identificar os pontos das nuvens para a definição dos planos (RANSAC). De notar que o método permite que o valor r seja ajustado com base na densidade de pontos da nuvem, podendo igualmente diferentes valores de r serem usados para as nuvens de âncora e nuvens a ajustar. Com base no valor de probabilidade do método RANSAC, foi possível rejeitar alguns dos pontos e / ou adaptar os seus valores.

A definição de todos os planos permitiu o estabelecimento das diferenças entre os planos em cada ponto da trajetória das nuvens do bloco B. Na Figura 3.9 é representado um exemplo da área de sobreposição de uma nuvem de via principal (roxo) e uma nuvem de uma via transversal

(amarelo), assim como os pontos estabelecidos ao longo da trajetória da nuvem da via transversal.




Figura 3.9 - Exemplo da distribuição dos pontos da trajetória na zona de sobreposição das nuvens.

Existe uma parte da nuvem da via transversal sem sobreposição com a nuvem principal, onde não é possível aplicar o método (pontos vermelhos da Figura 3.9). Nessa zona, fora do limite de sobreposição, optou-se por aplicar a correção correspondente ao último ponto de sobreposição (no caso da Figura 3.9, o ponto 21). Na Figura 3.10, apresenta-se a evolução dos valores de correção altimétrica aplicados a cada um dos pontos da trajetória, representados na Figura 3.9.




Figura 3.10 - Evolução dos valores de correção altimétrica aplicada aos pontos da Figura 3.9.

De forma a comparar as diferenças altimétricas entre as nuvens dos dois blocos, foram medidas as diferenças relativamente às nuvens do Bloco A, em todos os pontos da trajetória, antes e depois do ajustamento. Os valores obtidos antes do ajustamento variavam entre 5 e 55 cm, após a aplicação do método, todos os valores obtidos foram inferiores a 2 cm. Na Figura 3.11 é

apresentado um exemplo de um perfil longitudinal de uma via transversal antes e depois da aplicação do método.




Figura 3.11 - Perfil transversal, antes (esquerda) e depois (direita) de aplicação do método.

Os valores das diferenças referidas anteriormente foram obtidas ao longo das trajetórias das nuvens ajustadas. No entanto, foram detetados valores superiores em zonas distantes da trajetória das nuvens ajustadas, na sequência das medições ilustradas na Figura 3.11. Essas diferenças poderão resultar de erros da UMI ou de derivas devido a uma má calibração. Na Figura 3.12 é apresentada uma secção transversal na área de sobreposição entre as duas nuvens, antes e após o processo de ajustamento. Verifica-se que após o ajustamento, existe um ângulo de inclinação da nuvem do Bloco B em relação à nuvem do Bloco A, centrada simetricamente em relação aos pontos da trajetória. De forma a eliminar essas diferenças, foi introduzida uma variante ao método proposto. Além da correção da componente vertical, foram inseridos dois novos pontos ao longo de cada secção transversal em cada ponto da trajetória. Estes dois pontos foram facilmente adicionados alterando o valor do ângulo α na Equação (3.12). Neste caso, o ajustamento foi realizado ao longo da trajetória não apenas com um ponto, mas com 3 pontos, como exemplificado na Figura 3.12.




Figura 3.12 - Exemplo de um perfil antes e depois do ajustamento da trajetória.

Na Figura 3.13 é representado um exemplo da projeção dos pontos auxiliares na nuvem. É possível observar que a posição dos pontos auxiliares não é perpendicular à trajetória, uma vez que o sensor é colocado com um ângulo de 45 graus em relação à trajetória do veículo.




Figura 3.13 - Definição dos pontos auxiliares.

Tendo em conta que as coordenadas dos pontos auxiliares são conhecidas, é possível calcular a distância entre o ponto de trajetória e cada um dos pontos auxiliares. Aplicando o método proposto, foram obtidas as diferenças altimétricas entre as nuvens em todos os pontos (trajetória e auxiliares), sendo possível calcular o ângulo transversal através de:

$$\rho = \arccos\left(\frac{Dif_{a1} - Dif_p}{Dist_{a1}}\right) \cong \arccos\left(\frac{Dif_{a2} - Dif_p}{Dist_{a2}}\right) \quad (3.14)$$

onde, ρ é o ângulo de inclinação, Dif_{a1} e Dif_{a2} são as distâncias verticais entre as duas nuvens nos pontos auxiliares 1 e 2 respetivamente, $Dist_{a1}$ e $Dist_{a2}$ representam as distâncias entre o ponto central e os pontos auxiliares 1 e 2.

Entre pontos consecutivos da trajetória, o ângulo de inclinação (ρ) foi interpolado linearmente da mesma forma que os valores das diferenças verticais. Através da introdução dos pontos auxiliares foi possível efetuar para além do ajustamento altimétrico das nuvens ao longo da sua trajetória, o ajuste relativamente aos ângulos transversais existentes entre as nuvens.

A aplicação do método proposto nas nuvens das vias transversais resultou na criação de 5406 pontos (incluindo os pontos ao longo da trajetória e os dois pontos auxiliares de correção angular). Os planos foram criados nas nuvens das vias transversais e nas nuvens da via principal, ambos centrados em cada ponto da trajetória das vias transversais. Na Tabela 3.2 são apresentadas as estatísticas das diferenças antes e depois da aplicação do método.

Tabela 3.2 - Resíduos dos pontos de controle, antes e depois da aplicação do método de ajustamento. Todos os valores apresentados, são valores absolutos.

	Valor Min.	Valor Max.	Min. Médias vias transversais ¹	Max. Médias vias transversais ²	Média ³
Antes da aplicação do método	0.05 m	0.55 m	0.09 m	0.45 m	0.29 m
Após a aplicação do método	0.00 m	0.04 m	0.01 m	0.025 m	0.01 m

1-Corresponde ao valor absoluto mínimo, da média dos resíduos dos pontos utilizados em cada via transversal.

2-Corresponde ao valor absoluto máximo, da média dos resíduos dos pontos utilizados em cada via transversal.

3-Corresponde à média dos resíduos de todos os pontos utilizados para aplicação do método.

Na Figura 3.14 é possível observar o efeito num perfil traçado nas duas nuvens, antes e depois da aplicação do método.




Figura 3.14 - Exemplo de nuvem antes e depois de aplicação do método.

As diferenças apresentadas na Tabela 3.2 referem-se a medições efetuadas entre as nuvens dos dois blocos nos pontos utilizados para o ajustamento. Para realizar uma verificação independente foram medidos três pontos manuais em cada uma das nuvens ajustadas das vias transversais. Os pontos foram estabelecidos aproximadamente no limite de sobreposição das nuvens. Um dos pontos foi medido aproximadamente ao longo da trajetória e os outros dois, um de cada lado, transversalmente à trajetória, de acordo com o esquema representado na Figura 3.15, num total de 318 locais.




Figura 3.15 - Definição dos pontos de controlo.

Em cada um desses locais, a elevação do ponto mais próximo em cada nuvem (estrada principal e cruzamento da rua) foi medida manualmente. Na Tabela 3.3, apresentam-se as estatísticas relativas às diferenças encontradas. As maiores diferenças foram encontradas em pontos distantes das trajetórias da nuvem, aumentando proporcionalmente com a distância à trajetória.

Tabela 3.3 - Estatísticas obtidas da aplicação do método.

Nº de pontos	Valor Min.	Valor Max.	Min. Médias vias transversais	Max. Médias vias transversais	Média
318	0.01 m	0.12 m	0.02 m	0.11 m	0.045 m

3.3. Método proposto para a classificação e extração de pontos do terreno

Apesar da grande diversidade de algoritmos propostos nas últimas décadas, é possível identificar genericamente três passos distintos: pré-processamento, discretização dos pontos e interpolação.

O pré-processamento dos dados destina-se essencialmente à remoção de *outliers*, que resultam do multitrajeto associado ao pulso emitido. Em muitos casos, a existência de superfícies espelhadas como janelas ou superfície de água provocam um desvio no pulso LASER antes de ser devolvido ao sistema, um atraso no seu tempo de percurso e conseqüente erro no cálculo da posição do ponto da nuvem. Uma conseqüência típica causada por estes *outliers* na geração automática do MDT resulta do facto de alguns desses pontos terem elevação inferior à superfície do terreno. Algumas técnicas foram utilizadas para a deteção e eliminação destes *outliers*, por exemplo, utilizando filtros baseados numa função de distribuição (Meng *et al.*, 2009), através de métodos matemáticos morfológicos (Kobler *et al.*, 2007) e deteção de variação de densidade (Sotoodeh, 2007).

Finalmente, a interpolação dos pontos obtidos no processo de discretização é normalmente efetuada para a representação contínua do MDT. A abordagem proposta utiliza genericamente estes três passos, iniciando-se a sua descrição pelo processo de filtragem.

3.3.1. Filtragem dos dados

O processo é iniciado através do estabelecimento de uma grelha regular ao longo de toda a área coberta pela nuvem. Para cada célula da grelha é identificado o ponto da nuvem no seu interior com menor valor de elevação, P_{Hmin} (pontos vermelhos da Figura 3.16). Em seguida, cada célula inicial é dividida em quatro novas células de tamanho igual. Para cada uma das novas células é associado um novo ponto da nuvem. O estabelecimento desses pontos é efetuado através da aplicação de uma restrição baseada na do ponto (P_{Hmin}) da célula original que lhe deu origem. Essa restrição é baseada na definição de um intervalo, limitado por um valor mínimo (L_{Min}) e um valor máximo (L_{Max}) de distância vertical. Assim, para cada célula, resultante da divisão, os pontos de nuvem dos candidatos (P_C) são selecionados com base na condição descrita na Equação (3.15).

$$H(P_{Hmin}) + L_{Min} < H(P_C) < H(P_{Hmin}) + L_{Max} \quad (3.15)$$

Entre todos os pontos da nuvem candidatos que satisfazem esta restrição descrita na Equação (3.15), é escolhido o ponto com o valor H mais baixo (pontos azuis na Figura 3.16).

Este processo é repetido iterativamente até ser atingido o critério de paragem. O critério de paragem pode ser estabelecido por um número máximo de iterações ou por uma dimensão mínima da célula. É possível estabelecer uma relação entre o número de iterações e o tamanho da célula em cada iteração através da Equação (3.16).

$$D(i) = \frac{D_{Ini}}{2^{(i-1)}} \quad (3.16)$$

onde, i é o número da iteração, D_{Ini} a dimensão das células iniciais e $D(i)$ a dimensão das células na iteração i




Figura 3.16 Esquema da divisão iterativa das células.

A ideia subjacente ao método proposto é, por um lado, identificar em cada iteração um ponto no interior de cada célula resultante, cujo valor de elevação é superior a $P_{Hmin} + L_{Min}$, permitindo assim garantir uma evolução da representação crescente do terreno na componente Z. Por outro lado, através da limitação superior $P_{Hmin} + L_{Max}$, é limitada a consideração de pontos que representam carros, árvores ou outros elementos exteriores ao terreno. A restrição dos pontos em cada uma das células resultantes das iterações pode ser sistematizada através da conjunção das condições seguintes.

$$P_{cel} = P_i(H_{Min}) \xrightarrow{\text{where}} \begin{cases} H(P_{i-1}) + L_{Min} < H(P_i) \\ H(P_{i-1}) + L_{Max} > H(P_i) \end{cases} \quad (3.17)$$

onde, P_{cel} representa o ponto associado a uma determinada célula, $H(P_{i-1})$ representa o valor de elevação do ponto considerado na iteração anterior, $P_i(H_{Min})$ é o ponto com o valor de

elevação mínima de entre os que satisfazem as restrições, P_i representa os pontos candidatos da nuvem e, L_{Min} e L_{Max} são respetivamente os valores máximo e mínimo previamente definidos. Para melhor ilustrar o processo, considere-se a célula inicial representada na Figura 3.17 em que os pontos no interior da célula (P_C) representam uma estrada aproximadamente horizontal sob alguns ramos de uma árvore.




Figura 3.17 - Exemplificação do funcionamento do método proposto.

Na Figura 3.17, P_{Hmin} representa a elevação do ponto com o menor valor no interior da célula e, caso nenhum ponto no seu interior (P_C) satisfaça a condição $H(P_{Hmin}) + L_{Min} < H(P_C)$ será associado nenhum ponto às novas quatro células resultantes da divisão da célula inicial. Neste caso, o processo iterativo para essa célula termina e apenas um ponto da nuvem no espaço interno da célula inicial será considerado.

O valor L_{Max} é estabelecido para limitar situações em que o valor de elevação dos pontos candidatos considerados no processo iterativo têm uma diferença de elevação muito grande em relação ao ponto da célula inicial. Considerando a célula representada na Figura 3.17, na primeira iteração, o ponto com menor elevação no interior da célula corresponde aproximadamente ao valor de elevação da estrada (P_{Hmin}). Na iteração seguinte, nenhum outro ponto da nuvem no interior da célula, representando estrada, satisfaz a condição $H(P_{Hmin}) + L_{Min} < H(P_C)$, sendo por isso, descartados pelo processo. No entanto, os pontos da nuvem que representam os ramos da árvore satisfazem essa condição. Tendo em conta, que o valor L_{Max} definido é menor que a altura dos ramos em relação à estrada, todos os pontos dos ramos das árvores são descartados através da condição $H(P_{Hmin}) + L_{Max} > H(P_C)$, não sendo considerados para o MDT.

O valor L_{Min} está diretamente relacionado com o detalhe pretendido para o MDT final. A utilização de menores valores para L_{Min} , produz menor variação de elevação entre pontos resultantes de iterações consecutivas. Menores variações na forma do terreno são representadas e, conseqüentemente, o MDT resultante tem um maior detalhe. Em contrapartida, valores baixos de L_{Min} conduzem a um MDT com um número mais elevado de pontos, devendo ser estabelecido o seu valor em função da escala pretendida para o MDT.

Uma grande vantagem deste processo é que os pontos resultantes não são equidistantes, sendo a distância entre eles inversamente proporcional à variação do terreno, resultando numa menor densidade de pontos em zonas aproximadamente planas e horizontais e maior densidade nas zonas com maior declive do terreno. Este efeito é exemplificado na Figura 3.18, onde é representada esquematicamente uma nuvem de pontos colorida por altura, ao longo de uma rodovia e respetivo passeio (verde). Na Figura 3.18a) está representada uma vista isométrica da nuvem de pontos e uma representação esquemática da divisão das células ao longo de 3 iterações, com os respetivos pontos resultantes da aplicação do método. Na Figura 3.18b) é representada a vista superior do mesmo resultado. É possível verificar que a distância entre pontos é irregular e inversamente proporcional à variação do terreno, nomeadamente uma maior densidade ao longo da linha de quebra e uma menor densidade ao longo das zonas planas.

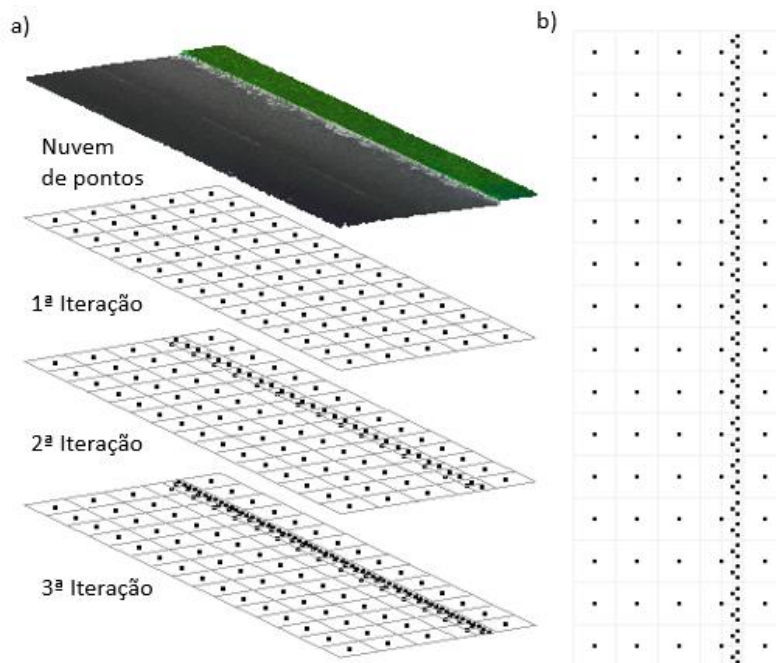


Figura 3.18 - Ilustração da distribuição espacial dos pontos por iteração.

A discretização dos pontos da nuvem através do método proposto permite diminuir o número de pontos resultante, mantendo, no entanto, os pontos chave que representam a forma do

terreno. Uma das limitações do método, prende-se com situações em que o terreno no interior de um célula, apesar de plano, não é horizontal. Nesses casos, o número de pontos para a representação do terreno será superior ao necessário.

Outra limitação associada ao método, resulta do pressuposto de que o ponto com menor elevação no interior de cada uma das células iniciais representa o terreno, pois todo o processo é inicializado com base nessa suposição. No entanto, esse ponto poderá estar acima do terreno, por exemplo, em casos de vegetação densa e, conseqüentemente, todos os pontos resultantes do processo dentro dessa célula não representarão o terreno. Por outro lado, como referido anteriormente, existem pontos que tipicamente, devido a reflexões em zonas espelhadas, (e conseqüente atraso no tempo de percurso), apresentam erradamente valores de elevação inferiores ao terreno.

Ambas as situações são críticas para a qualidade do MDT final. Na Figura 3.19 é ilustrado o efeito, de um ponto com elevação inferior à superfície do terreno.




Figura 3.19 - Efeito de erosão provocada por um ponto *outlier* com elevação inferior ao terreno.

No primeiro caso em que todos os pontos no interior de uma célula têm uma elevação superior à superfície do terreno, a limitação pode ser atenuada através do aumento da dimensão das células iniciais. Esse aumento, permite aumentar a probabilidade de pelo menos um ponto da nuvem (P_{HMin}) representar a superfície do terreno. No entanto, quanto maior for a célula inicial, menor será o detalhe do MDT final. No segundo caso, em que existem pontos com elevação inferior à superfície do terreno, não existe uma solução intrínseca ao processo que permita a sua remoção. Em qualquer dos casos a existência desses pontos conspícuos representa um obstáculo na correta classificação dos pontos de terreno. Apresenta-se de seguida uma

metodologia de pré-processamento para a diminuição desses pontos e consequente atenuação desse obstáculo, especificamente para as nuvens de pontos recolhidas por SLMT.

3.3.2. Pré-processamento dos dados

O processo de pré-processamento tem por objetivo, por um lado, eliminar os pontos conspícuos, afastados da superfície do terreno e, por outro lado, restringir o número de pontos candidatos.

A estratégia proposta tira partido da identificação dos pontos da trajetória do SLMT da nuvem de pontos, baseada na descrição efetuada na Secção 3.2.1. O intervalo entre pontos da trajetória é sincronizado com a frequência da UMI do sistema, sendo estabelecida uma camada limitada por superfícies quadráticas definidas pelos valores L_d e L_u , são classificados os pontos fora desse intervalo (acima e abaixo) permitindo eliminá-los do processo.

Utilizando uma função quadrática (Equação (3.18)) e fazendo variar o valor do seu coeficiente de 2º grau (a), é possível uma adaptação a diferentes tipos de terreno.

$$\begin{cases} H(P_i) - L_d < a \cdot (D)^2 + b \cdot D + H(T_i) \\ H(P_i) + L_u > a \cdot (D)^2 + b \cdot D + H(T_i) \end{cases} \quad (3.18)$$

onde, $H(P_i)$ é o valor de elevação do ponto candidato da nuvem, $H(T_i)$ é a elevação do ponto da trajetória no momento da aquisição, D é a distancia entre o ponto da nuvem e o ponto da trajetória no momento da aquisição, a e b representam o coeficiente quadrático e linear, e L_d , L_u representam respetivamente os limites superior e inferior, sendo estes parâmetros definidos previamente com base na observação da nuvem e de acordo com o tipo de relevo paralelo à via.

Na Figura 3.2 são ilustradas variações da fórmula quadrática de modo a melhorar a sua adaptação à forma do terreno. No caso de ocorrerem várias mudanças de terreno ao longo da trajetória e não ser possível definir uma tendência, o intervalo (L_d , L_u) pode ser aumentado de forma a incluir todos os pontos do terreno, mas ainda assim eliminando os valores extremos.




Figura 3.20 - Esquema da função quadrática com variação do valor a . a) $a = 0$; b) $a > 0$; c) $a < 0$.

É importante realçar que a aplicação desta restrição apenas pretende eliminar pontos que apresentam valores de altitude significativamente distantes do terreno, ao qual o processo seguinte é sensível. Os pontos mais próximos do terreno serão eliminados no processo de interpolação descrito na secção seguinte.

3.3.3. Interpolação e eliminação de pontos conspícuos à superfície do terreno

Ao longo deste passo é criada uma rede irregular de triângulos, sendo proposta uma metodologia para a eliminação de pontos conspícuos, exteriores ao terreno, que não foram eliminados nos processos anteriores do processo.

O operador Laplaciano é talvez o operador de suavização mais conhecido e utilizado (Belkin *et al.*, 2008). Este operador baseia-se no estabelecimento de uma relação de vizinhança através dos triângulos com arestas partilhadas. Na Figura 3.21 é apresentado um exemplo do estabelecimento de uma vizinhança, onde os pontos vermelhos representam os vizinhos do ponto azul.




Figura 3.21 - Vizinhança baseada nas arestas comuns dos triângulos.

O algoritmo do operador Laplaciano, utilizado no contexto de suavização de superfícies, pode ser definido reduzidamente da seguinte forma, tendo em conta os pontos da Figura 3.21: a posição do ponto azul (e o vértice do triângulo correspondente) é substituída pelo ponto médio das posições dos seus vizinhos (pontos vermelhos) (Vollmer *et al.*, 1999).

Ao longo deste trabalho, em vez de mudar de posição, o ponto é potencialmente removido, através do estabelecimento de vários operadores com base nos triângulos vizinhos. Um desses operadores propostos é baseado no plano ou planos gerados pelos pontos vizinhos, esquematizados na Figura 3.22.

A distância D representa a distância mínima entre o ponto azul e um plano gerado pelos pontos vizinhos (pontos vermelhos). Para calcular D é necessário determinar a equação do plano a partir das coordenadas tridimensionais dos pontos, tendo em conta a descrição efetuada na Secção 3.1.2.




Figura 3.22 - Distância ao plano definido por três vizinhos.

No caso de um ponto ter mais de três vizinhos, é provável que nem todos estejam no mesmo plano. Nesse caso, poderão ser aplicados métodos estatísticos para obter o plano médio, através de mínimos quadrados ou definindo todos os planos que são gerados agrupando os vizinhos três por três e calculando todas as distâncias mínimas entre os planos gerados e o ponto. Na Figura 3.23, os valores de D_{Max} e D_{Min} representam as distâncias mínimas correspondentes aos planos mais distantes e menos distantes gerados por três vizinhos agrupados.




Figura 3.23 - Distâncias máxima e mínima aos planos gerados pelos pontos vizinhos.

O principal objetivo da aplicação destes operadores, é por um lado, a identificação e eliminação de pontos conspícuos à superfície, e por outro lado, eliminar os pontos nas áreas aproximadamente planas, não horizontais, não eliminados nos passos anteriores.

A aplicação destes operadores é efetuada de forma iterativa, sendo estabelecido um intervalo entre dois valores limite de distância D_1 e D_2 . Em cada iteração é criada uma nova triangulação de Delaunay, sendo eliminados os pontos que apresentem valores de distância fora do intervalo estabelecido ($D_1 > D_{Max}$ ou $D_2 < D_{Min}$).

Tendo em consideração a reciprocidade da vizinhança, ou seja, um determinado ponto pertence à vizinhança de cada um dos pontos vizinhos, de forma a evitar uma erosão da superfície, é adicionada uma nova restrição em cada iteração, não permitindo a eliminação de pontos vizinhos previamente identificados para serem eliminados do modelo.

Os critérios de paragem para as iterações podem ser estabelecidos por um valor mínimo absoluto para o número de pontos eliminados ou definindo um valor mínimo para os pontos eliminados entre iterações consecutivas.

Finalmente, evidencia-se o facto de todos os pontos resultantes de qualquer um dos passos do método proposto, serem pontos diretamente medidos das nuvens, sem qualquer processo de interpolação.

3.3.4. Resultados obtidos

De forma a avaliar os resultados obtidos através do método proposto, foram implementados cada um dos passos descritos anteriormente em .NET C# . Ao longo desta secção são descritos os resultados mais significativos obtidos em conjunto com uma análise de sensibilidade do método proposto. Os exemplos apresentados, foram escolhidos de forma a demonstrar a aplicação do método em diferentes ambientes (rurais e urbanos), nas situações mais extremas de variação do terreno (linhas de quebra) e em outras situações específicas onde será expectável maiores dificuldades do método na classificação dos pontos do terreno.

Na Figura 3.24a apresenta-se um extrato de uma nuvem de pontos obtida por um SLMT ao longo de uma área rural, sendo ilustrado na Figura 3.24b o resultado obtido através da aplicação do método. É possível verificar que os pontos da nuvem, exteriores ao terreno, que representam a vegetação, a casa, as linhas e os postes de electricidade são globalmente eliminados, mantendo apenas pontos que representam a forma do terreno. Observa-se igualmente a densidade irregular dos pontos, inversamente proporcional às variações do terreno.




Figura 3.24 - a) Exemplo de nuvem de ponto colorido por altura b) Pontos resultantes obtidos da aplicação do Passo 1 após quatro iterações, onde $D_{ini} = 1$ m, $L_{min} = 0.04$ m, $L_{max} = 0.08$ m.

Na Figura 3.25 é apresentada uma análise comparativa dos resultados obtidos através da variação da dimensão inicial da célula (D_{ini}). Ao diminuir o valor de D_{ini} , a densidade dos pontos resultantes aumenta, permitindo uma melhor representação dos detalhes do terreno.




Figura 3.25 - Análise comparativa com base na variação de dimensão da célula inicial. a) Nuvem de pontos colorida por elevação b) Resultado obtido com $D_{Ini} = 4$ m c) Resultado obtido com $D_{Ini} = 2$ m d) Resultado obtido com $D_{Ini} = 1$ m.

Na parte inferior da Figura 3.26 são apresentados diferentes resultados da aplicação do método em diferentes ambientes e estruturas, cujas nuvens de pontos são representadas na parte superior da mesma figura.




Figura 3.26 - Exemplos de resultados da aplicação do método proposto.

Um conhecido desafio na criação e representação do MDT é a modelação das linhas de quebra do terreno, sendo a linha ao longo dos lancis dos passeios nas áreas urbanas, um bom exemplo disso. Na Figura 3.27 é apresentada uma secção transversal de uma nuvem de pontos que cruza um lancil. A secção transversal possui uma largura de 0.25 m e um comprimento de 2 m, sendo representados os pontos obtidos em iterações sucessivas da aplicação do método.




Figura 3.27 - Esquema de uma secção transversal cruzando uma linha de quebra do terreno. a) Resultado obtido após uma iteração b) Resultado obtido após duas iterações c) Resultado obtido após três iterações.

Na primeira iteração (Figura 3.27a), apenas são observados os pontos com a menor elevação $P_{H_{\min}}$ no interior das células iniciais. À medida que o número de iterações aumenta (Figuras 3.27b e 3.27c), a divisão de cada uma das células iniciais permite uma maior discretização da área, através da divisão das células iniciais e, conseqüentemente, o aumento do número de pontos. Ao aumentar o número de iterações, verifica-se uma maior concentração de pontos na área da linha de quebra do lancil, enquanto que nas áreas mais planas essa densidade não aumenta. Este efeito resulta do facto, de com o aumento das iterações, nas áreas aproximadamente planas horizontais, nenhum dos pontos dentro das células satisfazer as restrições (3.17), sendo o processo interrompido dentro dessas células. Nas áreas de maior variação do terreno, as células continuam a dividir-se até que não haja mais pontos que satisfaçam a condição ou até que o critério de paragem seja atingido. Isto explica o facto da distância entre os pontos resultantes ser inversamente proporcional à variação do terreno. Esta maior densidade de pontos ao longo das zonas de linhas de quebra, permite assim atenuar a dificuldade de representação do MDT ao longo dessas zonas.

Para além do desafio de representação do MDT ao longo das linhas de lancil em áreas urbanas, os carros estacionados ao longo das estradas em ambientes urbanos são outro problema comum na criação de MDT a partir de nuvens de pontos coletadas por SLMT. O objetivo do método proposto, é obter um efeito contrário para estes dois elementos, ou seja, manter uma maior concentração de pontos ao longo da linha de quebra dos lancis e remover o maior número de pontos de objetos não pertencentes ao terreno, como o caso dos pontos que representam os carros.

Na Figura 3.28a é possível observar uma nuvem de pontos em que dois carros estacionados foram capturados pela nuvem recolhida pelo SLMT. Nas Figuras 3.28b e 3.28c comparam-se os resultados obtidos pelo método proposto através da variação do valor L_{\max} . Na Figura 3.28b, é utilizado um valor de $L_{\max} = 40$ cm, permanecendo no resultado, pontos que representam o

piso inferior do carro recolhidos pelo exterior ou através da janela do carro. Ao diminuir o valor L_{Max} (Figura 3.28c) para 15 cm, o número de pontos que representam os veículos no resultado também diminui. Isto deve-se ao facto de o valor L_{Max} usado no exemplo da Figura 3.28c ser menor que a distância entre o piso inferior do carro e o chão. Logo, o processo iterativo, nas células na zona dos carros, termina antes de atingir esses pontos. Os únicos pontos que representam o carro e que permanecem na Figura 3.28c são os pontos das rodas do carro que estão em contato com o solo.




Figura 3.28 - Exemplo de aplicação do método em zonas com veículos estacionados b) Resultado do processo de filtragem com $L_{Max} = 0.40$ m c) Resultado do processo de filtragem com $L_{Max} = 0.15$ m.

Os resultados apresentados nas Figuras 3.24 a 3.28, foram obtidos apenas com base no processo de filtragem do método, para implementação do processo de interpolação. Foi implementado o algoritmo *S-hull* (Sinclair, 2010) para criação da triangulação de Delaunay.

Na Figura 3.29a é apresentado o resultado da triangulação de Delaunay dos pontos resultantes da aplicação do método na nuvem representada na Figura 3.24. As Figuras 3.29b e 3.29c, representam uma ampliação da área vermelha da Figura 3.29a, antes e depois da aplicação do

algoritmo iterativo descrito na Secção 3.3.3. Apesar de globalmente a forma da superfície não mudar, é possível eliminar a maioria dos pontos conspícuos à superfície, mantendo a linha de quebra. O resultado foi obtido com os valores limite $D_{Max} > 0.05$ m, $D_{Min} < 0.005$ m, $Tri_{Min} < 0.5$ m e $Tri_{Max} < 0.75$ m (Figuras 3.21 e 3.23). O número de pontos foi reduzido de aproximadamente 122000 resultantes do processo de filtragem para aproximadamente 53000 pontos. O resultado apresentado foi obtido após 37 iterações em 42 segundos.




Figura 3.29 - Análise do resultado do método proposto. a) Triangulação de Delaunay dos pontos da Figura a. b) Ampliação da zona marcada a vermelho na Figura a. c) Resultado obtido após aplicação do filtro com base no operador Laplaciano.

Paralelamente ao processo de eliminação dos pontos conspícuos à superfície, através do valor P_{Min} , o método permite diminuir o número de pontos em áreas planas. Na Figura 3.30 é apresentado o resultado obtido antes da aplicação do processo de interpolação do método. Verifica-se que, mesmo na zona da estrada, apesar de plana, uma vez que tem uma inclinação em relação à horizontal, o número de pontos é substancialmente reduzido.




Figura 3.30 - Análise do resultado do método proposto. a) Triangulação de Delaunay dos pontos da Figura 3.29c b) Resultado obtido após redução dos pontos

Em todos os exemplos apresentados ao longo desta secção, foram utilizadas células de forma quadrada. De forma a avaliar a influência da forma das células nos resultados do processo de filtragem, foram implementadas diferentes formas de células regulares e irregulares. Na secção seguinte são apresentados os algoritmos de implementação dessas células com base no conceito de coordenadas-grelha, que permite diminuir significativamente os tempos de execução.

3.3.5. Coordenadas-grelha e análise de sensibilidade à forma das células utilizadas

O método proposto, descrito nas secções anteriores, para a classificação dos pontos do terreno, baseia-se na divisão recursiva do espaço, utilizando células. As células são divididas iterativamente, onde cada uma das células resulta da divisão da célula da iteração anterior. Ao longo deste trabalho optou-se por designar este processo por multigrelha. Neste processo, apenas um ponto da nuvem é associado a cada uma das células da grelha.

Um aspeto crucial na eficiência da implementação do método multigrelha é o algoritmo que permite determinar, se um determinado ponto da nuvem está ou não no interior de cada uma das células da grelha. Dado o elevado número de pontos das nuvens, de células das grelhas e de iterações, este processo pode tornar-se muito lento. Em vez de implementar um algoritmo que, para verificar essa condição, use diretamente as coordenadas dos vértices da célula, é proposto um método alternativo. O método é baseado no estabelecimento de um sistema de referência de cada célula com base na sua linha e coluna, designado ao longo deste trabalho por coordenadas-grelha. Este método permite reduzir o problema “em que célula se encontra o

ponto?”, ao problema de determinar as coordenadas-grelha da célula com base nas coordenadas do ponto da nuvem. Através desta mudança, é possível obter independência do número de células da grelha, uma vez que não existe necessidade de testar todas as células, permitindo utilizar células mais pequenas em áreas maiores, sem perda significativa de tempo de execução.

Para além disso, este método permite a aplicação em células de diferentes formas, ficando o problema reduzido à determinação das coordenadas linha e coluna para essas formas, com base nas coordenadas planimétricas dos pontos da nuvem.

Ao longo desta secção descrevem-se os algoritmos de implementação do método para células quadradas, triangulares e hexagonais, avaliando-se a sensibilidade do método à forma das células. Embora não sejam esperadas diferenças significativas entre as diferentes formas de células em zonas planas, pretende-se avaliar o impacto da variação dessas formas no resultado obtido em zonas com variações mais acentuadas de elevação do terreno.

As coordenadas referentes ao sistema linha e coluna de cada grelha são ao longo deste trabalho designadas por coordenadas-grelha. Uma grelha é considerada regular quando todas as suas células são iguais, não necessariamente simétricas.

Para além dos três tipos de células regulares foi testada a implementação do método utilizando células triangulares irregulares.

3.3.5.1. Células quadradas

O uso de células quadradas é claramente a forma mais intuitiva de divisão do espaço de uma forma regular. A fácil implementação e abstração desse tipo de células torna-a a forma mais popular para a representação da informação geográfica através de uma grelha regular. Os pixéis quadrados associados ao formato matricial de uma imagem são o caso mais paradigmático dessa representação. As coordenadas-grelha de uma célula quadrada utilizando as coordenadas planimétricas de um ponto da nuvem podem ser determinadas por:

$$\begin{cases} Lin = Int\left(\frac{Y}{D_{cel}}\right) \\ Col = Int\left(\frac{X}{D_{cel}}\right) \end{cases} \quad (3.19)$$

onde, D_{cel} é a dimensão linear do tamanho da célula, Lin e Col representam respetivamente a linha e coluna da célula que contém o ponto e (X, Y) são as coordenadas planimétricas do ponto de nuvem.

3.3.5.2. Células hexagonais

Uma vantagem na utilização de células hexagonais é a sua aplicação em algoritmos em que é necessária a determinação de vizinhanças, uma vez que ao contrário das células quadrangulares e triangulares, o centro de uma determinada célula hexagonal é equidistante de todas as suas células vizinhas

No entanto, a implementação de um sistema de referência com base em linhas e colunas numa grelha de células hexagonais é consideravelmente mais complexa do que em células quadradas.

Na Figura 2.31, é apresentado o sistema de coordenadas-grelha definido para células hexagonais. As colunas são verticais, mas as linhas não são horizontais, o que aumenta a complexidade de sua implementação. As células hexagonais aqui apresentadas são geralmente designadas de horizontais, ou seja, a parte superior de cada célula é uma aresta horizontal. Existe uma outra versão, chamada vertical, resultante de uma rotação de 90° das células, onde a parte superior de cada célula é um vértice.




Figura 3.31 - Esquema das coordenadas-grelha para as células hexagonais.

No triângulo T, representado na Figura 3.32, a relação entre sua altura e base é $1/\sqrt{3}$, e a largura total do hexágono é quatro vezes o valor da base do triângulo T. Assim, a relação entre a altura da célula (h) e a sua largura (w) pode ser representada através da equação (3.20).




Figura 3.32 - Relação altura largura das células hexagonais.

$$w = 4 \times \frac{h/2}{\sqrt{3}} \quad (3.20)$$

onde, w e h são, respectivamente, a largura e altura da célula hexagonal.

No caso das células hexagonais, o algoritmo para a determinação das coordenadas-grelha (Lin , Col) é dividido em 3 passos. No primeiro passo, um valor temporário para a linha e coluna da célula é estabelecido (C_C , R_C), assumindo uma simplificação das células hexagonais para retangulares, cuja altura é igual à altura da célula e a sua largura é três quartos desse valor (retângulo vermelho da Figura 3.33). Tendo em conta que as linhas das células não são horizontais é necessário distinguir entre as células das colunas pares e ímpares.

No segundo passo, pretende-se verificar se o ponto se encontra no interior dos triângulos representados a verde e azul dentro do retângulo da Figura 3.33. Finalmente, no passo 3, com base nos resultados do passo 2, as coordenadas-grelha candidatas (C_C , R_C) são ajustadas. A formulação dos passos 1, 2 e 3 são apresentadas respetivamente nas equações (3.21), (3.22) e (3.23).




Figura 3.33 - Definição das áreas auxiliares, para estabelecimento das coordenadas-grelha em células hexagonais.

Passo 1:

Booleano A = Falso

Booleano B = Falso

$$\begin{aligned}
 Cc &= \text{int} \left(\frac{X}{0.75 w} \right) \\
 \text{Se } Cc \text{ é par} &\begin{cases} Rc = \text{Int} \left(\frac{Y}{h} \right) \\ Dx = X - Cc * w \end{cases} \\
 \text{Se } Cc \text{ é ímpar} &\begin{cases} Rc = \text{Int} \left(\frac{Y - \frac{h}{2}}{h} \right) \\ Dy = X - (Cc - 1) * w \end{cases}
 \end{aligned} \tag{3.21}$$

Passo 2:

$Dy = y - Rc * h$

$$\text{Se } Dx < \frac{w}{4} \begin{cases} \text{if } Dy < \frac{h}{2} \text{ and } \frac{Dx}{Dy} > \sqrt{3} \Rightarrow B \text{ é verdadeiro} \\ \text{if } Dy \geq \frac{h}{2} \text{ and } -\frac{Dx}{Dy} > \sqrt{3} \Rightarrow A \text{ é verdadeiro} \end{cases} \tag{3.22}$$

Passo 3:

$$\begin{cases} \text{Se } A \text{ é Falso e } B \text{ é Falso} \Rightarrow Col = Cc \text{ e } Row = Rc \\ \text{Se } A \text{ é Verdadeiro ou } B \text{ é Verdadeiro} \Rightarrow Col = Cc - 1 \\ \text{Se } B \text{ é Verdadeiro and } Cc \text{ é par} \Rightarrow Row = Rc - 1 \\ \text{Se } B \text{ é Verdadeiro e } Cc \text{ é ímpar} \Rightarrow Row = Rc \end{cases} \tag{3.23}$$

onde, Cc e Rc representam respetivamente a coluna e linha do retângulo candidato, h e w correspondem à altura e largura das células hexagonais e (X, Y) são as coordenadas planimétricas dos pontos das nuvens.

3.3.5.3. Células triangulares

O triângulo é a unidade mais básica de todos os padrões geométricos, uma vez que um retângulo, hexágono ou qualquer outro polígono pode ser decomposto em triângulos.

Neste caso a grelha triangular é composta por triângulos equiláteros verticais. A relação nos triângulos equiláteros entre altura (h) e largura (w) pode ser determinada através da Equação (3.24).

$$w = 2 \frac{h}{\sqrt{3}} \tag{3.24}$$

onde, w e h correspondem respectivamente à largura e altura da célula triangular.

No caso das células triangulares, é necessário distinguir entre os triângulos com o vértice para cima e os triângulos com o vértice para baixo. Um valor de 0.5 é adicionado ao valor da coluna anterior se o vértice estiver apontando para baixo. Assim, todos os triângulos apontando para baixo terão um índice de coluna de meia unidade e todos os triângulos apontando para cima um índice de coluna inteiro. Considerando que a primeira coluna corresponde ao número K , a sequência da coluna será: K , $K + 0.5$, $K + 1$, $K + 1.5$, $K + 2$, etc. O esquema de coordenadas-grelha triangular está representado na Figura 3.34.




Figura 3.34 - Coordenadas-grelhas triangulares.

O algoritmo usado para calcular as coordenadas-grelha utilizando células triangulares pode ser dividido em 2 passos. No primeiro passo, é utilizado um retângulo candidato com a largura (w) e altura (h) do triângulo, para estabelecer as coordenadas candidatas (R_C , C_C). Na Figura 3.35, o retângulo candidato está representado a vermelho.

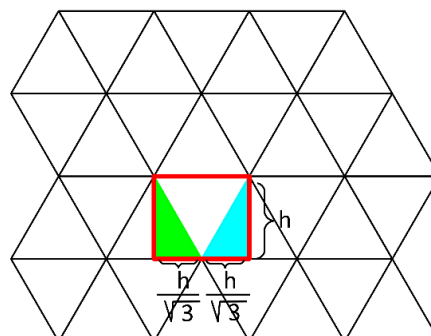


Figura 3.35 - Definição das áreas auxiliares para o cálculo das coordenadas auxiliares.

No segundo passo, é estabelecida uma situação semelhante às células hexagonais, para verificar se o ponto está dentro de um dos triângulos internos ao quadrado, exemplificados a azul e verde

da Figura 3.35. Um ajuste final do valor da coluna é então efetuado de acordo com a direção do vértice vertical, sendo adicionado 0.5, no caso de apontar para baixo. Os três passos do método são formulados através do conjunto das Equações (3.25), (3.26) e (3.27).

Passo 1:

$$\begin{cases} L = \text{Int}\left(\frac{y}{h}\right) \\ Cc = \text{Int}\left(\frac{x}{w}\right) \end{cases} \quad (3.25)$$

Passo 2:

$$Dx = X - Cc * w$$

$$Dy = (L + 1) * h - y \quad (3.26)$$

$$\text{Se } L \text{ é par} \Rightarrow Dy = h - Dy$$

Se $Dy > 1$

$$\begin{cases} \text{Se } Dx < \frac{w}{2} \text{ e } \frac{Dx}{Dy} < \frac{1}{\sqrt{3}} \Rightarrow Col = Cc - 0.5 \\ \text{Se } Dx \geq \frac{w}{2} \text{ e } \frac{(w-Dx)}{Dy} < \frac{1}{\sqrt{3}} \Rightarrow Col = Cc + 0.5 \end{cases} \quad (3.27)$$

onde, Cc representa respectivamente a coluna do retângulo candidato, L é a linha da célula, h e w correspondem à altura e largura das células triangulares e X , Y são as coordenadas planimétricas dos pontos das nuvens.

3.3.5.4. Grelhas irregulares

Para a implementação do método sobre grelhas irregulares, optou-se por utilizar uma divisão irregular recursiva do espaço através de triângulos. Ao contrário das grelhas regulares, neste caso é necessário pré-estabelecer um conjunto de pontos iniciais ao longo da área de trabalho, a fim de iniciar o processo de divisão recursiva dos triângulos. Esses pontos iniciais podem ser estabelecidos por meio de um único triângulo inicial que contém todos os pontos da nuvem dentro (Figura 3.36). Ou para acelerar o processo, usando uma grelha de células regulares onde o ponto de elevação mais baixo é identificado dentro de cada célula. Esse conjunto de pontos é

então triangulado e os triângulos resultantes são usados para iniciar o processo de divisão de triangulação recursiva.

Partindo da triangulação inicial, a divisão de triângulos é feita recursivamente através da identificação de um ponto no interior de cada triângulo, sendo que, em cada iteração, cada um dos triângulos é passível de ser dividido em três novos triângulos.




Figura 3.36 - Esquema da triangulação recursiva irregular.

No caso das grelhas irregulares não é possível usar o conceito de coordenadas-grelha estabelecido para as grelhas regulares. No entanto, a relação hierárquica espacial entre a célula dividida e as células resultantes em iterações consecutivas é mantida.

O problema associado à determinação de se um ponto está ou não no interior de um triângulo no espaço, pode ser abordado em função da dimensão do espaço considerado: no caso 2D, em que é considerada a projeção do ponto e do triângulo no plano horizontal, ou no caso 3D, em que é considerada a projeção do ponto no plano do triângulo.

Na Figura 3.37 é representado um triângulo 3D (T) e dois pontos no espaço, P1 e P2. Tendo em conta que até agora a variável utilizada para estabelecer os pontos dentro da célula é a sua elevação, ao projetar o ponto P1 e P2 ao longo do eixo Z, no plano horizontal (P1'' e P2''), conclui-se que P2'' está fora do triângulo T' e, conseqüentemente, fora de T. Por outro lado, P1'' estará dentro T. No entanto, ao considerar-se as projeções de P1 e P2 no plano do triângulo T (P1' e P2'), pode ser concluído o oposto.

De forma a tirar vantagem dos triângulos 3D, especialmente nas áreas de maior declive do terreno, optou-se por utilizar a distância perpendicular do ponto ao plano do triângulo, em vez da variável elevação dos pontos para estabelecer novos triângulos.




Figura 3.37 - Definição de ponto no interior do triângulo.

Heidrich (2005), apresenta um algoritmo baseado no cálculo das coordenadas baricêntricas, para determinar a projeção de um ponto no plano de um triângulo e, conseqüentemente, verificar se este está ou não no interior do triângulo. Tendo em conta a sua eficiência, este algoritmo foi utilizado para a implementação do método, justificando-se assim, uma descrição detalhada.

Com base no triângulo T representado na Figura 3.37, definido pelos pontos (Pa, Pb, Pc), as coordenadas baricêntricas B1, B2 e B3 são determinadas através das equações (2.18), (2.19) e (2.20). Neste caso a projeção P2' encontra-se no interior do triângulo se se encontrar do lado esquerdo dos vetores que representam os lados do triângulo, ou seja, se todas coordenadas B1, B2 e B3 têm valores entre 0 e 1. Nas Equações (3.28) a (3.34), são formulados os passos intermédios para a determinação das coordenadas baricêntricas.

$$\vec{u} = P_b - P_a \quad (3.28)$$

$$\vec{v} = P_c - P_a \quad (3.29)$$

$$\vec{w} = P_2 - P_a \quad (3.30)$$

$$\vec{n} = \vec{u} \times \vec{v} \quad (3.31)$$

$$B_3 = \frac{(\vec{u} \cdot \vec{w}) \times \vec{n}}{\vec{n} \cdot \vec{n}} \quad (3.32)$$

$$B_2 = \frac{((\vec{w} \times \vec{v}) \cdot \vec{n})}{(\vec{n} \cdot \vec{n})} \quad (3.33)$$

$$B_1 = 1 - B_3 - B_2 \quad (3.34)$$

se $0 \leq B_2 < 1$ e $0 \leq B_1 < 1$ e $0 \leq B_3 < 1 \Rightarrow P_2$ está no interior de T

onde, P_2 é ponto tridimensional no espaço, P_a , P_b e P_c são os vértices do triângulo e B_1 , B_2 e B_3 representam as coordenadas baricêntricas da projeção do ponto no plano do triângulo.

Após a verificação do ponto no interior do triângulo, é necessário calcular a sua distância ao plano do triângulo. Essa distância é igual à distância entre o ponto P_2 e sua projeção no triângulo plano P_2'' , ficando o problema reduzido ao cálculo das coordenadas de P_2'' , apresentadas na Equação (3.35).

$$\begin{cases} X'' = B_1X_a + B_2X_b + B_3X_c \\ Y'' = B_1Y_a + B_2Y_b + B_3Y_c \\ Z'' = B_1Z_a + B_2Z_b + B_3Z_c \end{cases} \quad (3.35)$$

onde, (X'', Y'', Z'') são as coordenadas cartesianas da projeção do ponto no plano do triângulo, B_1 , B_2 e B_3 as coordenadas baricêntricas da projeção do ponto no plano do triângulo e (X_i, Y_i, Z_i) as coordenadas dos vértices do triângulo ($i = a, b, c$).

3.3.5.5. Implementação e funcionamento dos algoritmos

No caso das grelhas regulares, os únicos parâmetros necessários para o desencadeamento do processo, são a dimensão das células iniciais e o critério de paragem.

Na primeira iteração, para cada ponto da nuvem são determinadas as suas coordenadas-grelha (Lin, Col), de acordo com a sua forma, utilizando a formulação descrita na secção anterior e o valor de célula inicial pré-definido. Após esse processo, é verificado se já existe algum ponto associado a essa célula; no caso negativo, o ponto é associado à célula; no caso positivo, o ponto substitui o ponto já associado à célula apenas no caso de ter uma elevação menor. O caso em que a elevação entre os pontos é igual, é indiferente qual o ponto considerado. Após terem sido percorridos todos os pontos da nuvem, é iniciada uma nova iteração, percorrendo novamente todos os pontos das nuvens. Nesta segunda iteração o valor de dimensão da célula, para determinação das coordenadas-grelha, é metade do valor utilizado para a grelha inicial. Mais uma vez, é verificado se já existe algum ponto associado a essa célula e, no caso negativo, é necessário comparar a elevação desse ponto com a elevação do ponto associado à célula da grelha anterior. Para determinar qual a célula da grelha anterior, basta utilizar a formulação da secção anterior, utilizando a dimensão das células dessa grelha. O ponto da nuvem é associado à célula, apenas no caso de satisfazer a condição definida na Equação (3.17). No caso de mais de um ponto satisfazer a condição, para uma determinada célula, é associado a essa célula o ponto com menor elevação.

O processo é repetido iterativamente, até ser atingido o critério de paragem, tendo em conta que no caso de nenhum ponto ter sido associado à célula da grelha da interação anterior, nenhum ponto é associado à célula na presente interação.

As vantagens do processo de multigrelha estão claramente patentes na descrição anterior. Permitem a rápida comparação entre pontos associados a células de grelhas resultantes de iterações sucessivas, independentemente da sua forma, apenas alterando a sua dimensão. De notar que a dimensão da célula pode ser obtida com base no valor da interação através da Equação (3.16). Este processo permite ganhos computacionais muito elevados, já que não é necessário percorrer todas as células da grelha para verificar em que célula o ponto se encontra, permitindo, deste modo, processar cerca de três milhões de pontos por segundo⁸.

Outra vantagem deste processo multigrelha, é o facto de não ser necessário definir a dimensão das grelhas *a priori*. As células de cada grelha vão sendo geradas, à medida que um ponto da nuvem satisfaz as condições para essa célula. Isto permite um ganho bastante grande em termos de recursos computacionais, nomeadamente, não ser necessário alocar memória do sistema para as células de todas as grelhas.

Os critérios de paragem do método podem ser definidos através de um número limitado de iterações, um número máximo de pontos em uma interação ou uma diferença mínima de pontos obtidos entre iterações consecutivas. A divisão das células entre duas iterações consecutivas é diferente consoante a sua forma, apesar do valor de tamanho da célula considerado seja sempre metade do da interação anterior. Na Figura 3.38 é apresentado o processo de divisão das células de diferentes formas. Embora, tanto as células quadradas como as triangulares sejam divididas em quatro novas células, a divisão é feita de forma diferente no espaço. A divisão das células hexagonais resulta em 7 novas células, além disso, ao contrário das outras formas, as células hexagonais resultantes da divisão cobrem uma área superior à da célula dividida, como se verifica na Figura 3.38.

⁸ Utilizando um processador Intel(R) Core(TM) I5-8250U CPU @ 1.65GHz




Figura 3.38 - Processo de divisão das células regulares.

No caso das grelhas irregulares, um aspeto interessante relativo à utilização de triângulos tridimensionais, é o lado em que o ponto se encontra em relação ao plano do triângulo. A posição do ponto em relação a esse plano pode ser obtida pelo sinal do produto escalar entre o produto vetorial ($\vec{u} \times \vec{v}$) e \vec{w} , definidos em (3.30) e (3.31).

De forma a controlar o lado em que o ponto se encontra em relação ao plano do triângulo é necessário garantir que os pontos dos triângulos são ordenados no sentido horário. Nesse caso, o produto escalar será positivo se o ponto estiver acima do plano dum triângulo e negativo se se encontrar abaixo desse plano. A Figura 3.39 representa esquematicamente um triângulo num plano diferente do horizontal, cruzando um lancil paralelo a uma rua coletado por uma nuvem de pontos. Supondo que os vértices do triângulo T se encontram ordenados no sentido horário, o produto escalar definido será positivo para o ponto P1 e negativo para o ponto P2. Na implementação do método, a restrição definida na Equação (3.15) é adaptada para $L_{Min} < d_i < L_{Max}$, onde d_i é a distância do ponto candidato ao plano do triângulo.




Figura 3.39 - Lado do triângulo tridimensional.

3.3.5.6. Análise comparativa dos resultados

Na parte superior da Figura 3.40, é representada uma nuvem com aproximadamente oito milhões de pontos recolhida por um SLMT Trimble MX8. Na parte de baixo da mesma figura, são representados os pontos resultantes da aplicação do método proposto, utilizando grelhas

regulares com as diferentes formas de células, quadrados (verde), hexágonos (vermelho) e triângulos (azul). Os resultados apresentados são obtidos com apenas duas iterações, com os valores L_{Min} de 0.12 m e L_{Max} de 0.24 m.




Figura 3.40 - Resultados obtidos com diferentes células regulares.

À primeira vista, os resultados apresentados na Figura 3.40, são muito semelhantes, sendo os pontos que representam elementos fora do solo globalmente eliminados, ou seja, casas, árvores, postes, sinais de trânsito, etc. Verifica-se que em todos os casos a distribuição espacial dos pontos não é regular, existindo menos pontos em áreas planas quase horizontais, e mais pontos em áreas com maior variação de elevação do terreno. A quantidade de pontos resultantes, com o tamanho da célula inicial 1 metro, para cada tipo de célula foi respectivamente: 16018 para as células quadradas, 17600 para as hexagonais e 25310 para as triangulares.

Apesar da mesma dimensão de célula, a diferença entre as quantidades de pontos resultantes é significativa, especialmente entre as células quadradas e triangulares. A justificativa para isso, resulta dos diferentes valores das áreas ocupadas para cada uma das formas das células. Apesar do mesmo valor de altura, a área espacial ocupada pelos triângulos é menor, sendo necessário um maior número de células para cobrir toda a área e, conseqüentemente, resulta um MDT com mais pontos.

De modo a comparar as diferentes formas celulares com a mesma área (1 m^2), foi executado um novo processamento, usando 1 m para os valores iniciais do tamanho das células quadradas,

1.75 m para células hexagonais e 1.316 m para células triangulares. Após esse segundo processamento, a quantidade de pontos resultante para cada tipo de célula, foram: 16018 para as quadradas, 16223 para as hexagonais e 16600 para os triângulos.

Na Figura 3.41 é apresentada uma amplificação do resultado obtido para cada tipo de células com áreas iguais para a área amarela desenhada na nuvem de pontos da Figura 3.40




Figura 3.41 - Extrato dos resultados obtidos com células com 1 m².

Na Figura 3.42 é apresentada uma nuvem de pontos, obtida ao longo de uma estrada rural, não pavimentada e ladeada por vegetação densa. Os resultados apresentados foram obtidos após 4 iterações, com os seguintes valores: área de célula inicial = 4 m², $L_{\text{Min}} = 0.20$ m, $L_{\text{Max}} = 0.30$ m. A nuvem tem cerca de 3 milhões de pontos, e para as diferentes forma de células o número de pontos obtidos foram: 7587 para as células quadradas, 8754 para as hexagonais e 8379 para as triangulares.

O maior número de pontos obtidos pelas células hexagonais resulta de uma maior discretização do espaço dos hexágonos em relação às outras formas de células. Conseqüentemente, são detetadas mais variações de terreno entre as iterações e mais pontos são incluídos no resultado, à medida que o número de iterações aumenta.




Figura 3.42 - Resultados obtidos em zonas de vegetação.

Pela observação da Figura 3.42, verifica-se que, globalmente, a vegetação alta foi eliminada e a maior densidade de pontos é observada fora da estrada onde existe vegetação baixa e maiores variações do terreno. Os pontos obtidos a partir dos hexágonos revelaram-se mais bem distribuídos ao longo da estrada que os pontos resultantes das outras formas de células. A possível razão para isso, é a simetria associada à vizinhança dos hexágonos, que demonstra uma menor sensibilidade à inclinação do terreno.

Na Figura 3.43, é apresentada uma nuvem de pontos recolhida por um SLMT, *Lynx* – Optech, ao longo de uma área urbana. Um passeio com o respetivo lancil e um camião foram captados pela nuvem. Na mesma figura, são apresentadas as triangulações dos pontos resultantes da aplicação das grelhas regulares quadradas, hexagonais e triangulares, respetivamente.




Figura 3.43 - Resultados obtidos em zonas urbanas. Resultado obtido com células quadradas a verde, hexagonais a vermelho e triangulares a azul.

Também em ambiente urbano, para as diferentes formas das células, os pontos que representam os elementos fora do terreno foram genericamente eliminados, incluindo os pontos que representam o camião. No entanto, ao longo do lancil, há uma maior densidade de pontos, o que permite uma melhor representação da linha de quebra na superfície triangulada.

Após sucessivos testes, utilizando sistematicamente diferentes valores para a dimensão das células e para o número de iterações, não foram encontradas diferenças significativas entre os resultados obtidos. No entanto, verificam-se diferenças significativas no método de triangulação usado para representar os pontos resultantes.

Apesar de apenas as coordenadas planimétricas (2D) dos pontos serem usadas para definir a triangulação de Delaunay, os triângulos resultantes são tridimensionais, ou seja, os seus vértices não têm necessariamente $Z=0$, assim, a triangulação de Delaunay é normalmente classificada como um método de dimensão 2.5D. Devido às suas propriedades, este método de triangulação é claramente a forma de triangulação mais divulgada nas últimas décadas, sendo atualmente utilizada na maioria dos softwares comerciais de modelação do terreno. No entanto, principalmente devido à sua distribuição irregular, o método de triangulação Delaunay revela

algumas limitações na modelação dos pontos obtidos pelo método proposto ao longo das linhas de quebra.

Na Figura 3.44 é apresentada uma amplificação do quadrado amarelo desenhado sobre a nuvem de pontos da Figura 3.43, tendo o método de Delaunay sido utilizado para geração dos triângulos. É possível observar uma representação deficiente do lancil, onde os triângulos cruzam a linha de base e a crista da linha de quebra.




Figura 3.44 - Triangulação de Delaunay.

Na Figura 3.45 é apresentado o mesmo conjunto de pontos da Figura 3.44, em que a triangulação é baseada na reconstrução da superfície de Poisson. A abordagem da reconstrução da superfície de Poisson pode ser conseguida através de 3 passos: 1) Transformação do conjunto de pontos orientados num campo vetorial contínuo; 2) Determinação da função escalar cujos gradientes se adaptam melhor ao campo vetorial; 3) Extração da melhor *iso-surface* (Kazhdan *et al.* 2006).




Figura 3.45 - Triangulação baseada na reconstrução da superfície de Poisson.

Na triangulação baseada na reconstrução da superfície de Poisson, o lancil é claramente mais bem definida do que na triangulação de Delaunay. Existem apenas alguns triângulos que cruzam a base da linha de quebra, revelando-se assim mais adequada para a triangulação dos pontos resultantes do método proposto.

Relativamente aos resultados obtidos pela grelha irregular, é possível observar na Figura 3.46 os pontos resultantes da aplicação do método à nuvem de pontos da Figura 3.42.




Figura 3.46 - Resultado obtido utilizando grelhas triangulares irregulares em zonas de vegetação.

O resultado apresentado na Figura 3.46 foi obtido após quatro iterações, sendo obtidos 2869 pontos, o que representa uma redução considerável do número de pontos quando comparado com as grelhas regulares.

Na Figura 3.47 é apresentada uma nuvem de pontos representando uma estrada ladeada por um talude de escavação. Os pontos azuis representam o resultado obtido utilizando uma grelha regular triangular após 4 iterações, usando células iniciais com área de 2m^2 , $L_{\text{Min}} = 0.2\text{ m}$ e $L_{\text{Max}} = 0.4\text{ m}$. Os pontos magenta representam o resultado obtido após a aplicação do método usando grelhas irregulares triangulares, cujos pontos iniciais foram obtidos usando a primeira iteração da grelha regular triangular. O resultado final da grelha triangular regular tem 6393 pontos e a irregular tem 2899 pontos.

A diferença entre o número de pontos é justificada pelo facto de nas grelhas regulares, o valor L_{Max} provocar uma evolução de representação de terreno na direção vertical através das divisões recursivas das células. Isso resulta num grande número de pontos ao longo de áreas planas inclinadas. Nas grelhas irregulares a restrição é baseada na distâncias ao plano dos triângulos, resultando num menor número de pontos na definição dos planos independentemente da sua inclinação.




Figura 3.47 -Comparação entre os resultados obtidos em zonas planas inclinadas, utilizando células triangulares regulares e irregulares. a) Nuvem de pontos original; b) Resultado obtido utilizando células triangulares regulares. c) Resultado obtido utilizando células triangulares irregulares.

Na Figura 3.48, é apresentada uma nuvem de pontos obtida ao longo de uma área urbana. Na mesma figura, os pontos magenta representam os resultados obtidos usando grelhas irregulares triangulares e os pontos vermelhos usando grelhas hexagonais regulares. A nuvem tem aproximadamente 1 milhão de pontos e os resultados foram obtidos após 5 iterações com uma área de célula inicial de 4 m^2 , $L_{\text{Min}} = 0.08 \text{ m}$ e $L_{\text{Max}} = 0.16 \text{ m}$.




Figura 3.48 - Comparação dos resultados obtidos com grelhas regulares e irregulares em zonas urbanas.

Comparando os resultados da Figura 3.48, é possível observar que a representação do terreno é menos detalhada no resultado obtido utilizando grelhas irregulares. A variação da densidade de pontos mostra que as linhas de quebra e a superfície do terreno são melhor definidas no resultado da grelhas regulares, utilizando os mesmos parâmetros e número de iterações. Esta diferença pode ser explicada com base no funcionamento do método irregular, uma vez que utilizando a distância ao plano dos triângulos, a convergência para a forma do terreno com muitas variações, é mais lenta, sendo necessárias mais iterações para se obter um resultado semelhante ao obtido pelas grelhas regulares. Além disso, as grelhas irregulares revelaram-se significativamente mais ineficientes em relação ao tempo de processamento. Na Tabela 3.4 apresentam-se o número de pontos e o tempo de execução do método sobre a nuvem de pontos da Figura 3.48, ao longo de 5 iterações.

A partir da análise dos valores da Tabela 3.4, evidencia-se a eficiência do método multigrelha proposto, patente na diferença de tempo de execução entre as células regulares e irregulares.

Tabela 3.4 - Comparação estatística dos diferentes métodos.

Nº de iterações	Regular						Irregular	
	Quadrados		Hexágonos		Triângulos		Triângulos	
	Nº de Pontos	Tempo (s)	Nº de Pontos	Tempo (s)	Nº de Pontos	Tempo (s)	Nº de Pontos	Tempo (s)
1	141	2.6	144	2.6	143	2.6	143	2.6
2	346	3.1	367	4	365	3.4	219	178
3	707	3.2	857	4.1	878	3.4	545	382
4	778	3.3	963	4.2	988	3.5	1259	1073
5	1258	3.3	1680	4.2	1651	3.9	2804	3284
Totais	3230	16	4011	19	4025	17	4070	4920

Apesar dos pontos resultantes do método proposto para extração de pontos de terreno, apresentarem uma densidade superior na zona das linhas de quebra, permitindo uma melhor modelação dessas linhas, a modelação dessas zonas demonstra algumas incongruências, existindo triângulos que cruzam as linhas de base e crista, como exemplificado nas Figuras 3.44 e 3.45. Para além disso, a aplicação do método ao longo de grandes áreas obriga a que o resultado contenha uma grande quantidade de pontos para a representação dessas zonas.

Tendo em conta que, através da utilização de linhas de quebra, o número de pontos aleatórios necessários para representar a forma do terreno pode ser significativamente reduzido a integração de linhas de quebra no MDT constitui ainda o paradigma para a sua geração a grandes escalas (Yang *et al.*, 2016). Torna-se, então, necessária a integração de linhas de quebra no MDT, que através da restrição de cruzamento pelos triângulos, permitam a correta modelação dessas zonas de quebra do terreno. Ao longo da secção seguinte é proposto um conjunto de métodos inovadores para a extração de linhas de quebra tridimensionais de nuvens de pontos recolhidas por SLMT.

3.4. Métodos de extração de linhas de quebra de nuvens de pontos recolhidas por SLMT

Ao longo desta secção apresenta-se um conjunto de métodos para a classificação dos dados armazenados nas nuvens de pontos recolhidas por SLMT para a extração de linhas de quebra. Será também apresentada a implementação do método manual que permitirá estabelecer dados de referência para a validação dos restantes métodos. Propõe-se um método semiautomático de extração de linhas de quebra, pensado para implementação em plataformas CAD, que permita ao utilizador o acompanhamento da extração das linhas de quebra. Em seguida é proposto um método inovador totalmente automático que efetua a extração das linhas de quebra, tirando

partido dos dados armazenados em formato LAS. Finalmente, é proposto um outro método para a extração de linhas de quebra de nuvens de pontos recolhidas por SLMT especificamente ao longo de linhas ferroviárias, tirando partido da limitação de movimentos laterais do sensor.

3.4.1. Método manual

De forma a facilitar a digitalização tridimensional, de forma manual, das linhas de quebra sobre as nuvens de pontos recolhidas por SLMT, foi implementado um conjunto de rotinas em ambiente CAD. Para além de outras funcionalidades, o princípio básico de funcionamento dessas rotinas é a visualização do plano do corte transversal da linha de quebra, permitindo ao operador a digitalização dos pontos de crista e de base dessa linha. Através da repetição de cortes espaçados ao longo da linha de quebra, vão sendo gerados pares de pontos de base e crista, cuja união dá origem às linhas de quebra. A Figura 3.49a ilustra a posição dos diversos cortes ao longo da linha de quebra e na Figura 3.49b apresenta-se o plano transversal resultante do corte com a marcação do ponto de crista a azul e de base a vermelho.




Figura 3.49 - Método manual de extração das linhas de quebra; a) Faixas sequenciais ao longo da linha de quebra. b) Vista de perfil e respetivos pontos de crista e base.

Para além de por si só, este método permitir otimizar o processo de digitalização tridimensional das linhas de quebra, foi utilizado para criar os resultados de referência para validação dos métodos automatizados propostos.

3.4.2. Método semiautomático

Com base nos princípios de funcionamento do método manual, foi estruturado e implementado um método inovador, semiautomático, para extração das linhas de quebra. O método proposto baseia-se no estabelecimento automático de secções transversais ao longo da linha de quebra e na identificação em cada uma das secções do par de pontos que representam a base e a crista da

linha de quebra. Através da definição de um conjunto de critérios de aceitação desses pontos, em cada uma das secções transversais, é garantida a consistência das linhas de base e crista resultantes da união desses pontos.

Na Figura 3.50, é apresentado o fluxograma de funcionamento do método proposto. Para desencadear o processo é necessário fornecer uma posição inicial e um rumo. As posições seguintes são calculadas automaticamente através de valores de distância, previamente definidos e os novos rumos corrigidos com base nas posições anteriores. Para além da distância entre posições, é estabelecido um conjunto de valores *a priori* que permitem aplicar restrições geométricas aos pontos de base e crista calculados em cada uma das posições, e assim, permitir ao método decidir se termina ou avança para a posição seguinte. Cada um dos passos da Figura 3.50, assim como todos os parâmetros de restrição utilizados, são descritos em pormenor nas secções seguintes.

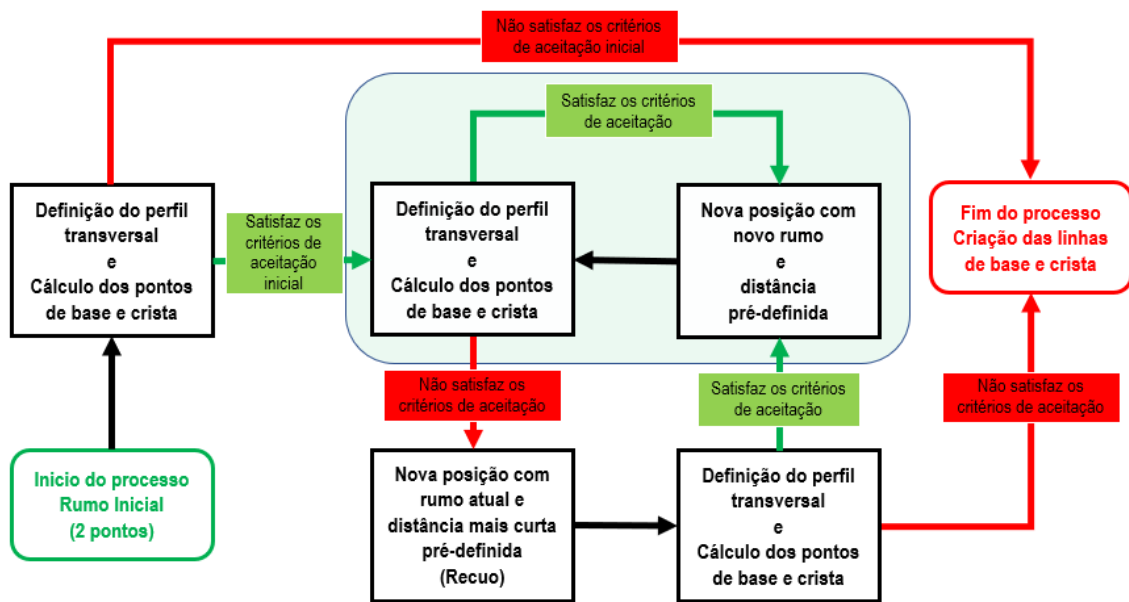


Figura 3.50 - Fluxograma do método semiautomático proposto para extração das linhas de quebra.

3.4.2.1. Estabelecimento das posições ao longo da linha de quebra

A posição e rumo inicial podem ser introduzidos no processo pelo operador, sob a forma de valores explícitos, ou através de dois pontos sequenciais ao longo da direção inicial da linha de quebra em ambiente CAD. Nesse caso, tal como nas posições seguintes, o rumo é calculado utilizando as coordenadas planimétricas de dois pontos através da fórmula de cálculo do rumo bem conhecida da topografia.

Na Figura 3.51, é apresentado o esquema de funcionamento do algoritmo para o estabelecimento das posições ao longo do lancil de uma via rodoviária. A azul estão representados os dados necessários para desencadear o processo (P_0 , R_0) e a vermelho cada uma das novas posições (P_i) utilizando a distância pré-definida (D) e os novos rumos calculados (R_1, \dots, R_n).

Através do cálculo dos rumos em cada nova posição, é corrigida a direção relativa aos pontos anteriores, de forma a acompanhar as variações da direção da linha de quebra. Em cada uma das posições, são calculados os pontos de base e crista da linha de quebra. Na secção seguinte é descrita a determinação da posição que permite o cálculo de cada novo rumo.

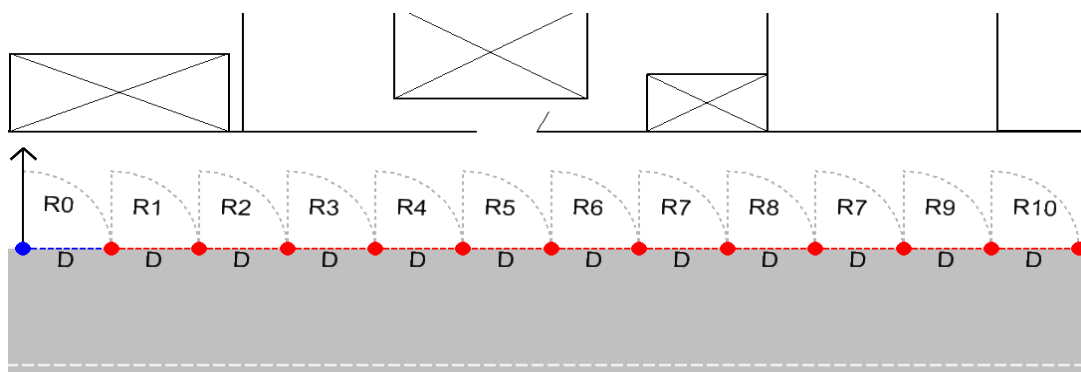


Figura 3.51 - Esquema do estabelecimento das posições ao longo da linha de quebra

3.4.2.2. Definição dos perfis transversais e dos pontos de base e crista da linha de quebra

Em cada posição estabelecida ao longo da linha de quebra, descrita na secção anterior, é definido um perfil transversal ao rumo (R_i). A direção desse perfil é facilmente determinada utilizando (R_i+90°). Na Figura 3.52a é apresentado o esquema dos perfis traçados em cada posição, sendo considerados para cada perfil os pontos da nuvem no interior do retângulo com comprimento L e uma largura I .




Figura 3.52 - Esquema de funcionamento do algoritmo semiautomático; a) Estabelecimento dos perfis transversais; b) Pontos resultantes do perfil transversal e estabelecimento da janela móvel

Todos os pontos da nuvem no interior de cada retângulo horizontal (I, L) são projetados na linha de perfil. Na Figura 3.52b são representados os pontos da nuvem no interior de um desses retângulos onde é possível observar a linha de quebra do lancil. Em seguida é aplicada uma janela móvel, de altura J e largura j, centrada em cada um dos pontos ao longo do perfil, para determinar a máxima diferença de cotas (Dz) dos pontos no interior de cada janela. De entre os resultados que apresentam valores Dz mais elevados é identificada a janela com maior valor de declive entre os pontos com valor de cota mais baixo e mais alto. Esses pontos são classificados, respetivamente, como o ponto de base e crista da linha de quebra (ponto verde e azul da Figura 3.52b).

3.4.2.3. Correção do rumo e definição da distância de recuo

Após o estabelecimento dos pontos de base e crista em cada perfil, é calculado o ponto médio entre ambos (ponto vermelho da Figura 3.52b). As coordenadas desse ponto são utilizadas para o cálculo do novo perfil e o estabelecimento de uma nova posição. Nas Figura 3.53a estão representados um conjunto de posições ao longo de uma linha de quebra. As linhas azuis representam a aplicação do rumo obtido das duas posições anteriores com base na distância D.

Apesar do ponto resultante ficar longe da linha de quebra, esta é, no entanto, intersectada pelo perfil, o que permite o cálculo de novos pontos de base e crista. Com base nesses pontos é calculado novo ponto médio, o que permite determinar uma nova posição e corrigir o rumo anterior, recomeçando assim um novo ciclo.

Este processo de correção do rumo, permite que o método funcione em linhas de quebra em zonas de curva, apenas no caso em que a distância entre a posição resultante e a intersecção do

perfil com a linha de quebra é inferior a $L/2$ ou seja, em que a linha de quebra é cruzada pelo perfil. Em zonas de curvatura mais acentuada, em que a distância entre a linha de quebra e a posição obtida através do rumo calculado, com base nas duas posições anteriores é superior a $L/2$, a linha de quebra não é cruzada pelo perfil e conseqüentemente o processo termina.

Uma forma de colmatar esta situação será aumentar o valor L , no entanto o método é baseado no facto de apenas uma quebra do terreno ser intersectada pelo perfil. Ao aumentar muito o valor de L vai-se aumentar a probabilidade de vegetação rasteira, veículos ou outros objetos, serem intersectados pelo perfil, conduzindo a resultados errados na identificação dos pontos de base e crista da linha de quebra. Assim, para contornar esta limitação, em vez de aumentar L , propõe-se a introdução de uma distância mais curta a que se chamou distância de recuo. A razão desta terminologia está relacionada com o efeito visual que esta distância produz no processo, fazendo com que este “recue” à posição anterior e se efetue o cálculo de uma nova posição com outra distância. Na prática a distância de recuo é bastante mais curta que D , o que permite aumentar a probabilidade de intersecção da linha de quebra pelo perfil, mantendo o valor L . Na Figura 3.53b está representada uma situação de curvatura mais acentuada da linha de quebra, na passagem da posição $P4$ para $P5$. Utilizando a distância D , o perfil resultante não cruza a linha de quebra. No entanto, utilizando uma distância mais curta (representada a verde na Figura 3.53b) permite que o perfil intersecte a linha de quebra e que o processo avance.

Tendo em conta a descrição efetuada, poderá surgir a questão: qual a razão de não se utilizar sempre o valor de distância D mais curta, eliminando este passo do método? A resposta a esta questão, prende-se com o facto de um valor maior para D , permitir que o método avance bastante mais rápido em zonas retas e para além disso, diminui o número de pontos das linhas de quebra que em nada contribuem para a sua forma. No caso da Figura 3.53b, as posições $P5$ e $P6$ são obtidas através da distância de recuo, enquanto que a posição $P7$ foi obtida novamente utilizando a distância D . A conjugação destas duas distâncias permite obter linhas de quebra em que os pontos estão mais espaçados ao longo de zonas mais retas e mais próximos em zona de curva, sem perder a eficiência do método.

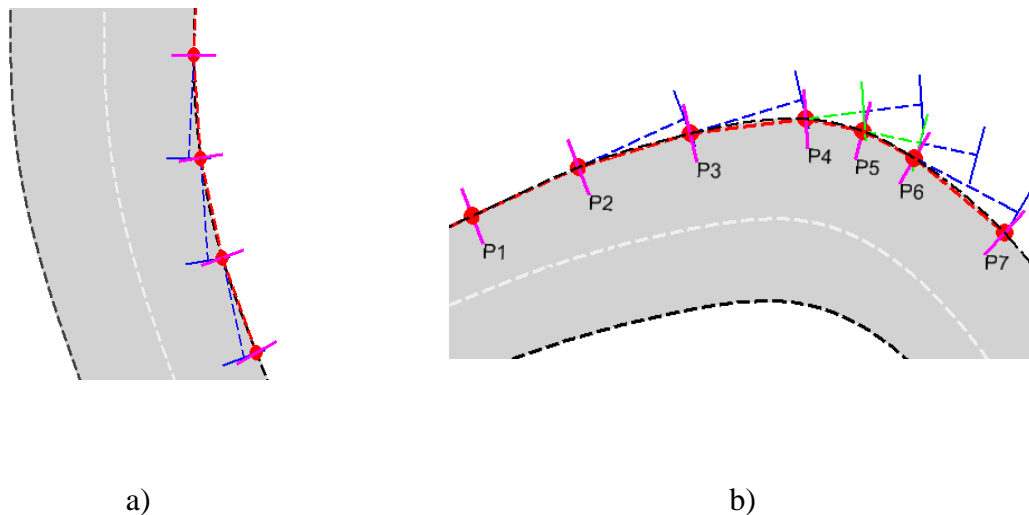


Figura 3.53 - Correção do rumo e distância de recuo; a) Esquema da correção do rumo entre posições; b) Aplicação da distância de recuo.

A utilidade do conceito, distância de recuo, estende-se a todos os critérios de aceitação a aplicar aos pontos de base e crista da linha de quebra em cada posição. Por exemplo, para garantir o detalhe pretendido na variação das cotas das posições ao longo da linha de quebra, é introduzido um valor limite à diferença absoluta de cota entre posições consecutivas. Se utilizando a distância D , esse valor poderá ser ultrapassado, recorrendo à distância de recuo é possível aumentar a probabilidade de ficar abaixo desse valor, evitando assim a paragem do processo.

Após o fim do processo, em consequência de numa determinada posição, os pontos de crista e base da linha de quebra não passarem nos critérios de aceitação definidos (mesmo após o uso da distância de recuo), as linhas de quebra são desenhadas automaticamente através da união sequencial dos pontos de base e crista estabelecidos nas diferentes posições.

3.4.2.4. Implementação e resultados

De forma a avaliar os resultados, o método foi implementado em ambiente CAD, permitindo tirar partido da visualização das nuvens, o utilizador pode dar a indicação do rumo inicial e facilitar o desenho das linhas de quebra resultantes. O método foi implementado em linguagem C# e corre numa caixa de ferramentas integrada em ambiente CAD, que por opção recaiu sobre o software *Microstation* da *Bentley*.

Na Figura 3.54a é representada a vista superior de uma nuvem de pontos colorida por elevação, ou seja, foram associadas diferentes cores a intervalos de valores de elevação. Após a identificação da linha de lancil, o utilizador inicia o processo através de dois pontos ao longo da linha de quebra que se pretende restituir. O primeiro ponto estabelece a primeira posição, o

segundo permite o cálculo do rumo inicial para desencadear todo o processo. Na Figura 3.54b é apresentada a mesma nuvem de uma diferente perspectiva, colorida por valores de intensidade em tons de cinzento, onde se inclui os pontos de base (vermelho) e crista (azul), resultantes da aplicação do método ao longo da linha de quebra.




Figura 3.54 - Pontos resultantes do processo semiautomático. a) Nuvem de pontos colorida por cota b) Par de pontos ao longo da linha de quebra (base a vermelho e crista a azul).

Apesar de a linha de quebra estar sob árvores e cabos elétricos em algumas zonas, como sucede no caso do lancil da Figura 3.54, estas situações não representam um problema para o método proposto. Uma vez que os pontos da nuvem que representam esses elementos são excluídos do processo em cada uma das posições através da introdução de um limite à diferença de cota entre o ponto mais baixo e mais alto no interior de cada janela móvel, representada na Figura 3.52b. O valor definido para esse limite deverá ser superior à altura máxima da linha de quebra e inferior à altura dos elementos existentes sobre essa linha de quebra (vegetação, cabos de eletricidade, etc.). De notar que em situações em que existe vegetação rasteira ao longo do lancil, ou qualquer outro objeto cujos pontos sejam passíveis de ser aceites pelos valores definidos para os critérios de aceitação, isso poderá levar a resultados errados na definição dos pontos de base e, consequentemente, na geometria das linhas resultantes. De forma a facilitar a identificação dessas situações e a sua posterior eliminação, a implementação do método permite centrar no ecrã cada uma das posições e os respetivos pontos resultantes, permitindo ao

utilizador um acompanhamento da progressão do algoritmo. Esse acompanhamento pode ser efetuado visualmente, e/ou através do relatório gerado em tempo real, com os valores obtidos para os parâmetros definidos, em cada posição. Nomeadamente, a diferença de cota entre o ponto de base e crista em cada posição; a diferença de cota entre os pontos de base de posições consecutivas; a inclinação do vetor entre o ponto de base e crista; os valores de distância normal; e, os valores da distância de recuo.

A análise destes valores pelo utilizador em cada uma das posições, nomeadamente, na que não passa nos critérios definidos, facilita a decisão sobre eventuais ajustes dos valores limite para cada um dos parâmetros.

De forma a comparar a eficiência e completude do resultado obtido através da implementação do método proposto, foi efetuada a restituição manual das linhas de crista e base do lancil de forma manual sobre a nuvem. A metodologia utilizada baseou-se no estabelecimento de perfis ao longo da linha de quebra de forma manual, tendo o utilizador a liberdade de decidir a localização dos perfis e respetivos pontos de base e crista ao longo da linha de quebra.

Na Figura 3.55a e 3.55b são apresentadas as linhas de crista e base do lancil, resultantes da união sequencial dos pontos, resultantes do processo manual e semiautomático, respetivamente. É possível observar que no resultado do processo semiautomático, os pontos não são equidistantes, pois existiram algumas posições que foram calculadas com recurso à distância de recuo.




Figura 3.55 - Linhas de quebra extraídas (base a vermelho e crista a azul) (a) Resultado do processo manual b) Resultado do processo semiautomático proposto

Ambos os métodos foram aplicados na nuvem representada na Figuras 3.54a, que tem cerca de 70 metros de comprimento e 1.5 milhões de pontos. Na Tabela 3.5 são apresentados alguns valores estatísticos comparativos dos resultados obtidos pelos dois processos.

Tabela 3.5 - Valores estatísticos comparativos entre o método manual e semiautomático.

Método	Nº de pontos	DMax ¹ (m)	DiMin ² (m)	Tempo (s)
Semiautomático	31	2.5	0.5	60
Manual	19	7	1.6	570

¹ Distância máxima entre pontos consecutivos da linha de quebra

² Distância mínima entre pontos consecutivos da linha de quebra

O menor número de pontos nas linhas resultantes do método manual, relativamente ao semiautomático resulta da perceção do utilizador relativamente à necessidade de pontos para a representação planimétrica das linhas, colocando menos pontos ao longo das zonas retas. Uma consequência desse maior intervalo entre pontos, no caso manual, é as linhas resultantes poderem apresentar uma maior diferença altimétrica relativamente aos pontos da nuvem, já que o operador tem muito maior dificuldade em estimar as variações altimétricas entre perfis. Já no caso do processo semiautomático a variação altimétrica é validada através do limite máximo entre pontos de base da linha de quebra em posições consecutivas. Finalmente, apesar do tempo de execução no caso manual poder depender da experiência do operador, a diferença abismal

dos tempos de execução entre os dois métodos demonstra que esta é incontornavelmente uma grande vantagem do método semiautomático.

3.5. Método automático

Ao longo desta secção descrevem-se os diferentes passos de um método inovador proposto, totalmente automático, para a extração das linhas de crista e base de linhas de quebra. A abordagem proposta tira partido do conhecimento dos princípios de funcionamento dos SLMT, utilizando não apenas a geometria dos pontos, mas também os dados associados a cada ponto de nuvem.

Numa primeira fase, os perfis originais do sensor obtidos durante o processo de recolha dos dados são recuperados, sendo posteriormente, aplicado um filtro aos pontos com base na época de aquisição dos pontos e a sua distância à trajetória, removendo a maioria dos pontos da nuvem que não representam o terreno. Em seguida, através da decomposição dos perfis em cadeias monótonas, são identificados os pares de pontos candidatos. Por fim, um filtro aplicado às matrizes dos pares de pontos candidatos permite a eliminação de falsos positivos e a criação das linhas de quebra. Na Figura 3.56 é apresentado o fluxograma com a sequência dos passos do método proposto, sendo cada um dos passos descrito em detalhe nas secções seguintes.



Figura 3.56 - Fluxograma dos passos do método automático proposto para extração das linhas de quebra.

3.5.1. Decomposição em secções transversais temporais

Baseado na descrição dos princípios de funcionamento dos SLMT, efetuada ao longo do Capítulo 2, é possível decompor uma nuvem de pontos recolhida por SLMT nos perfis originais

obtidos pelo sensor. Na Figura 3.57 é apresentado um esquema do processo de criação dos perfis consecutivos, resultantes do movimento de rotação do sensor e da deslocação do veículo.




Figura 3.57 - Esquema da recolha de dados por um SLMT.

Cada um desses perfis é composto por uma sequência de pontos, que podem ser classificadas em direita e esquerda de acordo com a sua posição relativa à trajetória, efetuada pelo sensor ao longo do processo de recolha dos dados. Para efetuar essa decomposição, é necessário recuperar o ângulo de varrimento do sistema. Tendo em conta a estrutura dos ficheiros LAS, descrita na Secção 2.9.1, o valor do ângulo da varredura armazenado, é baseado na direção de 0 graus do nadir e crescente no sentido anti-horário. Por sua vez, a época GPS é armazenada em segundos semanais. Assim, à semelhança do processo descrito na Secção 3.2.1, a trajetória do sensor pode ser obtida usando os pontos de nuvem onde o ângulo de varrimento é zero e cada um dos pontos do perfil pode ser classificado em esquerda ou direita, de acordo com a formulação apresentada em (3.36).

$$\begin{cases} Li = P(t)_\alpha, P(t+1)_\alpha, P(t+2)_\alpha, P(t+3)_\alpha, \dots, P(t+N)_\alpha, & 0 \leq \alpha < 180^\circ \\ Ri = P(t)_\alpha, P(t+1)_\alpha, P(t+2)_\alpha, P(t+3)_\alpha, \dots, P(t+N)_\alpha, & 180 < \alpha \leq 360^\circ \\ t(f) \leq t \leq t(f+1) \end{cases} \quad (3.36)$$

onde (Li, Ri) são as cadeias de pontos respetivamente do lado esquerdo e direito do sensor e t é a época GPS do ponto. f é o número de rotações do espelho e α é o ângulo de varrimento.

A ordem dos pontos no interior de cada um dos perfis originais do sensor, é sequencialmente baseada da época GPS do momento de recolha e não na distância ao sensor, como sucede com outro tipo de perfis. Como forma de diferenciação deste tipo de perfis, optou-se por doravante designá-los por Secções Transversais Temporais (STT), sendo cada STT dividida em esquerda

e direita. A Figura 3.58b ilustra o resultado da decomposição em STT da nuvem de pontos representada na Figura 3.58a.




Figura 3.58 - Decomposição das nuvens em STT. a) Nuvem de pontos original. b) Resultado da decomposição em STT esquerda (azul) e direita (vermelho).

A distância entre duas STT consecutivas ao longo da trajetória pode ser obtida, dividindo a velocidade do veículo pela frequência de rotação. Por exemplo, para um sensor com frequência de rotação de 200 Hz instalado num carro em movimento a 36 km/h (igual a 1000 cm/s), a distância entre STT consecutivas será de 5 cm.

Tendo em conta que cada STT inclui todos os pontos recolhidos pelo sistema, pode facilmente atingir-se alguns milhares em cada STT, sendo que a maioria desses pontos não contribuem para a forma do terreno. De forma a diminuir esse número de pontos, revelou-se vantajoso aplicar um filtro, mantendo, no entanto, os pontos-chave da forma do terreno, uma vez que são esses que serão usados para obter as linhas de quebra.

Optou-se pela aplicação do algoritmo de Douglas-Peucker (Douglas & Peucker, 1973) devido à sua capacidade de preservar os pontos característicos da forma dos dados. Em vez da sua aplicação mais comum na simplificação de linhas poligonais planas horizontais, o algoritmo foi adaptado para simplificar as linhas. No entanto, na implementação do método, a coordenada Y dos vértices dos pontos das STT é substituída pela coordenada Z e a coordenada X é substituída pela distância euclidiana ao ponto da trajetória. O resultado do efeito da aplicação do algoritmo ao longo das STT é ilustrado na Figura 3.59b. Verifica-se uma redução significativa do número

de pontos, em relação às STT originais da Figura 3.59a, após a aplicação do algoritmo de Douglas-Peucker. Sendo eliminados os pontos em zonas planas ou com pequenas variações de elevação, geralmente resultantes da incerteza associada à precisão do sensor ou a pequenas irregularidades do terreno. De forma a preservar os pontos chave das linhas de quebra, o valor limiar utilizado para a aplicação do algoritmo deve ser menor que a altura relativa das linhas de quebra que se pretendem extrair.




Figura 3.59 - Vista isométrica do resultado de aplicação do método de Douglas- Peucker. a) STT originais. b) Resultado de aplicação do método.

3.5.2. Filtro baseado na época GPS versus distância à trajetória

De forma a eliminar a maioria dos pontos que não representam o terreno e para transformar a aparente confusão da Figura 3.58b na superfície do terreno, é proposto um algoritmo baseado na época GPS de cada ponto *versus* a sua distância à trajetória do sensor.

Tendo em conta que tipicamente a instalação do sensor na plataforma do SLMT não é efetuada de forma vertical, através da projeção da intersecção das STT com o terreno é possível observar um efeito repentino da mudança na direção em zonas de terreno com variações abruptas, como sucede ao longo do lancil apresentado na Figura 3.60.

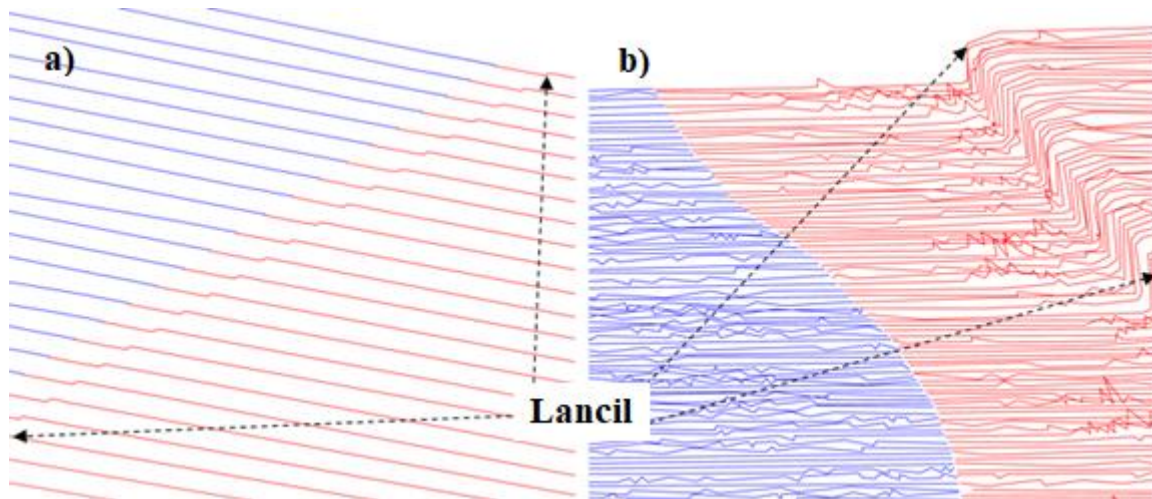


Figura 3.60 - Efeito da intersecção das STT com as linhas de quebra do terreno. a) Vista horizontal do terreno. b) Vista isométrica do terreno.

Quanto maior o declive do terreno, mais acentuado é o efeito da inflexão. Com base nesse pressuposto, usando a distância à trajetória de cada ponto, é possível quantificar a variação relativa vertical de cada ponto da STT. A Figura 3.61 ilustra um esquema do cálculo da distância à trajetória (D) de um ponto da STT.




Figura 3.61 - Distância perpendicular à trajetória.

As coordenadas XY do ponto Q e a distância D podem ser calculadas, uma vez que o triângulo T_1PQ é retângulo,

$$|\overline{PQ}| = \text{Sen}(\alpha) \cdot |\overline{T_1P}| \quad (3.37)$$

Como as coordenadas T_1 , T_2 e P são conhecidas, as coordenadas de Q podem ser determinadas,

$$\begin{cases} X_Q = X_{T_1} + \frac{|\overline{T_1Q}|}{|\overline{T_1T_2}|} \cdot (X_{T_2} - X_{T_1}) \\ Y_Q = Y_{T_1} + \frac{|\overline{T_1Q}|}{|\overline{T_1T_2}|} \cdot (Y_{T_2} - Y_{T_1}) \end{cases} \quad (3.38)$$

Após o cálculo de D , um processo iterativo é aplicado a cada STT, a fim de remover todos os pontos com distância perpendicular menor à trajetória do ponto precedente dentro da ordem da STT. O pseudocódigo desse processo pode ser representado da seguinte forma:

$$\begin{aligned}
 & \text{Para cada STT em Lista } \langle \text{STT} \rangle \\
 & \text{Para cada ponto } P_i \text{ em STT } \langle P \rangle \\
 & \quad \text{Caso } P_i \in R_i \text{ e } (D_p(P_i + 1) < D(P_i) \Rightarrow \text{remove } (P_i + 1) \\
 & \quad \text{Caso } P_i \in L_i \text{ e } (D_p(P_i + 1) > D(P_i) \Rightarrow \text{remove } (P_i + 1)
 \end{aligned} \tag{3.39}$$

onde P_i são os pontos da ST e, L_i e R_i representam os pontos da parte esquerda e direita. Esta separação é necessária uma vez que a época GPS tem diferentes ordens relativamente à trajetória do sensor, diminuindo à esquerda e aumentando à direita.

A ideia subjacente ao funcionamento do filtro resulta do princípio de continuidade do terreno, em que por vezes, a monotonia da relação entre a distância à trajetória e a época GPS é interrompida por objetos exteriores ao terreno, tais como, vegetação, carros, pessoas, etc.

A garantia do sucesso do filtro passa pela capacidade de alguns pulsos do sensor atingirem o terreno, especialmente em áreas de vegetação, devido à elevada densidade de pontos ao longo de cada STT.

De forma a exemplificar o funcionamento do filtro, é apresentado na Figura 3.62, o efeito das diferentes iterações numa STT. Na Figura 3.62a é apresentado a STT original, contendo todos os pontos resultantes da aplicação do algoritmo de Douglas-Peucker. Nas figuras 3.62b, 3.62c, 3.62d e 3.62e, são apresentados os resultados das iterações consecutivas resultantes da aplicação do pseudocódigo apresentado em (3.39). Em cada iteração, os pontos com uma distância de trajetória menor do que a anterior (na sequência temporal da STT) são removidos (pontos verdes). Quando todos os pontos da STT têm uma distância de trajetória superior ao ponto anterior, o processo termina. O aspeto final da STT é apresentado na Figura 3.62f. A maioria dos pontos exteriores ao terreno foram eliminados, mantendo-se, no entanto, os pontos chave da sua forma base, utilizados na extração das linhas de quebra.

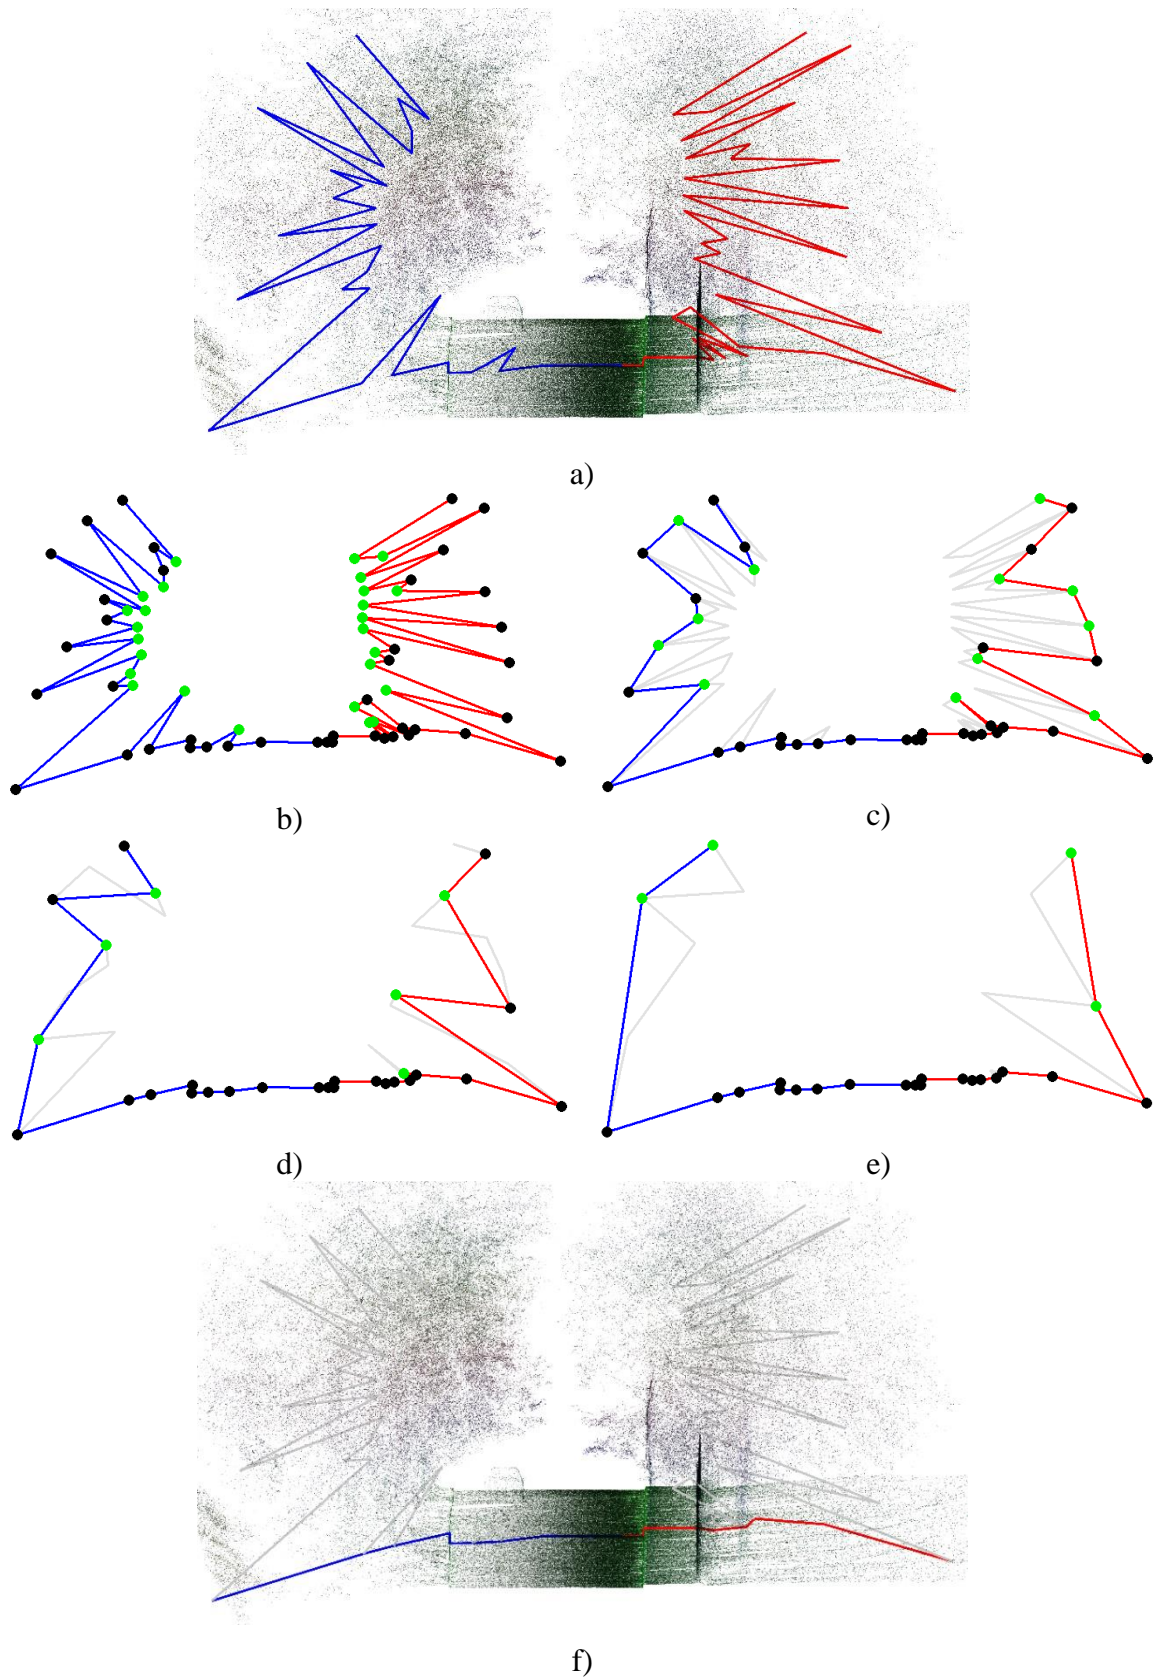


Figura 3.62 - Detalhe das iterações do filtro baseado na época GPS *versus* distância à trajetória. a) STT original. b) Primeira iteração. c) Segunda iteração. d) Terceira iteração. e) Quarta iteração. f) STT final.

Na Figura 3.63a são apresentadas as STT originais obtidas da decomposição da nuvem e na Figura 3.63b as mesmas STT, após a aplicação do filtro. É possível observar que a maioria dos pontos que representam objetos exteriores ao terreno, essencialmente vegetação, foram eliminados.




Figura 3.63 - Filtro época GPS versus distância à trajetória; a) STT originais; b) Resultado da aplicação do filtro.

Existem pontos que representam objetos compactos, como casas ou muros que não representam o terreno, que pelo facto de não invertermem a relação da época GPS versus distância à trajetória, permanecem nas STT, após a aplicação do filtro. No entanto, isso não é uma limitação para a aplicação do método proposto, uma vez que esses elementos serão detetados e descartados nos próximos passos.

Na Figura 3.64 está representado um esquema da variação vertical possível, de uma linha de quebra de um lancil. A situação em que a direção vertical do lancil é inferior a 90° (linha vermelha), é designada por infraescavação.




Figura 3.64 Vista de perfil do esquema de variação vertical da calçada da estrada. A linha vermelha representa a situação da calçada de infraescavação.

A aplicação do filtro descrito anteriormente, produz uma aparente degradação na representação do terreno, em linhas de quebra com infraescavação, i.e., situações em que a crista da linha de

quebra está mais próxima da trajetória que a base. Como consequência, todos os pontos com inclinação vertical inferior a 90° serão eliminados. Esta situação está ilustrada na Figura 3.65.

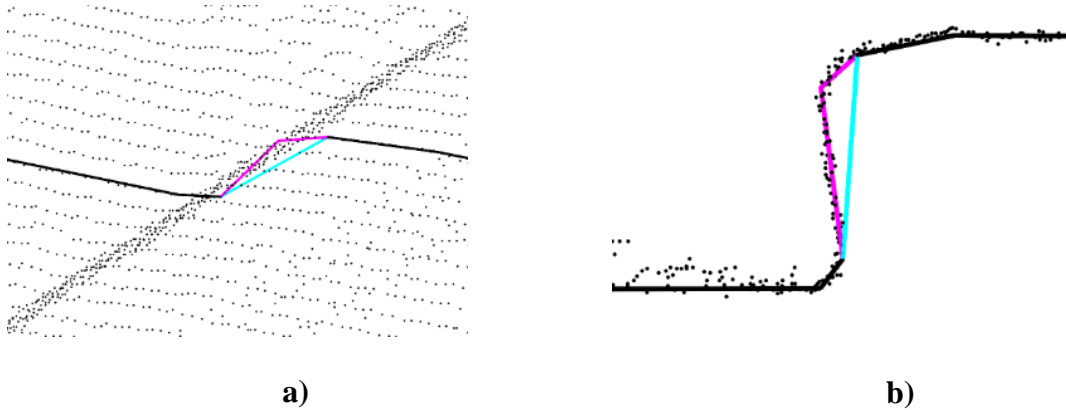


Figura 3.65 - Exemplo do efeito em zonas de infraescavação, STT original (magenta) resultado após aplicação do filtro (azul)
a) Vista de topo da linha de quebra do lancil; b) Vista de perfil da linha de quebra do lancil.

Na Figura 3.65a pode ser observada uma mudança do sentido da STT resultante da aplicação do filtro. Na Figura 3.65b verifica-se que a STT resultante (linha azul) provoca indubitavelmente uma modificação do terreno. No entanto, esta aparente falha do método pode efetivamente ser uma vantagem, considerando que o processo mais comum de criação da triangulação para modelação do terreno é baseado no método de Delaunay. A triangulação de Delaunay é geralmente conhecida como um método de dimensão 2.5 D, em contraponto com as técnicas de triangulação 3D, não sendo, no entanto, adequada para a representação do terreno na situação específica de infraescavação. Como foi exemplificado, a aplicação do método elimina todos os pontos em situações de infraescavação, permitindo que o método de triangulação de Delaunay modele corretamente as linhas de quebra. Para além disso, a alteração da forma de terreno não é significativa na maioria das linhas de quebra e tipicamente é também produzida nos levantamentos topográficos clássicos.

3.5.3. Decomposição em cadeias monótonas

Ao longo deste trabalho o termo cadeia, designa uma sequência de segmentos de reta conectados entre si. Uma cadeia C é monótona em relação a uma linha L se C tem no máximo um ponto de intersecção com qualquer linha L_i perpendicular a L (Park, 2012).

Na Figura 3.66a é apresentado um exemplo de duas cadeias, onde C_1 é monótona em relação à direção de varredura L . A linha de varredura L_2 intercepta C_2 em três pontos, tornando C_2 não

monótona em relação à direção de varredura L . No entanto, como é mostrado na Figura 3.66b, dividindo-se C_2 em C_{21} , C_{22} e C_{23} , todas as subcadeias resultantes são consideradas monótonas em relação a L .

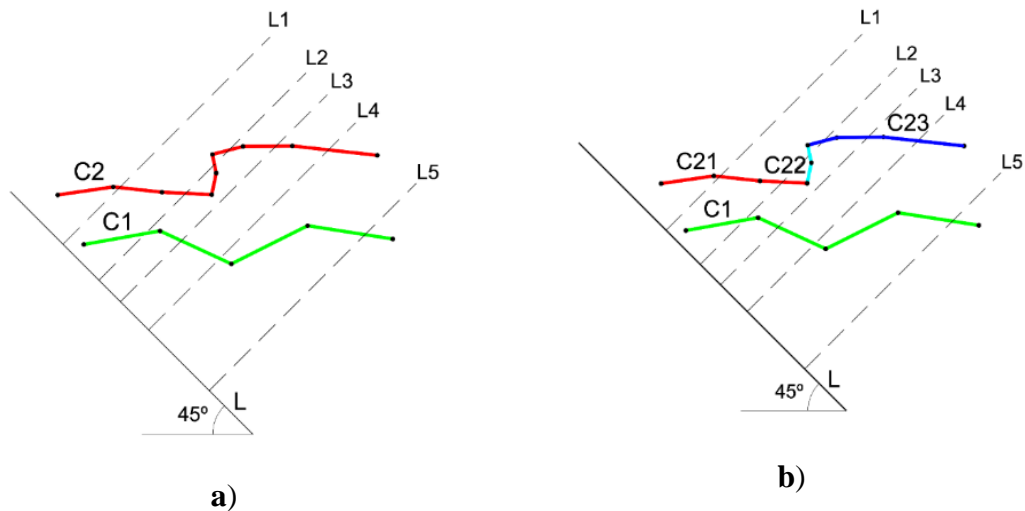


Figura 3.66 - Decomposição em cadeias monótonas: a) Exemplo de uma cadeia C_1 monótona e uma C_2 não monótona; b) Decomposição em cadeias monótonas de C_2 .

A decomposição em cadeias monótonas é uma questão muito bem estudada, devido ao papel que desempenha em vários algoritmos geométricos de otimização. O mais conhecido é talvez o algoritmo de Andrew, usado para resolver o problema da determinação do *convex hull* de um conjunto de pontos (Andrew, 1979). Desde então, muitos autores reivindicam a otimização do processo e/ou o uso do conceito na solução de outros problemas geométricos (Tereshchenko & Tereshchenko, 2017).

No presente trabalho, a teoria de decomposição em cadeias monótonas é especificamente utilizada para dividir cada uma das STT, com base nos pontos chave de inflexão do terreno. Para isso, em vez de se usar as coordenadas planimétricas (X , Y) dos pontos para definir os segmentos, a coordenada X do ponto é substituída pelo valor da distância euclidiana à origem da STT e a coordenada Y é substituída pela coordenada Z de cada ponto. Na Figura 3.67 apresenta-se um exemplo da decomposição das STT coloridas por cadeias monótonas.




Figura 3.67 - Cadeias monótonas coloridas.

3.5.4. Identificação dos pares de pontos candidatos

Após a decomposição em cadeias monótonas, é aplicado um conjunto de restrições, com base na diferença de altura e inclinação entre os pontos mais baixos e mais altos de cada cadeia. Todas as cadeias que apresentam valores fora dos valores previamente definidos, são eliminadas. Na Figura 3.68 é apresentado o resultado da decomposição monótona da Figura 3.67, após a eliminação das cadeias fora dos intervalos predefinidos, tendo sido utilizados valores, $0,05 \text{ m} < \text{Altura} < 0,40 \text{ m}$ e $\text{inclinação} > 70^\circ$.




Figura 3.68 - Resultado após aplicação das restrições.

Cada cadeia restante é então armazenada sob a forma de pares de pontos, constituídos pelos valores mínimos e máximos de elevação representados na Figura 3.69. Esses pares de pontos representam os pontos candidatos para a criação das linhas de quebra.




Figura 3.69 - Pares de pontos candidatos base (azul) e crista (vermelho).

É expectável que após a aplicação do filtro, muitas outras cadeias e correspondentes pares de pontos sejam identificados como candidatos, para além daqueles que representam efetivamente linhas de quebra. De forma a eliminar esses pares de pontos e dar sequência aos pontos no interior das linhas de quebra, são construídas matrizes de pares de pontos utilizando a sequência das STT ao longo da trajetória.

3.5.5. Matrizes de pares de pontos candidatos

A geração das matrizes inicia-se com a primeira STT, em que para cada par de pontos dessa STT é criada uma nova matriz. O esquema deste processo está representado na Figura 3.70, em que são iniciadas 3 diferentes matrizes para os três pares de pontos existentes.




Figura 3.70 - Esquema de inicialização das matrizes na primeira STT.

Na STT seguinte, cada par de pontos é comparado com o último par de cada uma das matrizes disponíveis, sendo adicionado a essa matriz, sempre que satisfazer os critérios definidos. Caso contrário, a matriz é “encerrada”, deixando de ser considerada nas iterações seguintes, sendo

iniciada uma nova matriz, com esse par de pontos. O critério usado para adicionar um par de pontos a uma matriz é a distância média perpendicular à trajetória, de forma a garantir a continuidade da linha de quebra. Além disso, são utilizadas semelhanças geométricas, como diferença de elevação e inclinação entre os dois pontos do par. No final do processo, cada matriz contém os pares de pontos sequenciais com continuidade espacial e geométrica. Na Figura 3.71 é apresentado o resultado obtido após o fim do processo no extrato da Figura 3.70. Cada matriz está representada com uma cor diferente, podendo-se verificar que existem diversas matrizes que têm apenas um par de pontos, (por exemplo o par de pontos representado a amarelo na Figura 3.71). Esta situação resulta do facto de nenhum ponto da STT seguinte satisfazer os critérios definidos, sendo iniciada uma nova matriz (exemplo da matriz representada pelos pontos vermelhos na Figura 3.71).




Figura 3.71 - Resultado do processo de construção das matrizes de pares de pontos.

3.5.6. Reconstrução das linhas de quebra

Antes da etapa final, é executada uma avaliação entre matrizes sequenciais, na qual, são comparados o último e primeiro par de pontos das matrizes consecutivas com distância média à trajetória semelhante. Finalmente, as linhas de crista e base das linhas de quebra são reconstruídas através da união sequencial dos pares de pontos de cada matriz. Essa etapa final permite unir matrizes sequenciais que representam a mesma linha de quebra, mas apresentam uma interrupção, correspondente a algumas STT. Na Figura 3.71 facilmente se verifica que as matrizes representadas pelas cores verde, vermelho e azul, representam a mesmas linhas de quebra, no entanto, são interrompidas por uma STT. Essa interrupção pode ser causada por um carro estacionado, vegetação rasteira ou outro objeto que provoque a oclusão da linha de quebra. Um exemplo desta situação é ilustrado na Figura 3.74, em que um motociclista cria uma sombra

na nuvem de pontos sobre a área do lancil. Na Figura 3.72, é representado o resultado após o processo de avaliação entre matrizes consecutivas (pontos verdes e roxos), que permite dar continuidade às linhas de quebra.




Figura 3.72 - Resultado do processo de agregação de matrizes consecutivas.

Em seguida, são descartadas todas as matrizes que têm apenas um número reduzido de par de pontos, considerando apenas as que têm um número significativo de pares de pontos, com maior continuidade espacial e que potencialmente representam linhas de quebra. Na Figura 3.73, é apresentado o resultado das matrizes da Figura 3.72, após a eliminação das matrizes com apenas um par de pontos.




Figura 3.73 - Pares de pontos resultantes do processo.

Finalmente, os pontos das matrizes restantes são unidos sequencialmente de acordo com a ordem das STT, obtendo-se as linhas de base e topo das linhas de quebra, tal como ilustrado no exemplo da Figura 3.74.




Figura 3.74 - Exemplo do resultado da extração das linhas de quebra.

3.5.7. Resultados

De forma a avaliar a precisão, exatidão e o desempenho do método proposto, foi utilizada uma nuvem de pontos recolhida por SLMT, ilustrada na Figura 3.75. A nuvem representa cerca de 250 metros de uma estrada ladeada por lancis. As árvores, postes, e áreas de vegetação rasteira ao longo da linha de lancil, tornam a nuvem desafiante para testar o método proposto.




Figura 3.75 - Nuvem de pontos da área de teste.

O SLMT usado para recolha das linhas de quebra foi um Trimble MX8 com a configuração do sensor RIEGL VQ-250. Na Tabela 3.6, são apresentadas as principais características do sensor.

Tabela 3.6 - Características do sensor utilizado (VQ,250)

Características	Valores
Exatidão ¹	10 mm
Precisão ²	5 mm
Frequência de medição	300000 pontos/segundo
Frequência de rotação	Até 200 perfis/segundo

¹ A exatidão é o grau de conformidade de uma quantidade medida em relação ao seu valor real.

² Precisão é o grau de conformidade entre medições

Na Tabela 3.7 são apresentados os parâmetros utilizados na aplicação do método proposto.

Tabela 3.7 - Parâmetros utilizados na aplicação do método proposto

Parâmetros	Valores
Intervalo entre STT	0.12 s
Tolerância Douglas - Peucker	0.15 cm
Ângulo para decomposição em cadeias monótonas	30°
Intervalo de altura (A) considerado para identificação de pares de pontos candidatos	$0.04 \text{ m} < A < 0.4 \text{ m}$
Valor de inclinação máxima para a identificação de pares de pontos candidatos	50%
Valor máximo de variação de distância à trajetória para a associação às matrizes de pares de pontos	10%
Valor máximo de variação de entre pontos para a associação às matrizes de pares de pontos	5%
Número máximo de STT entre matrizes	4

Tendo em conta que a velocidade do veículo que transportava o SLMT durante o processo de recolha foi sempre inferior a 40 km/h, foi utilizado um valor de 0.12 segundos para o intervalo de tempo entre STT. As alturas dos lancis na área de teste são inferiores a 30 cm, assim, os restantes parâmetros utilizados foram: um valor de 0.15 m de tolerância para o algoritmo Douglas-Peucker e um ângulo de 30 graus para a decomposição em cadeias monótonas. Para identificar os pares de pontos candidatos, os limites do intervalo para altura utilizados foram respetivamente 0.04m e 0.4 m, e uma inclinação máxima de 50%. Para a criação das matrizes foi utilizado um valor de variação da distância perpendicular à trajetória inferior a 10% e uma variação em altura de 5%. Uma vez que existem algumas oclusões devido a vegetação e veículos, foi utilizado um valor máximo de 4 STT para ligação entre matrizes. Na Figura 3.76 é apresentada uma vista geral das linhas obtidas.



Figura 3.76 - Linhas de quebra obtidas pelo método proposto.

Para avaliar o resultado do método proposto, foram obtidas as linhas de quebra sobre a mesma área, através de duas metodologias distintas, de forma a servirem de referência para as linhas de quebra dos lancis. Por um lado, foi utilizado o método manual descrito na Secção 3.4.1. Para

além disso, de forma a verificar a posição absoluta dos dados, foi efetuado um levantamento topográfico por métodos clássicos em campo.

O trabalho de campo foi realizado utilizando recetores GNSS-RTK de dupla frequência e nas áreas com sinal GNSS bloqueado devido a casas e árvores foi utilizada uma estação total topográfica. Em ambos os casos o bastão (com a antena GNSS ou prisma) foi colocado espaçadamente ao longo do lancil, sendo medidos os pontos de crista e base.

De forma a criar um MDT contínuo, alguns pontos do terreno foram extraídos da nuvem utilizando o método proposto no Capítulo 4, e triangulados em conjunto com as linhas de quebra obtidas utilizando o método de Delaunay. Na Figura 3.77 são apresentados os resultados dos três métodos, nomeadamente, o método manual, o levantamento topográfico clássico e o método automático proposto.




Figura 3.77 - Análise da triangulação dos resultados obtidos pelas diferentes metodologias; a) Método proposto; b) Método manual; c) Levantamento de campo.

Na Tabela 3.8 apresentam-se as estatísticas referentes aos resultados obtidos pelos diferentes métodos. Através da observação da Figura 3.77 e dos valores da Tabela 3.8 é possível verificar que a distância entre pares de pontos aumenta gradualmente do método proposto para os métodos manual e levantamento em campo. Isso sucede porque nos últimos dois métodos, a distância entre pontos é estabelecida pela perceção dos operadores em função das variações de

altura e de direção ao longo da linha de quebra (menor no levantamento em campo). Enquanto no método proposto essa distância é fixa com base no intervalo estabelecido entre as STT.

Tabela 3.8 - Valores comparativos dos métodos propostos.

Métodos	Nº de pares de pontos	Distância média (m)	Tempo de execução
Proposto	227	0.8	20 segundos
Manual	56	4.2	25 minutos
Campo	23	8.5	3.5 horas

Para avaliar a distribuição espacial dos resultados, foram criadas duas superfícies com base nas diferenças de elevação entre o método proposto, o manual e o de campo. As superfícies resultantes, coloridas por diferenças de elevação dos centros dos triângulos, são apresentadas na Figura 3.78.




Figura 3.78 - Distribuição espacial das diferenças obtidas; a) Método proposto versus levantamento manual; b) Método proposto versus levantamento campo.

A comparação com o método manual permite validar a consistência do método proposto com a geometria da nuvem de pontos (Figura 3.78a). Através da comparação com o levantamento de campo é possível validar de forma independente o processo global, incluindo o processamento da nuvem de pontos (Figura 3.78b). Apenas os triângulos que compartilham pelo menos um vértice com um ponto de uma linha de quebra foram considerados. Os valores estatísticos apresentados dos resultados obtidos, são apresentados na Tabela 3.9.

Tabela 3.9 - Valores estatísticos das diferenças obtidas entre métodos.

Método proposto <i>versus</i>	Valor max. Dif.	Valor min. Dif.	Média
Manual	7.9 cm	0.1 cm	2.9 cm
Campo	11.2 cm	1.8 cm	4.2 cm

Constata-se uma maior inconsistência entre as superfícies obtidas pelo método proposto e o levantamento de campo. Isto resulta do facto, dessa superfície acumular os erros associados aos instrumentos de topografia, georreferenciação e processamento das nuvens de pontos.

De forma a estabelecer critérios de comparação, foram calculados os índices de completude (3.40), exatidão (3.41) e qualidade (3.42) comumente utilizados neste tipo de comparações (Hu, 2013; Kumar, 2013).

$$Completude = \frac{\text{comprimento da extração total correcta}}{\text{comprimento de referência}} \quad (3.40)$$

$$Exatidão = \frac{\text{comprimento da extração total correta}}{\text{comprimento da extração}} \quad (3.41)$$

$$Qualidade = \frac{\text{comprimento da extração total correcta}}{\text{comprimento da extração} + \text{comprimento dos elementos não extraídos}} \quad (3.42)$$

O “comprimento da extração total correta” representa o comprimento de linhas extraídas, consideradas corretas relativamente aos dados de referência e ao comprimento total das linhas de quebra nos dados de referência - “comprimento de referência”,.

O “comprimento da extração” inclui o “comprimento da extração total correta” e o comprimento das linhas erradamente extraídas relativamente aos dados de referência. O “comprimento dos elementos não extraídos”, corresponde ao comprimento das linhas de quebra existentes nos dados de referência que não foram corretamente extraídos pelo método proposto. A Tabela 3.10 apresenta os valores obtidos, cujas distância correspondem à soma dos segmentos entre os pares de pontos das linhas de quebra superior e inferior. Um segmento foi considerado corretamente extraído quando a distância máxima para a linha de referência é inferior a 5 cm.

Tabela 3.10 – Valores de completude, exatidão e qualidade.

Parâmetro	Manual	Campo
Comprimento de referência	493.75 m	493.75 m
Comprimento da extração total correta	473.00 m	418.00 m
Comprimento da extração	486.25 m	486.25 m
Comprimento dos elementos não extraídos	20.75 m	75.75 m
Completude	95.80%	84.66%
Exatidão	97.28%	85.96%
Qualidade	93.29%	74.38%

Como esperado, os valores de completude, exatidão e qualidade são menores quando o levantamento de campo é utilizado como referência, devido à acumulação dos erros associados ao processamento das nuvens.

3.6. Caso particular das linhas ferroviárias

A monitorização da infraestrutura ferroviária e manutenção do seu ambiente circundante são essenciais para garantir a segurança da circulação das composições ferroviárias e consequentemente de mercadorias e passageiros. A execução de intervenções preventivas é crucial, nomeadamente, no que respeita a correções de variação da bitola, deformações do balastro e degradação dos taludes circundantes. Para a identificação da necessidade dessas intervenções, é necessária uma monitorização contínua da geometria ferroviária e do ambiente circundante, que permita a deteção precoce de patologias resultantes do inevitável desgaste da ferrovia ao longo do tempo.

Baseado na simetria do perfil padrão associado à construção das linhas ferroviárias, existe um conjunto de elementos lineares tridimensionais que ladeia quase paralelamente os carris, nomeadamente, as linhas de quebra da crista e base do balastro, linhas elétricas, etc. A representação tridimensional desses elementos lineares é fundamental para a modelação tridimensional do ambiente envolvente à linha ferroviária.


A utilização de métodos topográficos clássicos para recolher esse tipo de dados, nomeadamente, a utilização de estações totais e recetores GNSS, é uma tarefa muito exigente e morosa. Além de morosos, esses métodos, exigem medidas de segurança para as operações, o que implica redução na velocidade de circulação dos comboios em curso ou mesmo interrupção temporária da operação ferroviária.

Ao longo desta secção propõe-se um método eficiente para a extração de elementos lineares tridimensionais ao longo de ambientes ferroviários, utilizando nuvens de pontos especificamente recolhidas por SLMT, para além das linhas de quebra passíveis de ser utilizadas na construção do MDT. Pretende-se ainda demonstrar que o método é aplicável para a extração de outras linhas tridimensionais integrantes da própria infraestrutura rodoviária, nomeadamente, o eixo de via, os carris, as linhas elétricas etc., cuja constante monitorização e manutenção são fundamentais para a garantia da segurança de mercadorias e passageiros.


O método proposto parte do pressuposto que os elementos lineares a extrair são aproximadamente paralelos aos carris da linha ferroviária e, consequentemente, à trajetória do sensor. Este método é estritamente aplicável à situação em que a plataforma do SLMT é instalada sobre uma composição ferroviária e não tem liberdade de trajetória, ao contrário do que acontece no caso dos SLMT instalados em veículos rodoviários a circular em estrada.

Com base na descrição dos princípios de funcionamento dos SLMT e da estrutura do formato LAS é possível efetuar uma classificação dos pontos da nuvem com base no ângulo de varrimento registado. Tendo em conta que os ficheiros LAS utilizados estão armazenados na versão 1.2, a estrutura da variável do ângulo de varrimento é um inteiro com 1 byte, permitindo apenas 255 valores distintos, foi necessário efetuar a conversão para os 360 valores possíveis.

Na Figura 3.79a apresenta-se um extrato de uma nuvem obtida por um SLMT instalado numa composição ferroviária, colorida por intensidade e na Figura 3.79b apresenta-se uma versão da mesma nuvem colorida por ângulo de varrimento.



a)



b)

Figura 3.79 - Nuvem de pontos recolhida por um SLMT instalado num comboio. a) Representação em valores de cinzento; b) Nuvem de pontos colorida por ângulo de varrimento.

Na Figura 3.79b, é possível observar o efeito simétrico dos valores do ângulo de varrimento em relação à trajetória do sensor. Apesar da limitação de conversão de valores de 255, verifica-se uma segmentação significativa da nuvem. Na Figura 3.80 encontra-se representado uma seção transversal típica da nuvem de pontos, colorida por ângulo de varrimento.




Figura 3.80 - Perfil da nuvem de pontos colorida por ângulo de varrimento.

3.6.1. Descrição do método proposto

O objetivo do método proposto, é utilizar a classificação da nuvem com base no valor do ângulo de varrimento, descrita anteriormente, para restringir o número de pontos que representam o elemento linear a ser extraído. Assume-se que os elementos lineares são aproximadamente paralelos à trajetória do SLMT e, conseqüentemente, todos os pontos de nuvem que os representam terão aproximadamente o mesmo ângulo de varrimento. Em seguida, usando esses pontos da nuvem classificados, é aplicado um algoritmo para criar os vértices dos elementos lineares tridimensionais, possibilitando a sua extração

Por exemplo, considerando o ângulo de varrimento de 0 graus, é possível obter uma faixa de pontos da nuvem sob a posição do sensor, correspondente à trajetória do sensor, uma vez que a origem do ângulo de varrimento é a direção do nadir do sensor. Na Figura 3.81, todos os pontos com ângulo de varrimento zero estão representados a vermelho e os pontos restantes da nuvem a tons de cinzento.




Figura 3.81 - Pontos da nuvem com ângulo de varrimento zero.

Após a classificação dos pontos com base no seu ângulo de varrimento, de forma a restringir o número de pontos da nuvem que representam o elemento linear, é necessário converter os pontos de nuvem classificada para um elemento tridimensional linear vetorial. Para isso, é definido um valor D para a distância entre os vértices das linhas a extrair e um raio R aos pontos da nuvem que são utilizados para o cálculo de cada vértice. O funcionamento do algoritmo é baseado no facto dos pontos classificados terem a forma de uma faixa, garantindo que os vértices da linha estarão, tendencialmente, localizados ao longo do eixo dessa faixa. Uma ilustração esquemática do algoritmo é apresentada na Figura 3.82.




Figura 3.82 - Esquema de criação das linhas tridimensionais.

O valor D deve ser ajustado com base no detalhe pretendido para a linha a extrair. No exemplo da Figura 3.82, a coordenada Z dos vértices da linha de trajetória é obtida, através da média da coordenada Z dos pontos classificados. No entanto, dependendo do tipo de elemento linear, poderá ser usado o valor máximo ou mínimo da coordenada Z dos pontos da nuvem considerados.

É importante ter em consideração, que no caso de ser utilizado um valor de R muito baixo, isso diminui o número de pontos da nuvem considerados para o cálculo dos valores Z dos vértices da linha e o algoritmo fica mais sensível a *outliers*. Por outro lado, a utilização de um valor R muito alto, aumenta o número de pontos da nuvem classificados considerados, o que pode levar a desvios padrão mais elevados e à degradação da precisão da coordenada Z . Como referência, o valor R deve ser mantido próximo do dobro do valor da largura da faixa dos pontos classificados.

Para o funcionamento correto do método, os pontos classificados devem estar ordenados de acordo com a direção da trajetória, o que deverá acontecer por defeito, uma vez que é essa a ordem de aquisição e de armazenamento no ficheiro LAS. Caso contrário, pode ser usado para efetuar essa ordenação o atributo tempo (época GPS).

O pseudocódigo do algoritmo pode ser esquematizado da seguinte forma:

Input: *Listagem de pontos (P_i) da nuvem restringidos pelo ângulo de varrimento*

= $P_{i=0}$

Para cada ponto em P_i (3.43)

Se distancia2D ($P_{Anterior}, P_i$) < D

Se distancia2D ($P_{Anterior}, P_i$) < R

PointsList add P_i

senão

Vertice = Média (PointList (X, Y, Z))

ListaVertices acrescenta Vertice

Esvazia ListaPontos

ListaPontos add P_i

Fim

Ir para saída:

Fim

$P_{Anterior} = P_i$

saída:

Seguinte

Linha = ListaVertices

Na Figura 3.83 é apresentada a linha de trajetória tridimensional extraída.




Figura 3.83 - Resultado obtido para a linha tridimensional representado a trajetória do sensor.

De forma a demonstrar a versatilidade do método proposto, apresentam-se de seguida alguns exemplos de linhas tridimensionais passíveis de serem extraídas.

3.6.2. Linha central do topo dos carris

Dada a espessura e a configuração dos carris, os pontos de nuvem que os representam poderão ter mais de um valor de ângulo de varrimento, ou seja, todos os pontos da nuvem que representam os carris poderão não ter o mesmo valor de ângulo de varrimento. Na seção transversal apresentada na Figura 3.84, verifica-se a necessidade de três valores de ângulo de varrimento para garantir que todos os pontos da nuvem que representam o carril são extraídos. É importante notar, que neste caso, por comodidade, os ângulos de varrimento estão armazenados na nuvem entre 0 e 180 graus, para a esquerda e direita do sensor, e não de 0 a 360 graus como referido em capítulos anteriores. Para além disso, os valores de ângulo de varrimento para o carril esquerdo e direito não são simétricos, uma vez que a trajetória do sensor não coincide com o eixo ferroviário.




Figura 3.84 - Classificação dos ângulos de varrimento dos pontos que representam os carris.

Após a identificação dos ângulos de varrimento dos pontos da nuvem que representam cada um dos carris, estes podem ser facilmente isolados, como mostrado na Figura 3.85.




Figura 3.85 - Classificação dos pontos que representam os carris; a) Classificação dos pontos da nuvem que representam os carris; b) Detalhe dos pontos que representam os carris.

O algoritmo para a criação da linha central dos carris, é muito semelhante ao descrito anteriormente para a extração da linha de trajetória. No entanto, em vez de ser considerada a média das coordenadas tridimensionais dos pontos da nuvem, para determinar as coordenadas dos vértices, é utilizada apenas a média das coordenadas planimétricas. A coordenada altimétrica é calculada utilizando o valor Z máximo dos pontos da nuvem dentro da distância R definida. A justificação para a utilização do Z máximo, resulta do facto de se pretender que os vértices de linha resultante tenham a cota do topo dos carris. O que não acontece se for utilizada a coordenada Z média dos pontos seleccionados, uma vez que os pontos classificados, representam a parte superior e inferior do carril. Na Figura 3.86 é apresentado um exemplo das linhas de centro do topo dos carris extraídas.




Figura 3.86 - Exemplo de linhas de topo do carril extraídas. Pontos da nuvem que representam o carril (vermelho) e linhas de topo dos carris (azul) resultantes da união dos pontos obtidos (verde).

3.6.3. Linhas de quebra da crista e base do balastro

Um exemplo típico das linhas de quebra em ambiente ferroviário, são as linhas de crista e base do balastro (Figura 3.87). A manutenção do balastro é fundamental para distribuir as cargas dinâmicas do comboio e para assegurar a estabilidade dos carris. Os perfis transversais são, por isso, críticos para avaliar o estado do balastro (Ciotlaus & Kollo, 2018; Zarembski *et al.* 2014). A modelação tridimensional do balastro é uma forma expedita de obter esses perfis ao longo da infraestrutura ferroviária.

Na Figura 3.87 é assinalada a área lateral do balastro, compreendida entre as linhas de quebra da respetiva crista e base, tendo sido obtidos os valores dos ângulos de varrimento dessas linhas.




Figura 3.87 - Ângulos de varrimento dos pontos da crista e base das linhas de quebra do balastro.

Na Figura 3.88, apresenta-se o resultado da classificação da nuvem de pontos após a identificação dos ângulos de varrimento das linhas de crista e base do balastro.



Figura 3.88 - Classificação dos pontos da crista e base das linhas de quebra do balastro.

Nas Figuras 3.87 e 3.88, observa-se uma dispersão elevada dos pontos classificados nas zonas das linhas de quebra do balastro. Essa dispersão ocorre essencialmente devido à existência de vegetação rasteira. No entanto, basta um dos pontos da nuvem considerados para a determinação da coordenada Z dos vértices atingir o terreno, para que o vértice da linha esteja sobre o terreno, uma vez que neste caso foi utilizada a coordenada Z mínima dos pontos para o

cálculo de cada vértice de linha, de forma a eliminar o efeito da vegetação. Na Figura 3.89 é apresentado o resultado obtido para as linhas de quebra da crista e base de balastro.




Figura 3.89 - Resultado obtido para as linhas de crista e base do balastro.

3.6.4. Resultados

A fim de validar a metodologia descrita anteriormente, para a extração de linhas tridimensionais em ambiente ferroviário, foi utilizada uma nuvem de pontos obtida por um SLMT instalado numa composição ferroviária, com o sensor RIEGL VQ-250. O troço de linha ferroviária coberto pelas nuvens tem aproximadamente 550 m de comprimento. Após a aquisição dos dados, a trajetória foi processada utilizando os dados da UMI e das antenas GNSS e, posteriormente, foram integradas as distâncias e ângulos recolhidos pelo sensor LASER. A nuvem de pontos georreferenciados obtida foi exportada para o formato LAS, versão 1.2, sendo apresentada na Figura 3.90, colorida por elevação.




Figura 3.90 - Nuvem da área de teste colorida por elevação.

Várias seções transversais foram criadas ao longo da nuvem e materializadas em ambiente CAD para identificar manualmente os valores dos ângulos de varrimento, dos pontos que representam cada uma das linhas a extrair.

Após a identificação dos valores dos ângulos de varrimento, o algoritmo descrito na Secção 3.6.1, implementado em C#.NET, permitiu a geração das linhas tridimensionais. Na Figura 3.91 apresentam-se as linhas tridimensionais obtidas, sendo um extrato do modelo tridimensional apresentado na Figura 3.92.




Figura 3.91 - Ampliação das linhas obtidas.




Figura 3.92 - Extrato da modelação tridimensional das linhas obtidas.

Na Figura 3.92, as linhas azuis representam as linhas centrais do topo dos carris e as linhas vermelhas e verdes representam, respetivamente, a crista e o topo do balastro extraídas da nuvem de pontos.

Outros elementos relevantes para a manutenção e segurança ferroviária podem ser obtidos, como a linha do eixo da ferrovia, a bitola, definida como a distância mínima entre os dois carris, muros de suporte, linhas elétricas, etc. Inclusive, a forma dos carris pode ser modelada usando os seus valores paramétricos.

Para avaliar a qualidade dos resultados obtidos, as mesmas linhas foram obtidas por um processo manual semelhante ao descrito na Secção 3.4.1. Foi medida a distância entre os vértices das linhas obtidas através do método proposto e as linhas obtidas manualmente. Sendo considerados corretamente extraídos, os vértices que apresentam valores inferiores a 5 cm. Com base nesses valores, foram calculadas as métricas de completude, exatidão e qualidade, descritas em (3.40), (3.41) e (3.42). Os valores obtidos são apresentados na Tabela 3.11.

Tabela 3.11 - Estatísticas das linhas extraídas.

Linhas extraídas	Completude (%)	Exatidão (%)	Qualidade (%)
Linha de base do balastro (esquerda)	82.0	81.6	69.2
Linha de crista do balastro (esquerda)	85.8	85.4	74.8
Linha de base do balastro (direita)	80.6	80.4	67.3
Linha de crista do balastro (direita)	82.9	82.5	70.5
Linha de topo do carril esquerdo	98.7	98.9	97.7
Linha de topo do carril direito	99.3	99.3	98.6

As linhas de quebra do balastro apresentam valores estatísticos mais baixos do que as linhas de centro dos carris. Isso acontece porque essas linhas são muito menos definidas, conseqüentemente, o valor de 5 cm utilizado é bastante exigente para esse tipo de linhas. Ao aumentar o limite para 15 cm, a qualidade é superior a 85% para todas as linhas extraídas.

3.7. Criação de perfis transversais com base em nuvens de pontos recolhidas por SLMT

Os perfis transversais, também designados por secções transversais, obtidos a grandes escalas, representam a base do atual paradigma para a modelação do terreno, em projetos de execução de vias lineares, nomeadamente, rodoviárias e ferroviárias. Dada a sua importância, a sua execução é exigida em todos os projetos de concursos públicos, quer para a construção de novas vias, quer para a manutenção das existentes (Estradas de Portugal, 2014; Infraestruturas de Portugal, 2020). As nuvens de pontos recolhidas por SLMT, poderão ser uma solução bastante mais económica e rápida para a execução desses perfis quando comparada com os levantamentos clássicos. No entanto, mais importante que as estratégias de criação desses perfis, a forma como os pontos das nuvens são agrupados para a criação desses perfis poderá ter maior influência na exatidão desses perfis. Ao longo desta secção apresenta-se um estudo comparativo de 4 estratégias diferentes para o agrupamento dos pontos da nuvem para a geração de perfis transversais. Para esse efeito, é utilizada uma metodologia que é aplicada à medição de uma patologia associada à utilização intensiva das estradas, designada por Cavado de Rodeiras (CDR), que tipicamente é medida através de perfis transversais.

O CDR é uma deformação permanente longitudinal do pavimento das estradas, criada pelo desgaste da passagem repetitiva dos veículos. A acumulação de água ao longo da depressão do CDR reduz a resistência dos pneus e aumenta o perigo de aquaplanagem, contribuindo para a sinistralidade automóvel (Chilukwa & Lungu, 2019). Geralmente, e apesar de não existir um consenso quanto aos limiares de classificação entre países e agências (Fang Fwa *et al.*, 2016), são utilizados três níveis de severidade para a classificação do cavado de rodeiras (baixa, média e alta). Contudo, existe um amplo consenso da correlação direta entre a severidade da profundidade do CDR e o aumento dos acidentes de trânsito. Assim, as medições periódicas de valores de profundidade do CDR são essenciais para a definição de planos de intervenção de manutenção viária, evitando-se, desse modo, a degradação da segurança viária e economizando custos (Chilukwa & Lungu, 2019; Fwa *et al.*, 2016; Hong *et al.* 2018).

O método manual clássico (Figura 3.93a) para medir a profundidade da CDR consiste na colocação de uma régua transversalmente ao CDR, sendo medida depois a distância entre a base da régua e a zona mais profunda do CDR. Além de moroso, este procedimento interfere com o normal funcionamento e utilização da via, requerendo medidas de segurança e condicionando parcialmente ou totalmente a circulação de veículos na via.

Existem atualmente sistemas concebidos especificamente para a medição do CDR, que incluem um veículo com um número discreto de feixes de laser instalados numa barra horizontal e perpendicular à direção da estrada (Figura 3.93b). Comparando as diferentes distâncias ao solo, a medida da CDR por essa técnica pode ser determinada por um mínimo de três feixes de laser. Um na direção de cada roda dianteira e outro no centro do carro. No entanto, como o sistema não tem forma de assegurar que as rodas se encontram sempre no valor mais profundo do CDR, o número de feixes de laser está diretamente relacionado com a precisão pretendida para a medida do CDR. Quanto menor for o número de feixes de laser, menor as chances de o ponto mais profundo da CDR ser detetado e medido.

Sistemas mais recentes, para a medição da CDR, incluem o uso de sistemas de laser 3D contínuos (Figura 3.93c). Tais sistemas permitem a medição de milhares de pontos em cada perfil, aumentando a precisão da medição da CDR. No entanto, estes sistemas são desenvolvidos especificamente para esta tarefa, e conseqüentemente, são bastante dispendiosos (Hong *et al.* 2018).

Na Figura 3.93 apresentam-se as representações esquemáticas da medição manual e das metodologias LASER discreta e contínua.




Figura 3.93 - Esquemático dos métodos de medição do CDR. a) Método manual usando uma régua transversal; b) Sistema laser terrestre. c) Sistema laser contínuo.

Ao longo das descrições das diferentes estratégias para agrupamento dos pontos da nuvem, são mencionados recorrentemente dois tipos de perfil, os perfis dos pontos das nuvens resultantes

da rotação do sensor, e os perfis transversais à estrada, usados para medir a profundidade da CDR. Para evitar confusão entre as duas terminologias o termo perfil será usado sempre referindo o primeiro tipo e o termo secção transversal o segundo tipo.

3.7.1. Estratégias para a criação dos pontos das secções transversais

Na Figura 3.94, é apresentado um extrato de uma nuvem de pontos recolhida ao longo de uma rodovia. Nas secções seguintes, são descritas quatro estratégias propostas, para agrupamento dos pontos das nuvens, de forma a criar as secções transversais, sendo para isso, utilizada a linha vermelha desenhada transversalmente à estrada, na Figura 3.94, utilizada como referência para a posição da secção transversal. Através da ampliação da zona delimitada pela linha amarela, é possível observar os perfis originais do sensor que deram origem à nuvem de pontos (Figuras 3.95, 3.97, 3.99 e 3.101).



Figura 3.94 - Nuvem de pontos e exemplo de linha transversal.

3.7.1.1. Pontos projetados na linha da secção transversal

A primeira estratégia proposta para criar os pontos da secção transversal, é provavelmente a mais intuitiva. Todos os pontos da nuvem a uma distância inferior a um valor predefinido, são projetados sobre a linha do segmento de reta da secção transversal. A Figura 3.95 mostra a área amarela ampliada da Figura 3.94 com a linha de corte transversal a vermelho.




Figura 3.95 - Esquema da primeira estratégia proposta.

Na Figura 3.95, P1 e P2 são os dois pontos que definem a linha de seção transversal, P é um ponto aleatório da nuvem e Q é a projeção de P na linha de seção transversal. A distância euclidiana bidimensional entre P e Q é representada por D, e L é o valor limite máximo para a distância, abaixo da qual os pontos de nuvem são considerados.

As coordenadas (X, Y) do ponto Q podem então ser calculadas por

$$\begin{cases} X_Q = X_1 + \frac{|\vec{P_1Q}|}{|\vec{P_1P_2}|} \cdot (X_2 - X_1) \\ Y_Q = Y_1 + \frac{|\vec{P_1Q}|}{|\vec{P_1P_2}|} \cdot (Y_2 - Y_1) \end{cases} \quad (3.44)$$

Após a determinação das coordenadas de Q, a distância D pode ser calculada, aplicando a fórmula de distância euclidiana às coordenadas de pontos P e Q.

As coordenadas planimétricas dos pontos da seção transversal são calculadas usando as Equações (3.45), sendo mantida a coordenada altimétrica do ponto da nuvem. Ou seja, cada ponto da nuvem a uma distância inferior a L é projetado no plano de seção transversal.

Somente os pontos da nuvem com distância D menor que L e cuja projeção está sobre o segmento de linha de perfil são considerados. As restrições aplicáveis aos pontos da nuvem são apresentadas em (3.45).

$$\begin{cases} D \leq L \\ X_1 \leq X_Q \leq X_2 \\ Y_1 \leq Y_Q \leq Y_2 \end{cases} \quad (3.45)$$

Na Figura 3.96, são apresentados os resultados obtidos para as seções transversais utilizando valores variáveis de L.




Figura 3.96 - Resultados obtidos da primeira estratégia proposta.

3.7.1.2. Agregação dos pontos da nuvem através da média das coordenadas planimétricas

Na segunda estratégia proposta, é predefinido um número específico de pontos para a secção transversal. A coordenada Z de cada um desses pontos resulta da média da coordenada Z dos pontos da nuvem a menos da distância definida R. Um exemplo de uma secção transversal de 9 pontos é apresentado na Figura 3.97.




Figura 3.97 - Esquema da segunda estratégia proposta.

M é a distância entre dois pontos consecutivos de seção transversal. As coordenadas (X, Y) de cada ponto podem ser calculadas através da conjugação das Equações (3.46) e (3.47).

$$A(P1, P2) = \text{Atan} \left(\frac{X_2 - X_1}{Y_2 - Y_1} \right) \quad (3.46)$$

$$\begin{cases} X_i = X_1 + M \cdot \sin(A) \\ Y_i = Y_1 + M \cdot \cos(A) \end{cases} \quad (3.47)$$

Na Figura 3.98, são apresentados vários exemplos de seções transversais obtidas usando diferentes valores para R. Em todas as amostras, foram utilizados 50 pontos para a seção transversal, sendo $M = W/50$, onde W é o comprimento da linha de corte transversal.




Figura 3.98 - Resultados obtidos da segunda estratégia proposta.

3.7.1.3. Perfil original do sensor

A terceira estratégia proposta utiliza um único perfil original do sensor. É utilizado o perfil que cruza a linha da secção transversal. A Figura 3.99 mostra, em azul, o perfil do sensor original usado.




Figura 3.99 - Esquema da terceira estratégia proposta.

Tendo em conta que o sensor foi instalado de forma a que a direção dos perfis do sensor em relação à direção do veículo é aproximadamente 45°, o perfil original não coincide com a secção transversal. No entanto, não é espetável que existam variações longitudinais drásticas nos valores de profundidade do CDR. Consequentemente, o valor da profundidade do CDR obtido na direção do perfil do sensor deverá ser muito semelhante ao obtido ao longo da linha da secção transversal. Esta estratégia permite avaliar o comportamento das nuvens de pontos ao longo de um único perfil do sensor.

Para a identificação dos pontos de um único perfil, foi utilizada a época GPS de cada ponto da nuvem. Após a identificação do ponto da nuvem mais próximo do centro da linha da secção transversal, os pontos pertencentes ao mesmo perfil desse ponto podem ser obtidos aplicando as seguintes restrições definidas em (3.48).

$$\begin{cases} Di \leq \sqrt{(Ei)^2 - \left(\frac{|P1P2|}{2}\right)^2} \\ |Tc - Ti| < f \end{cases} \quad (3.48)$$

Onde, D_i e E_i são respetivamente a distância perpendicular à linha e a distância euclidiana de cada ponto de nuvem para o centro de linha de perfil. T_c representa a época GPS do ponto de nuvem C (mais próximo ao centro de linha de perfil), T_i a época GPS de cada ponto de nuvem e f a frequência de rotação do sensor. Em resumo, a primeira restrição assegura que os pontos de nuvem projetados se encontram na linha de corte transversal, e a segunda, que apenas os pontos pertencentes ao mesmo perfil original são considerados.

Uma vez que o perfil do sensor original não é coincidente com a linha de perfil, foi efetuada uma projeção dos pontos de nuvem, conforme descrito na Secção 3.7.1.1. A Figura 3.100 mostra o perfil do sensor resultante, após a projeção dos pontos nas linhas de secção transversal. Deve-se notar, que esta projeção dos pontos na linha transversal causa uma deformação na forma dos CDR, no entanto, o valor de profundidade será o mesmo.




Figura 3.100 - Resultados obtidos da terceira estratégia proposta.

3.7.1.4. Agregação dos pontos com base no perfil original do sensor

A quarta estratégia, agrega os pontos da nuvem com base no perfil original do sensor a que pertencem. Para cada perfil independente do sensor, é calculada a média das coordenadas dos pontos da nuvem a menos de uma distância L da linha, que cruza a linha da secção transversal. A Figura 3.101 ilustra os pontos da secção transversal obtidos por este método.




Figura 3.101 - Esquema da quarta estratégia proposta.

Cada ponto representado ao longo da linha da secção transversal, na Figura 3.101, resulta da média das coordenadas dos pontos pertencentes a cada um dos perfis. De forma a identificar os pontos de cada perfil, são utilizadas restrições semelhantes às das secções anteriores, representadas em (3.49).

$$\begin{cases} Di \leq L \\ |Tj - Ti| \leq f \end{cases} \quad (3.49)$$

Tendo em conta que os pontos da nuvem são armazenados de acordo com a sua época do GPS, o primeiro ponto da nuvem cuja distância D_i é menor que L é considerado como o primeiro ponto do perfil. Até que a diferença da época GPS em relação a esse ponto seja superior a f , todos os pontos subsequentes da nuvem são considerados como parte desse perfil. O primeiro ponto que não satisfaz a segunda restrição é usado como ponto inicial de um novo perfil e o ciclo reinicia.

De forma a permitir a comparação com as outras estratégias, e para eliminar os pontos cuja projeção está fora da linha de perfil, os pontos de média são projetados na linha de seção transversal, seguindo a descrição da Secção 3.7.1.1. Na Figura 3.102 apresentam-se exemplos de secções transversais utilizando diferentes valores de L .

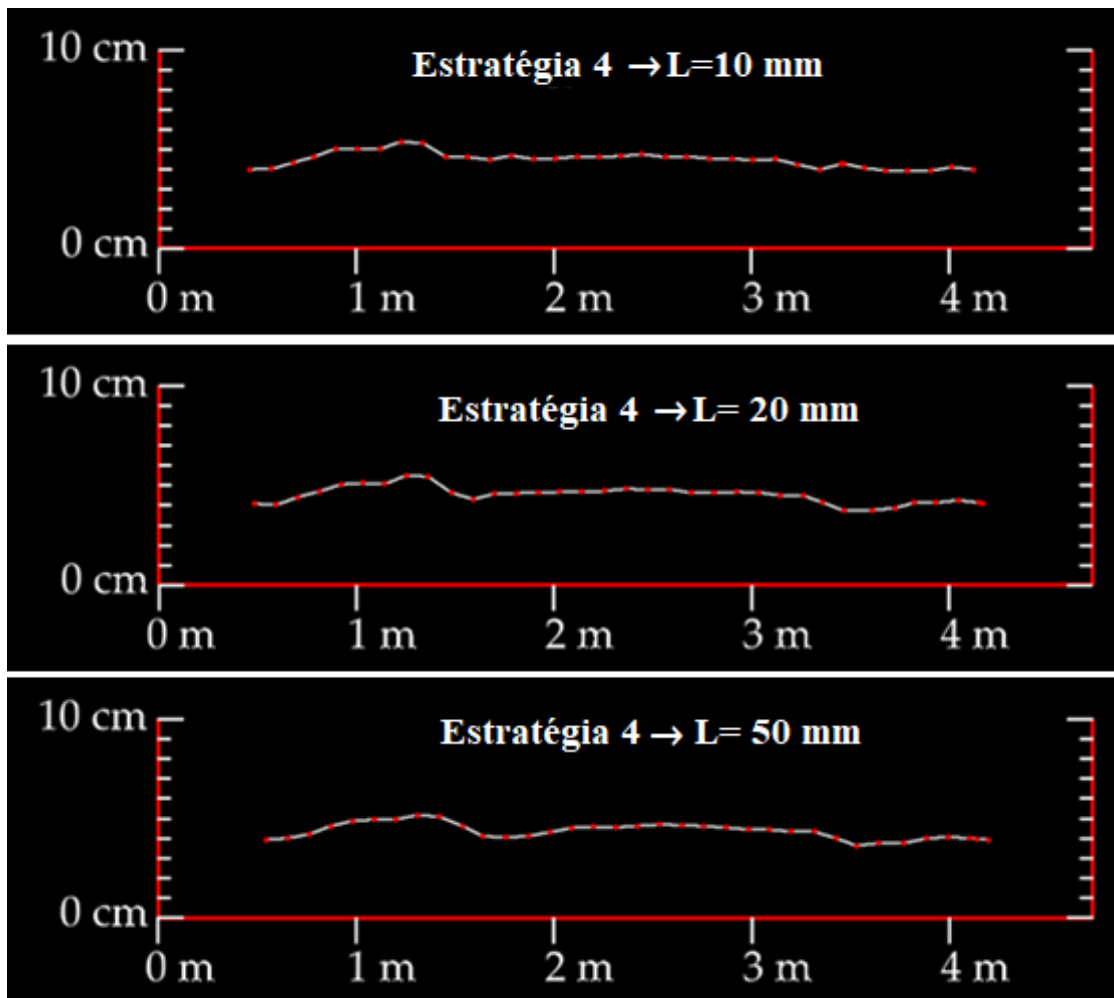


Figura 3.102 - Resultados obtidos da quarta estratégia proposta.

3.7.2. Resultados

De forma a avaliar e comparar os resultados obtidos pelas estratégias propostas, foi realizado um conjunto de 10 medições manuais em campo. As medições foram realizadas ao longo da faixa direita da estrada, usando uma régua, como ilustrado na Figura 3.93a. Somente a faixa direita da estrada foi considerada, pois no exemplo usado é aquela que devido ao tráfego pesado é expectável que tenha os CDR mais acentuados. Na Tabela 3.12, são apresentados os valores obtidos para os CDR do lado esquerdo e direito. Os valores foram medidos com intervalo de 100 metros, sendo os sinais quilométricos da rodovia utilizados como referência.

Tabela 3.12 - Valores do CDR medidos em campo.

Km	Valor CDR direito (mm)	Valor CDR esquerdo (mm)
52+800	12	9
52+900	13	11
53+000	13	10
53+100	10	8
53+200	11	10
53+300	15	12
53+400	11	9
53+500	14	11
53+600	14	10
53+700	8	7

O primeiro passo para comparar as estratégias propostas com os valores manuais medidos em campo foi a materialização das linhas de corte transversal nos mesmos locais onde foram realizadas medições manuais. Na Figura 3.103 são apresentados exemplos dessas localizações.




Figura 3.103 - Exemplo da distribuição das linhas transversais ao longo da estrada.

Todas as medições de profundidade dos CDR, efetuadas sobre as secções transversais criadas utilizando as diferentes estratégias, foram executadas manualmente. Foi utilizado um método

semelhante ao método manual executado em campo. Para cada seção transversal, foi desenhada manualmente uma linha auxiliar entre os dois pontos mais altos de cada lado do CDR.

Foram testados sucessivos valores para os parâmetros de cada estratégia, tendo sido apenas utilizados os que apresentaram maiores valores de CDR. Para a primeira estratégia foi usado um valor de $L = 30$ mm, para a segunda estratégia, foram utilizados 50 pontos e um valor de $R = 30$ mm, na terceira estratégia foi considerado o perfil original mais próximo do centro da secção e finalmente, para a quarta estratégia, foi utilizado o valor de $L=30$ mm.

Na Tabela 3.13, estão listados os valores obtidos para cada estratégia proposta.

Tabela 3.13 – Valores esquerdos e direitos obtidos para cada estratégia

km	Estratégia 1		Estratégia 2		Estratégia 3		Estratégia 4	
	Esquerda (mm)	Direita (mm)	Esquerda (mm)	Direita (mm)	Esquerda (mm)	Direita (mm)	Esquerda (mm)	Direita (mm)
52+800	5	3	7	5	4	4	8	6
52+900	5	2	7	4	5	4	9	8
53+000	4	4	8	4	4	3	11	7
53+100	4	3	6	3	5	3	8	6
53+200	3	3	6	4	4	2	8	8
53+300	6	5	8	4	5	3	13	9
53+400	3	3	6	5	4	2	7	7
53+500	4	4	7	3	5	3	11	7
53+600	4	3	6	4	5	2	10	8
53+700	3	3	4	6	4	3	7	5

Com base nos valores obtidos, é possível representar a evolução longitudinal dos valores de profundidade do CDR ao longo da estrada. As Figuras 3.104, 3.105 e 3.106 representam, respetivamente, os valores da esquerda, direita e máximo dos valores das medições de campo e de cada uma das estratégias.




Figura 3.104 - Representação longitudinal dos valores esquerdos do CDR.




Figura 3.105 - Representação longitudinal dos valores direitos do CDR.




Figura 3.106 - Representação longitudinal dos valores máximos do CDR.

A Tabela 3.14 apresenta a listagem do EMQ (erro médio quadrático) obtido das diferenças entre os valores obtidos por cada uma das estratégias e os valores de referência medidos em campo.

Tabela 3.14 - Valores de EMQ relativamente aos valores de referência.

Nº da estratégia	EMQ (mm)
4	3.2
2	5.6
3	7.9
1	8.3

A primeira estratégia proposta é provavelmente a solução mais intuitiva e vulgarmente utilizada para criar uma secção transversal, projetando os pontos da nuvem diretamente no plano vertical da secção transversal.

A segunda estratégia proposta, usa um número limitado de pontos ao longo da secção transversal, sendo utilizada a média das coordenadas Z dos pontos da nuvem num determinado raio para o seu cálculo. Em ambas as estratégias, são misturados pontos de diferentes perfis. Tendo em conta

que, cada posição absoluta do perfil é calculada usando os sensores auxiliares (GNSS, UMI, DMI etc.), o valor de erro absoluto de cada perfil é diferente e a inconsistência entre os pontos da secção transversal aumenta.

Os resultados obtidos pela estratégia três, mostram que mesmo os pontos resultantes de um único perfil do sensor apresentam alguma inconsistência. Essas inconsistências resultam da limitação da precisão do sensor e da rugosidade do asfalto. A estratégia quatro utiliza as médias das coordenadas dos pontos da nuvem, discriminados por perfil, permitindo diminuir as inconsistências internas de cada perfil do sensor.

As secções transversais obtidas das estratégias um e três apresentam pontos muito irregulares tornando-se difícil medir baixos valores de CDR. A estratégia dois, gera secções transversais com menos pontos, facilitando as medições. No entanto, os critérios exclusivamente espaciais tendem a suavizar a seção transversal, alterando os valores do CDR. A quarta estratégia proposta utiliza os princípios de funcionamento do SLMT, classificando os pontos por perfil do sensor. Conclui-se que esta última estratégia apresenta claramente o resultado mais próximo das medições de referência executadas manualmente em campo.

3.8. Integração dos métodos propostos para geração do MDT

A produção de MDT a grandes escalas ao longo de corredores rodoviários e ferroviários é uma necessidade recorrente, quer para construção de novas infraestruturas, quer para manutenção das existentes. O contínuo aumento do seu número e o desenvolvimento da tecnologia associada aos SLMT demonstra bem a importância que esta tecnologia tem atualmente na recolha de dados georreferenciados ao longo de corredores (Lohani & Yadav 2108). Atualmente, a minimização dos processos manuais e o desenho de algoritmos automáticos para extração de estruturas das nuvens de pontos são identificados como os maiores desafios para o desenvolvimento da tecnologia (Kumar *et al.* 2018).

Através do presente estudo pretendeu-se dar um contributo para a automatização do processo de classificação e extração de dados das nuvens de pontos recolhidas por SLMT, para a geração de modelos digitais de terreno a grandes escalas.

De forma a obter uma ferramenta única, que integre os principais algoritmos propostos ao longo deste trabalho, foi efetuada a integração do método descrito na Secção 3.3, de extração de pontos do terreno, com o método automático de extração de linhas de quebra, descrito na Secção 3.5. A conjugação destes dois métodos permitiu obter a classificação não supervisionada das

nuvens de pontos, e a extração das estruturas que representam a forma do terreno. Na Figura 3.107 é apresentado o fluxograma de integração dos métodos.

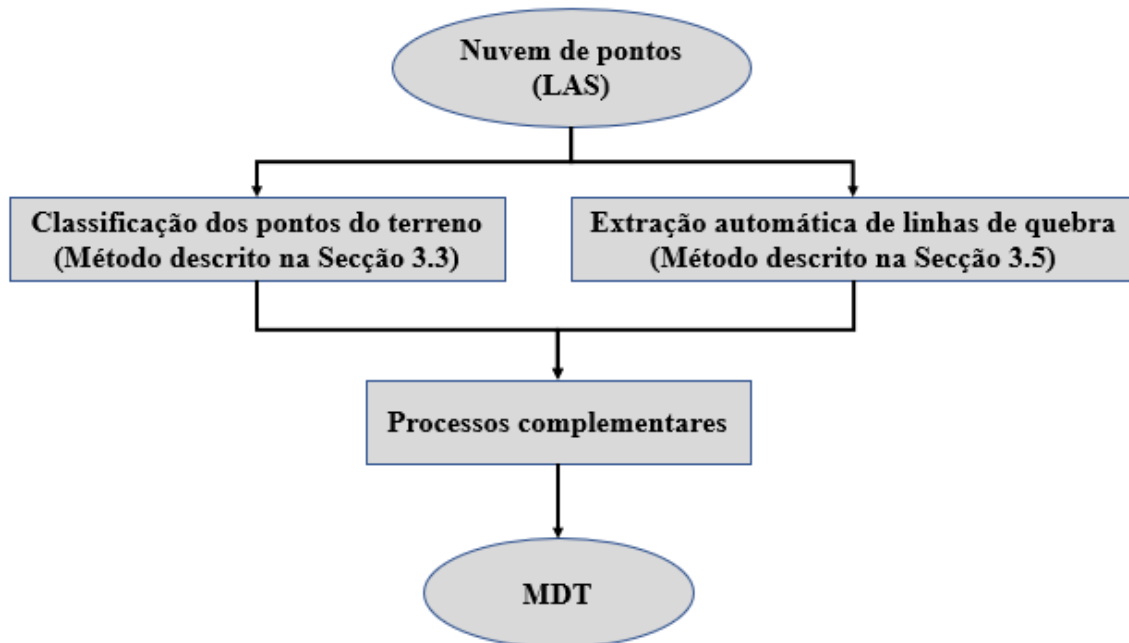


Figura 3.107 - Fluxograma dos métodos integrados.

Para uma total automatização do processo de criação do MDT, foram necessários a implementação de alguns processos complementares, referidos na Figura 3.107. Dada a sua simplicidade, não se justifica uma descrição detalhada da sua implementação. No entanto, apresentam-se de seguida, as situações que levaram à necessidade da sua integração, ilustrando o seu contributo na geração de MDT.

No caso da integração dos pontos de cota com as linhas de quebra, verificou-se que na situação em que os pontos de cota estão muito próximos das linhas de quebra, existem pequenas incongruências entre as duas estruturas. Tendo sido implementado um método auxiliar para eliminar todos os pontos cotados da proximidade das linhas de quebra. Na Figura 3.108a é exemplificado o efeito das pequenas incongruências provocadas pela proximidade entre os pontos de cota e as linhas de quebra. Na Figura 3.108b apresenta-se o resultado obtido, após a aplicação do método auxiliar, que elimina os pontos nas proximidades das linhas de quebra.




Figura 3.108 - Aplicação do método auxiliar, para remoção dos pontos cotados próximos das linhas de quebra. a) Exemplo da linha de quebra antes de aplicação do método. b) Resultado após aplicação do método auxiliar.

Verificou-se que, em resultados em que a equidistância entre os vértices das linhas de quebra é muito superior à equidistância entre os pontos cotados, são normalmente gerados triângulos muito grandes. Por uma questão estética, foi introduzido um método auxiliar que interpola os vértices das linhas de quebra, aproximando-a dos pontos cotados. Este procedimento não modifica a forma das linhas de quebra, já que os vértices intermédios resultam de uma interpolação linear. Na Figura 3.109 é apresentado o resultado antes (Figura 3.109a) e depois (Figura 3.109b) da aplicação do método.




Figura 3.109 - Método auxiliar de interpolação dos vértices de linha de quebra. a) Exemplo antes da aplicação do método. b) Resultado após a aplicação do método.

Capítulo 4.

Discussão e conclusões

O principal objetivo desta tese foi propor um conjunto de métodos para contribuir para uma maior eficiência e automatismo no processo de geração de MDT a grandes escalas com base em nuvens recolhidas por SLMT. Dada a elevada densidade de pontos recolhidos por estes sistemas de aquisição de dados, os programas comerciais existentes, na sua maioria idealizados para nuvens obtidas por SLA, ou não são eficientes ou consomem muito tempo, provocando um estrangulamento no processo de geração do MDT.

Tendo em conta que, sempre que são recolhidas duas ou mais nuvens sobre a mesma área geográfica, de diferentes pontos de vista ou em diferentes épocas, existem impreterivelmente diferenças relativas de posicionamento entre elas, é inevitável que essas diferenças dificultem ou impossibilitem a aplicação dos métodos de classificação de dados para a geração de MDT. Assim, foi proposto um método para efetuar o ajustamento entre nuvens de pontos sobrepostas. O método proposto é baseado nos princípios de funcionamento do SLMT, utilizando exclusivamente dados contidos nos ficheiros *standard LAS*, não necessitando, por isso, dos ficheiros de trajetória. Esta característica representa uma grande vantagem, já que tipicamente, os dados referentes à trajetória original são apenas utilizados no processamento das nuvens, sendo apenas os ficheiros das nuvens de pontos fornecidos a utilizadores e programadores.

A inovação desta abordagem relativamente a trabalhos publicados, que utilizam a trajetória como base para efetuar o ajustamento de nuvens recolhidas por SLMT, por exemplo Gressin *et al.* (2012), é que nestes casos apesar de ser utilizada a trajetória, são aplicadas transformações locais em blocos das nuvens. Esse método é atualmente utilizado em *softwares* comerciais como o TerraScan e Optech LMS PRO. Para além de provocar diferenças entre os blocos de nuvens utilizados, este processo não tira partido dos dados da trajetória, sendo estes utilizados apenas para a divisão da nuvem em blocos, sem serem aplicadas as correções continuamente como sucede na abordagem proposta. Através do estabelecimento dos pontos ao longo da trajetória o método proposto permite um ajustamento contínuo e variável ao longo do tempo de aquisição da nuvem. Para além disso, a utilização dos planos e do ajuste da dimensão dos círculos ao longo da trajetória, faz com que o método proposto seja insensível a variações de densidade dos pontos das nuvens. Finalmente, o facto de o método proposto ser totalmente automático e com reduzidos tempos de execução, permitindo o ajustamento entre duas nuvens com dezenas de

milhões de pontos em apenas alguns segundos, são mais valias inequívocas para ajustamento entre nuvens de pontos sobrepostas.

O método proposto para a classificação dos pontos do terreno, permite obter uma densidade dos pontos proporcional à variação do terreno. Este facto permite que os pontos resultantes do processo tenham uma maior densidade em zonas de maior variação do terreno, permitindo uma melhor modelação dessas zonas. Por outro lado, a menor densidade em zonas planas, permite uma redução significativa da quantidade de pontos do resultado final, sendo assim, compatível com os atuais recursos computacionais da maioria dos utilizadores. Para além disso, a implementação do algoritmo, baseado em coordenadas-grelha, permite por um lado, facilitar a sua implementação em células de diferente forma, e por outro lado, a otimização muito significativa do tempo de execução. Essa otimização está patente na Tabela 3.4, onde o tempo de execução total é inferior a 5 s, para as células regulares baseadas nas coordenadas-grelha e é superior a uma hora, nas células irregulares onde esse método não é aplicável. Para além disso o método revelou-se bastante eficiente tanto em ambientes rurais onde existe mais vegetação, como em ambientes urbanos onde obstáculos, tais como carros estacionados, dificultam o processo de geração do MDT (Figuras 3.26 e 3.28).

O método semiautomático proposto para a extração das linhas de quebra, apesar de requerer uma intervenção inicial por parte do utilizador, permite uma fácil integração em ambiente CAD. Este facto facilita o acompanhamento visual do processo por parte do utilizador, permitindo a sua validação e adaptação dos parâmetros às diferentes linhas de quebra.

O método automático de extração das linhas de quebra, descrito na Secção 3.5, baseado na decomposição das nuvens em secções lineares, revelou uma rapidez de execução muito significativa, permitindo, no exemplo prático, a extração das linhas de crista e base do lancil em apenas 20 segundos, em comparação com os 25 minutos do método manual (Tabela 3.8), obtendo-se, ainda, valores de completude, exatidão e qualidade acima dos 90% em relação ao método manual (Tabela 3.10).

Dada a importância do MDT na manutenção das linhas ferroviárias e o papel que os SLMT podem ter na recolha de dados para a sua geração, foi apresentado um método específico para a extração de linhas tridimensionais de nuvens obtidas a partir de SLMT instalado em comboios. O método baseia-se na limitação de movimentos do SLMT e na simetria dos elementos da linha ferroviária em relação ao seu eixo. O método utiliza apenas os dados contidos nos ficheiros abertos *standard LAS*, podendo ser aplicado ao processo de extração de

outros elementos lineares da infraestrutura ferroviária, como linhas elétricas, ou medição de bitola.

Tendo em conta que, os perfis transversais a grandes escalas representam o atual paradigma para a modelação do terreno como base para projetos de execução e manutenção de vias lineares, nomeadamente, rodoviárias e ferroviárias, é apresentado um estudo comparativo de várias estratégias propostas para o agrupamento dos pontos das nuvens com vista à criação desses perfis transversais. Para isso, utilizou-se a medição de uma patologia designada por cavados de rodeira, tipicamente medida através de perfis transversais à via. A estratégia baseada na agregação dos pontos por perfil, revelou resultados mais próximos do método de referência. Este é um fator a ter em conta aquando da utilização das nuvens de pontos recolhidas por SLMT, para a geração de perfis transversais a grandes escalas, de suporte a estudos de execução e manutenção de rodovias e ferrovias.

Finalmente, a integração dos métodos de classificação de pontos e extração de linhas de quebra permitiu a criação de uma forma automática e eficiente de geração do MDT, a grandes escalas, com base em nuvens recolhidas por SLMT.

Uma área de investigação recente associada à obtenção de informação de uma quantidade substancial de dados (conhecida como *big data*) é a designada mineração de dados (*data mining*). A mineração de dados é definida como o desenvolvimento de algoritmos ou metodologias processuais para a extração de informações desejadas de um conjunto de dados espaciais complexos (Shirowzhan & Sepasgozar, 2019). Tendo em conta os resultados obtidos pelos métodos propostos, acredita-se que este trabalho representa um passo significativo nos processos de mineração de dados espaciais, nomeadamente, de grandes quantidades de nuvens de pontos recolhidas por SLMT.

4.1. Perspetivas e desenvolvimento de trabalhos futuros

A integração dos métodos propostos em nuvens consecutivas obtidas ao longo da trajetória poderá ser o próximo passo lógico para a obtenção contínua do MDT ao longo de rodovias e ferrovias. Para além disso, será interessante testar a aplicação dos métodos em nuvens obtidas por SLMT com mais do que um sensor.

Outro desenvolvimento futuro poderá também ser a integração de algoritmos de *machine learning*, permitindo a adaptação dos parâmetros ao tipo de terreno, permitindo inclusive a predição e preenchimento da informação em zonas de sombra das nuvens de pontos.

Referências bibliográficas

- Andrew, A. (1979). Another Efficient Algorithm for Convex Hulls in Two Dimensions. *Info. Proc. Letters*, 9, 216-219.
- Axelsson P. 2000. DEM generation from laser scanner data using adaptive TIN models. *Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 35(B4/1): 236–241.
- Al-Durgham M. & Habib A. (2013). A framework for the registration and segmentation of heterogeneous LiDAR data. *Photogrammetry Engineering and Remote Sensing*, 79: 135–145.
- ASPRS (2020). LASer (LAS) File Format Exchange Activities, Acedido em 02 de Março de 2020. <https://www.asprs.org/committee-general/laser-las-file-format-exchange-activities.html>
- Bae K. (2010). Automated Registration of Three-Dimensional Unorganized Point Clouds from Terrestrial Laser Scanners. *Ph.D. Thesis. Curtin University of Technology*, Perth, Australia.
- Belkin M., Sun J. & Wang Y. (2008). Discrete Laplace operator on meshed surfaces. *SOCG 2008*, 278–287.
- Barnea S & Filin S. (2008). Key point based autonomous registration of terrestrial laser point-clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(1),19–35.
- Berkovic G. & Shafir E. (2012). Optical methods for distance and displacement measurements. *Advances in Optics and Photonics*, 4: 441–471.
- Besl P. & McKay N. (1992). A Method for Registration of 3D Shapes. *Transitions PAMI*, 14 (2).
- Breitenreicher D. & Schnörr C. (2011). Model-based multiple rigid object detection and registration in unstructured range data. *International Journal of Computer Vision*, 92(1), 32–52.
- Bretar F & Chehata N. (2007). Digital terrain model on vegetated areas: joint use of airborne lidar data and optical images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 36(3W49A): 19–24.
- Briese, C. (2004). Three-Dimensional Modelling of Break lines from Airborne Laser Scanner Data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XXXV, B3, 1097 – 1102.
- Briese, C., Mandlbürger, C., Ressel, C. & Brockmann. H. (2009). Automatic break line determination for the generation of a DTM along the river main. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 34, 3/W8, 236-241.
- Bronstein A., Bronstein M., Bustos B., Castellani U., Crisani M., Falcidieno B., Guibas L., Kokkinos I., Murino V. & Ovsjanikov M. (2010). SHREC'10 track: Feature detection and description. *3rd Euro graphics Conference on 3D Object Retrieval, EG 3DOR'10*, 2 May 2010, 79–86, Norrköping, Sweden.
- Brugelmann, R. (2000). Automatic break line detection from airborne laser range data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XXXIII, B3, 109–115.

- Chen Y. & Medioni G. (1991). Object Modeling by Registration of Multiple Range Images. *IEEE Conference on Robotics and Automation, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36(3W49A): pp. 19–24.
- Chen Q., Gong P., Baldocchi D. & Xie G. (2007). Filtering airborne laser scanning data with morphological methods. *Photogrammetric Engineering & Remote Sensing*, 73(2), 171–181.
- Cheng L., Tong L., Li M. & Liu Y. (2013). Semi-Automatic Registration of Airborne and Terrestrial Laser Scanning Data Using Building Corner Matching with Boundaries as Reliability Check. *Remote Sensing*, 5: 6260–6283. doi: 10.3390/rs5126260.
- Chen M., Wang S., Wang M., Wan Y. & He P. (2017). Entropy-Based Registration of Point Clouds Using Terrestrial Laser Scanning and Smartphone GPS. *Habib AF (ed.) Sensors*, Basel, Switzerland, 17(1), 197. doi: 10.3390/s17010197.
- Chen Z., Gao B., Devereux B. (2017). State-of-the-Art: DTM Generation Using Airborne LIDAR Data. *Sensors*, 17(1): 150. doi: 10.3390/s17010150.
- Chien-Chou L., Yen-Chou, T., Chen, J. & Yong-Sheng. (2017). A novel point cloud registration using 2D image features. *EURASIP Journal on Advances in Signal Processing*. doi: 10.1186/s13634-016-0435-y.
- Chilukwa, N.& Lungu, R. (2019). Determination of Layers Responsible for Rutting Failure in a Pavement Structure. *Infrastructures*, 4, 29.
- Ciotlaus, M., & Kollo, G. (2018). Ballast bed cleaning and recycling – influence on stability of continuously welded rail track. *Procedia Manufacturing*, 22, 294-300.
- Clay A. & Wygant P. (2009). User tests of the Optech lynx mobile mapping system, data QC to ground survey control, *ASPRS 2009 Annual Conference*, Baltimore, Maryland, March 9-13.
- Chuang T. & Jaw J. (2015). Automated 3D feature matching. *The Photogrammetric Record* 30(149), 8–29. doi: 10.1111/phor.12089.
- Chuang T. & Jaw J. (2017). Multi-Feature Registration of Point Clouds. *Remote Sensing*, 9(3): 281. doi: 10.3390/rs90302812017.
- Crosilla F., Macorig D., Sebastianutti I. & Visintini D. (2011). Points classification by a sequential higher – order moments statistical analysis of LiDAR data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XXXVIII-5/W12.
- Crosilla F., Macorig D., Scaioni M., Sebastianutti I. & Visintini D. (2013). LiDAR data filtering and classification by skewness and kurtosis iterative analysis of multiple point cloud data categories. *Applied Geomatics*, 5(3): 225–240.
- Delaunay, B. (1934). "Sur la sphère vide". *Bulletin de l'Académie des Sciences de l'URSS, Classe des Sciences Mathématiques et Naturelles*. 6: 793–800.
- Douglas, D. & Peucker, T. (1973). Algorithms for the reduction of the number of points required to represent a digitized line or its caricature. *The Canadian Cartographer*. 10, 2, 112–122.
- El-Rabbany A. (2002). GPS Positioning Modes, Introduction to GPS: The Global Positioning System. *Artech House, Inc.*, Norwood, MA, 69–83.
- El-Sheimy N. (2005). An overview of mobile mapping systems. Pharaohs to Geoinformatics, In FIG Working Week 2005 and GSDI-8, Cairo, Egypt, April 16-21.

- Elmqvist M. (2001). Ground Estimation of Laser Radar Data using Active Shape Models. *Airborne laser scanning and interferometric SAR for detailed digital elevation models 1-3 March Royal Institute of Technology Department of Geodesy and Photogrammetry*, Stockholm, Sweden.
- Estradas de Portugal, S.A. (2014)., Caderno de Encargos Tipo Obra. 15.03 – *Pavimentação-Métodos construtivos*, Acedido em Março 02, 2020. https://www.ippatrimonio.pt/sites/default/files/cet/15_03_set_2014.pdf
- Evans J., & Hudak A. (2007). A multiscale curvature algorithm for classifying discrete return LiDAR in forested environments. *IEEE Transactions on Geoscience and Remote Sensing*, 45 (4): 1029–1038.
- Fang Fwa, T., Chu, L.& Tan, K. (2016). Rational Procedure for Determination of Rut Depth Intervention Level in Network-Level Pavement Management. *Transportation Research Record: Journal of the Transportation Research Board*, 2589, 59-67.
- Fellendorf M. (2013). Digital terrain models for road design and traffic simulation. *Photogrammetric Week '13*, 309–317. Stuttgart, Germany.
- Filin S, Pfeifer N. (2006). Segmentation of airborne laser scanning data using a slope adaptive neighborhood. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 60(2): 71–80.
- Fischler M., & Bolles R. (1981). Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image. *Analysis and Automated Cartography*. Comm. ACM. 24 (6): 381–395. doi:10.1145/358669.358692.
- Forstner, W. (1998) Image processing for feature extraction in digital intensity, color and range images. *International Summer School on 'Data Analysis and Statistical Foundations of Geomatics*, Greece, May 25. Springer Lecture Notes on Earth Sciences.
- Gal R. & Cohen-Or D. (2006). Salient geometric features for partial shape matching and similarity. *ACM Transactions and Graphics*. 25, 130–150.
- Gao Y., Huang X., Zhang F., Fu Z. & Yang C. 2015. Automatic Geo-referencing Mobile Laser Scanning Data to UAV images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, XL-1/W4*.
- Gelfand N., Ikemoto L., Rusinkiewicz S. & Levoy M. (2003). Geometrically stable sampling for the ICP algorithm. *International Conference on 3D Digital Imaging and Modeling*, 6–10. IEEE, Banff, Alberta, Canada, 260–267.
- Gelfand N., Mitra N., Guibas L. & Pottmann H. (2005). Robust global registration. *Euro graphics Symposium on Geometry Processing*, Vienna, Austria, 4–6 July, 197–206.
- Gézero, L. & Antunes, C. (2017a), An efficient method to create digital terrain models from point clouds collected by mobile lidar systems. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, International xlii-1/w1*, 289-296. <https://doi.org/10.5194/isprs-archives-xlii-1-w1-289-2017>
- Gézero, L. & Antunes, C. (2017b). A registration method of point clouds collected by mobile lidar using solely standard las files information. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, xlii-1/w1*, 121-128. <https://doi.org/10.5194/isprs-archives-xlii-1-w1-121-2017>
- Gézero, L. & Antunes, C. (2018a). Multigrid cell shape evaluation in DTM filtering of mobile lidar point clouds. *International Archives of the Photogrammetry, Remote Sensing and Spatial*

Information Sciences - ISPRS Archives, xlii-4, 225-232. <https://doi.org/10.5194/isprs-archives-xlii-4-225-2018>

Gézero, L. & Antunes, C. (2018b) Restituição semiautomática de linhas de quebra sobre nuvens de pontos recolhidas por sistemas LiDAR móveis terrestres. *IX Conferência Nacional de Cartografia e Geodesia*, Lisboa, 25-26 Outubro. https://www.cncg.ordemengenheiros.pt/fotos/editor2/cncg_2019_2_1_3.pdf

Gézero L. & Antunes C. (2019a). Automated Road Curb Break Lines Extraction from Mobile LiDAR Point Clouds. *ISPRS International Journal of Geo-Information*, 8(11):476. <https://www.mdpi.com/2220-9964/8/11/476/htm>

Gézero L. & Antunes C. (2019b). Automated Three-Dimensional Linear Elements Extraction from Mobile LiDAR Point Clouds in Railway Environments. *Infrastructures*, 4(3):46. <https://www.mdpi.com/2412-3811/4/3/46/htm>.

Gézero L. & Antunes C. (2019c). Road Rutting Measurement Using Mobile LiDAR Systems Point Cloud. *ISPRS International Journal of Geo-Information*, 8(9):404. <https://www.mdpi.com/2220-9964/8/9/404/htm>

Goepfert J., Soergel U. & Brzank A. (2008). Integration of intensity information and echo distribution in the filtering process of LIDAR data in vegetated areas. *Silvilaser 2008: 8 International Conference on LiDAR Applications in Forest Assessment and Inventory*, September 17-19, Edinburgh, United Kingdom.

González H., Martínez-Sánchez J., Díaz-Vilariño L., Puente I. & Arias P. (2016). Automatic Registration of Mobile LiDAR Data Using High-Reflectivity Traffic Signs. *Journal of Construction Engineering and Management*, 04016022. doi:10.1061/(ASCE)CO.1943-7862.0001143.

Grant D., Bethel J. & Crawford M. (2012). Point-to-plane registration of terrestrial laser scans. *ISPRS Journal of Photogrammetry and Remote Sensing*, 72(2): 16–26.

Gruen A. & Akca D. (2005). Least squares 3d surface and curve matching. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59(3): 151–174.

Gressin A., Cannelle B., Mallet C., Papelard J. (2012). Trajectory-based registration of 3D LiDAR point clouds acquired with a mobile mapping system. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, I-3, XXII ISPRS Congress, 25 August – 01 September, Melbourne, Australia.

Gressin, A., Mallet C., Demantk J. & David N. (2013). Towards 3D LiDAR point cloud registration improvement using optimal neighborhood knowledge. *ISPRS Journal of Photogrammetry and Remote Sensing*, 79: 240–251.

Guan H., Li J, Yu Y., Wang C. (2013). Geometric validation of a mobile laser scanning system for urban applications. *MMT 2013*, Taiwan, China, 1-3 May.

Guan H, Li J, Yu Y, Zhong L & Ji Z. (2014). DEM generation from LiDAR data in wooded mountain areas by cross-section-plane analysis. *International Journal of Remote Sensing*. 35(3): 927–948. doi: 10.1080/01431161.2013.873833.

Guan H, Li J, Yu Y, Chapman M, Wang, C. (2015a). Automated road information extraction from mobile laser scanning data. *IEEE Transactions on Intelligent Transportation Systems*, 16(1): 194–205.

- Guan H, Li J, Yu Y, Chapman M, Wang H, Wang C, Zhai R. (2015b). Iterative tensor voting for pavement crack extraction using mobile laser scanning data. *IEEE Transactions on Geoscience and Remote Sensing*, 53(3): 1527–1537.
- Guojun, W., Wu, J., He, R. & Yang, S. (2019). A Point Cloud Based Robust Road Curb Detection and Tracking Method. *IEEE Access*. 1-1.
- Haala N., Peter M., Kremer J. & Hunter G. (2008). Mobile LiDAR Mapping for 3D point cloud collection in urban areas – a performance test. *XXI ISPRS Congress*, 1114–1124.
- Habib A., Bang K., Kersting A. & Chow J. (2010). Alternative methodologies for LiDAR system calibration. *Remote Sensing* (ISSN 2072-4292), 2: 874–907 doi:10.3390/rs2030874 874-907.
- Han J.& Jaw J. (2013). Solving a similarity transformation between two reference frames using hybrid geometric control features. *Journal of the Chinese Institute of Engineers*, 36, 304–313.
- Hänsch R., Weber T. & Hellwich O. (2014). Comparison of 3D interest point detectors and descriptors for point cloud fusion. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, II-3: 57–64.
- Heidrich W. (2005). Computing the Barycentric Coordinates of a Projected Point. *Journal of Graphics Tools*, 10:3, 9-12. DOI: 10.1080/2151237X.2005.10129200.
- Hingee, K., Caccetta, P. & Caccetta, L. (2019). Modelling discontinuous terrain from DSMs using segment labelling, outlier removal and thin-plate splines, *ISPRS Journal of Photogrammetry and Remote Sensing*, 155, 159- 171.
- Holz, B. (2014). Registration of Non-Uniform Density 3D Point Clouds using Approximate Surface Reconstruction, *International Symposium on Robotics*, Messe München, Munich, Germany, June 2-3.
- Hong, Z., Ai, Q. & Chen, K. (2018). Line-laser-based visual measurement for pavement 3D rut depth in driving state. *Electron. Lett*, 54, 1172–1174
- Hu J., Razdan, J. Femiani C., Cui M. & Wonka P. (2007). Road Network Extraction and Intersection Detection from Aerial Images by Tracking Road Footprints. *IEEE Transactions on Geoscience and Remote Sensing*, 45, 12, 4144-4157.
- Infraestruturas de Portugal (2020). Acedido em Março 02, 2020, <https://www.infraestruturasdeportugal.pt/pt-pt/rede/ferroviaria/manutencao>
- Jaw J. & Chuang T. (2008). Feature-based registration of terrestrial LIDAR point clouds. Chen J, Jiang J, Maas HG (Eds.), *International Society for Photogrammetry and Remote Sensing, XXI Congress, Commission III. Processing of Point Clouds from Laser Scanners and Other Sensors, WG III/3 International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, China, 303–308.
- Ji S, Ren Y & Ji Z (2017). An improved method for registration of point cloud. *Optik - International Journal for Light and Electron Optics*, Vol. 140, pp. 451–458. July.
- Kavanagh R. (2007). Gyroscopes for orientation and inertial navigation systems. *Kartografija I Geoinformacije*, 6, 254–271.
- Kazhdan, M., Bolitho, M. & Hoppe, H. (2006). Screened Poisson Surface Reconstruction. *ACM Transactions on Graphics*. 32. 61-70. Doi:10.1145/1281957.1281965.

- Kim, C. (2016). Automatic Registration of LASER scanned color point clouds based on common feature extraction. *16th International Conference on Construction Applications of Virtual Reality*, 11-13 December, HK, 700-712.
- Kitamura K., Kochi N. & Kaneko S. (2012). Automated feature-based TLS data registration for 3D building modeling. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XXXIX-B5, 2012 XXII ISPRS Congress, 25 August – 01 September, Melbourne, Australia.
- Kobler A, Pfeifer N, Ogrinc P, Todorovski L, Ostir K & Dzeroski S. (2007). Repetitive interpolation: A robust algorithm for DTM generation from aerial laser scanner data in forested terrain. *Remote Sensing of Environment*, 108: 9–23.
- Kraus K & Pfeifer N. (2001). Advanced DTM generation from LiDAR data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 34 (3/W4).
- Kumar, P., McElhinney, C.P., Lewis, P. & McCarthy, T. (2013). An automated algorithm for extracting road edges from terrestrial mobile LiDAR data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 85, 44–55.
- Kumar, B., Lohani, B. & Pandey, G. (2018). Development of deep learning architecture for automatic classification of outdoor mobile LiDAR data. *International Journal of Remote Sensing*. 40. 1-12. 10.1080/01431161.2018.1547929.
- Lei H., Jiang G. & Quan L. (2017). Descriptors and Correspondence Propagation for Robust Global Point Cloud Registration. *IEEE Transactions on Image Processing*, 26(8): 3614 – 3623.
- Le Scouarnec R., Touzé T., Lacambreb J.B. & Seube N. (2014). A new reliable boresight calibration method for mobile laser scanning applications. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XL-3/W1.
- Li H. & Hartley R. (2007). The 3D-3D registration problem revisited. *Computer Vision. IEEE 11th International Conference*, 1–8.
- Li X. & Guskov I. (2005). Multi-scale features for approximate alignment of point-based surfaces. *3rd Euro graphics Symposium on Geometry Processing*, Vienna, Austria, 4–6 July, 217–226.
- Li, Z., Zhu, Q. & Gold, C. (2005). *Digital Terrain Modeling: Principles and Methodology*. CRC Press, Boca Raton, London, New York, and Washington, D.C.
- Lichtenstein, A. & Doytsher, Y. (2004). Geospatial Aspects of merging DTM with break lines. *Proceedings of FIG Working Week 2004*, Athens, Greece, May 22-27.
- Little, J.; Shi, P. (2001). Structural lines, TINs, and DEMs. *Algorithmica*. 30 (2), 243-263.
- Liu Y., Li Z., Hayward R., Walker R. & Jin H. (2009). Classification of airborne LIDAR intensity data using statistical analysis and Hough Transform with application to power line corridors. *Digital Image Computing: Techniques and Applications*, December 1-3, Melbourne, Australia.
- Lohani, B. & Yadav M. (2108). Mobile Lidar Systems Today and Tomorrow: The Promising Future of Mobile Mapping and Laser Scanning. *GIM- International*, 19-21.

- Maalej Y., (2018). VANETs meet autonomous vehicles: *Multimodal surrounding recognition using manifold alignment*, 6, 29026–29040.
- Mao Q., Zhang L., Li Q., Hu Q., Yu J., Feng J., Ochieng W. & Gong H. (2015). A Least Squares Collocation Method for Accuracy Improvement of Mobile LiDAR Systems, *Remote Sensing*, 7(6): 7402.
- Mandlbürger G., Briese C. & Pfeifer N. (2007). Progress in LiDAR sensor technology - chance and challenge for DTM generation and data administration. D. Fritsch (ed.), *51st Photogrammetric Week, Herbert Wichmann Verlag, Heidelberg, Germany*, 159–169.
- Meng X., Wang L., Silván-Cárdenas J. & Currit N. (2009). A multi-directional ground filtering algorithm for airborne LIDAR. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(1): 117–124.
- Mostafa M. & Hutton J. & Reid B. (2001). GPS/IMU products – the Applanix approach. *Proceedings of the 48th Photogrammetric Week, Stuttgart, Germany, September 24-28*.
- Myronenko A. & Song X. (2010). Point set registration: coherent point drift. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(12), 2262–2275.
- Narayana K. (2011). Solutions for the localization of mobile mapping systems in structured environments. *Automatic Control Engineering. Ecole Nationale Supérieure des Mines de Paris*.
- Navidi N. & Landry R. (2015). A new survey on self-tuning integrated low-cost gps/ins vehicle navigation system in harsh environment. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XL-1/W4.
- Nolan J., Eckels R., Evers M., Singh R. & Olsen M. (2015). Multi-pass approach for mobile terrestrial laser scanning. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W5.
- Optech Incorporated. (2011). Lynx Mobile Mapper Survey Operation Manual. *Optech Inc.*
- Özcan A. & Ünsalan C. (2017). LiDAR Data Filtering and DTM Generation Using Empirical Mode Decomposition. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(1): 360–371. doi: 10.1109/JSTARS.2016.2543464.
- Papazov C. & Burschka D. (2011). Deformable 3D shape registration based on local similarity transforms. *Computer Graphics Forum*, 30(5): 1492–1503.
- Park, C. & Hayong, H. (2012). Polygonal Chain Intersection. *Computers & Graphics*. 26. 341-350.
- Petrie G. (2010). Mobile mapping systems: an introduction to the technology. *Geoinformatics*, 13(1), 32–43.
- Pfeifer N., Stadler P. & Briese C. (2001). Derivation of digital terrain models in the SCOP++ environment. *Airborne Laser scanning and Interferometric SAR for Detailed Digital Terrain Models*, Stockholm, Sweden.
- Puente H., González-Jorge H., Martínez-Sánchez J. & Arias P. (2013). Review of mobile mapping and surveying technologies. *Measurement*, 46: 2127–2145.
- Raber, G., Jensen, J., Schill, S. & Schuckman, K. (2002) Creation of Digital Terrain Models using an adaptive Lidar vegetation point removal process. *Photogrammetry. Eng. Remote Sens*, 68, 1307-1316.

- Ripperda N. & Brenner C. (2005). Marker-free registration of terrestrial laser scans using the normal distribution transform. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 36(5/W17), 86–91.
- Rodríguez-Cuenca, B., Garcia-Cortes, S., Ordóñez, C. & Alonso, M. (2016). Morphological Operations to Extract Urban Curbs in 3D MLS Point Clouds. *ISPRS International Journal of Geo-Information*, 5, 93.
- Roggero M. 2001. Airborne laser scanning: clustering in raw data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 34(3/W4): 227–232.
- Rusinkiewicz S. & Levoy M. (2001). Efficient variants of the ICP algorithm. *International Conference on 3D Digital Imaging and Modeling*, 145–152. IEEE, Québec, Canada.
- Samberg A. (2007). An implementation of the ASPRS LAS standard. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XXXVI.
- Scherzinger B. & Hutton J. (2006). Applanix IN-Fusion Technology Explained - *White Paper*. Applanix Corporation.
- Schuckman K. & Renslow M. (2014) Topographic Mapping with Lidar, Introduction to Lasers and Lidar. Geography. Acedido em Março 02, 2020. https://web.archive.org/web/20160616223207/https://www.e-education.psu.edu/geog481/11_p3.html
- Scouarnec, R., Touzé, T., Lacambre, J. & Seube, N. (2014). A New Reliable Boresight Calibration Method for Mobile Laser Scanning Applications. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XL-3/W1. 10.5194/isprsarchives-XL-3-W1-67-2014.
- Segal A., Haehnel D. & Thrun S. (2009). Generalized ICP. *Proceedings of Robotics: Science and Systems*, Seattle, USA.
- Shan J., Toth C.K. (2008). Topographic Laser Ranging and Scanning: Principles and Processing. CRC Press Taylor Francis, London.
- Schickler W & Thorpe A. (2001). Surface estimation based on LiDAR. *American Society of Photogrammetry & Remote Sensing Annual Conference*, April 23-27, St. Louis, Missouri, USA.
- Shirowzhan, S. & Sepasgozar, S. (2019). Spatial Analysis Using Temporal Point Clouds in Advanced GIS: Methods for Ground Elevation Extraction in Slant Areas and Building Classifications. *International Journal of Geo-Information*, 8, 120.
- Silva L., Bellon O. & Boyer K. (2005). Precision range image registration using a robust surface interpenetration measure and enhanced genetic algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(5), 762–776.
- Silvan-Cardenas J. & Wang L. (2006). A multi-resolution approach for filtering LiDAR altimetry data. *ISPRS Journal of Photogrammetry & Remote Sensing*, 61(1): 11–22.
- Sithole G. (2001). Filtering of laser altimetry data using a slope adaptive filter. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 34(3/W4): 203–210.

- Sithole G. & Vosselman G. (2005). Filtering of airborne laser scanner data based on segmented point clouds. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 36(3/W19): 66–71.
- Smadja L., Ninot J. & Gavrilovic T. (2010). Road extraction and environment interpretation from LiDAR sensors. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 38(3/A): 281–286.
- Soilán, M., Truong-Hong, L., Riveiro, B. & Laefer, D. (2018). Automatic extraction of road features in urban environments using dense ALS data. *International Journal of Applied Earth Observation and Geoinformation*, 2108 64, 226-236.
- Sotoodeh S. (2007). Hierarchical clustered outlier detection in laser scanner point clouds. *Laser07*, 383.
- Tang J., Chen Y., Niu X., Wang L., Chen L., Liu J., Shi C. & Hyypä J. (2015). LiDAR Scan Matching Aided Inertial Navigation System in GNSS-Denied Environments. *Sensors*, 15(7): 16710–16728.
- Tereshchenko, V.; Tereshchenko, Y. (2017). Triangulating a region between arbitrary polygons. *International Journal of Computing*. 16. 160-165.
- Teo TA & Huang SH. (2014). Surface-based registration of airborne and terrestrial mobile LiDAR point clouds. *Remote Sensing*, 6, 12686–12707.
- Titterton D. & Weston J. (2004). Strapdown Inertial Navigation Technology. *Aerospace & Electronics Systems Magazine IEEE*, 20, 33-34.
- Thapa A, Pu S, Gerke M. 2009. Semantic Feature Based Registration of Terrestrial Point Clouds. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, Workshop Laser scanning '09, 230–235.
- Tsin, Yanghai & Kanade, Takeo. (2004). A Correlation-Based Approach to Robust Point Set Registration. *ECCV*. 3. 558-569. 10.1007/978-3-540-24672-5_44.
- Tyagur N & Hollaus M. (2016). Digital Terrain Models from Mobile Laser Scanning Data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, XLI, Part B3, 387–394.
- Vallet B & Papelard JP. (2015). Road orthophoto/DTM generation from mobile laser scanning. *Annals of Photogrammetry Remote Sensing and Spatial Information Sciences*, 3/W5,377–384.
- Verghese S. (2017)., Self-driving cars and lidar. *CLEO Appl. Technol. Opt. Soc. Amer.*, AM3A.1.
- Vollmer J., Mencl R. & Muller H. (1999). Improved Laplacian Smoothing of Noisy Surface Meshes. In: Brunet P, Scopigno R. (eds.), *Euro graphics*, Vol. 18 (3).
- Vosselman G. (2000). Slope based filtering of laser altimetry data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 33(B3/2): 935–942.
- Wack R & Wimmer A. (2001). Digital terrain models from airborne laser scanner data – a grid-based approach. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 34(3B): 293–296.
- Wang Z & Brenner C. (2008). Point based registration of terrestrial laser data using intensity and geometry features. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, Beijing, China.

- Weinmann M., Hinz S. & Jutzi B. (2011). Fast and automatic image-based registration of TLS data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6), 62–70.
- Woodman O. (2007). An introduction to inertial navigation, *Technical Report 696*. University of Cambridge.
- Wang C. & Glenn N. (2009). Integrating LiDAR intensity and elevation data for terrain characterization in a forested area. *IEEE Geoscience and Remote Sensing Letters*, 6(3): 463–466.
- Wu B., Guo J., Hu H., Li Z. & Chen Y. (2013). Co-registration of lunar topographic models derived from Chang'E-1, SELENE, and LRO laser altimeter data based on a novel surface matching method. *Science Direct. Earth Planetary Science Letter*, 364, 68–84.
- Xu S., Wang R. & Zheng H. (2017). Road curb extraction from mobile LiDAR point clouds, *IEEE Transactions on Geoscience and Remote Sensing*. 55, 2, 996-1009.
- Yang, B., Huang, R., Dong, Z., Zang, Y. & Li, J. (2016). Two-step adaptive extraction method for ground points and break lines from lidar point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*. 119. 373-389. Doi: 10.1016/j.isprsjprs.2016.07.002.
- Yuan X., Zhao C. & Zhang H. (2010). Road detection and corner extraction using high definition LiDAR. *Information Technology Journal*, 9: 1022–1030.
- Zai D. (2018) 3-D road boundary extraction from mobile laser scanning data via super voxels and graph cuts. *Trans. Intell. Transp. Syst.*, 19, 3, 802–813.
- Zarembski, A., Grissom, G. & Euston, T. (2014). On the Use of Ballast Inspection Technology for the Management of Track Substructure. *Transp. Infrastruct. Geotech.*, 1, 83–109.
- Zhang K & Whitman D. (2005). Comparison of three algorithms for filtering airborne LIDAR data. *Photogrammetric Engineering & Remote Sensing*, 71(3): 313–324.
- Zhang K & Cui Z. (2007). Airborne LiDAR Data Processing and Analysis Tools, *ALDPAT 1.0. National Center for Airborne Laser Mapping, International Hurricane Research Center, Department of Environmental Studies, Florida International University*, pp. 81.
- Zhang K, Chen S, Whitman D, Shyu M, Yan J, Zhang C. 2003. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 41(4): 872–882.
- Zhang, Y., Wang, J., Wang, X. & Dolan, J. (2018). Road-segmentation-based curb detection method for self-driving via a 3D-LiDAR sensor. *Trans. Intell. Transp. Syst.* 19, 12, 3981–3991.
- Zhao, J. & Yuan, J. (2012). Curb detection and tracking using 3D-LIDAR scanner. *19th IEEE International Conference on Image Processing*, Orlando. 437-440.
- Zaksek K. & Pfeifer N. (2006). An improved morphological filter for selecting relief points from a LiDAR point cloud in steep area with dense vegetation. *IEEE Transactions on Geoscience and Remote Sensing*, 41(4): 872–882.
- Zhou, L. & Vosselman, G. (2012). Mapping curbstones in airborne and mobile laser scanning data. *International Journal of Applied Earth Observation and Geoinformation*. 18, 293-304.