



Instituto Universitário de Lisboa

Departamento de Ciências e Tecnologias da Informação

Deteção de Obstáculos em Passagens de Nível

Vítor José Matias Amaral

Dissertação submetida como requisito parcial para obtenção do grau de
Mestre em Engenharia Informática

Orientador

Prof. Doutor Pedro Figueiredo Santana, Professor Auxiliar
ISCTE - Instituto Universitário de Lisboa

Setembro, 2015

Quem? O infinito?
Diz-lhe que entre.
Faz bem ao infinito
estar entre gente.

Alexandre O'neill

Resumo

As passagens de nível automáticas são pontos sensíveis na ferrovia, onde anualmente ocorrem acidentes com vítimas mortais. Com vista a mitigar o número de vítimas, esta dissertação apresenta um sistema para detecção de obstáculos em passagens de nível a partir de nuvens de pontos 3D recolhidas com um sensor laser 2D montado sobre uma plataforma oscilante.

Numa fase de calibração, o sistema aprende a posição e orientação da passagem de nível relativamente ao sensor laser. Seguidamente o sistema aprende um mapa volumétrico que indica as zonas da passagem de nível que estão ocupadas com objetos estáticos e, portanto, não são obstáculos. Terminado o treino, o sistema procura, antes de cada passagem de um comboio, por objetos presentes no ambiente que não estejam representados no mapa volumétrico aprendido. Esses objetos são reportados como obstáculos, cujo nível de relevância varia de acordo com as suas dimensões e distância ao eixo da via.

Comparativamente a sistemas anteriores, tipicamente baseados em RADAR, câmaras de vídeo e sensores laser estáticos, o sistema aqui apresentado é capaz de simultaneamente detetar obstáculos de menor volumetria, ser robusto a variações de iluminação e ser calibrado de forma semi-automática, o que reduz o tempo de instalação. Estas características foram validadas num conjunto de 32 nuvens de pontos recolhidas numa passagem de nível ocupada com obstáculos de variada dimensão. Os testes experimentais mostram que o sistema é capaz de detetar obstáculos de volumetria igual ou superior a $\approx 10 \text{ dm}^3$ em cerca de 615 ms. Este desempenho é suficiente para garantir os requisitos operacionais das passagens de nível automatizadas.

Palavras-chave: Detecção de Obstáculos, Passagens de Nível, PN, Sistema de Detecção de Obstáculos, SDO, PCL, Point Cloud Library.

Abstract

Automatic level crossings are sensitive points on the railway infrastructure, where accidents occur annually with fatalities. In order to mitigate the number of victims, this work presents a system for obstacle detection at level crossings from 3D point clouds acquired with tilting 2D laser scanners.

During a calibration phase, the system learns the position and orientation of the level crossing with respect to the laser sensor. Then, the system learns a volumetric map indicating the level crossing's zones that are occupied with static objects and, therefore, are not obstacles. After the training phase, the system checks, before each passage of a train, for the presence of objects in the environment that are not represented in the learnt volumetric map. These objects are reported as obstacles, whose level of importance varies according to their size and distance to the center of the track.

Compared to previous systems, typically based on RADAR, video cameras, and static 2D laser scanners, the system herein presented is capable of simultaneously detecting obstacles of lower volume, robustly handle lighting variations, and being calibrated semi-automatically, which reduces setup time. These characteristics were validated on a set of 32 point clouds acquired on a level crossing occupied with obstacles of various sizes. The experimental results show that the system is able to detect obstacles as small as $\approx 10 \text{ dm}^3$ in 615 ms. This performance is sufficient to ensure the operational requirements of automated level crossings.

Keywords: Detection of Obstacles, Level Crossings, LC, Obstacle Detection System, ODS, PCL, Point Cloud Library.

Agradecimentos

Um agradecimento, muito singelo e sincero, ao Doutor José Manuel Matos Pinto, que desde a Licenciatura me tem dado o seu apoio e a força necessária, nas horas mais difíceis, para que fosse possível terminar este curso.

Gostaria de agradecer ao meu orientador científico, Prof. Doutor Pedro Santana, pela oportunidade que me proporcionou na realização desta dissertação. Em todos os momentos, soube sempre encontrar as palavras certas e o rigor necessário, partilhando experiências, mostrando uma disponibilidade total e a dose de paciência necessária, para que fosse possível concluir este trabalho.

Gostaria também de agradecer ao ISCTE, pelas meios que proporcionou e pelo acolhimento que ofereceu, para que fosse possível a minha evolução profissional e pessoal. A todos os colegas que comigo participaram nesta aventura, em especial ao Telmo, à Guida, à Alexandra, ao Gilberto, ao José, ao Daniel Candeias, ao Daniel Sousa e ao Tiago. Também gostaria de agradecer aos colegas Francisco Marques e André Lourenço da UNINOVA pela preciosa colaboração que deram na recolha das nuvens de pontos.

Gostaria de agradecer também à minha família e aos meus amigos, porque os privei da minha companhia durante o tempo que durou esta aventura. Também um especial agradecimento aos meus colegas de trabalho pela compreensão e incentivo que me deram.

Conteúdo

Resumo	v
Abstract	vii
Agradecimentos	ix
Lista de Figuras	xv
Acrónimos	xix
1 Introdução	1
1.1 Motivação	1
1.2 Enquadramento	3
1.3 Questão de Investigação	4
1.4 Objetivos	5
1.5 Método de Investigação	5
1.6 Organização do documento	6
2 Revisão da Literatura	7
2.1 Tecnologias de deteção	7
2.1.1 Espiras Magnéticas	8
2.1.2 Sensores de interrupção de feixe óptico	9
2.1.3 Sensores de Ultrassons	9
2.1.4 Câmaras de vídeo	11
2.1.5 RADAR	12
2.1.6 LIDAR	13
2.2 Sistemas de deteção	14
2.2.1 Sistema de deteção a partir de visão monocular	14
2.2.2 Sistema de deteção a partir de visão binocular	15
2.2.3 Sistema LIDAR	17
2.2.4 Sistema de Radar de Micro-Ondas	19
3 Descrição do Sistema Proposto	21
3.1 A passagem de nível: assunções e requisitos	21
3.2 Visão global do sistema	23
3.2.1 Fase mapeamento semântico da PN	24

3.2.2	Fase de detecção e caracterização dos obstáculos	25
3.3	Detecção da localização das Meias Barreiras	26
3.3.1	Detecção das Meias Barreiras	26
3.3.1.1	Rejeitar pontos ao nível do chão	27
3.3.1.2	Agrupar pontos	28
3.3.1.3	Rejeitar agrupamentos pela sua altura	29
3.3.1.4	Calcular centróides dos agrupamentos	30
3.3.2	Detecção da passagem de nível	30
3.3.2.1	Encontrar PN	31
3.3.2.2	Definição das áreas de supervisão	33
3.3.2.3	Projetar centróides das MB no plano	35
3.3.2.4	Criação das zonas de supervisão B e C	35
3.4	Detecção dos Carris	36
3.4.1	Criar área para pesquisa dos carris	36
3.4.2	Algoritmo para pesquisa dos carris	38
3.4.3	Estrutura de dados auxiliar para pesquisa dos carris	41
3.4.4	Obtenção dos segmentos de reta que representam os carris	41
3.4.5	Obtenção da distância entre carris	42
3.5	Mapeamento volumétrico	42
3.6	Processamento e detecção dos obstáculos	45
3.6.1	Detecção de Obstáculos	45
3.6.1.1	Isolar pontos na zona do gabarito	45
3.6.1.2	Remover pontos <i>outliers</i>	46
3.6.1.3	Rejeitar pontos ao nível do chão	47
3.6.1.4	Detetar alterações	47
3.6.2	Caracterização dos obstáculos	48
3.6.2.1	Caraterização do obstáculo pela altura	49
3.6.2.2	Caraterização do obstáculo pela largura	49
3.6.2.3	Caraterização do obstáculo pela distância ao eixo da via	49
4	Resultados Experimentais	51
4.1	Instalação Experimental	51
4.2	Conjunto de dados	52
4.3	Parametrização do Sistema	53
4.3.1	Detecção das meias barreiras	54
4.3.1.1	Rejeitar pontos ao nível do chão	54
4.3.1.2	Agrupar pontos	55
4.3.1.3	Rejeitar agrupamentos pela altura	56
4.3.2	Detecção dos carris	56
4.3.3	Detecção dos obstáculos	57
4.3.3.1	Isolar pontos na zona do gabarito	57
4.3.3.2	Rejeitar pontos ao nível do chão	58
4.3.3.3	Detetar alterações	59

4.3.3.4	Agrupar pontos	59
4.3.3.5	Filtrar pontos acima do chão	60
4.4	Desempenho do Sistema	60
4.5	Análise de sensibilidade	62
4.5.1	Tempo médio de processamento das <i>octrees</i>	63
4.5.1.1	Considerações	63
4.5.2	Deteção das Meias Barreiras	64
4.5.2.1	Considerações	66
4.5.3	Deteção dos carris	66
4.5.3.1	Considerações	67
4.5.4	Deteção dos obstáculos	68
4.5.4.1	Considerações	71
5	Conclusões e Trabalho Futuro	73
5.1	Conclusões	73
5.2	Trabalho Futuro	75
A	Descrição das Nuvens de Pontos	79
B	Tempos de processamento	81
C	Visualização dos obstáculos existentes por nuvem de pontos	83
	Bibliografia	89

Lista de Figuras

1.1	Supressões e reclassificações nos últimos 16 anos.	2
2.1	Deteção de obstáculos utilizando espiras magnéticas.	8
2.2	Sensores de interrupção de feixe óptico usado no Japão.	10
2.3	Exemplo de deteção de obstáculos por sensores de ultrassons.	10
2.4	Princípio de funcionamento da tecnologia de deteção de obstáculos por radar.	12
2.5	Método de deteção do sensor LIDAR com duas possibilidades de varrimento.	13
2.6	Princípio de funcionamento do detetor de obstáculos da IHI.	18
2.7	Método de deteção de um obstáculo utilizado pelo SDO da IHI.	18
2.8	Arquitetura do SDO por RADAR instalado na PN do Sabugo.	19
3.1	PN do Sabugo com as MB em cima e em posição quase vertical.	23
3.2	Localização do Sensor LIDAR na PN	24
3.3	Modelo global do Sistema - Mapeamento semântico da PN.	25
3.4	Modelo global do Sistema - Deteção e caraterização dos obstáculos.	26
3.5	Modelo para deteção da localização das MB.	27
3.6	Exemplo do conjunto de todos os centróides obtidos para a deteção das MB.	31
3.7	Exemplo das formas utilizadas para estimar a posição das MB.	31
3.8	Estimar posição das MB.	32
3.9	Eleição da combinação de centróides correspondente à disposição das MB.	33
3.10	Definição das Zonas de Supervisão de obstáculos na PN.	34
3.11	Exemplificação para obter a posição relativa do ponto p em relação ao quadrilátero representado na figura.	35
3.12	Minimizar o erro na estimação da localização dos carris.	37
3.13	Definição das zonas de pesquisa dos carris formadas pelos segmentos de reta ac e df	37
3.14	Obtenção dos vetores de pesquisa dos carris, v ₁ e v ₂ , v ₃ e v ₄ , com origem nos pontos b e e , respetivamente, e que cruzam os carris.	38
3.15	Ilustração da metodologia utilizada para o deslocamento do vetor v ₁ para obtenção de um novo ponto a pesquisar.	39
3.16	Representação esquemática dos centróides c ₁ , c ₂ , c ₃ e c ₄ sobre os carris.	39

3.17	Representação dos carris R_+ e R_-	42
3.18	Resultado da detecção da posição dos carris	43
3.19	Subdivisão do espaço 3D de uma <i>octree</i> até ao nível 3.	44
3.20	Representação do eixo da via e da área de gabarito.	46
4.1	Área da PN coberta pela nuvem de pontos.	52
4.2	A imagem ilustra o contexto da PN.	53
4.3	Alguns dos tipos de obstáculos de baixa volumetria considerados nos testes.	53
4.4	Segmentação da nuvem de pontos referência $\mathcal{P}_0$ utilizada para fazer a detecção das MB.	55
4.5	Parametrização dos parâmetros, ω_1 e ω_2 , utilizados para obtenção das zonas para pesquisa dos carris.	57
4.6	Gabarito para as zonas de supervisão A, B e C.	58
4.7	Densidade de pontos nas zonas de supervisão A, B e C.	59
4.8	Nuvem de pontos 19 - Quatro pessoas na zona A.	62
4.9	Nuvem de pontos 21 - Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C.	62
4.10	Gráfico do tempo médio de processamento da <i>octree</i>	64
4.11	Exemplo da detecção das MB e Carris, utilizando os valores atribuídos aos parâmetros na configuração escolhida.	65
4.12	Resultados dos testes de sensibilidade realizados aos parâmetros utilizados na detecção das MB.	66
4.13	Resultados dos testes de sensibilidade realizados aos parâmetros utilizados na detecção dos Carris.	67
4.14	Resultados do teste de sensibilidade ao parâmetro d_l utilizando a nuvem de pontos 21.pcd.	68
4.15	Resultados do teste de sensibilidade ao parâmetro d_l utilizando a nuvem de pontos 31.pcd.	69
4.16	Resultados dos testes de sensibilidade aos parâmetros K_B e α_B utilizando a nuvem de pontos 31.pcd.	70
4.17	Resultado do teste de sensibilidade ao parâmetro d_p^A utilizando a nuvem de pontos 21.pcd.	71
4.18	Resultado do teste de sensibilidade ao parâmetro n_{min}^A utilizando a nuvem de pontos 21.pcd.	72
4.19	Resultado do teste de sensibilidade ao parâmetro n_{min}^A , com -10% do valor utilizado na configuração escolhida, utilizando a nuvem de pontos 11.pcd, que está vazia de obstáculos.	72
C.1	Nuvem de pontos 10 - Carro a passar na zona A	83
C.2	Nuvem de pontos 12 - Carro a passar na zona A	83
C.3	Nuvem de pontos 13 - Carro a passar na zona A	83
C.4	Nuvem de pontos 14 - Camião a passar na zona A	84
C.5	Nuvem de pontos 17 - Três pessoas na zona A	84
C.6	Nuvem de pontos 18 - Quatro pessoas na zona A	84
C.7	Nuvem de pontos 19 - Quatro pessoas na zona A	84

C.8	Nuvem de pontos 20 - Duas pessoas e um cesto de papéis na zona A e um jerrican na zona B	84
C.9	Nuvem de pontos 21 - Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C	84
C.10	Nuvem de pontos 22 - Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C	85
C.11	Nuvem de pontos 23 - Um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C	85
C.12	Nuvem de pontos 24 - Um cesto de papéis e a cauda de um carro na zona A e uma pessoa ajoelhada na zona B	85
C.13	Nuvem de pontos 25 - Um cesto de papéis na zona A e uma pessoa ajoelhada na zona B	85
C.14	Nuvem de pontos 26 - Um cesto de papéis na zona A	85
C.15	Nuvem de pontos 27 - Um cesto de papéis na zona A e uma pessoa ajoelhada na zona B	85
C.16	Nuvem de pontos 28 - Um carro a passar na zona A e uma pessoa e uma pedra junto a um dos carris na zona B	86
C.17	Nuvem de pontos 29 - Uma pessoa na zona B	86
C.18	Nuvem de pontos 30 - Uma pedra encostada ao carril e ao estrado da PN e uma pessoa do lado de fora da via na zona B	86
C.19	Nuvem de pontos 31 - Uma pessoa na zona A, uma pessoa e uma pedra encostada ao carril e ao estrado da PN na zona B	86
C.20	Nuvem de pontos 32 - Duas pessoas na zona B	86
C.21	Nuvem de pontos 33 - Um carro a passar na zona A	87
C.22	Nuvem de pontos 34 - Um carro a passar na zona A	87
C.23	Nuvem de pontos 35 - Um carro a passar na zona A	87
C.24	Nuvem de pontos 36 - Traseira de um carro a sair na zona A	87
C.25	Nuvem de pontos 37 - Uma pessoa e um jerrican na zona B	87
C.26	Nuvem de pontos 38 - Uma pedra encostada ao carril na zona B	88
C.27	Nuvem de pontos 39 - Uma pedra encostada ao carril na zona B	88
C.28	Nuvem de pontos 41 - Uma pedra encostada ao carril na zona B	88

Acrónimos

AVS	A utomatic V ideo- S urveillance
BC	B arreiras C ompletas
BSD	B erkley S oftware D istribution
CCTV	C losed- C ircuit T ele V ision
CCD	C harge- C oupled D evice
ERA	E uropean R ailway A gency
IMU	I nertial M easurement U nit
IP	I nfraestruturas de P ortugal
LIDAR	L ight D etection A nd R anging
MB	M eia B arreira
PCL	P oint C loud L ibrary
PN	P assagem de N ível
RANSAC	R ANdom S Ample C onsensus
ROS	R obot O perating S ystem
SDO	S istema de D eteção de O bstáculos
UE	U nião E uropeia

Lista de Símbolos

A lista seguinte contém os símbolos mais utilizados ao longo desta dissertação, a sua descrição e a secção onde o símbolo surge pela primeira vez.

Símbolo	Descrição	Secção
$\mathcal{P}_0$	Nuvem de pontos referência, utilizada para fazer a deteção das MBs e dos carris	3.3.1.1
$\mathcal{P}'_0$	Nuvem de pontos obtida, depois de segmentada a nuvem de pontos $\mathcal{P}_0$	3.3.1.1
d_l	Distância limiar para rejeitar pontos ao nível do chão	3.3.1.1
k	Número máximo de iterações	3.3.1.1
π	Plano definido pela equação paramétrica $\alpha = ax + by + cz + d$, estimado a partir de um conjunto de dados contendo valores discrepantes	3.3.1.1
$\mathbf{p}$	Ponto 3D com coordenadas geométricas $\{x,y,z\}$	3.3.1.1
$\mathcal{A}$	Conjunto de agrupamentos diferentes	3.3.1.2
$\mathbf{a}$	Agrupamento constituído por um conjunto de pontos $\mathbf{p}$, com as mesmas características	3.3.1.2
d_{min}	Distância máxima imposta entre agrupamentos diferentes	3.3.1.2
n_{min}	Define o número mínimo de pontos necessários que um agrupamento precisa de conter para ser considerado válido	3.3.1.2
n_{max}	Define o número máximo de pontos que um agrupamento pode conter para ser considerado válido	3.3.1.2
z	Eixo z de um sistema de coordenadas	3.3.1.3
h_z	Rejeitar agrupamentos pela sua altura	3.3.1.3
Δz	Distância máxima entre quaisquer dois pontos em $\mathbf{a}_i$	3.3.1.3
$\mathcal{A}'$	Conjunto dos centróides filtrados pela coordenada z	3.3.1.3
$\bar{\mathbf{c}}$	Centróide de um agrupamento de pontos	3.3.1.4
$\mathcal{B}$	Conjunto de todos os centróides	3.3.1.4
$\mathbf{q}_r$	Forma esperada na origem do referencial	3.3.2.1
$\mathbf{q}$	Forma desconhecida dado n vértices v	3.3.2.1
$\mathbf{v}'$	Representa um vértice da forma conhecida	3.3.2.1
$\mathbf{v}$	Representa um vértice da forma desconhecida	3.3.2.1
$\mathcal{Q}$	Conjunto de todas as formas	3.3.2.1
n	Número de vértices de uma forma	3.3.2.1

Continua na página seguinte

Continuação da página anterior

Símbolo	Descrição	Secção
$\hat{\mathbf{q}}_0$	Representa a combinação de centróides eleita, que corresponde à localização da PN	3.3.2.1
$\mathcal{Z}$	Zona de supervisão para deteção de obstáculos, definida por um quadrilátero	3.3.2.2
$\mathbf{p}_{proj}$	Ponto $\mathbf{p}$ projetado no plano π	3.3.2.3
ω_1	Valor do deslocamento da origem do vetor $\mathbf{u}_1$	3.4
ω_2	Valor do deslocamento da origem do vetor $\mathbf{u}_2$	3.4
r	Raio de uma esfera para obter os pontos em torno da vizinhança do ponto a pesquisar	3.4
β	Fator de incremento do vetor de pesquisa dos carris	3.4
$\mathcal{C}$	Conjunto de nuvens de pontos utilizadas para criar os mapas volumétricos	3.5
$\mathcal{M}$	Mapa volumétrico definido para uma zona de supervisão composto por objetos que não são considerados obstáculos	3.5
$\mathcal{P}$	Nuvem de pontos capturada pelo sensor LIDAR	3.6.1.1
$\mathcal{Z}$	Zona de supervisão definida para deteção de obstáculos	3.6.1.1
$dist_A^g$	Máxima distância de gabarito definida para a zona A	3.6.1.1
$\mathcal{G}$	Nuvem de pontos que representa o gabarito	3.6.1.1
$\mathbf{r}$	Segmento de reta que define o eixo da via férrea	3.6.1.1
$\mathcal{P}^k$	Conjunto de pontos $\mathbf{p}_j$, localizados na vizinhança de um dado ponto $\mathbf{p}_i$, com $(j \leq k)$	3.6.1.2
$\mathcal{G}'$	Nuvem de pontos que representa o gabarito depois de os pontos <i>outliers</i> terem sido removidos	3.6.1.3
$\mathcal{E}$	Mapa volumétrico instantâneo da PN	3.6.1.3
d_p^A	Distância do ponto $\mathbf{p}$ ao plano π_A da zona A	3.6.1.4
$\mathcal{O}$	Conjunto de obstáculos formados pelos agrupamentos do conjunto $\mathcal{A}$	3.6.2.1
h_o	Altura do obstáculo $\mathbf{o}$	3.6.2.1
l_o	Largura do obstáculo $\mathbf{o}$	3.6.2.2
d_o	Distância do obstáculo $\mathbf{o}$ ao eixo da via	3.6.2.3

Capítulo 1

Introdução

1.1 Motivação

As passagens de nível (PN), no caminho de ferro, são um ponto de conflito e de insegurança, quer para a exploração ferroviária, quer para os utilizadores da rodovia. Por esse motivo o aumento da segurança é uma das prioridades para a Infraestruturas de Portugal, S.A. (IP, S.A.) em cumprimento com o decreto-lei nº 568/99 de 23 de dezembro, que impõe objetivos de redução da sinistralidade em PN [1]. Para dar cumprimento ao referido decreto-lei, a IP, S.A. elabora anualmente um programa de supressão e reclassificação de passagens de nível [2]. Reclassificar uma PN significa uma alteração da sua tipologia, que pode incluir, por exemplo, automatizá-la com meias barreiras ou melhorar as condições de visibilidade da mesma. Suprimir uma PN significa criar uma passagem desnivelada ou criar caminhos de ligação alternativos, obedecendo aos critérios definidos no decreto-lei [2].

O gráfico ilustrado na Figura 1.1 mostra o resultado dos programas anuais de supressão e reclassificação desde a entrada em vigor do decreto-lei nº 568/99, onde é possível observar que em 31 de dezembro de 1999 existiam na rede ferroviária nacional 2494 passagens de nível e em 31 de dezembro de 2014 existiam apenas 856 passagens de nível, a que corresponde a uma redução de 66% das passagens de nível na rede ferroviária nacional, em 16 anos.

A Tabela 1.1 apresenta o número de acidentes ocorridos dos últimos 16 anos, por categoria de PN. Os dados mostram que a sinistralidade em PN baixou em




FIGURA 1.1: Supressões e reclassificações nos últimos 16 anos.
(Os dados do gráfico foram obtidos de [3])

TABELA 1.1: Acidentes por categoria de PN nos últimos 16 anos.

Ano	Categoria						Total
	ACMB	ASMB	Com Guarda	Sem Guarda	Particulares	Peões	
1999	17	15	20	87	5	8	154
2000	19	16	8	66	3	7	119
2001	14	13	10	79	1	6	123
2002	16	15	10	60	1	11	113
2003	9	14	7	64	3	8	105
2004	19	16	4	51	2	10	102
2005	9	6	6	39	4	8	72
2006	17	4	1	37	2	7	68
2007	14	1	3	37	1	10	66
2008	11	3	-	32	4	5	55
2009	11	1	-	29	1	7	49
2010	11	-	2	20	-	5	38
2011	10	-	-	13	1	1	25
2012	10	-	1	9	1	4	25
2013	11	-	1	12	1	2	27
2014	11	1	1	7	1	5	26

ACMB = Automatizadas com meias barreiras; ASMB = Automatizadas sem meias barreiras
Os dados da tabela foram obtidos de [3]

cerca de 83% e que a política de supressão e reclassificação de passagens de nível, bem como a melhoria das condições de segurança, têm produzido bons resultados.

Contudo, a sinistralidade em PN automatizadas com meias barreiras (ACMB) tem sido ainda muito elevada, tendo nos últimos 4 anos representado 40% dos acidentes ocorridos em cada um desses mesmos anos [1].

A nível europeu o panorama não é melhor. O relatório sobre segurança em passagens de nível, publicado pela European Railway Agency (ERA) em 2014, refere que em 2012 ocorreram 555 acidentes de que resultaram 686 vítimas, entre mortos e feridos graves [4]. Estes acidentes representam mais de um quarto de todos os acidentes que ocorreram na infraestrutura ferroviária nesse ano [4].

A elevada sinistralidade leva a que hoje em dia exista uma grande preocupação por parte das empresas gestoras das infraestruturas ferroviárias em instalar sistemas que aumentem a segurança dos utentes das PN. Neste contexto, é necessário recorrer a novos meios tecnológicos que permitam melhorar as condições de segurança, uma vez que os acidentes têm sempre consequências quer para as pessoas, quer para a disponibilidade da infraestrutura e para os operadores ferroviários. De forma a mitigar os riscos de acidentes em PN, têm vindo a ser desenvolvidos sistemas de deteção de obstáculos baseados em sensores (ver Secção 2.2), oferecendo soluções complementares de segurança. Esta dissertação enquadra-se neste esforço de desenvolvimento de detetores de obstáculos cada vez mais robustos e precisos.

1.2 Enquadramento

A sinistralidade em passagens de nível é um problema real, onde infelizmente, os comportamentos de risco são uma causa corrente [5]. Este, não é apenas um problema português; outros países, como por exemplo USA e Inglaterra, têm um problema semelhante e começam a utilizar outros tipos de abordagem que permitam mitigar o risco de acidente, nomeadamente os comportamentos de risco por parte dos utilizadores e as violações ao código da estrada, conhecidos como “*THREE Es*” [6] [7], a saber:

- *Engineering*¹ – Promover a investigação e desenvolver novas soluções de engenharia, para tornar as PN mais seguras, de maneira a mitigar o risco de acidente;

¹Em português: Engenharia.

- *Education*² – Consciencializar os utentes das passagens de nível para os cuidados a ter e as regras a cumprir, para prevenir comportamentos de risco. Todos os anos são feitas campanhas de sensibilização pelas empresas gestoras da infraestrutura ferroviária, como por exemplo a campanha “Pare Escute Olhe”;
- *Enforcement*³ – Maior cooperação entre as autoridades civis e as empresas gestoras da infraestrutura ferroviária no sentido de promover um maior sentido de responsabilidade da parte dos utilizadores das PN e, se necessário, penalizar os utilizadores que não respeitem a sinalização de proibição de passar pela PN.

Esta dissertação insere-se no E de *Engineering* e pretende dar o seu contributo na investigação da deteção de obstáculos no contexto de uma PN, que permita desenvolver novas soluções que aumentem as suas condições de segurança.

No contexto de uma PN, um obstáculo é tudo aquilo que possa pôr em perigo a circulação ferroviária originando um acidente. Neste contexto incluem-se obstáculos de variada dimensão, cuja catalogação em termos de alarmística deve ter em conta a sua localização na área de influência da PN. Existe, portanto, a necessidade de analisar os resultados da deteção no contexto espacial da PN, algo que ainda não foi coberto de forma sistemática por trabalhos anteriores (e.g. [8] [9]).

1.3 Questão de Investigação

Um sistema de deteção de obstáculos deve afetar o menos possível a disponibilidade da infraestrutura, i.e., deve cumprir a sua função gerando o mínimo possível de falsos alarmes. Alguns sistemas de deteção desenvolvidos têm limitações na deteção de objetos pequenos, pelo que a deteção de obstáculos tem-se centrado em veículos rodoviários, veículos de 2 rodas e pessoas (e.g. [8], [9]).

Já existem estudos de soluções baseadas em visão binocular que podem oferecer resultados a baixo custo (e.g., [10], [11]). Contudo, estes sistemas apresentam limitações importantes em condições de fraca iluminação e condições atmosféricas adversas. Estas limitações poderão ser bastante mitigadas por uma solução baseada em sensores laser denominados de LIDAR (*Laser Imaging Detection And Ranging*) (e.g., [12]).

²Em português: Educação.

³Em português: Fazer cumprir a lei.

Presentemente, os sistemas baseados em LIDAR são capazes de detetar de forma robusta obstáculos com um volume superior a 1 m^3 . Contudo, é necessário ser capaz de detetar obstáculos mais pequenos, que apesar de poderem não ser problemáticos para o comboio, o poderão ser para os utilizadores da PN quando projetados sobre estes. Esta dissertação apresenta um sistema, também ele baseado em LIDAR, desenvolvido com vista a corrigir esta limitação e, dessa forma, responder à seguinte questão de investigação:

É possível, recorrendo a nuvens de pontos 3D recolhidas com um sensor laser, detetar de forma automática obstáculos com volumetrias inferiores a 1 m^3 na zona de influência da PN?

1.4 Objetivos

Com vista a responder à pergunta de investigação foram definidos os seguintes objetivos para esta dissertação:

- Recolher nuvens de pontos 3D numa PN real recorrendo a um laser scanner 2D montado numa plataforma oscilante;
- Desenvolver um módulo de software que permita estimar a pose da PN e dos carris relativa ao sensor laser e, dessa forma, calibrar o detetor de obstáculos automaticamente;
- Desenvolver um módulo de software capaz de detetar obstáculos com volume inferior a 1 m^3 , quando presentes na área de influência da PN;
- Desenvolver um módulo de software que classifique os obstáculos detetados em termos da perigosidade que representam para o funcionamento da PN;
- Validar nas nuvens de pontos recolhidas na PN real os módulos de software que compõe o detetor de obstáculos.

1.5 Método de Investigação

O método de investigação utilizado obedeceu aos critérios definidos por Peffers et al. [13], no método Design Science Research Methodology Process Model, que é composto pelas seguintes 6 atividades: (1) Identificação do problema; (2) Definição dos objetivos da solução; (3) Concepção e Desenvolvimento; (4) Demonstração; (5) Avaliação; (6) Disseminação.

Na Secção 1.1 e na Secção 1.2 é identificado o problema, mostrando a necessidade de encontrar meios tecnológicos que permitam reforçar a segurança dos utilizadores das passagens de nível.

Na Secção 1.4 são definidos os objetivos desta dissertação de modo a responder à questão de investigação levantada na Secção 1.3.

No Capítulo 3 é descrita a concepção e a metodologia utilizada para desenvolver o sistema proposto nesta dissertação, de maneira a poder atingir os objetivos definidos.

No Capítulo 4 é feita a demonstração do sistema proposto nesta dissertação e é feita a avaliação dos resultados produzidos, de maneira a responder à questão em investigação para poder cumprir os objetivos definidos.

O trabalho apresentado nesta dissertação deu origem a um artigo com o título *Laser-Based Obstacle Detection at Railway Level Crossings*, que foi submetido para publicação no *Journal of Sensors*.

1.6 Organização do documento

Esta dissertação, para além deste capítulo, é composta por mais 5 Capítulos e 3 Anexos, organizados da seguinte maneira:

Capítulo 2 – Revisão da literatura dos sistemas de deteção de obstáculos em passagens de nível.

Capítulo 3 – Descrição do sistema proposto para fazer a deteção de obstáculos em passagens de nível.

Capítulo 4 – Apresentação da configuração experimental utilizada, parametrização e descrição dos testes de sensibilidade realizados para avaliar a robustez do sistema de deteção de obstáculos.

Capítulo 5 – Apresentação das conclusões, contribuições desta dissertação e novas oportunidades de investigação na área.

Anexo A – Apresentação de uma tabela com o conjunto de nuvens de pontos utilizadas para efetuar os testes do algoritmo de deteção de obstáculos

Anexo B – Apresentação de uma tabela com os tempos intermédios gastos pelo sistema, em cada uma das fases do processamento das nuvens de pontos.

Anexo C – Apresentação de uma impressão de cada uma das nuvens de pontos que contêm obstáculos, utilizando os valores atribuídos aos parâmetros na configuração inicial.

Capítulo 2

Revisão da Literatura

As passagens de nível têm sido identificadas como um ponto fraco nas infraestruturas ferroviária e rodoviária, afetando seriamente a segurança destas infraestruturas [10]. A solução mais confiável para diminuir o risco de acidente é suprimi-las ou reforçar a sua segurança [8]. Só com ações técnicas consertadas e complementadas por ações de sensibilização às populações em geral e aos utilizadores em particular, é possível diminuir o risco de acidente numa PN. No entanto, apesar dos esforços que têm sido feitos no aumento da segurança das PN, dotando-as de equipamentos automáticos de anúncio às circulações ferroviárias, que avisem e impeçam os utilizadores de atravessarem a via quando um comboio dela se aproxima, ainda ocorrem muitos acidentes com elevados prejuízos materiais e humanos [14]. Neste contexto e como forma de aumentar ainda mais a segurança das PN por parte de quem as utiliza, surgiram os sistemas de deteção de obstáculos (SDO) [15].

Os sistemas de deteção de obstáculos não se destinam a substituir os equipamentos já instalados [16], como por exemplo meias barreiras barreiras ou barreiras completas de comando automático, sinalização luminosa e avisos sonoros. Os SDO têm como finalidade fornecer informação adicional sobre o estado de ocupação da área da PN, i.e., verificar se está livre de obstáculos que ponha em risco a segurança das pessoas e das circulações ferroviárias quando um comboio dela se aproxima. Esta informação permite de forma automática e em tempo útil forçar a paragem do comboio antes da PN.

2.1 Tecnologias de deteção

Existem várias opções tecnológicas para detetar a presença de um objeto numa PN (e.g. [8] [16] [17]). No entanto, a sua escolha depende de vários fatores, como




FIGURA 2.1: Detecção de obstáculos utilizando espiras magnéticas. As linhas tracejadas a vermelho representam a zona onde as espiras magnéticas estão embebidas no chão da PN.

por exemplo, as condições ambientais e o tamanho do objeto a detetar. Apesar de existirem diferenças nas tecnologias utilizadas, o objetivo principal é fornecer um sistema para deteção de obstáculos que seja confiável e robusto. Tendo sido detetada a presença de um obstáculo, o detetor deve manter o sinal de proteção da PN fechado e informar o posto de comando central [16].

Foram identificados seis tipos de tecnologias que têm sido utilizadas na investigação, para fazer deteção de obstáculos em PN [16]: (a) Espiras Magnéticas¹; (b) Feixes Óticos²; (c) Sensores de Ultrassons³; (d) Câmaras de vídeo⁴; (e) RADAR⁵ e (f) LIDAR⁶. Seguidamente é detalhada cada uma destas tecnologias.

2.1.1 Espiras Magnéticas

Na área da PN são embebidas espiras indutivas no chão, como representado na Figura 2.1, com a capacidade para detetar as massas metálicas dos veículos que por lá passem ou estejam parados. Ao fazermos circular uma corrente eléctrica variável no tempo pelas espiras é gerado um campo magnético. Quando uma massa metálica passa sobre as espiras faz alterar o campo magnético, permitindo assim detetar o objeto [16].

¹do inglês *Induction Loops*

²do inglês *Optical Beam*

³do inglês *Ultrasonic Sensors*

⁴do inglês *Imaging*

⁵do inglês *RADio Detection And Ranging*

⁶do inglês *LASER Imaging Detection And Ranging*

O ajuste de sensibilidade do detetar deve ter em conta que existem objetos com pouca massa metálica e que é necessário detetar, como por exemplo pessoas que transportam pequenos objetos metálicos ou bicicletas, quando se encontram na área da PN. Também será necessário ter em conta as alterações do campo magnético causadas por veículos maiores, i.e., com uma grande massa metálica, quando estão na proximidade da PN mas fora do gabarito e que não devem ser considerados como um obstáculo [18]. Os limites de regulação inferior e superior têm que ser ajustados a cada local, de forma a garantir um eficaz funcionamento da PN.

Uma das vantagens na utilização de espiras magnéticas é a de não serem sensíveis às condições ambientais. Existem também algumas desvantagens, que são: não detetam pessoas; o elevado custo de instalação; não é imune às interferências electromagnéticas geradas pela electrónica de potência dos comboios e pela corrente de retorno da tração eléctrica dos comboios que circula pelos carris [19]; o esmagamento das espiras por acção do esforço mecânico exercido, pela passagem do transito rodoviário.

2.1.2 Sensores de interrupção de feixe óptico

Os sensores óticos (emissores e recetores) [20] são instalados na proximidade da PN, de maneira a que os feixes óticos a cruzem e não existam espaços onde possa ficar um veículo sem ser detetado. Cada emissor emite um feixe ótico orientado na direção do recetor. Os recetores, por sua vez, têm também um campo de receção definido, que intersesta o campo de emissão do emissor. Se o feixe ótico é interrompido, isso significa que existe um obstáculo na PN (ver Figura 2.2).

Este método apresenta a vantagem de ser fácil de substituir em relação a outros SDOs, no entanto, a instalação deste sistema é muito cara, necessita de vários detetores instalados ao longo da PN, não deteta pessoas e em dias com muita neve não funciona corretamente.

2.1.3 Sensores de Ultrassons

Os sensores de ultrassons foram concebidos para detetar a presença de objetos. Os sensores emitem pulsos de ultrassons que têm uma frequência inaudível para o ouvido humano. Quando o pulso de ultrassom atinge um objeto é refletido para o recetor pela superfície deste. Estes sensores permitem saber a distância (pelo tempo de ida e volta do pulso) e a orientação (pela direção do pulso refletido).




FIGURA 2.2: Sensores de interrupção de feixe óptico usado no Japão. No lado esquerdo da imagem está representado o princípio de funcionamento de detecção dos obstáculos, utilizando sensores óticos por interrupção de feixe óptico. No lado direito da imagem é mostrado um SDO para detecção dos obstáculos, que utiliza sensores óticos, instalado numa PN do Japão.

(Imagem adaptada de [17])

Os sensores de ultrassons são, normalmente instalados sobre uma estrutura de modo a ficarem suspensos e apontados para abaixo, na direção da estrada (ver Figura 2.3). Em linhas electrificadas obriga a ter cuidados especiais, para evitar interferências com a catenária. A catenária, é uma linha aérea longitudinal à via férrea, constituída pelo fio de contacto e uma estrutura para o suportar mecanicamente, que tem a função de transporte de energia, de tensão elevada⁷, para alimentação da locomotiva elétrica de um comboio [19]. Para abranger toda a área da PN é necessário instalar vários sensores para evitar zonas não cobertas e desta maneira garantir que os objetos que entram na área da PN sejam detetados.




FIGURA 2.3: Exemplo de detecção de obstáculos por sensores de ultrassons.

(Imagem adaptada de [8])

⁷No caso português a alimentação da catenária é feita a 25 kilovolts (KV).

A vantagem destes sensores é que tanto podem detetar veículos parados ou em movimento. Algumas desvantagens deste sensores são: o elevado custo dos sensores e da instalação; a sua susceptibilidade a atos de vandalismo, uma vez que são mais visíveis e acessíveis do que outros equipamentos utilizados para deteção de obstáculos; a sua sensibilidade às condições ambientais (são imprecisos em condições de congestionamento).

2.1.4 Câmaras de vídeo

Um dos principais objetivos para a introdução de sistemas de CCTV⁸ (circuito fechado de televisão) em PN é a deteção automática de eventos que comprometam a segurança dos utilizadores da PN [21] e de vigilância de suporte para intervenção humana, permitindo ao mesmo tempo a gravação de imagens para posterior análise. Alguns fornecedores de sistemas de deteção de obstáculos incluem-no nas soluções que propõem. A Grã-Bretanha tem instalado sistemas de CCTV em algumas passagens de nível, obrigando à intervenção humana para verificar se a PN está livre de obstáculos [16]. O CCTV pode também ser usado em PN para a prevenção do crime, monitorizar o tráfego rodoviário na PN ou detetar graves violações da lei por parte dos utilizadores, como por exemplo contorno das meias barreiras quando estão em baixo [16].

A imagem captada por câmaras video pode ser processada por *software* de maneira a classificar os objetos e automatizar os alarmes, i.e., fazer a deteção automática dos obstáculos. Esta tipo de solução baseada em visão monocular apresenta desvantagens devido à dificuldade em lidar com a presença de sombras, variações repentinas da iluminação e ao surgimento imprevisível de objetos (ver Secção 2.2.1). Para contornar estas dificuldades pode-se utilizar câmaras de visão estereoscópica. As câmaras de visão estereoscópica permitem distinguir os objetos tridimensionais das sombras e têm sido utilizadas em trabalhos de investigação na deteção de obstáculos em passagens de nível (e.g., [8], [21], [10], [22]). A visão estéreo ou binocular permite a reconstrução artificial de um objeto a três dimensões a partir de duas ou mais imagens do mesmo objeto, captadas a partir de pontos de vista diferentes. A sua capacidade para detetar objetos pela sua assinatura volumétrica resulta da capacidade de reconstrução 3D do ambiente. No caso mais comum são colocadas duas câmaras, uma ao lado da outra, com os seus eixos óticos paralelos, reproduzindo artificialmente a visão binocular dos animais.

⁸do inglês *Closed-Circuit TeleVision*

Na Secção 2.2.1 e na Secção 2.2.2 são descritos alguns trabalhos de investigação que aplicam os princípios da visão binocular e processamento de imagem no estudo de sistemas de deteção de obstáculos em passagens de nível.

2.1.5 RADAR

Radio Detection and Ranging (RADAR) [23] é um método que permite detetar objetos através de ondas de rádio. Seguidamente são descritos dois métodos.

No primeiro método o radar emite ondas de rádio sobre a área de interesse e fica à escuta do eco das ondas emitidas. Se receber um eco, isso significa que a onda de rádio emitida foi refletida pela superfície de um objeto. Analisando o eco recebido é possível determinar a distância, a posição e a velocidade a que o objeto se desloca. Sabendo-se o intervalo de tempo entre a onda emitida e o eco recebido e a velocidade de propagação das ondas de rádio na atmosfera, pode-se obter a distância a que está o objeto [16].

No segundo método a deteção do obstáculo com um radar é feita com a interrupção de feixe. A antena emissora emite um sinal de feixe, normalmente em frequência modulada (FM), para a antena recetora. Se um objeto entra na zona de propagação do feixe, o sinal perde-se ou chega enfraquecido à antena recetora, indicando a presença de um obstáculo (ver Figura 2.4). Numa PN a instalação das antenas do radar é feita na diagonal de maneira a cobrir toda a área de interesse. O número de feixes necessários depende da largura da PN e do tamanho mínimo do obstáculo a detetar [16].




FIGURA 2.4: Princípio de funcionamento da tecnologia de deteção de obstáculos por radar.

(Imagem adaptada de [15])

Uma das vantagens para o uso do radar em relação a outros meios de deteção, como por exemplo a imagem, é a facilidade de filtrar alguns falsos positivos. Por exemplo se uma folha de papel passasse pela PN empurrada pelo vento e no caso do detetor estar ativo é pouco provável que causasse uma falsa deteção, uma vez que as ondas de rádio passam através do papel e neste caso o feixe não seria interrompido [16].

Uma das desvantagens é a de que se os refletores forem accidental ou deliberadamente deslocados, isto pode interferir com o correto funcionamento do detetor. Existe outra desvantagem conhecida como *efeito de captura*: se existirem dois ou mais sinais emitidos na mesma frequência, o recetor irá responder ao sinal de maior potência e ignorar os restantes.

Em Portugal está instalado um sistema de radar de micro-ondas para deteção de obstáculos em PN, cuja deteção dos obstáculo é feita pelo método “interrupção de feixe”. Este sistema é descrito com mais detalhe na Secção 2.2.4.

2.1.6 LIDAR

LIDAR pode ser utilizado para detetar a presença de objetos, numa área de interesse. A Figura 2.5 ilustra o princípio de funcionamento LIDAR para detetar a presença de objetos.




FIGURA 2.5: Método de deteção do sensor LIDAR com duas possibilidades de varrimento: (a) Ângulo de varrimento de 100°; (b) Ângulo de varrimento de 180°. As linhas radiais de cor azul que saem do sensor LIDAR representam os feixes de laser gerados por este. O retângulo de cor cinzenta representa um obstáculo. Os feixes de laser emitidos pelo sensor quando encontram o obstáculo são refletidos para a fonte pela superfície deste. O tempo que o pulso de laser demora até ao obstáculo e a ser refletido pela superfície deste, para a fonte emissora, designa-se de tempo de voo. Através do tempo de voo de um pulso de laser obtém-se a distância entre o obstáculo e o equipamento emissor de pulsos de laser.

(Imagem adaptada de [24])

A área de interesse é varrida com pulsos de laser, que são refletidos pela superfície dos objetos. Os pulsos de laser refletidos podem ser analisados para determinar a localização e a direção. A localização do objeto é determinada a partir do tempo que o pulso de laser demora a ser refletido para a fonte; a direção é determinada a partir do ângulo de emissão do pulso de laser emitido e da orientação da reflexão do pulso de laser para a fonte [16].

A luz tem comprimentos de onda muito mais curtos do que as ondas de rádio, por isso o LIDAR tem maior precisão na determinação do tamanho dos objetos do que o radar. A área analisada pode ser controlada através da variação do ângulo em que o pulso é emitido [16].

Na Secção 2.2.3 é descrita uma solução para deteção de obstáculos baseada em LIDAR.

2.2 Sistemas de deteção

Nesta secção são apresentados alguns trabalhos que utilizam os princípios da visão binocular e uma solução que usa a tecnologia LIDAR e outra que usa a tecnologia RADAR.

2.2.1 Sistema de deteção a partir de visão monocular

Um método desenvolvido por Foresti [25] utiliza apenas uma câmara CCD (*Charge-Coupled Device*) colocada sobre poste alto num dos cantos da PN. A deteção dos obstáculos é efectuada pela diferença de imagens obtidas em momentos consecutivos. Assim, conhecendo os parâmetros intrínsecos da câmara e os parâmetros que descrevem o posicionamento da câmara em relação ao mundo, é possível calcular a posição 3D dos diferentes objetos que se encontrem localizados dentro da área da PN, que se assume planar. Depois, os objetos são seguidos recorrendo a um estimador ótimo, como um filtro de *Kalman Extendido*. Por fim, a classificação dos objetos como veículos automóveis, motos, camiões, peões, etc., é realizada através de um descritor morfológico usado para comparar os objetos da imagem com os presentes numa bases de dados.

Os testes mostraram que o sistema funciona bem em diferentes situações. No entanto, o sistema mostrou ser limitado em condições de fraca luminosidade e a presença de sombras tende a originar falsos alarmes.

Os sistemas de deteção de obstáculos foram concebidos para evitar colisões entre comboios e veículos automóveis. Um dos problemas no uso de uma única

câmara de vídeo para aquisição de imagens em ambientes exteriores são os faróis dos veículos automóveis ou as sombras dos mesmos, pois estes causam erros na deteção.

2.2.2 Sistema de deteção a partir de visão binocular

Com o objetivo de reduzir a sensibilidade à iluminação em ambientes exteriores, os investigadores começaram por introduzir câmaras binoculares para processamento de dados tridimensionais e assim melhorar a segurança das PN [10].

M. Ohta [8] propõe o desenvolvimento de um SDO que utiliza dois pares de câmaras binoculares. Cada câmara capta uma imagem que depois de combinadas resulta numa imagem tridimensional da área de interesse da PN. A deteção do obstáculo é feita pela subtração do plano de fundo da área da PN à imagem corrente. Desta forma reduzem-se os falsos alarmes provenientes das sombras e dos faróis dos veículos automóveis. Os testes mostraram que o sistema deteta veículos automóveis, pessoas e veículos de duas rodas corretamente durante o dia e noite, sob condições normais de tempo. Mas o principal problema com este sistema é que ele é extremamente sensível às condições meteorológicas adversas, como chuva forte, neblina ou neve.

No Japão, os acidentes com peões ou veículos de duas rodas têm aumentado muito [8]. Também os acidentes que envolvem pessoas idosas aumentaram e o número de quadriciclos ou veículos automóveis a baterias também tem aumentado na mesma medida em que a população envelhece [8].

Com a preocupação de vigiar a passagem das pessoas pela PN, um grupo de investigadores japoneses, I. Yoda et al. [9], instalou câmaras binoculares nos quatro cantos da PN, apontadas para o centro desta, com o objetivo de detetar as pessoas que por lá passam. O sistema deteta automaticamente e em tempo real a passagem das pessoas ou a sua permanência dentro da PN. No essencial, o sistema é capaz de detetar a presença de múltiplas pessoas e diferenciá-las com base na informação de cor dos objetos. O principal problema com este sistema é que apenas deteta pessoas, revelando alguma dificuldade em detetar crianças e em condições ambientais adversas apresenta problemas de funcionamento.

O algoritmo de localização 3D proposto por M. Ohta mostrou-se muito sensível às condições ambientais adversas. Também o algoritmo proposto por I. Yoda et al. apenas deteta pessoas e apresenta problemas de funcionamento em condições ambientais adversas. Para resolver as limitações anteriores Fakhfakh et al. [21], [10]

e [22] propõe um sistema *Automatic Video-Surveillance*⁹ (AVS). O sistema utiliza duas câmaras binoculares para detetar e localizar qualquer objeto que permaneça na PN. O sistema estima e supervisiona situações críticas automaticamente, através da localização dos objetos presentes dentro da PN.

Na primeira fase do sistema proposto por Fakhfakh et al. é realizada a deteção do movimento, separando as regiões com movimento do plano do fundo, i.e., para realizar a detecção de objetos em movimento é aplicada a técnica de subtração de fundo a sequências de imagens naturais. Na fase seguinte é feita a localização 3D dos objetos em movimento ou parados na PN. Os testes mostraram que o sistema é capaz de detetar a localização 3D dos obstáculos, quer dentro da PN quer à volta da PN. O sistema foi testado em quatro PN diferentes, em cenários diferentes incluindo as condições ambientais e de iluminação. A desvantagem deste sistema é a sua incapacidade para lidar com as variações de luminosidade e com as más condições ambientais onde a deteção dos obstáculos pode falhar.

Nos últimos anos tem havido a preocupação de tornar os SDOs mais “inteligentes”, i.e., para além de detetarem os obstáculos, serem capazes de prever também o comportamentos dos utilizadores. Hoje em dia existe também a preocupação de fazer uma avaliação do risco de acidentes em PN. Em França, o projeto “*PANsafer : towards a safer level crossing*”, tem como objetivo contribuir ativamente para a redução do risco de acidentes em passagens de nível. Neste projeto um dos objetivos é realizar, com base na teoria *Dempster-Shafer*¹⁰, o cálculo do risco a fim de avaliar o grau de perigo de cada objeto detetado, que esteja em movimento na PN [26].

Inserido no projeto *PANsafer*, H. Salmane et al. [26] propõem uma solução de videovigilância inteligente que permita o reconhecimento automático e a avaliação de situações críticas em passagens de nível. O modelo tem definido um índice do risco de acidente, para poder avaliar o risco dos objetos seguidos dentro do campo de visão da câmara de video. No primeiro passo o modelo deteta e segue os objetos que estão dentro do campo de visão. O segundo passo consiste em prever, para cada objeto seguido, a trajetória ideal que permita evitar as situações de risco. A previsão da trajetória real é realizada com base no modelo escondido de Markov. O terceiro passo está relacionado com a análise da trajetória prevista a fim de avaliar o perigo relacionado com cada objeto seguido. Neste passo, o nível de risco

⁹Sistema Automático de Videovigilância

¹⁰*Dempster-Shafer* formularam uma teoria matemática da evidência, que permite combinar evidências de diferentes fontes e chegar a um grau de credibilidade (representada por uma função de credibilidade) que leva em conta toda a evidência disponível. A teoria foi primeiramente desenvolvida por *Arthur P. Dempster* e *Glenn Shafer*.

para cada objeto seguido é estimado instantaneamente considerando as diversas fontes de perigosidade usando a teoria *Dempster-Shafer*.

Para testar o modelo são definidos três cenários de perigo, que são avaliados com diferentes sequências de imagens de vídeo: presença de obstáculos dentro da PN, veículos em fila na PN e com as duas meias barreiras fechadas um veículo faz ziguezague entre as meias barreiras. Os testes mostraram que o modelo funcionou bem. A desvantagem deste modelo é que as imagens foram obtidas apenas com uma câmara de vídeo.

2.2.3 Sistema LIDAR

A aplicação de soluções baseadas em LIDAR, não foram ainda suficientemente reportadas e estudadas e não existe muita literatura disponível. No entanto, a IHI Corporation comercializa uma solução baseada em sensores lasers 2D para detecção de obstáculos em passagens de nível [12]. O método utilizado para fazer a detecção dos obstáculos, assume conhecer à priori a localização do plano do chão em relação ao sensor laser, i.e., não constrói um mapa volumétrico referência do ambiente da PN, o que constitui uma limitação na sua capacidade de fazer uma análise volumétrica detalhada e robusta. Além disso, o método assume que o chão da PN é plano, cuja pose em relação ao sensor deve ser conhecida previamente, o que limita a sua capacidade para fazer a detecção de pequenos obstáculos. O método deteta objetos com uma dimensão igual ou superior a 1 m^3 e o tempo necessário para o fazer é de cerca de 0.5 s. O método não consegue fazer a estimação automática da pose da PN e dos carris em relação ao sensor, ao contrário do trabalho aqui apresentado que possibilita uma calibração automática da pose da PN e dos carris e deteta obstáculos com uma volumetria igual ou superior de aproximadamente 10 dm^3 .

A Figura 2.6 ilustra o princípio de funcionamento da solução da IHI Corporation para determinar a posição do obstáculo no espaço 3D e a Figura 2.7 ilustra o método utilizado para fazer a detecção do obstáculo. Seguidamente são descritos os principais passos utilizados para fazer a detecção de obstáculos pelo SDO: (a) são emitidos pulsos laser horizontal e verticalmente, que varrem toda a área da PN; (b) por cada pulso refletido pela superfície dos objetos, é obtido um ponto tridimensional e são guardadas as suas coordenadas 3D; (c) depois são processados e agrupados todos pontos 3D cujas coordenadas estão acima do solo; (d) os grupos de pontos obtidos são processados para obter a posição e o tamanho do objeto dentro da PN.




FIGURA 2.6: Princípio de funcionamento do detetor de obstáculos da IHI (Imagem adaptada de [12]). Na imagem do lado esquerdo, o sensor mede a distância ao objeto pelo tempo que o pulso laser demora a ser refletido para a fonte pela superfície do obstáculo; Na imagem do lado direito, o sensor obtém a posição do objeto pela alteração da direção dos pulsos laser refletidos para a fonte pela superfície do obstáculo.




FIGURA 2.7: Método de detecção de um obstáculo utilizado pelo SDO da IHI. (Imagem adaptada de [12])

Os SDOs para PN que utilizam sensores laser 2D, apresentam alguns problemas devido a interferências causada por equipamento de emissão ou recepção de luz dos utilizadores, deslocamento de feixes óticos, interferências com a emissão ou recepção de luz pela passagem dos comboios em momentos de chuva intensa. Para evitar este tipo de problemas o sensor deve ser instalado a uma altura igual ou superior a 4 m [12].

O SDO da IHI Corporation, segundo o fabricante, funciona corretamente, tanto de dia como de noite, o que é uma grande vantagem em relação aos SDO convencionais baseados, por exemplo, em câmaras de vídeo. Os autores não apresentam testes, pelo que não é possível caracterizar o funcionamento do SDO em condições ambientais adversas.

A primeira unidade foi instalada em Dezembro de 2005, no Japão, na PN de *Nanbu-line Eidanmae* da *East Japan Railway Company* e no ano de 2008 estavam mais de 200 PN equipadas com este sistema.

2.2.4 Sistema de Radar de Micro-Ondas

A PN do Sabugo, ao Quilómetro 24,988 da Linha do Oeste, é uma PN do tipo B automatizada com 4 meias barreiras e dispõe de um sistema de deteção de obstáculos por Radar de Micro-Ondas. É uma PN com influência de estação e tem instalado sinais de proteção à PN, também conhecidos por SPN.

Esta PN dispõe ainda de um sistema auxiliar de video para as áreas que estão a ser supervisionadas. Seguidamente é feita uma breve descrição do funcionamento do SDO instalado nesta PN.

A Figura 2.8 ilustra a arquitetura do sistema SDO [15], que é de segurança intrínseca, i.e., quando está no estado inicial considera a zona de supervisão obs-




FIGURA 2.8: Arquitetura do SDO por RADAR instalado na PN do Sabugo.
(Imagem adaptada de [15])

truída, ou seja, “estado de obstáculo detetado” e fecho dos SPN. Resumidamente a arquitetura do SDO descrito em [15] é composta por: (a) um sistema de Radar, que utiliza um conjunto de antenas emissoras/recetoras; (b) uma unidade lógica de controlo, para fazer a análise e processar a informação recebida do radar; (c) uma unidade de avaliação, que é constituída pelos subsistemas de lógica de controlo e lógica operacional; (d) um posto central de controlo e supervisão, que é a unidade responsável pelas parametrizações e controlo do SDO, que faz a gestão dos eventos e dos alarmes enviados pela Unidade de Avaliação; (e) um ponto de acesso à informação do SDO, que é composto por um PC para visualização das mensagens técnicas.

A supervisão da zona é feita mediante a emissão de um sinal, através das antenas emissoras do radar instaladas na zona circundante da PN e respetiva deteção

do mesmo sinal nas antenas recetoras. O emissor do radar tem a capacidade de ser ao mesmo tempo o recetor dos próprios feixes de micro-ondas que emite.

O primeiro ciclo de varrimento da zona a supervisionar, de duração programável, é efetuado após ter sido desencadeado um anúncio automático de um comboio à PN e no momento em que as MB iniciam a descida. No final do primeiro ciclo de varrimento e no caso da zona de supervisão se encontrar desobstruída, a unidade lógica de controlo do SDO, transmite o estado de zona de supervisão desobstruída. Se o SDO detetar a zona obstruída, é iniciado um novo ciclo de varrimento e no fim deste ciclo, se a zona supervisionada se mantiver obstruída, o sistema passa ao estado de “obstáculo detectado” e não envia qualquer sinal de comando de abertura dos SPN. Se pelo contrário a zona a supervisionar estiver desobstruída, o sistema passa ao estado de “zona livre” e envia sinal de comando de abertura dos SPN.

No momento em que é desencadeado um anúncio e após as MB de entrada terem descido e estarem comprovadas em baixo, o SDO verifica se existe algum obstáculo dentro da PN e, no caso desta estar livre de obstáculos, 8s depois começam a descer as MB de saída, fechando completamente a PN ao trânsito.

Como forma de garantir que um obstáculo que invada a zona de gabarito seja detetado, foi definida uma zona de deteção na área envolvente da PN. Esta zona está delimitada na vertical a 50 centímetros do solo e até 1,80 metros na lateral. O sistema está configurado para detetar obstáculos com uma volumetria superior a 0.5 m^3 .

A vantagem deste SDO é a deteção de obstáculos com uma volumetria superior a 0.5 m^3 . Algumas das desvantagens são: (a) o sistema é muito dispendioso em virtude do elevado número de equipamentos a instalar; (b) em PN localizadas em via dupla ou mais vias é necessário multiplicar os equipamentos, para discriminar os comboios por via; (c) o tempo necessário para detetar os obstáculos é muito longo em PN de atravessamento largo (PN localizadas em via dupla ou mais vias). (d) não permite distinguir corretamente os obstáculos nem os caracterizar; (e) no caso do piso da PN ser irregular pode não detetar corretamente os obstáculos.

Capítulo 3

Descrição do Sistema Proposto

Este capítulo descreve o sistema proposto que foi desenvolvido para detetar obstáculos de baixa volumetria em passagens de nível (PN). A Secção 3.1 descreve genericamente o funcionamento de uma PN automática. A Secção 3.2 descreve o sistema dando uma visão geral do mesmo. A Secção 3.3 descreve o processamento necessário para fazer a estimativa automática da pose da PN. A Secção 3.4 descreve o processamento necessário para fazer a estimativa automática da pose dos carris. A Secção 3.5 descreve o processamento necessário para criar o mapa volumétrico referência da PN constrangido pela pose da PN e dos carris. A Secção 3.6 descreve o processamento necessário para fazer a deteção e a caracterização dos obstáculos a partir do mapa volumétrico referência da PN.

3.1 A passagem de nível: assunções e requisitos

As passagens de nível podem dispor de equipamentos de comando manual, e estão garantidas por um agente, ou em alternativa estão equipadas com equipamentos de segurança de comando automático. As passagens de nível de comando automático, i.e., o fecho e a abertura ao trânsito rodoviário são comandados em condições normais pela circulação dos comboios, podem dispor do seguinte equipamento: meias barreiras ou barreiras completas de proteção para o trânsito rodoviário. No sentido do trânsito rodoviário são instaladas duas meias barreiras, sinalização sonora e luminosa. A sinalização luminosa é composta, normalmente, por duas luzes encarnadas que acendem alternadamente quando a passagem se encontra fechada. São fechadas ao trânsito com uma antecedência mínima de 25 segundos.

As passagens de nível automáticas encontram-se abertas ao trânsito rodoviário na ausência de anúncio, i.e., os sinais rodoviários encontram-se apagados e as

meias barreiras estão em cima. Quando uma circulação ferroviária atinge a zona de anúncio, entram em funcionamento os sinais rodoviários. As luzes vermelhas acendem alternadamente e as campainhas, quando existem, tocam. Passados alguns segundos começam a descer as meias barreiras. Durante o fecho da passagem de nível os sinais luminosos e sonoros estão em funcionamento, havendo, no entanto, a possibilidade em algumas passagens de nível de as campainhas deixarem de funcionar quando as meias barreiras estão na posição horizontal. Quando o último veículo ferroviário passa pela passagem de nível, esta abre, permitindo o atravessamento dos veículos rodoviários.

As passagens de nível dotadas de sistemas de deteção de obstáculos, são regra geral protegidas por sinais luminosos, designados por “sinal de proteção a passagens de nível” (SPN). Este sinal pode apresentar os seguintes aspetos: um aspeto não restritivo, que indica ao maquinista que pode prosseguir a marcha sem quaisquer condicionamentos impostos pela passagem de nível; um aspeto restritivo, que indica ao maquinista que deve-se aproximar da passagem de nível, de forma a poder parar o comboio antes de a atingir. O sinal SPN está instalado à distância de frenagem necessária, relativamente à passagem de nível, de maneira a que, quando o sinal apresenta o aspeto restritivo, o comboio possa parar com segurança.

Quando é instalado um sistema de deteção de obstáculos numa PN, esta deve dispor de 4 meias barreiras para a fechar completamente ao trânsito rodoviário. As análises de risco [16] mostram que a aplicação de sistemas de obstáculos em PN só com duas meias barreiras (barreiras de entrada da PN), pode ser problemático e traria poucos benefícios de segurança. Depois do SDO ter verificado que a PN está livre de obstáculos e ter comandado o SPN correspondente para o aspeto de abertura, um utilizador mais impaciente pode contornar as meias barreiras originando perturbações na exploração ferroviária, mesmo que não haja nenhum incidente de segurança. Por isso estas PN devem ser completamente fechadas ao trânsito, instalando 4 meias barreiras (barreiras de entrada e barreiras de saída da PN) garantindo desta forma que após o SDO ter verificado que a PN está livre de obstáculos nenhum veículo rodoviário entra na PN.

A PN do Sabugo, está instalada ao Km 24,989 da Linha do Oeste, dispõe de sinalização luminosa e sonora e tem instalado duplas meias barreiras (MB) em cada uma das extremidades do cruzamento, isto é, em cada um dos vértices do quadrilátero formado pelas quatro MB, como ilustrado na Figura 3.1, e também tem instalado um sistema de deteção de obstáculos por RADAR (ver Secção 2.2.4).




FIGURA 3.1: PN do Sabugo com as MB em cima e em posição quase vertical.

As quatro MB são designadas da seguinte forma e estão ilustradas na Figura 3.2:

- MB-X e MB-Y – Barreiras de entrada da PN são as primeiras a descer sempre que existe um anúncio automático de aproximação de uma circulação ferroviária à PN, obstruindo metade da largura da estrada no sentido do trânsito.
- MB-W e MB-Z – Barreiras de saída da PN, descem após haver a garantia de que as MB de entrada estão comprovadamente em baixo e não existe nenhum obstáculo dentro da PN. O fecho destas barreiras é desfasado das primeiras, para a permitir a saída de um veículo rodoviário que esteja dentro da PN. .

Após a PN estar fechada ao trânsito, i.e., depois das barreiras de entrada da PN terem descido, obstruindo a passagem, o SDO verifica se a PN está livre de obstáculos. Após o fecho de todas as MB o SDO comanda o SPN correspondente ao sentido de circulação do comboio para o aspeto não restritivo. Caso contrário, i.e., se existir um obstáculo dentro da PN, as barreiras de saída da PN não descem e o SPN, correspondente ao sentido de circulação do comboio, é mantida no aspeto restritivo.

3.2 Visão global do sistema

Esta secção descreve o sistema proposto, que na sua essência é composto por duas fases: fase mapeamento semântico da PN e fase deteção e caraterização




FIGURA 3.2: Localização do Sensor LIDAR na PN e definição das zonas de supervisão A, B e C.

dos obstáculos. A primeira fase é a fase de treino do sistema, i.e., o sistema automaticamente aprende a localização das 4 MB e dos carris e com base nesta informação constrói o mapa volumétrico referência da PN. Na segunda fase utiliza o conhecimento obtido na fase de treino, para de cada vez que um comboio se aproxima da PN criar um mapa volumétrico instantâneo que é comparado com o de referência com vista a determinar se existem diferenças e, portanto, verificar se a PN está livre de obstáculos. Seguidamente é apresentada cada uma destas fases.

3.2.1 Fase mapeamento semântico da PN

A Figura 3.3 apresenta o modelo proposto para fazer o mapeamento da PN. Começa-se por fazer a deteção da PN a partir da nuvem de pontos referência $\mathcal{P}_0$, o que possibilita definir três zonas de supervisão para fazer a deteção dos obstáculos, ilustradas na Figura 3.2.

O passo seguinte é a deteção da localização dos carris. Sabendo a posição dos carris, é possível estimar a bitola da via. A bitola da via é a distância entre carris, medida à face interior de cada carril, que no caso português é de 1668 milímetros (mm) [19]. A partir da definição da bitola da via determina-se o eixo da via, para depois poder ser estimado o gabarito. O gabarito é o máximo espaço que um veículo ferroviário pode ocupar, quando circula na via férrea [19].

Com localização das meias barreiras (MB) e dos carris e tomando como referência as três zonas de supervisão definidas (ver Figura 3.2), é realizado a construção do mapa volumétrico referência da PN a partir do conjunto de nuvem de pontos




FIGURA 3.3: Modelo global do Sistema - Mapeamento semântico da PN.

$\{P_0, \dots, P_k\}$. O mapa volumétrico referência da PN é uma representação discreta da zona da PN a supervisionar, num dado momento, livre dos obstáculos a detetar.

3.2.2 Fase de deteção e caracterização dos obstáculos

A Figura 3.4 apresenta o modelo proposto para fazer a deteção dos obstáculos e a sua caracterização, depois de ter-se aprendido o mapa volumétrico referência da PN. Após ter sido desencadeado um anúncio automático à PN, é feito um pedido ao sensor LIDAR para efetuar a captura de uma nuvem de pontos sobre o estado da PN. A nuvem de pontos é processada no sentido de obter o mapa volumétrico instantâneo que depois é comparado com o mapa volumétrico referência. O resultado desta comparação permite obter os potenciais obstáculos na área da PN e, por fim, são obtidas as características do obstáculo (e.g., altura, largura e distância ao eixo da via). Por último é gerado o estado da PN, o que permite controlar o sinal de proteção da PN, no sentido de o fechar e obrigar o comboio a parar antes de passar pela PN, ou de o abrir e permitir que o comboio prossiga a sua marcha sem qualquer tipo de constrangimento. Caso haja necessidade, o sistema pode efetuar um novo pedido para captura de uma nova nuvem de pontos. Então volta a repetir-se todo o processo.

Seguidamente é feita uma explicação detalhada de cada um dos módulos anteriormente descritos.




FIGURA 3.4: Modelo global do Sistema - Deteção e caraterização dos obstáculos.

3.3 Deteção da localização das Meias Barreiras

O sensor LIDAR utilizado para fazer a recolha das nuvens de pontos, é colocado junto da MB-Z, como mostrado na Figura 3.2. Na ausência de anúncio, encontrando-se a PN no seu normal funcionamento, as hastes das MB estão em cima, numa posição quase vertical, como mostrado na Figura 3.1. É a partir dessa posição que se começa por fazer a deteção e localização das MB. O modelo proposto para o fazer é apresentado na Figura 3.5. O modelo está dividido em duas partes. A primeira parte (ver Secção 3.3.1) descreve o processamento necessário para fazer a deteção das meias barreiras. A partir de uma nuvem de pontos começa-se por estimar um conjunto de possíveis posições da localização das MB. A segunda parte (ver Secção 3.3.2) descreve o processamento necessário para fazer a deteção da passagem de nível. A partir do conjunto de possíveis localizações das MB, acham-se combinações de quatro localizações. Cada combinação achada é comparada com uma forma semelhante à disposição das MB e a combinação achada mais semelhante define a posição das MB no terreno.

3.3.1 Deteção das Meias Barreiras

Para iniciar a fase de deteção das MB, é escolhida uma nuvem de pontos recolhida no local sem a presença de obstáculos e quando as MB estão em cima. A essa nuvem de pontos de referência chama-se $\mathcal{P}_0$.




FIGURA 3.5: Modelo para detecção da localização das MB.

O problema da detecção das MB está dividido em 4 partes, reduzindo desta forma a complexidade do problema. Começa-se por estimar o plano do chão, com o objetivo de determinar que pontos pertencem ao chão. Seguidamente, os pontos que não foram identificados como pertencentes ao chão (potenciais objetos na PN) são agrupados por vizinhanças. Os elementos que compõem alguns dos agrupamentos e que interessa localizar são as hastes das MB. O comprimento das hastes das MB pode variar entre 2 metros e, pelo menos, 6.5 metros, dependendo da largura da estrada. Este conhecimento permite remover agrupamentos que não fazem sentido. Por último, o centróide de cada um dos agrupamentos é calculado. Seguidamente é realizada uma descrição detalhada de cada um destes passos.

3.3.1.1 Rejeitar pontos ao nível do chão

Por definição, a nuvem de pontos referência $\mathcal{P}_0$ é uma coleção de pontos $\mathbf{p} = (\mathbf{p}_x, \mathbf{p}_y, \mathbf{p}_z)$ representados pelas suas coordenadas (x, y, z) num espaço tridimensional. As coordenadas de cada ponto $\mathbf{p}_i \in \mathcal{P}_0$ são obtidas em relação a um sistema de coordenadas fixo, que normalmente tem a origem no dispositivo utilizado para fazer a aquisição dos dados [27]. A nuvem de pontos é composta por milhares de pontos $\mathbf{p}$ o que a torna muito densa dificultando a sua manipulação através de transformações geométricas, sendo, por isso, necessário utilizar algoritmos que otimizem a seu processamento.

O primeiro problema a resolver é estimar o plano do chão π da nuvem de pontos referência $\mathcal{P}_0$ e rejeitar os pontos ao nível do chão, de acordo com uma distância de limiar d_l , definida empiricamente. Para estimar o plano do chão π , aplica-se o algoritmo *RANdom SAmple Consensus* (RANSAC) [28]. Este gera hipóteses do modelo planar que represente o plano do chão onde estão localizadas as MB. Uma das vantagens deste algoritmo é a de ser um estimador de parâmetros, capaz de evitar que os dados *outliers*¹ interfiram no modelo final.

Como o modelo a encontrar representa um plano e um plano é definido por 3 pontos não colineares, as principais etapas do algoritmo são:

1. seleccionar aleatoriamente 3 pontos não colineares $\mathbf{p}_1, \mathbf{p}_2, \mathbf{p}_3$ da nuvem de pontos referência $\mathcal{P}_0$;
2. calcular os coeficientes da equação do plano que contém os 3 pontos, $(ax + by + cz + d = 0)$;
3. calcular as distâncias de todos os pontos $\mathbf{p} \in \mathcal{P}_0$ ao modelo do plano (a, b, c, d) ;
4. contar o número de pontos $\mathbf{p}_k \in \mathcal{P}_0$ cuja distância ao plano está contida no intervalo $[0, d_l]$.

Os passos anteriores são repetidos em k iterações. O número máximo de iterações escolhido, k , deve ser suficientemente elevado para garantir uma elevada probabilidade, p , de que pelo menos um dos conjuntos das amostras aleatórias não mostrem *outliers*.

Depois de executadas as várias iterações do algoritmo, é seleccionado o conjunto de 3 pontos 3D com maior número de pontos dando suporte ao modelo planar que melhor descreve o plano do chão onde estão localizadas as MB. Como se pretende os pontos que estão acima do plano do chão, i.e., pontos que não pertencem ao intervalo $[0, d_l]$, a esse conjunto de pontos chama-se nuvem de pontos $\mathcal{P}'_0$. O passo seguinte passa por estudar as características dos pontos acima do plano do chão.

3.3.1.2 Agrupar pontos

O agrupamento dos pontos acima do plano do chão é realizado com base na distância entre estes, deste modo, os pontos com menor distância entre si, são os mais semelhantes. A distância é determinada com base na distância euclidiana entre pontos. Então, sejam os pontos tridimensionais $\mathbf{p} = (p_x, p_y, p_z) \in \mathcal{P}'_0$ e

¹*outliers*: pontos que apresentam um grande afastamento em relação à média e estão fora da tolerância de erro definida.

$\mathbf{q} = (q_x, q_y, q_z) \in \mathcal{P}'_0$, a distância euclidiana entre os pontos $\mathbf{p}$ e $\mathbf{q}$ é dada por:

$$\|\mathbf{p} - \mathbf{q}\| = \sqrt{(p_x - q_x)^2 + (p_y - q_y)^2 + (p_z - q_z)^2}. \quad (3.1)$$

Para segmentar a nuvem de pontos é utilizado o algoritmo de extração de conjuntos de pontos proposto por Rusu [27]. Este algoritmo tem como objetivo extrair conjuntos de pontos da nuvem de pontos $\mathcal{P}'_0$ que representam diferentes agrupamentos, i.e., $\mathcal{A}_i = \{\mathbf{p}'_i \in \mathcal{P}'_0\}$ é um agrupamento diferente do agrupamento $\mathcal{A}_j = \{\mathbf{p}'_j \in \mathcal{P}'_0\}$ se:

$$\min_{\mathbf{p}'_i \in \mathcal{A}_i, \mathbf{p}'_j \in \mathcal{A}_j} \{\|\mathbf{p}'_i - \mathbf{p}'_j\|_2\} \geq d_{min}, \quad (3.2)$$

onde, d_{min} é a distância mínima entre agrupamentos diferentes. Pela equação 3.2, verifica-se que se a distância mínima entre o conjunto de pontos $\mathbf{p}'_i \in \mathcal{P}'_0$ e o outro conjunto de pontos $\mathbf{p}'_j \in \mathcal{P}'_0$, for maior do que o valor da distância d_{min} , então o conjunto de pontos $\mathbf{p}'_i$ pertence ao agrupamento $\mathcal{A}_i$ e o conjunto de pontos $\mathbf{p}'_j$ pertence ao agrupamento $\mathcal{A}_j$.

Do ponto de vista de implementação prática, a distância d_{min} deve ser cuidadosamente definida, uma vez que, se esse valor for muito pequeno, o objeto pode ser dividido em múltiplos objetos, por outro lado, se esse valor for elevado, múltiplos objectos podem ser considerados como um único objeto [27].

Assim, $\mathcal{A}_0 = \{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_k\}$ é o conjunto de todos os agrupamentos em que é decomposta a nuvem de pontos $\mathcal{P}'_0$.

Este método para além do parâmetro da distância mínima entre agrupamentos anteriormente descrito, necessita da definição de outros dois parâmetros. O primeiro é o número de pontos mínimo n_{min} necessários que um agrupamento precisa de conter para ser considerado válido, o segundo é o número de pontos máximo n_{max} que um agrupamento pode conter para ser considerado válido.

3.3.1.3 Rejeitar agrupamentos pela sua altura

As hastes das MB estão fixas a um mecanismo que as comanda, a cerca de 90 cm acima do solo e o seu comprimento, dependendo da largura da estrada, pode variar entre 2 e 6.5 metros. Assim, as MB são representadas pelos agrupamentos cuja altura esteja acima do valor definido empiricamente para o parâmetro h_z .

A coordenada z dá-nos a altura em relação ao referencial, $\mathcal{A}_0$ é o conjunto de todos os agrupamentos e $\mathcal{A}'_0 = \{\mathbf{a}'_1, \mathbf{a}'_2, \dots, \mathbf{a}'_m\}$ com $m \leq k$, é o conjunto dos agrupamentos filtrados pela coordenada z . Considere-se um agrupamento $\mathbf{a}'_i \in \mathcal{A}'_0$,

a distância máxima entre quaisquer dois pontos é:

$$\Delta z(\mathbf{a}'_i) = \max\{\mathbf{p}_z : \forall \mathbf{p} \in \mathbf{a}'_i\} - \min\{\mathbf{q}_z : \forall \mathbf{q} \in \mathbf{a}'_i\}, \quad (3.3)$$

então $\forall \mathbf{a}'_i : \Delta z(\mathbf{a}'_i) \geq h_z, \mathbf{a}'_i \in \mathcal{A}'_0$.

3.3.1.4 Calcular centróides dos agrupamentos

Com a obtenção do conjunto de agrupamentos $\mathcal{A}'_0$, com altura dentro dos parâmetros das MB, é necessário agora encontrar os seus centróides. O centróide de um dado agrupamento é obtido pela média das coordenadas de todos os pontos que o constituem, i.e., é o centro geométrico do agrupamento, que irá ser usado nos cálculos para obtenção da localização das MB. O conjunto de todos os centróides é definido como $\mathcal{B}_0 = \{\mathbf{c}(\mathbf{a}'_1), \mathbf{c}(\mathbf{a}'_2), \dots, \mathbf{c}(\mathbf{a}'_m)\}$. Tome-se como exemplo o agrupamento $\mathbf{a}'_1 \in \mathcal{A}'_0$. O centróide do agrupamento $\mathbf{c}(\mathbf{a}'_1) \in \mathcal{A}'_0$ é dado por:

$$\mathbf{c}(\mathbf{a}'_1) = \frac{1}{|\mathbf{a}'_1|} \sum_{i=1}^{|\mathbf{a}'_1|} \mathbf{p}'_i, \quad \mathbf{p}'_i \in \mathbf{a}'_1, \quad (3.4)$$

onde o número de pontos em $\mathbf{a}'_1$ é $|\mathbf{a}'_1|$.

3.3.2 Detecção da passagem de nível

As Mb correspondem a 4 centróides que fazem parte do conjunto de centróides $\mathcal{B}_0$, que incluem objetos que não apenas as próprias MB. O passo seguinte é achar, de todas as combinações de quatro centróides, qual delas de facto corresponde à combinação de centróides das 4 MB.

Para saber qual a combinação que representa a localização das MB é necessário dispor de um elemento de comparação, que seja semelhante à disposição real das MB. Então, começa-se por definir um quadrilátero centrado na origem do referencial, que é definido com as dimensões expectáveis para a PN. A este quadrilátero chama-se *forma esperada*.

Para terminar, é feita a comparação entre todas as formas das combinações possíveis e a forma esperada. A combinação que apresentar uma forma mais semelhante à forma esperada é tida como a combinação correta, ou seja, que corresponde à localização das MB. A Figura 3.6, mostra a disposição do conjunto de centróides $\mathcal{B}_0$ no terreno. Seguidamente é feita uma descrição de cada um dos processos.




FIGURA 3.6: Exemplo do conjunto de todos os centróides obtidos para a detecção das MB. Na imagem do lado esquerdo são visíveis os centróides que correspondem às MB e do lado direito vê-se um aglomerado de centróides, que é necessário filtrar.

3.3.2.1 Encontrar PN

Para achar a combinação de centróides contidos em $\mathcal{B}_0$ que representa a posição das MB é necessário comparar cada combinação de centróides com a forma esperada. A forma esperada, $\mathbf{q}_r = \{\mathbf{v}'_1, \mathbf{v}'_2, \mathbf{v}'_3, \mathbf{v}'_4\}$, é um quadrilátero com 4 vértices centrados na origem do referencial, ilustrada na Figura 3.7a. A Figura ?? representa uma possível combinação de centróides $\mathbf{q} = \{\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3, \mathbf{v}_4\}$.




FIGURA 3.7: Exemplo das formas utilizadas para estimar a posição das MB. (a) Forma esperada $\mathbf{q}_r$ centrada na origem do referencial; ?? Uma combinação possível dos vários centróides, $\mathbf{q}$.

A Figura 3.8a, mostra uma combinação possível e a forma esperada centrada na origem do referencial. Para estabelecer a comparação entre duas quaisquer formas é necessário deslocar a forma da combinação a testar para origem do referencial, como mostrado na Figura 3.8b. Para o realizar é necessário obter o vértice médio.

O ponto médio de uma forma $\mathbf{q} = \{\mathbf{v}_i\}$ é dado por:

$$\mathbf{v}_m = \frac{\sum_{i=1}^{n=4} \mathbf{v}_i}{4}. \quad (3.5)$$




FIGURA 3.8: Estimar posição das MB. (a) Combinação de centróides eleita, $\mathbf{q}$ e a forma esperada $\mathbf{q}_r$ centrada na origem do referencial; (b) A forma $\mathbf{q}$ foi deslocada para origem do referencial, para permitir obter o valor acumulado da distância euclidiana entre os vértices das formas; (c) Combinação de centróides $\mathbf{q}$ correspondente à localização das MB e a forma esperada $\mathbf{q}_r$ centrada na origem do referencial; (d) A forma $\mathbf{q}$ foi deslocada para origem do referencial, para permitir obter o valor acumulado da distância euclidiana entre os vértices das formas.

Depois retira-se a média $\mathbf{v}_m$ a cada um dos vértices da forma $\mathbf{q}$. Com as 2 formas centradas na origem do referencial, é acumulada a distância euclidiana entre cada um dos vértices das formas. Essa métrica para duas formas $\mathbf{q} = \{\mathbf{v}_i\}$ e $\mathbf{q}_r = \{\mathbf{v}'_i\}$ é:

$$\Psi(\mathbf{q}, \mathbf{q}_r) = \sum_{i=1}^{n=4} \|(\mathbf{v}_i - \mathbf{v}_m) - \mathbf{v}'_i\|. \quad (3.6)$$

A função objetivo que minimiza $\Psi(\mathbf{q}, \mathbf{q}_r)$ e determina se a hipótese $\mathbf{q}$ é verdadeira, é dada por:

$$\hat{\mathbf{q}}_0 = \arg \min_{\mathbf{q}} \Psi(\mathbf{q}_r, \mathbf{q}). \quad (3.7)$$

A forma $\hat{\mathbf{q}}_0$ representa a combinação de centróides eleita, que corresponde à localização da PN, como mostrado na Figura 3.8d. A Figura 3.9 mostra a combinação de centróides eleita, que corresponde à localização da PN.




FIGURA 3.9: Eleição da combinação de centróides correspondente à disposição das MB.

3.3.2.2 Definição das áreas de supervisão

A zona de supervisão A é definida por um quadrilátero, onde em cada um dos seus vértices está representada uma MB. Cada um dos vértices é representado por um ponto no espaço cartesiano 3D. Afim de facilitar e tornar os cálculos mais exatos, torna-se necessário fazer a projeção de cada vértice no plano, ou seja, fazer a representação gráfica de cada vértice no plano.

Seja, $\mathbf{r}$ o segmento de reta definido pelos pontos $\mathbf{p}_1 = (x_1, y_1)$ e $\mathbf{p}_2 = (x_2, y_2)$, $\mathbf{p} = (x, y)$ é um ponto sobre o segmento de reta $\mathbf{r}$. Como os pontos pertencem ao segmento de reta $\mathbf{r}$, isso significa que os pontos são colineares. O determinante da matriz construída utilizando as coordenadas dos 3 pontos é:

$$\begin{vmatrix} x_1 & y_1 & 1 \\ x_2 & y_2 & 1 \\ x & y & 1 \end{vmatrix} = 0. \quad (3.8)$$

Se o determinante da matriz for igual a zero, significa que os pontos são colineares. Calculando o determinante da matriz 3.8, vem que:

$$f(x, y) = (y_1 - y_2)x + (x_2 - x_1)y + x_1y_2 - x_2y_1 = 0, \quad (3.9)$$

obtemos a equação geral da reta:

$$ax + by + c = 0, \quad (3.10)$$

onde, $a = (y_1 - y_2)$, $b = (x_2 - x_1)$ e $c = x_1y_2 - x_2y_1$, são números reais, a e b não podem ser nulos em simultâneo, x e y são coordenadas de um ponto do segmento de reta.

Para criar a zona de supervisão A, $\mathcal{Z}_A$, considere-se o quadrilátero $\hat{\mathbf{q}}_0 = (\mathbf{i}, \mathbf{g}, \mathbf{k}, \mathbf{m})$ representado na Figura 3.10 e $\mathcal{P}_0$ a nuvem de pontos a segmentar. Seja $\mathbf{p}_i = (p_i^x, p_i^y, p_i^z) \in \mathcal{P}_0$ e $\mathbf{l}_1 = (\mathbf{i}, \mathbf{g})$, $\mathbf{l}_2 = (\mathbf{g}, \mathbf{k})$, $\mathbf{l}_3 = (\mathbf{k}, \mathbf{m})$ e $\mathbf{l}_4 = (\mathbf{m}, \mathbf{i})$ os




FIGURA 3.10: Definição das Zonas de Supervisão de obstáculos na PN.

lados do quadrilátero da zona de supervisão A, aplicando a Equação 3.9 tem-se:

$$\mathcal{Z}_A = \{(p_i^x, p_i^y, p_i^z) \in \mathcal{P}_0, f_k(p_i^x, p_i^y) > 0, \forall k \in \{1, 2, 3, 4\}\}. \quad (3.11)$$

A Figura 3.11 ilustra o modo para obter a posição relativa do ponto $\mathbf{p}$ em relação ao quadrilátero da figura. As funções $f_1(x, y)$, $f_2(x, y)$, $f_3(x, y)$ e $f_4(x, y)$ definem cada um dos segmentos de reta que formam o quadrilátero da figura. A posição relativa do ponto $\mathbf{p}$ em relação ao quadrilátero é dada pela Equação 3.9. Se o resultado das funções f_1 , f_2 , f_3 e f_4 for maior do que zero, o ponto está no interior do quadrilátero; se o resultado de uma das funções for igual a zero o ponto está sobre esse lado do quadrilátero; se o resultado de uma das funções for menor do que zero, o ponto está fora do quadrilátero.




FIGURA 3.11: Exemplificação para obter a posição relativa do ponto $\mathbf{p}$ em relação ao quadrilátero representado na figura.

3.3.2.3 Projetar centróides das MB no plano

Considere-se a nuvem de pontos da zona de supervisão A, $\mathcal{Z}_A$, a distância limiar d_l^A , o plano da zona de supervisão A, π_A , então pelo exposto na Secção 3.3.1.1, obtém-se o plano do chão $\pi_A = (a, b, c, d)$.

Com a localização da PN determinada, os vértices do quadrilátero são projetados no plano π_A . Seja $\mathbf{p}$ um dos vértices a projetar no plano π_A , definido pela equação $ax + by + cz + d = 0$, $\mathbf{n} = (a, b, c) / \|(a, b, c)\|$ é o vetor unitário ortogonal ao plano π_A e $\mathbf{q} = (x_1, y_1, z_1)$ um ponto qualquer do plano π_A . O primeiro passo é determinar o ponto $\mathbf{q}$ do plano π_A , então se $x_1 = y_1 = 0$ na equação do plano π_A , vem: $z_1 = -\frac{d}{c}$. Portanto, o ponto $\mathbf{q} = (0, 0, -\frac{d}{c})$ pertence ao plano π_A . O ponto $\mathbf{p}$ projetado no plano π_A é:

$$\mathbf{p}_{proj} = \mathbf{p} - ((\mathbf{p} - \mathbf{q}) \cdot \mathbf{n})\mathbf{n}. \quad (3.12)$$

3.3.2.4 Criação das zonas de supervisão B e C

A área coberta pelo sensor LIDAR vai para além da zona de supervisão A. Contudo, é possível aumentar a segurança da PN supervisionando áreas contíguas à zona A. De cada um dos lados da Zona A foi criada uma zona de supervisão, zona B e zona C, que são de igual dimensão à zona A (ver Figura 3.10).

Tome-se como exemplo a zona B. Na zona B a localização no espaço cartesiano 3D dos pontos $\mathbf{h}, \mathbf{j}$ é desconhecida e a dos pontos $\mathbf{g}, \mathbf{i}$ é conhecida. O ponto médio do segmento de reta formada pelos pontos $\mathbf{j}$ e $\mathbf{m}$, (ver Figura 3.10), é o ponto $\mathbf{i} = \frac{1}{2}(\mathbf{j} + \mathbf{m})$.

Da mesma forma, considerando o segmento de reta $\mathbf{j}\mathbf{m}$, com o ponto médio $\mathbf{i}$, a localização do ponto $\mathbf{j}$, no espaço cartesiano 3D, é dado por:

$$\mathbf{j} = 2\mathbf{i} - \mathbf{m}. \quad (3.13)$$

Os restantes pontos das Zonas B e C são obtidos de forma similar.

3.4 Detecção dos Carris

Com a obtenção da localização das MB, definiram-se as zonas de supervisão A, B e C para deteção de obstáculos. O passo seguinte é localizar a posição dos carris, para que seja possível estimar o gabarito. A localização dos carris é realizada sobre a nuvem de pontos de referência $\mathcal{P}_0$ e dentro da Zona B, porque a densidade de pontos no espaço interior entre carris nesta zona é mais uniforme do que nas duas outras zonas. Isto deve-se ao facto do sensor LIDAR estar mais próximo da zona B e nesta zona o balastro da via estar ao nível das travessas sobre as quais assentam os carris, contribuindo para que a densidade de pontos sobre a zona onde se localizam os carris seja mais elevada do que na entrevia. A ideia principal para localizar a posição dos carris na nuvem de pontos é obter 2 pontos sobre cada um dos carris, afastados um do outro o mais possível, com o objetivo de ser possível estimar um segmento de reta que represente o carril. Quanto maior for o afastamento entre os 2 pontos menor será o erro cometido na estimação de um segmento de reta que represente o carril.

A Figura 3.12 representa a vista em planta da mesa de rolamento de um carril com 3 pontos representados sobre a mesma. O segmento de reta $\mathbf{l}$ representa o centro da mesa de rolamento do carril real. A ideia base é estimar um segmento de reta que se aproxime do centro da mesa de rolamento real. Então, o segmento de reta $\mathbf{l}_1$ que passa pelos pontos $\mathbf{c}_1$ e $\mathbf{c}'_2$ tem um desvio maior em relação ao centro da mesa de rolamento do carril real do que o segmento de reta $\mathbf{l}_2$ que passa pelo pontos $\mathbf{c}_1$ e $\mathbf{c}_2$, i.e., quando maior for o afastamento entre os pontos $\mathbf{c}_1$ e $\mathbf{c}_2$ menor é o desvio do segmento de reta que os une em relação ao centro da mesa de rolamento do carril real.

3.4.1 Criar área para pesquisa dos carris

A partir do espaço interior entre carris inicia-se o processo para localizar os dois pontos sobre cada carril, sendo para isso necessário encontrar guias que conduzam




FIGURA 3.12: Minimizar o erro na estimação da localização dos carris.

um vetor que representa a direção de pesquisa dos carris. Desta forma é necessário encontrar dois segmentos de reta que cruzem os carris a toda a largura do quadrilátero. A Figura 3.13 ilustra a zona B delimitada pelo quadrilátero formado pelos vértices **g, h, i, j**, com os carris representados em planta. Sobre os lados **gh** e **ij** são criados dois vetores, $\mathbf{u}_1 = \mathbf{h} - \mathbf{g}$ e $\mathbf{u}_2 = \mathbf{j} - \mathbf{i}$, onde $\mathbf{n}_1 = \mathbf{u}_1 / |\mathbf{u}_1|$ e $\mathbf{n}_2 = \mathbf{u}_2 / |\mathbf{u}_2|$ representam respetivamente os vetores $\mathbf{u}_1$ e $\mathbf{u}_2$ normalizados (magnitude unitária). Os pontos que definem cada um dos segmentos de reta **d, f** e **a, c**, são obtidos pelo




FIGURA 3.13: Definição das zonas de pesquisa dos carris formadas pelos segmentos de reta **ac** e **df**. O início da pesquisa dos carris é feito a partir dos pontos **b** e **e**, para cada um dos lados e na direção dos carris.

deslocamento de magnitude ω_1 e ω_2 da origem dos vetores $\mathbf{u}_1$ e $\mathbf{u}_2$ na direção de $\mathbf{n}_1$ e $\mathbf{n}_2$, respetivamente. Então, tome-se como exemplo o lado **gh**, sobre o qual foi criado o vetor $\mathbf{u}_1$. O ponto **d** é obtido pelo deslocamento de magnitude ω_1 da origem do vetor $\mathbf{u}_1$, na direção de $\mathbf{n}_1$:

$$\mathbf{d} = \mathbf{g} + \omega_1 \mathbf{n}_1 \quad (3.14)$$

A obtenção dos pontos **a, c** e **f** é conseguida de forma similar a esta.

Com a obtenção dos pontos **a**, **d** e **c**, **f**, definem-se os segmentos de reta **ac** e **df**. Os pontos **b** e **e** são obtidos calculando o ponto médio dos segmentos de reta definidos anteriormente. Depois, definem-se os vetores $\mathbf{v}_1 = (\mathbf{a} - \mathbf{b})$, $\mathbf{v}_2 = (\mathbf{c} - \mathbf{b})$, $\mathbf{v}_3 = (\mathbf{d} - \mathbf{e})$ e $\mathbf{v}_4 = (\mathbf{f} - \mathbf{e})$ (ver Figura 3.14), onde $\mathbf{n}_1 = \mathbf{v}_1 / |\mathbf{v}_1|$, $\mathbf{n}_2 = \mathbf{v}_2 / |\mathbf{v}_2|$, $\mathbf{n}_3 = \mathbf{v}_3 / |\mathbf{v}_3|$ e $\mathbf{n}_4 = \mathbf{v}_4 / |\mathbf{v}_4|$ representam respetivamente os vetores $\mathbf{v}_1$, $\mathbf{v}_2$, $\mathbf{v}_3$ e $\mathbf{v}_4$ normalizados (magnitude unitária). A pesquisa dos carris inicia-se a partir dos




FIGURA 3.14: Obtenção dos vetores de pesquisa dos carris $\mathbf{v}_1$ e $\mathbf{v}_2$, $\mathbf{v}_3$ e $\mathbf{v}_4$, com origem nos pontos **b** e **e**, respetivamente, e que cruzam os carris.

pontos **b** e **e** na direção dos carris. Seguidamente é apresentado o algoritmo que realiza a pesquisa dos carris.

3.4.2 Algoritmo para pesquisa dos carris

Na nuvem de pontos a densidade de pontos que representam os carris é muito maior do que a densidade de pontos que representa o espaço interior entre carris. Partindo deste pressuposto, a pesquisa dos carris é realizada com base na variação da densidade de pontos, entre os pontos que representam o espaço interior entre carris e os pontos que representam os carris na nuvem de pontos. O algoritmo em cada iteração obtém um conjunto de pontos, que são os vizinhos mais próximos do ponto pesquisado. Se a cardinalidade do conjunto dos vizinhos mais próximos obtidos na iteração corrente for maior, mais um fator definido empiricamente, do que o valor obtido na iteração anterior, o algoritmo termina e devolve o centróide do conjunto de vizinhos mais próximos obtidos na pesquisa corrente.

A Figura 3.15 exemplifica o método utilizado para o deslocamento do vetor $\mathbf{v}_1$, para obtenção do novo ponto **p** a pesquisar. O raio define um ponto em torno

do qual é definida uma zona esférica para a pesquisa dos carris, pela variação da densidade do número de pontos. O ponto $\mathbf{p}_1$, na figura, representa o ponto de início para obtenção do conjunto de pontos dos vizinhos mais próximos (ver ponto $\mathbf{b}$ na Figura 3.14), em função do parâmetro raio r definido, representado pelas circunferências. O parâmetro β representa o valor da magnitude do deslocamento do vetor $\mathbf{v}_1$ e $\mathbf{n}_1$ representa a direção do deslocamento do vetor. Então, o ponto $\mathbf{p}_2$ é obtido pelo deslocamento do ponto $\mathbf{p}_1 + \mathbf{n}_1\beta$ e o ponto $\mathbf{p}_3$ é obtido de igual forma $\mathbf{p}_2 + \mathbf{n}_1\beta$.




FIGURA 3.15: Ilustração da metodologia utilizada para o deslocamento do vetor $\mathbf{v}_1$ para obtenção de um novo ponto a pesquisar.

Por uma questão de clareza e simplificação de raciocínio a explicação incide sobre a procura do ponto $\mathbf{c}_1$, que representa um ponto sobre um dos carris, como mostrado na Figura 3.16. A localização dos restantes pontos ($\mathbf{c}_2, \mathbf{c}_3$ e $\mathbf{c}_4$), é realizada de forma análoga. Seguidamente é apresentado o algoritmo utilizado para fazer a deteção da posição dos carris.




FIGURA 3.16: Representação esquemática dos centróides $\mathbf{c}_1, \mathbf{c}_2, \mathbf{c}_3$ e $\mathbf{c}_4$ sobre os carris.

O pseudocódigo do algoritmo (ver Algoritmo 1), ilustra o modo como é localizado o ponto $\mathbf{c}_1$ sobre um dos carris. O algoritmo recebe como parâmetros

de entrada a *árvore de pesquisa binária*, populada com a nuvem de pontos $\mathcal{P}_0$, os pontos **a** e **b** que cruzam um dos carris e o raio r para fazer a pesquisa dos vizinhos mais próximos (linha1).

Algorithm 1 Algoritmo para fazer a detecção da posição dos carris

```

1: Entrada : (b : inicio, a : fim,  $r$  : raio)
2:  $\mathbf{v} \leftarrow (\mathbf{a} - \mathbf{b})$ 
3:  $V \leftarrow \emptyset$ 
4:  $\beta \leftarrow \frac{r}{2}$ 
5:  $\mathbf{p} \leftarrow \mathbf{b}$ 
6: while ( $|\mathbf{p} - \mathbf{a}| > \beta$ ) do
7:    $\mathbf{p} \leftarrow \mathbf{p} + \beta \mathbf{v}$ 
8:    $V' \leftarrow \text{vizinhos}(\mathbf{p}, r)$ 
9:   if ( $|V| > |V'| + \delta$ ) then
10:    return  $V$ 
11:   end if
12:    $V \leftarrow V'$ 
13: end while
14: return  $\emptyset$ 

```

Na linha 2 é criado o vetor de pesquisa e na linha 4 é definido o fator β , para incremento do vetor definido na linha 2. O valor do parâmetro β é metade do valor do raio r . O valor do raio é obtido empiricamente.

Na linha 6 inicia-se o ciclo de detecção dos carris, tendo como critério de paragem (a) o valor do comprimento do vetor ser menor do que o valor do fator β ou (b) o número de pontos da pesquisa anterior $|V|$, ser maior do que o número de pontos obtidos na pesquisa corrente, V' , mais um valor δ . Por cada iteração, o vetor definido na linha 2, é usado para deslocar $\mathbf{p}$ proporcionalmente ao valor do parâmetro β (linha 7 e ver Figura 3.15). Na nova posição efetua-se uma pesquisa na *árvore de pesquisa binária* para obtenção dos seus vizinhos mais próximos, V' , de acordo com um raio r (linha 8). Se o número de pontos obtidos na pesquisa anterior $|V|$, for maior do que o número de pontos obtidos na pesquisa corrente $|V'|$, mais um valor δ (linha 9), então o algoritmo retorna o conjunto de pontos obtidos na pesquisa anterior V e termina (linha 10). Caso contrário o algoritmo atualiza as variáveis (linhas 12, 13 e 14) e continua até que tenha sido atingido um dos critérios de paragem.

A Figura 3.16 mostra uma representação esquemática dos centróides $\mathbf{c}_1$, $\mathbf{c}_2$, $\mathbf{c}_3$ e $\mathbf{c}_4$ sobre os carris, obtidos pelo Algoritmo 1.

3.4.3 Estrutura de dados auxiliar para pesquisa dos carris

A pesquisa dos vizinhos mais próximos do ponto $\mathbf{p}$ diretamente sobre a nuvem de pontos $\mathcal{P}_0$ pode ser um processo demorado. A pesquisa deve ser um processo rápido e eficiente, para que seja possível a sua utilização em aplicações em tempo real [29]. Afim de evitar a comparação do ponto a pesquisar $\mathbf{p}$, com todos os pontos da nuvem de pontos $\mathcal{P}_0$, recorre-se a uma Kd-Tree [29].

Uma Kd-Tree ou *árvore de pesquisa binária*, é uma estrutura de dados indexada, que organiza um conjunto de dados em k-dimensões. Cada nível de profundidade da árvore está associado a uma dimensão. Assim, no primeiro nível da árvore, ou raiz da árvore o espaço é dividido em duas partes dada uma dimensão, como se outro plano perpendicular ao primeiro o dividesse em duas metades; a divisão do espaço é encontrada pela mediana da dimensão com maior variância do conjunto de dados; tome-se como exemplo a dimensão x e x_i a mediana da dimensão x , então todos os pontos cujo valor seja menor que x_i ficam do lado esquerdo da árvore e os valores maiores do que x_i irão aparecer do lado direito da árvore; recursivamente, cada uma das subdivisões da árvore irá ser subdividida em nós pelo mesmo processo, até ser criada uma árvore binária balanceada; cada nó corresponde a um único ponto do conjunto de dados; a altura da árvore será $\log_2 N$, onde N é o número de pontos do conjunto de dados [30].

3.4.4 Obtenção dos segmentos de reta que representam os carris

Para obter os segmentos de reta, $\mathbf{R}_+$ e $\mathbf{R}_-$, que representam os carris, os centróides $\mathbf{c}_1$ e $\mathbf{c}_4$ são projetados sobre o lado $\mathbf{hj}$ da zona B e os centróides $\mathbf{c}_2$ e $\mathbf{c}_3$ são projetados sobre o lado $\mathbf{ln}$ da zona C (ver Figura 3.17), permitindo desta maneira obter os pontos $\mathbf{c}'_1$, $\mathbf{c}'_2$ e $\mathbf{c}'_3$, $\mathbf{c}'_4$. Para simplificar a explicação, esta incide apenas sobre a obtenção do ponto $\mathbf{c}'_4$, sendo os restantes pontos $\mathbf{c}'_2$, $\mathbf{c}'_3$ e $\mathbf{c}'_4$ obtidos de forma similar.

Então, considere-se os centróides $\mathbf{c}_3$ e $\mathbf{c}_4$, o ponto $\mathbf{c}'_4$ é dado pela seguinte expressão:

$$\mathbf{c}_4 + \frac{\mathbf{c}_3 - \mathbf{c}_4}{\|\mathbf{c}_3 - \mathbf{c}_4\|}d, \quad (3.15)$$

onde d é o escalar de projeção definido pela expressão:

$$d = \|\mathbf{j} - \mathbf{c}_4\| \cdot (\mathbf{u} \cdot \mathbf{v}), \quad (3.16)$$




FIGURA 3.17: Representação dos carris R_+ e R_- .

onde os vetores $\mathbf{u}$ e $\mathbf{v}$ são obtidos pela expressão:

$$\mathbf{u} = \frac{\mathbf{c}_3 - \mathbf{c}_4}{\|\mathbf{c}_3 - \mathbf{c}_4\|}, \quad \mathbf{v} = \frac{\mathbf{j} - \mathbf{c}_4}{\|\mathbf{j} - \mathbf{c}_4\|}, \quad (3.17)$$

A Figura 3.18 mostra o resultado da localização dos carris realizada sobre a nuvem de pontos de referência $\mathcal{P}_0$.

3.4.5 Obtenção da distância entre carris

Para calcular a distância entre carris, obtém-se a distância, por exemplo, do ponto $\mathbf{c}_1$ ao segmento de reta $\mathbf{r}$ definido pelos pontos $\mathbf{c}_4$ e $\mathbf{c}_3$, que é paralela ao vetor $\mathbf{u}$ (ver Figura 3.17). A distância do ponto $\mathbf{c}_1$ ao segmento de reta $\mathbf{r}$, é:

$$\frac{\|(\mathbf{c}_1 - \mathbf{c}_4) \times \mathbf{u}\|}{\|\mathbf{u}\|}, \quad (3.18)$$

onde $\mathbf{c}_4$, é um ponto conhecido do segmento de reta $\mathbf{r}$.

3.5 Mapeamento volumétrico

Os ambientes exteriores são muito dinâmicos e imprevisíveis, por isso é necessário encontrar meios que permitam minimizar os efeitos dessa imprevisibilidade. Também é importante ter em conta em ambientes exteriores a chuva intensa, a neve,




FIGURA 3.18: Resultado da detecção da posição dos carris. As duas linhas longitudinais a vermelho, representam o resultado obtido pelo detetor dos carris. A linha a vermelho perpendicular aos dois carris representa a bitola. A linha longitudinal a verde, representa o eixo da via férrea. As quatro setas, representam a localização das MB: a ponta da seta representa o centróide e a ponta inferior representa o centróide projetado no plano.

as alterações do relevo, entre outros [22]. Para recriar estes ambientes para serem usados por agentes de decisão autónomos é necessário ter uma representação tridimensional do ambiente [31].

O uso de modelos tridimensionais fornece uma representação volumétrica do espaço e são muito utilizados em sistemas robóticos, para gerar mapas para navegação autónoma, detetar obstáculos, etc. A construção destes modelos tridimensionais é realizada através da captação de nuvens de pontos tridimensionais do ambiente a representar. Estes modelos tridimensionais designam-se por mapas volumétricos [31].

A representação tridimensional do ambiente poderia ser feita a partir de uma grelha regular 3D, partindo de um cubo que envolvesse todo o ambiente 3D a modelar. Depois, para o discretizar, o cubo seria dividido em cubos mais pequenos formando uma grelha cúbica, em que cada um destes cubos que formam a grelha representa uma parte do ambiente 3D discretizado. Algumas das desvantagens deste método, para representar o ambiente 3D, são a elevada quantidade de memória necessária, as grelhas necessitam de ser inicializadas e no caso de ser necessário aumentar a resolução ou de expandir a área modelada, o custo computacional é

elevado [32].

Donald Meagher [33], em 1982, propôs a utilização de *octrees* para modelação de espaços tridimensionais. Uma *octree*, é uma estrutura de dados hierárquica em árvore para divisão do espaço 3D. Cada nó na *octree* representa o espaço contido num volume cúbico, designado por *voxel*,² e pode ter até oito filhos [32]. O volume do *voxel* mais pequeno, define a resolução da *octree* [31]. Um nó sem filhos significa que não é necessário fazer a subdivisão.

Quando é armazenada uma nuvem de pontos numa *octree* é necessário definir o critério de paragem para volumes ocupados, que são o tamanho do *voxel* mínimo e o número mínimo de pontos [32]. A aplicação destes critérios permite evitar a criação de uma *octree* completa, i.e., uma *octree* onde todos os nós têm exatamente 8 filhos e todas os nós folha têm a mesma profundidade, ou seja, uma grelha regular. O critério definido apenas é aplicado a volumes sem pontos, porque estes não necessitam de ser subdivididos. De facto apenas são criados nós filho para volumes que contêm pontos, como ilustrado na Figura 3.19. Todos os nós que não têm filhos são interpretados como espaço vazio ou espaço ocupado [32].




FIGURA 3.19: Subdivisão do espaço 3D de uma *octree* até ao nível 3. Os nós folha ocupados estão representados a cinzento e, na parte de baixo da figura, a correspondente representação esparsa da estrutura da árvore.
(Imagem retirada de [32])

No contexto desta dissertação, o mapeamento volumétrico é feito utilizando *octrees*. Para cada zona de supervisão é construído um mapa volumétrico referência da PN $\mathcal{M}$. Para fazer o mapeamento volumétrico da PN foi obtido o conjunto de nuvens de pontos $\{\mathcal{P}_0, \dots, \mathcal{P}_k\}$, que representa o ambiente da envolvente da PN, livre de obstáculos. Por uma questão de simplificação o conjunto de nuvens de pontos utilizadas para criar o mapa volumétrico referência da PN passa a ser representado por $\mathcal{C} = \mathcal{P}_0 \cup \dots \cup \mathcal{P}_k$.

Para construir um mapa volumétrico referência da PN por cada zona de supervisão, é necessário dividir o conjunto de nuvens pontos $\mathcal{C}$ em 3 partes. Por

² *Voxel* é a combinação das palavras “volume” e “*pixel*” e representa o espaço contido num volume cúbico, definido pela resolução da *octree*.

cada parte obtida é criada um *octree*. O método utilizado para fazer a segmentação é o mesmo que foi utilizado para criar as zonas de supervisão e é descrito na Secção 3.3.2.2.

Para construir o mapa volumétrico referência da zona de supervisão A, considere-se a *octree* $\mathcal{M}_A$ com a resolução *resol*, o quadrilátero que forma a mesma zona $\hat{\mathbf{q}}_A = (\mathbf{i}, \mathbf{g}, \mathbf{k}, \mathbf{m})$ (ver Figura 3.17), o conjunto de nuvens de pontos $\mathcal{C}$ e um ponto do conjunto de nuvens $\mathbf{p}_k \in \mathcal{C}$ e aplicando a Equação 3.9 tem-se:

$$\mathcal{M}_A = \{(p_k^x, p_k^y, p_k^z) \in \mathcal{C} : f_k(p_i^x, p_i^y) > 0, \forall k \in \{1, 2, 3, 4\}\}. \quad (3.19)$$

O mapa volumétrico referência associado às zonas B e C é obtido de forma semelhante.

3.6 Processamento e detecção dos obstáculos

O modelo proposto para fazer a detecção e caracterização dos obstáculos foi introduzido na Secção 3.2 (ver Figura 3.4), tendo este como parâmetros de entrada o mapeamento semântico da PN e a nuvem de pontos capturada pelo sensor LIDAR, $\mathcal{P}$, quando se aproxima um comboio da PN mas ainda não chegou. A Secção 3.6.1 descreve em detalhe o processamento necessário para fazer a detecção dos obstáculos e a Secção 3.6.2 descreve também em detalhe o processamento necessário para fazer a caracterização dos mesmos.

3.6.1 Detecção de Obstáculos

A detecção de obstáculos está subdividido em várias fases. Começa-se por determinar o gabarito para cada uma das zonas de supervisão, seguido da remoção de pontos resultantes de erros de medição do sensor. Seguidamente é feita a detecção de alterações entre a nuvem de pontos correspondente a uma zona de detecção e o mapa volumétrico referência dessa mesma zona. Por último os pontos obtidos são agrupados, evidenciando a presença de um obstáculo. Cada grupo é caracterizado em função da altura, largura, área e distância ao eixo da via. Cada um destes aspetos é detalhado seguidamente.

3.6.1.1 Isolar pontos na zona do gabarito

A nuvem de pontos $\mathcal{P}$ (capturada no instante antes da passagem do comboio pela PN) é segmentada em função de cada uma das zonas de supervisão $\mathcal{Z}_{j \in \{A, B, C\}}$,

pelo processo explicado na Secção 3.5. Para determinar o gabarito, é necessário projetar os pontos $\mathbf{p}_j \in \mathcal{Z}_{j \in \{A,B,C\}}$ pertencentes a cada zona, no plano $\pi_{j \in \{A,B,C\}}$, pelo processo explicado na Secção 3.3.2.3.

O gabarito $\mathcal{G}_{j \in \{A,B,C\}}$ é o máximo espaço que um veículo ferroviário pode ocupar e, por isso, deve estar livre de obstáculos para prevenir eventuais acidentes [19]. Para definir o gabarito, tome-se como exemplo a zona A. Seja $\mathbf{r}$ o segmento de reta que define o eixo da via, que é paralela ao vetor $\mathbf{u}$ e $\mathcal{Z}_A$ a nuvem de pontos da zona A (ver Figura 3.20). Para obter a distância de um qualquer ponto $\mathbf{p}_j \in \mathcal{Z}_A$ ao segmento de reta $\mathbf{r}$, aplica-se a Equação 3.18. Seja $dist_A^g$ a largura do gabarito definida para a zona A a partir de dados conhecidos da via, então o conjunto de pontos que fazem parte do gabarito da zona A é definido por:

$$\mathcal{G}_A = \{\mathbf{p} \in \mathcal{Z}_A : dist(\mathbf{p}, \mathbf{r}) \leq dist_A^g\}. \quad (3.20)$$




FIGURA 3.20: Representação do eixo da via pelo segmento de reta $\mathbf{r}$ a tracejado. A área representada a branco ilustra a definição do gabarito em cada uma das zonas de supervisão.

O conjunto de pontos $\mathcal{G}_B$ e $\mathcal{G}_C$, do gabarito das zonas B e C, respetivamente, são obtidos de forma similar.

3.6.1.2 Remover pontos *outliers*

As nuvens de pontos obtidas através do sensor LIDAR podem conter erros de medição, originando pontos que apresentam um grande afastamento em relação

às superfícies reais que lhes deram origem, introduzindo alguma distorção nos resultados finais. Esses pontos normalmente denominam-se de *outliers*. Assume-se como *outlier* um ponto 3D que tem um número de vizinhos num dado raio, inferior ao típico na nuvem de pontos [34]. Para reduzir a sensibilidade ao ruído os pontos *outliers* presentes em todas as nuvens de pontos são filtrados. Um ponto é descartado de processamentos futuros, se a média das distâncias entre si e os k vizinhos mais próximos é muito diferente da média das distâncias médias calculadas entre os restantes pontos e respetivos vizinhos. Por outras palavras, se um ponto apresentar uma topologia local muito diferente da topologia média, então é considerado um *outlier* [34]. Então, seja $d_{\mathbf{p}}$ a média das distâncias Euclidiana entre o ponto $\mathbf{p}$ e os k vizinhos mais próximos, e, seja μ e σ a média das distâncias e o desvio padrão, respetivamente, da média das distâncias de todos os pontos da nuvem de pontos $\mathcal{P}$, $\mu = \frac{1}{|\mathcal{P}|} \sum_{\mathbf{p} \in \mathcal{P}} d_{\mathbf{p}}$, onde $|\mathcal{P}|$ representa o número de pontos que compõem a nuvem de pontos $\mathcal{P}$. Então um ponto $\mathbf{p} \in \mathcal{G}'_{j \in \{A,B,C\}}$ se [34]:

$$\mu - \alpha\sigma \leq d_{\mathbf{p}} \leq \mu + \alpha\sigma, \quad (3.21)$$

onde α é um escalar definido empiricamente.

3.6.1.3 Rejeitar pontos ao nível do chão

As nuvens de pontos obtidas $\mathcal{G}'_{j \in \{A,B,C\}}$ são as que resultaram depois da remoção dos pontos *outliers*. Para permitir uma boa separação dos obstáculos que possam existir nas nuvens de pontos $\mathcal{G}'_{j \in \{A,B,C\}}$, começa-se por fazer a remoção dos pontos ao nível do chão de acordo com a distância d_l definida empiricamente. Estes pontos são removidos, pois o plano do chão não constitui obstáculo. Para o fazer usa-se a estimação robusta do plano do chão baseada no algoritmo RANSAC (ver Secção 3.3.1.1). Como se pretende os pontos que estão acima do plano do chão, então um ponto $\mathbf{p}_i \in \mathcal{E}_{j \in \{A,B,C\}}$ se a sua distância ao plano do chão for superior à distância de limiar d_l . Estes conjuntos de pontos representam o mapa volumétrico instantâneo da PN $\mathcal{E}$ no instante que precede a passagem do comboio pela PN.

3.6.1.4 Detetar alterações

Na Secção 3.5 é descrito o procedimento necessário à criação do mapa volumétrico referência da PN sem obstáculos recorrendo a uma *octree* $\mathcal{M}_{j \in \{A,B,C\}}$. Na Secção 3.6.1.3 é obtido o mapa volumétrico instantâneo da PN, $\mathcal{E}_{j \in \{A,B,C\}}$ por cada zona de supervisão, que é necessário comparar com o mapa volumétrico referência. Então,

por cada nuvem de pontos que representa o mapa instantâneo da PN, $\mathcal{E}$, é criada uma *octree*.

Os obstáculos são definidos como objetos presentes no mapa volumétrico instantâneo da PN, $\mathcal{E}_{j \in \{A,B,C\}}$, e que não estavam presentes no mapa volumétrico referência da PN, $\mathcal{M}_{j \in \{A,B,C\}}$. Então, por cada zona de supervisão são comparados os dois mapas volumétricos, i.e., são comparadas duas *octrees*, utilizando para isso o método proposto por Kammerl et al. [35]. O mapa volumétrico referência da PN, $\mathcal{M}_{j \in \{A,B,C\}}$, é utilizado para criar uma estrutura de duplo buffer da *octree*. Depois, a estrutura de duplo buffer da *octree* é alterada para poder acomodar o mapa volumétrico instantâneo $\mathcal{E}_{j \in \{A,B,C\}}$. Durante o processo são adicionados novos nós folha à estrutura da *octree*, de modo a poder representar os objetos do ambiente que não estavam representados na estrutura inicial da *octree*. Depois são obtidas as diferenças entre mapas volumétricos, ou seja, a nuvem de pontos $\mathcal{A}_{j \in \{A,B,C\}}$, cujo conteúdo são os centróides dos novos nós folha adicionados à estrutura da *octree*, representa o conjunto de pontos que formam os potenciais obstáculos.

O resultado obtido é o conjunto de 3 nuvens de pontos $\mathcal{A}_{j \in \{A,B,C\}}$, que representam a existência de obstáculos na PN em cada zona de supervisão. Seguidamente, cada uma dessas nuvens de pontos é segmentada em partes mais pequenas, recorrendo ao processo descrito na Secção 3.3.1.2. O resultado dessa segmentação é o conjunto de obstáculos $\mathcal{O} = \{\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_n\}$.

O conjunto de obstáculos obtido ainda podem conter algum ruído, ao nível do chão, que é necessário eliminar. Para remover esse ruído, foi criado um filtro para obter apenas os pontos que estão acima do plano do chão, de acordo com um limiar l_A , definido empiricamente. Então, tome-se como exemplo a zona A e seja $\mathbf{p}_o = (p_o^x, p_o^y, p_o^z)$ um ponto do agrupamento $\mathcal{A}_A$, π_A o plano da zona A definido por $ax + by + cz + d = 0$, a distância do ponto d_p ao plano π_A , é dada por:

$$d_p^A = \frac{ap_o^x + bp_o^y + cp_o^z + d}{\sqrt{a^2 + b^2 + c^2}}, \quad (3.22)$$

um ponto $\mathbf{p}_o$ é descartado se $d_p^A < l_A$.

3.6.2 Caracterização dos obstáculos

A caracterização dos obstáculos permite descrever a sua localização no espaço 3D, a sua posição em relação ao eixo da via, a sua altura e por fim a sua largura. Nas

secções seguintes é feita a descrição do modo como foram feitas as medições e, em todas elas, foram utilizados obstáculos localizados na zona A.

3.6.2.1 Caraterização do obstáculo pela altura

A altura de um obstáculo é definida como sendo a distância máxima encontrada entre todos os pontos que o compõem e o plano π_A . Seja $\mathbf{o}$ um obstáculo detetado na Zona A, o plano da zona A, $\pi_A = (a, b, c, d)$, definido pela equação $ax + by + cz + d = 0$, $\mathbf{p}_o = (p_o^x, p_o^y, p_o^z)$ um ponto do obstáculo $\mathbf{o}$, a altura do obstáculo é dada por:

$$h_{(o,\pi)} = \max \left\{ \frac{ap_o^x + bp_o^y + cp_o^z + d}{\sqrt{a^2 + b^2 + c^2}}, \quad (p_o^x, p_o^y, p_o^z) \in \mathbf{o} \right\}. \quad (3.23)$$

3.6.2.2 Caraterização do obstáculo pela largura

A largura de um obstáculo $\mathbf{o}$, $l_{(o,\pi)}$, é obtida projetando todos os pontos $\mathbf{p}$ do obstáculo no plano π_A . A projeção dos pontos $\mathbf{p}$ no plano π_A , é feita pelo método explicado na Secção 3.3.2.3. Seja, $\mathbf{p} = (p_x, p_y, p_z)$ e $\mathbf{q} = (q_x, q_y, q_z)$ dois pontos de um dado obstáculo $\mathbf{o} \in \mathcal{O}$, a distância euclidiana máxima entre os pontos $\mathbf{p}$ e $\mathbf{q}$ é dada por:

$$l_{(o,\pi)} = \max \left\{ \sqrt{(p_x - q_x)^2 + (p_y - q_y)^2 + (p_z - q_z)^2}, \quad \forall \mathbf{p}, \mathbf{q} \in \mathbf{o} \right\}. \quad (3.24)$$

3.6.2.3 Caraterização do obstáculo pela distância ao eixo da via

Para determinar a distância do obstáculo $\mathbf{o}$ ao eixo da via, $d_{(o,\pi)}$, é necessário, em primeiro lugar, calcular o centróide do obstáculo $\mathbf{c}(o)$, através do método explicado na Secção 3.3.1.4 e aplicando a Equação 3.4. Depois, é necessário fazer a sua projeção no plano π_A . Então, seja $\mathbf{c}(o)$ o centróide do obstáculo $\mathbf{o}$, pelo método explicado na Secção 3.3.2.3 e aplicando a Equação 3.12, obtém-se o centróide projetado no plano $\mathbf{c}_p(o)$. Por último, falta calcular a distância do centróide ao eixo da via. Seja $\mathbf{r}$ o segmento de reta que define o eixo da via, que é paralelo ao vetor $\mathbf{u}$ (ver Figura 3.20), a distância, do centróide projetado, ao segmento de reta $\mathbf{r}$ é:

$$d(o, \pi) = \frac{\|(\mathbf{c}_p(o) - \mathbf{q}) \times \mathbf{u}\|}{\|\mathbf{u}\|}, \quad (3.25)$$

onde $\mathbf{q}$ é um ponto qualquer do segmento de reta $\mathbf{r}$.

Capítulo 4

Resultados Experimentais

Este capítulo apresenta, na Secção 4.1, a instalação experimental utilizada para validar o sistema. Na Secção 4.2 é apresentado o conjunto de dados utilizados na validação do sistema. Na Secção 4.3 são descritos e apresentados os parâmetros da configuração considerados na validação do sistema. Na Secção 4.4 é feita uma avaliação do desempenho do sistema. Na Secção 4.5 é apresentada a análise de sensibilidade dos parâmetros utilizados.

4.1 Instalação Experimental

O sistema proposto foi testado numa unidade computacional com um processador de 2,66 GHz Intel Core 2 Duo-based MacBook Pro, com 8 Gb de memória RAM, correndo o sistema operativo OSX Maverick 10.9. Para implementar o sistema proposto foi utilizada a linguagem de programação C++ e a biblioteca *Point Cloud Library* (PCL) [36]. A PCL é uma biblioteca de *software* livre, para processamento de nuvens de pontos 3D. A sua distribuição é feita sob a licença *Berkley Software Distribution* (BSD), de acesso livre para fins comerciais e de investigação.

O equipamento utilizado para fazer a captura das nuvens de pontos inclui um sensor LIDAR SICK LMS 111, uma *Inertial Measurement Unit* (IMU) 1056 - PhidgetSpatial 3/3/3, com um servo dynamixel MX-64 para o fazer o fazer rodar ciclicamente entre -15° e 30°. A estimação da pose do laser é realizada através de um estimador ótimo [37], que corre como um nó *Robot Operating System* (ROS) [38] a partir da informação que vem da IMU, tendo em conta os seus magnetómetros, giroscópios e acelerómetros. A informação de pose do laser em cada instante é utilizada para registar o conjunto de pontos capturado num dado instante com os pontos capturados até então. O resultado é uma nuvem de pontos 3D, gerada numa

única oscilação (varrimento), que cobre uma grande porção da PN e imediações (e.g., ver Figura 4.1), cuja captura demora em média cerca de 5 segundos.




FIGURA 4.1: Área da PN coberta pelas nuvens de pontos.

A recolha do conjunto de nuvens de pontos na PN foi feita com um servo, com o LIDAR colocado sobre uma plataforma oscilante apoiada no chão. A PN tem um movimento intenso de veículos rodoviários e a plataforma foi colocada junto da estrada, por ser o local mais adequado para fazer a captura das nuvens de pontos. O modo de recolha de informação introduziu ruído nas nuvens de pontos, por o sensor estar a cerca de 1 metro de altura do chão e sujeito a vibrações que são transmitidas ao chão pela passagem dos veículos rodoviários.

4.2 Conjunto de dados

A figura 4.2 ilustra o contexto da PN do Sabugo, na Linha do Oeste, onde é possível observar as antenas do SDO por RADAR instalado na PN e a localização aproximada onde foi colocado o sensor LIDAR, para fazer a captura das nuvens de pontos.

Para fazer a validação experimental do algoritmo foram recolhidas 41 nuvens de pontos. Um subgrupo formado por 32 nuvens de pontos, das quais 4 não contêm obstáculos e 28 contêm obstáculos diversos, como pessoas em pé ou ajoelhadas e outros objetos de baixa volumetria, foi utilizado para validar e testar o sistema. Os obstáculos de baixa volumetria são um cesto de papéis, um jerrican e uma pedra, ilustrados na Figura 4.3; um segundo subgrupo formado por 9 nuvens de pontos sem obstáculos é utilizado para criar o mapa volumétrico referência descrito na Secção 3.5.



FIGURA 4.2: A imagem ilustra o contexto da PN, com a indicação da localização do sensor LIDAR, para captura das nuvens de pontos. Também apresenta as antenas do SDO por RADAR, que está instalado na PN.



FIGURA 4.3: Alguns dos tipos de obstáculos de baixa volumetria considerados nos testes: (a) Pedra ($\approx 10 \text{ dm}^3$); (b) Cesto de papéis ($\approx 20 \text{ dm}^3$); (c) Jerrican ($\approx 50 \text{ dm}^3$).

A Tabela A.1 resume as nuvens de pontos e faz uma descrição dos obstáculos por nuvem de pontos; O Anexo C apresenta uma visualização dos obstáculos existentes nas várias nuvens de pontos.

4.3 Parametrização do Sistema

Nesta secção são apresentados e caracterizados os parâmetros e apresentados os valores que lhes foram atribuídos na configuração escolhida. Por uma questão de metodologia a secção foi dividida em três subsecções: deteção das meias barreiras, deteção dos carris e deteção dos obstáculos.

Na zona C o número de pontos é esparsa, como ilustrado na Figura 4.7, o que dificulta a detecção de obstáculos de baixa volumetria. Devido a esse facto para evitar obter falsos positivos, foi necessário aumentar o valor do parâmetro d_p^C para 0.7 m, enquanto nas outras zonas, o valor atribuído aos parâmetros d_p^A e d_p^B é de 0.2 m e de 0.15 m, respetivamente, portanto bastante mais baixos.

4.3.1 Detecção das meias barreiras

Nesta secção pretende-se caraterizar os parâmetros utilizados na detecção das MB, a partir da nuvem de pontos referência $\mathcal{P}_0$. A detecção das MB é realizada utilizando os valores dos parâmetros apresentados seguidamente, obtidos empiricamente: $k = 1000$, $d_l = 1.5$ m, $d_{min} = 0.1$ m, $n_{min} = 10$, $n_{max} = 2500$ e $h_z = 2.5$ m.

4.3.1.1 Rejeitar pontos ao nível do chão

Na Secção 3.3.1.1 são explicados os conceitos teóricos utilizados para rejeitar pontos ao nível do chão i.e., garantidamente não obstáculos, onde são definidos os dois parâmetros necessários ao algoritmo *RANSAC*, para segmentar a nuvem de pontos $\mathcal{P}_0$ nomeadamente, k e d_l .

O parâmetro k define o número máximo de iterações necessárias, para que o algoritmo consiga estimar corretamente o plano do chão. Por outro lado, o número de iterações tem um forte impacto no tempo de processamento. Neste pressuposto o valor definido para este parâmetro é de 1000 iterações. Este valor procura estabelecer um compromisso entre o tempo de processamento e o número máximo de iterações, tendo em vista a obtenção de uma solução robusta para resolver o problema.

O parâmetro d_l , define o limiar a partir do qual um ponto faz parte do modelo para ser considerado um *inlier*. As hastes das MB são objetos altos, que se destacam na nuvem de pontos $\mathcal{P}_0$, com um comprimento que pode variar entre 2 e 6.5 m, dependendo da largura da estrada. As hastes das MB estão fixas a um mecanismo que as comanda, a cerca de 0.9 m acima do solo, por isso o parâmetro d_l foi definido com o valor de 1.5 m. Desta forma obtêm-se apenas os elementos que podem descrever as hastes das MB.

A Figura 4.4 mostra o resultado típico da aplicação do método *RANSAC* para segmentar a nuvem de pontos referência $\mathcal{P}_0$ com a parametrização escolhida. O conjunto de pontos representados a vermelho descrevem o plano do chão onde estão localizadas as MB. O conjunto de pontos representados a cinzento representam os

pontos rejeitados ao nível do chão e utilizados para obter os agrupamento que descrevem as hastes das MB.




FIGURA 4.4: Segmentação da nuvem de pontos referência $\mathcal{P}_0$, utilizada para fazer a detecção das MB. Os pontos representados a vermelho correspondem aos *inliers*, ou seja, aos pontos extraídos pela segmentação de pontos acima do plano do chão. Os representados a cinzento correspondem aos pontos que foram utilizados para obter os agrupamentos.

4.3.1.2 Agrupar pontos

Na Secção 3.3.1.2 são explicados os conceitos teóricos para obter os agrupamentos com base na distância entre pontos, de modo a que pontos com menor distância entre si são os mais semelhantes. O algoritmo utilizado para fazer a extração de agrupamentos utiliza três parâmetros essenciais: d_{min} , n_{min} e n_{max} .

O parâmetro d_{min} define a distância máxima que se aceita entre objetos diferentes para decompor a nuvens de pontos $\mathcal{P}'_0$ nos seus vários elementos separados no espaço. Apesar das hastes das MB serem elementos compridos, na nuvem de pontos o número de pontos que as definem são poucos e com algum afastamento entre si, por serem objetos com pouca espessura, pouca largura e estarem longe do sensor LIDAR. Por isso, o valor definido para o parâmetro foi de 10 cm. Para valores mais elevados, objetos diferentes poderiam ser representados pelo mesmo agrupamento. Por outro lado, com valores menores poderia acontecer que um agrupamento ficasse dividido em mais do que um agrupamento. Da mesma forma, o valor dos parâmetros n_{min} e n_{max} , conjugados com o parâmetro d_{max} condicionam os resultados dos agrupamentos obtidos, por isso, estes parâmetros foram definidos empiricamente, em função dos resultados a obter e dos objetos a extrair.

O conjunto de pontos representados a cinzento na Figura 4.4 representa a nuvem de pontos $\mathcal{P}'_0$, sobre a qual foi aplicado o algoritmo de extração de conjuntos de pontos para obter o conjunto de agrupamentos $\mathcal{A}_0$.

4.3.1.3 Rejeitar agrupamentos pela altura

Na Secção 3.3.1.3, são explicados os conceitos teóricos para rejeitar agrupamentos pela sua altura, porque os objetos a procurar são as hastes das MB para se poder inferir a localização das MB. No conjunto de agrupamentos $\mathcal{A}_0$ existem 4 agrupamentos que correspondem à localização das MB, portanto existe a necessidade de rejeitar alguns deles para reduzir o número de possíveis agrupamentos que possam corresponder à sua localização. Como as hastes das MB são elementos altos, o critério que melhor se ajusta a este filtro é a altura do agrupamento. A altura de um agrupamento é dada pela maior distância na coordenada z entre dois pontos diferentes do mesmo agrupamento.

As hastes das MB têm um comprimento superior a 2 m e estão fixas a um mecanismo que as comanda acerca de 0.9 m acima do solo. Neste pressuposto o parâmetro h_z foi definido como sendo 2.5 m, porque interessa obter os agrupamentos que pela sua altura possam representar as hastes das MB.

Na Figura 4.4 pode ver-se o conjunto de agrupamentos $\mathcal{A}'_0$ representados por setas com uma esfera na ponta, cuja a altura do agrupamento é maior do que o valor definido no parâmetro h_z . A origem da seta corresponde ao centróide — um ponto no espaço cartesiano representado na Figura 4.4 por uma esfera na ponta da seta — projetado no plano. No lado esquerdo da Figura 4.4 são visíveis os 4 centróides que correspondem à localização das MB e do lado direito da mesma figura, é visível um aglomerado de centróides, que foram filtrados pelo método explicado na Secção 3.3.2.1.

4.3.2 Detecção dos carris

Na Secção 3.4 são explicados os conceitos teóricos utilizados para detetar os carris, pela variação da densidade de pontos entre o espaço interior entre carris e os carris. Nesta secção pretende-se caraterizar os parâmetros utilizados na detecção dos carris, a partir da nuvem de pontos de referência $\mathcal{P}_0$. A detecção dos carris foi efetuada utilizando os valores dos parâmetros apresentados a seguir, obtidos empiricamente: $\omega_1 = 1.5$ m, $\omega_2 = 4$ m, $r = 0.07$ m e $\beta = \frac{r}{2}$.

O valor atribuído aos parâmetros ω_1 e ω_2 define a magnitude do deslocamento da origem dos vetores $\mathbf{u}_1$ e $\mathbf{u}_2$ em relação aos pontos $\mathbf{g}$ e $\mathbf{i}$, para obtenção das zonas para pesquisa dos carris, formadas pelos segmentos de reta $\mathbf{df}$ e $\mathbf{ac}$ respetivamente (ver Figura 4.5). O valor atribuído ao parâmetro r define o raio de pesquisa para obtenção do conjunto de vizinhos mais próximos do ponto a pesquisar. Por último,

o valor atribuído ao parâmetro β , representa a magnitude de deslocamento do vetor de pesquisa dos carris, que em cada iteração determina o novo ponto a pesquisar (linha 2 e linha 7 do Algoritmo 1), é definido como sendo metade do raio r . A pesquisa dos carris inicia-se a partir do meio do espaço interior entre carris perpendicularmente a estes, para cada um dos lados.




FIGURA 4.5: Parametrização dos parâmetros, ω_1 e ω_2 , utilizados para obtenção das zonas para pesquisa dos carris, formadas pelos segmentos de reta **df** e **ac**.

4.3.3 Detecção dos obstáculos

Na Secção 3.6, são explicados os conceitos teóricos utilizados para detetar e caraterizar os obstáculos. Nesta secção, pretende-se caraterizar os parâmetros utilizados neste processo. A Tabela 4.1 apresenta os valores dos parâmetros, obtidos empiricamente, para fazer a detecção dos obstáculos sem incorrer em falsos positivos ou falsos negativos.

4.3.3.1 Isolar pontos na zona do gabarito

O primeiro passo, antes de se iniciar a detecção de obstáculos, é obter o gabarito da área de influência da PN. Para isso são definidos 3 parâmetros, $dist_A^g$, $dist_B^g$ e $dist_C^g$ (ver Secção 3.6.1.1), cujos valores atribuídos estão presentes na Tabela 4.1. Cada um destes valores é medido a partir do eixo da via para cada um dos lados da mesma. O valor do gabarito para as zonas B e C, corresponde ao máximo espaço que um veículo ferroviário pode ocupar, enquanto para a zona A corresponde à área interior da PN (ver Figura 4.6).

TABELA 4.1: Tabela de configuração com os parâmetros e valores atribuídos para a detecção dos obstáculos

Zona A		Zona B		Zona C	
Parâmetro	Valor	Parâmetro	Valor	Parâmetro	Valor
$dist_A^g$	4.250 m	$dist_B^g$	1.750 m	$dist_C^g$	1.750 m
K_A	30	K_B	30	K_C	30
α_A	2.500	α_B	2.500	α_C	2.500
k_A	1000	k_B	1000	k_C	1000
d_l^A	0.175 m	d_l^B	0.150 m	d_l^C	0.025 m
$resol_A$	0.025 m	$resol_B$	0.075 m	$resol_C$	0.100 m
d_p^A	0.200 m	d_p^B	0.150 m	d_p^C	0.700 m
d_{min}^A	0.500 m	d_{min}^B	0.500 m	d_{min}^C	0.500 m
n_{min}^A	32	n_{min}^B	35	n_{min}^C	55
n_{max}^A	25000	n_{max}^B	25000	n_{max}^C	25000




FIGURA 4.6: Gabarito para as zonas de supervisão A, B e C. A figura ilustra a definição do gabarito para cada uma das zonas de supervisão definidas. O gabarito da zona A corresponde a toda a área da PN; O gabarito das zonas B e corresponde ao espaço que obrigatoriamente tem de estar livre de obstáculos.

O segundo passo é remover os pontos *outliers*, como explicado na Secção 3.6.1.2. Os parâmetros K_A , K_B e K_C são todos definidos com o valor de 30 pontos e os parâmetros α_A , α_B e α_C são definidos com o valor de 2.5. Os parâmetros $K_{\in A,B,C}$ correspondem ao número de vizinhos mais próximos analisados e os parâmetros $\alpha_{\in A,B,C}$ são os fatores que dependem do número de vizinhos mais próximos analisados [34], i.e., variam na razão inversa do número de vizinhos mais próximos analisados.

4.3.3.2 Rejeitar pontos ao nível do chão

Na Secção 3.6.1.3, são explicados os conceitos teóricos utilizados para rejeitar pontos ao nível do chão, onde são definidos os dois parâmetros necessários ao algoritmo RANSAC para segmentar a nuvem de pontos $\mathcal{C}$, k e d_l . Na Tabela 4.1 são apresentados os valores atribuídos a estes parâmetros.

Os parâmetros k_A , k_B e k_C , definem o número máximo de iterações, para cada uma das zonas de supervisão, para que o algoritmo consiga estimar corretamente o plano do chão, tendo sido definido com o valor de 1000 iterações. Na Secção 4.3.1.1 é explicada a razão para o parâmetro k ter sido definido com este valor.

Cada uma das zonas de supervisão apresenta características diferentes, por isso os valores atribuídos aos parâmetros d_l^A , d_l^B e d_l^C são também diferentes e são 0.175 m, 0.15 m e 0.025 m, respetivamente, tendo sido obtidos empiricamente.

4.3.3.3 Detetar alterações

Na Secção 3.6.1.4, são explicados os conceitos teóricos para detetar alterações entre o mapa volumétrico referência $\mathcal{M}$ e o mapa volumétrico instantâneo $\mathcal{E}$. Na Tabela 4.1, são apresentados os valores atribuídos aos parâmetros $resol_A$, $resol_B$ e $resol_C$, que são 0.025 m, 0.075 m e 0.1 m respetivamente. As áreas mais distantes do sensor LIDAR na zona A são definidas por poucos pontos ou pela ausência deles; na zona B existem áreas com poucos pontos ou ausência deles e em outras áreas existe uma boa densidade de pontos. A densidade de pontos na Zona C é esparsa, pouco definida e com poucos pontos para a representar, em resultado da distância a que o sensor LIDAR se situa da mesma. A zona C caracteriza-se pela dificuldade na deteção de obstáculos de baixa volumetria, devido à pouca densidade de pontos (ver Figura 4.7). Por isso, os valores atribuídos aos parâmetros são diferentes de acordo com a zona de supervisão a que estão associados, tendo sido obtidos empiricamente como aqueles que melhores resultados produzem.




FIGURA 4.7: Densidade de pontos nas zonas de supervisão A, B e C. Na zona A existem áreas onde os pontos são raros; na zona B existem áreas sem pontos e nas outras áreas existe uma boa densidade de pontos; a zona C caracteriza-se toda ela por ser pouco definida, i.e., é uma zona esparsa de pontos.

4.3.3.4 Agrupar pontos

Na Secção 3.3.1.2 são explicados os conceitos teóricos para obter os agrupamentos, ou seja, os vários potenciais obstáculos. Na Tabela 4.1 são apresentados, para cada

uma das zonas de supervisão, os valores atribuídos aos parâmetros: d_{min}^A , n_{min}^A e n_{max}^A , d_{min}^B , n_{min}^B e n_{max}^B , d_{min}^C , n_{min}^C e n_{max}^C .

Os parâmetros d_{min}^A , d_{min}^B e d_{min}^C definem a mínima distância que se aceita entre objetos diferentes. O valor definido para este parâmetro é 0.5m. Se o valor do parâmetro fosse mais elevado, poderia acontecer que objetos diferentes fizessem parte do mesmo agrupamento. Por outro lado, se valor do parâmetro fosse menor, poderia acontecer que um agrupamento fosse dividido em mais do que um agrupamento, quando a densidade de pontos é baixa. Os parâmetros n_{min}^A , n_{min}^B e n_{min}^C , definem o número mínimo de pontos necessários à formação dos agrupamentos, não podendo exceder o número máximo de pontos definido nos parâmetros n_{max}^A , n_{max}^B e n_{max}^C . Os valores definidos são diferentes em cada uma das zonas de supervisão e foram aqueles que, para todo o conjunto de nuvens de pontos utilizadas, permitiram detetar todos os obstáculos, ou seja, sem haver lugar a falsos positivos ou falsos negativos, tendo sido obtidos empiricamente.

4.3.3.5 Filtrar pontos acima do chão

Na Tabela 4.1, para cada uma das zonas de supervisão, são apresentados os valores atribuídos aos parâmetros: d_p^A , d_p^B e d_p^C .

Os valores definidos para estes parâmetros são aqueles que permitiram obter os melhores resultados. A zona de supervisão C é mais esparsa e o número de pontos que a representa é bastante baixa. Uma das consequências deste facto é a pouca definição dos objetos. Nestas condições para evitar obter falsos positivos, é necessário aumentar a distância relativa ao chão. Por isso, o parâmetro para esta zona, d_p^C , é definido com o valor de 0.7m, o que pode ser uma desvantagem, porque se houver objetos com uma altura inferior não serão detetados, originando falsos negativos. Contudo esta desvantagem será ultrapassada com a instalação do sensor sobre um poste alto, ou, em alternativa, a instalação de um sensor por cada zona de supervisão. Esta solução permitiria obter nuvens de pontos com uma densidade de pontos mais uniforme e uma melhor definição na captação do ambiente envolvente da PN.

4.4 Desempenho do Sistema

Um dos principais objetivos desta dissertação é a deteção de obstáculos de baixa volumetria, como os ilustrados na Figura 4.3. O sistema detetou corretamente

todos os obstáculos, incluindo os de baixa volumetria, no total do conjunto de dados testados.

No contexto de uma PN, o tempo que o SDO demora a verificar se a PN está livre de obstáculos é um fator muito importante, i.e., quanto mais rápido o SDO conseguir detetar os obstáculos melhor. A Tabela 4.2 apresenta os tempos médios observados na fases intermédias de processamento das nuvens de pontos:

TABELA 4.2: Tempos médios parciais gastos pelo sistema.

Fase de processamento	Duração
Captura de uma nuvem de pontos	5 000 ms
Deteção da passagem de nível	1 930 ms
Deteção dos carris	574 ms
Mapa volumétrico referência	210 ms
Mapa volumétrico instantâneo	515 ms
Deteção de alterações entre os mapas	100 ms

A Tabela 4.3 apresenta uma descrição pormenorizada de 3 nuvens de pontos representativas do conjunto das nuvens de pontos utilizadas nos testes. É apresentado uma descrição do conteúdo e do número de pontos por nuvem de pontos. A Tabela A.1, incluída no Anexo A, apresenta esta informação para todas as nuvens de pontos utilizadas nos testes.

TABELA 4.3: Excerto da informação constante na Tabela A.1.

Nuvem de pontos	Número de pontos	Obstáculos na nuvem de pontos
11.pcd	240 052	Sem obstáculos
19.pcd	242 480	Quatro pessoas na zona A
21.pcd	238 833	Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C

A Tabela 4.4 apresenta os tempos intermédios gastos pelo algoritmo no processamento das nuvem de pontos, estando dividida em duas partes. A tabela apresenta os tempos de leitura das nuvens de pontos a partir do disco e os tempos de processamento do gabarito associado a cada uma das zonas de supervisão. Verifica-se que o tempo de processamento necessário ao processamento do gabarito é muito semelhante e é independente do número de pontos processados. A tabela também apresenta o tempo gasto para fazer a deteção das alterações entre o mapa volumétrico referência e o mapa volumétrico instantâneo associado a cada uma das zonas de processamento. Verifica-se que os tempos gastos para detetar as

alterações entre os mapas volumétricos é maior na zona A do que nas Zonas B e C. Esta diferença de tempos deve-se ao facto de a quantidade de alterações entre mapas volumétricos na zona A ser maior do que nas outras zonas. No Anexo B, a Tabela B.1 apresenta esta informação para todas as nuvens de pontos utilizadas nos testes para validar o sistema.

TABELA 4.4: Excerto da informação constante na Tabela B.1.

Nuvens de pontos	Ler do disco	Gabarito			Deteção de Alterações		
		A	B	C	A	B	C
	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)
11.pcd	3 611	223	301	29	69	18	1
19.pcd	3 866	227	293	30	71	17	1
21.pcd	3 611	212	288	32	69	17	1

t = tempo de processamento; (ms) = milisegundos; A, B, C = zonas de supervisão.

As Figuras 4.8 e 4.9 exemplificam o resultado típico da deteção de obstáculos, a partir de duas nuvens de pontos utilizadas para validar o sistema.




FIGURA 4.8: Nuvem de pontos 19 - Quatro pessoas na zona A.




FIGURA 4.9: Nuvem de pontos 21 - Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C.

O Anexo C mostra uma visualização dos obstáculos existentes por nuvem de pontos na PN.

4.5 Análise de sensibilidade

Nesta secção é avaliada a sensibilidade do sistema às variações dos seus parâmetros, isto é, fazendo variar o valor atribuído aos parâmetros entre -50% e +50%, do valor

utilizado na configuração escolhida. Como se irá ver os sistema mostra-se em geral robusto às variações impostas.

4.5.1 Tempo médio de processamento das *octrees*

Nesta secção procura-se caraterizar o tempo de processamento das *octrees*, para fazer a deteção das alterações entre o mapa volumétrico referência $\mathcal{M}_j$ e o mapa volumétrico instantâneo $\mathcal{E}_j$, para cada uma das zonas de supervisão definidas. Na caraterização é utilizado o grupo de 32 nuvens de pontos (ver Secção 4.2), tendo sido obtidos 4608 registos com a variação dos seguintes parâmetros:

- i. O valor do parâmetro d_l , *rejeitar pontos ao nível do chão* (ver Secção 3.6.1.3), para cada uma das zonas de supervisão, variou nos seguintes valores, em metros: 0.05; 0.1; 0.15; 0.2; 0.3 e 0.7.
- ii. O valor do parâmetro $resol$, *resolução da octree* (ver Secção 3.6.1.4), para cada uma das zonas de supervisão e para cada valor do parâmetro d_l , variou entre 0.025 m e 0.255 m em intervalos de 0.01 m.
- iii. O valor do parâmetro n_{min} , *número mínimo de pontos necessários para formar um agrupamento* (ver Secção 3.6.1.4), foi de 32 pontos para a zona A, 35 pontos para a zona B e 55 pontos para a zona C.

O gráfico ilustrado na Figura 4.10 apresenta as curvas dos tempos médios de processamento gastos pelas *octrees*, na deteção das alterações entre o mapa volumétrico referência $\mathcal{M}_j$ e o mapa volumétrico instantâneo $\mathcal{E}_j$, em função da resolução das *octrees*. Pode-se observar que à medida que o valor do parâmetro resolução aumenta, diminui o tempo médio de processamento gasto pelas *octrees*, ou seja, ao aumentar o tamanho das *voxels* diminuí-se o número de *voxels* a processar e, desta forma, diminui o tempo de processamento.

4.5.1.1 Considerações

No contexto desta dissertação, o mapeamento volumétrico descrito na Secção 3.5 e a deteção de alterações descrito na Secção 3.6.1.4 são duas componentes importantes deste trabalho que utilizam *octrees*. Estas duas componentes no seu conjunto necessitam de ser eficientes, quer no tempo de processamento gastos pelas *octrees*, quer no consumo de memória necessária ao processamento das alterações. O gráfico ilustrado na Figura 4.10, mostra que com a diminuição da resolução das *octrees*, diminui também o tempo de processamento das alterações entre mapas




FIGURA 4.10: Gráfico do tempo médio de processamento da *octree*. A *octree*-B gasta mais tempo no processamento, devido ao número de pontos a processar.

volumétricos. Este é o custo a pagar entre precisão e eficiência na deteção dos obstáculos, i.e., a precisão na deteção dos obstáculos de baixa volumetria é paga com mais tempo gasto no processamento das alterações entre os mapas volumétricos.

4.5.2 Deteção das Meias Barreiras

Nesta secção analisa-se a variação dos valores atribuídos aos parâmetros utilizados para fazer a deteção das MB, no intervalo de -50% e + 50% do valor utilizado na configuração escolhida, em passos de 10%. Ainda que na variação dos valores utilizados nos parâmetros são detetadas as MB, os testes mostram que em algumas situações não é possível fazer a deteção dos carris, com essas mesmas parametrizações. Então, por isso, optou-se por, para cada parâmetro em teste, verificar se o valor utilizado no parâmetro permite detetar as MB e os carris em simultâneo.

A dificuldade na deteção dos carris em algumas situações prende-se com o facto de os pontos **g** e **i** (ver Figura 4.5), que são comuns às zonas A e B, terem alterado a sua posição e por consequência a zona de pesquisa dos carris, que é definida a partir destes pontos. A deteção das quatro MB é correta para todos os valores. O valor de distância obtido entre carris é de ≈ 1754.73 mm (ver Figura 4.11). Considerando que a bitola, também designada por largura da via, é de 1668 mm, medida à face interior das cabeças dos carris e que, a mesa de rolamento, i.e., a superfície da face superior do carril que está em contacto com a roda do comboio,

mede cerca de 72 mm; que somando ao valor da bitola duas vezes o valor da largura da mesa de rolamento, obtém-se o valor 1812 mm, que é o valor medido à face exterior de cada carril; considerando alguma imprecisão na captura da nuvem de pontos e no modo como o algoritmo deteta os carris, então o valor medido pelo algoritmo ≈ 1754.73 mm está muito próximo do valor real entre carris medido à face exterior de cada carril, i.e., corresponde a um erro de medição por excesso de $\approx 5,2\%$.




FIGURA 4.11: Exemplo da detecção das MB e Carris, utilizando os valores atribuídos aos parâmetros na configuração escolhida. As duas linhas marcadas com a cor vermelha, que atravessam toda a imagem, representam os dois carris; a linha marcada com a cor magenta, representa o eixo da via; As duas linhas marcadas com a cor vermelha, que cruzam os carris, representam a zona de pesquisa dos carris; os quatro pontos marcados com a cor azul sobre os carris, representam os pontos encontrados durante a pesquisa dos carris; A linha marcada com a cor vermelha e perpendicular aos dois carris representa a bitola da via.

Para o valor de -50% atribuído ao parâmetro n_{min} , o algoritmo deteta as quatro MB, no entanto, depois o algoritmo perde exatidão na detecção dos carris, onde a distância entre carris medida é de ≈ 1689.76 mm (ver Figura 4.12a). Para os restantes valores a detecção das quatro MB pelo algoritmo e, posteriormente, a detecção dos carris são feitas corretamente.

Para valores iguais ou inferiores a -10% atribuídos ao parâmetro d_{min} , o algoritmo não consegue detetar as MB. Para valores iguais ou superiores a $+10\%$, o algoritmo deteta as MB, no entanto, na fase seguinte não consegue fazer a detecção dos carris (ver Figura 4.12b). Este parâmetro revelou uma elevada sensibilidade devido á pouca densidade de pontos que representam as hastes das MB na nuvem de pontos, mostrando que esta pequena variação do valor atribuído ao parâmetro o algoritmo não conseguir formar agrupamentos.

Já para o parâmetro h_z , para valores iguais ou inferiores a -40% o algoritmo não consegue detetar as quatro MB. Para os restantes valores a detecção das quatro MB e dos carris é feita corretamente.




FIGURA 4.12: Resultados dos testes de sensibilidade realizados aos parâmetros utilizados na detecção das MB: (a) Resultado do teste ao parâmetro n_{min} , com um valor atribuído de -50% do valor utilizado na configuração escolhida. A distância entre carris medida foi de ≈ 1689.76 mm. A seta a preto, na imagem, assinala a falsa detecção dos carris. (b) Resultado do teste ao parâmetro d_{max} com um valor atribuído de +10% do valor utilizado na configuração escolhida. A seta bidirecional a preto, na imagem, mostra a falha da detecção do carril, ainda que a detecção das quatro MB tivesse sido feita corretamente.

4.5.2.1 Considerações

Os testes realizados com várias nuvens de pontos mostram que os parâmetros utilizados pelo algoritmo para a detecção das MB, com exceção do parâmetro d_{min} , apresentam pouca sensibilidade às variações dos valores testados nos parâmetros. Contudo o parâmetro d_{min} revelou uma elevada sensibilidade, uma vez que para valores diferentes do utilizado na configuração escolhida limitam a detecção das MB e/ou dos carris. Na nuvem de pontos, a representação das MB é feita com uma baixa densidade de pontos. Assim, qualquer pequena variação do valor da distância (parâmetro d_{min}) que se aceita entre objetos diferentes, gera uma má formação dos agrupamentos.

Os testes mostram também que, apesar dos parâmetros variarem dentro dos valores definidos e as MB serem detectadas, em alguns casos, na fase seguinte os carris não são detetados. Por isso optou-se por, para cada parâmetro em teste utilizado para a detecção das MB, verificar se a detecção das MB e dos carris é feita corretamente.

4.5.3 Detecção dos carris

Nesta secção analisa-se a variação dos valores atribuídos aos parâmetros utilizados para fazer a detecção dos carris, no intervalo de -50% e + 50% do valor utilizado na configuração escolhida, em passos de 10%.

A Figura 4.13a mostra o resultado da detecção dos carris utilizando os valores atribuídos aos parâmetros na configuração escolhida. A Figura 4.13b mostra o




FIGURA 4.13: Resultados dos testes de sensibilidade realizados aos parâmetros utilizados na detecção dos Carris: (a) Resultado obtido com os valores atribuídos aos parâmetros, para detecção dos carris na configuração escolhida. (b) Resultado do teste ao parâmetro r , com um valor atribuído de -50% do valor utilizado na configuração escolhida. A seta a preto, na imagem, assinala a falha da detecção do carril. (c) Resultado do teste ao parâmetro ω_2 , com um valor atribuído de +30% do valor utilizado na configuração escolhida. O círculo a preto, na imagem, mostra uma zona branca sem pontos, o que conduziu a uma falha na detecção do carril.

resultado da detecção dos carris, utilizando no parâmetro r -50% do valor atribuído ao parâmetro na configuração escolhida. Como o valor do raio r é metade do utilizado na configuração escolhida, o número de pontos obtidos pelo algoritmo é baixo (marcados com a cor azul sobre os carris na Figura 4.13b). Na Figura 4.13b é visível que no canto inferior esquerdo a detecção dos carris é feita de forma deficiente e fora do carril, porque naquela zona o número de pontos seleccionados é maior do que na zona do carril, originando uma falsa detecção. A Figura 4.13c mostra o resultado da detecção dos carris, utilizando no parâmetro ω_2 +30% do valor utilizado na configuração escolhida. Na Figura 4.13c, com a utilização deste valor, é visível que no canto inferior esquerdo existe uma zona branca, i. é., sem pontos e por isso a detecção dos carris pelo algoritmo falha.

4.5.3.1 Considerações

Os testes mostram que os parâmetros utilizados para a detecção dos carris são pouco sensíveis à variação dos valores atribuídos. Considerando alguma imprecisão resultante da captura da nuvem de pontos e que o conjunto de pontos que definem

os carris na nuvem de pontos não é uniforme, a distância medida entre carris pelo algoritmo apresenta um erro de medição por excesso de $\approx 5,2\%$, que é um valor bastante aceitável.

4.5.4 Detecção dos obstáculos

Nesta secção analisa-se a variação dos valores atribuídos aos parâmetros utilizados para fazer a detecção dos obstáculos, num intervalo de -50% e $+50\%$ do valor utilizado na configuração escolhida, em passos de 10% .

Na realização dos testes cada parâmetro varia 10 vezes. A detecção dos obstáculos nas suas diversas fases utiliza 7 parâmetros, por cada uma das zonas. Realizando os testes com o conjunto das 32 nuvens de pontos utilizadas para validar o sistema, o número de testes necessários seria demasiado grande. Por isso optou-se por realizar os testes por amostragem, sendo escolhidas 3 nuvens de pontos (ver Tabela A.1): (a) 11.pcd – nuvem de pontos vazia de obstáculos; (b) 21.pcd – nuvem de pontos com obstáculos nas 3 zonas de supervisão; e (c) 31.pcd – nuvem de pontos com a zona C vazia de obstáculos, existindo obstáculos na zona A e na zona B. Seguidamente são apresentados os resultados obtidos.




FIGURA 4.14: Resultados do teste de sensibilidade ao parâmetro d_l utilizando a nuvem de pontos 21.pcd: (a) Resultado do teste ao parâmetro d_l utilizando os valores atribuídos aos parâmetros na configuração escolhida. A imagem mostra: a vermelho, na zona A, dois homens e um cesto de papéis (assinalado por uma seta a preto); a verde, na zona B, um jerrican; e a ciano, na zona C, um homem. (b) Resultado do teste ao parâmetro d_l , com $+40\%$ do valor utilizado na configuração escolhida. A seta a preto assinala o elemento em falta na zona A, que é o cesto de papéis, originando um falso negativo.

Os valores dos parâmetros d_l^A , d_l^B e d_l^C , variaram dentro do intervalo definido, nas três nuvens de pontos em teste. A Figura 4.14a, mostra o resultado obtido,

utilizando a nuvem de pontos 21.pcd, para os valores atribuídos aos parâmetros na configuração escolhida. A Figura 4.14b mostra o resultado obtido, utilizando a nuvem de pontos 21.pcd, para o valor maior ou igual a +40% do valor utilizado na configuração escolhida. A seta a preto assinala o objeto não detetado na zona A, que é o cesto de papéis, originando um falso negativo. Isto deve-se ao facto de a distância ao chão para ser considerado um obstáculo ter aumentado muito, o que faz com que não detete o cesto de papéis. Para os restantes valores atribuídos aos parâmetros obtiveram-se os resultados esperados, i.e., todos os obstáculos foram detetados corretamente.




FIGURA 4.15: Resultados do teste de sensibilidade ao parâmetro d_l utilizando a nuvem de pontos 31.pcd: (a) Resultado do teste ao parâmetro d_l utilizando os valores atribuídos aos parâmetros na configuração escolhida. A imagem mostra: a vermelho, na zona A, um homem; a verde, na zona B, uma pedra encostada ao carril e um homem; e a zona C sem obstáculos. (b) Resultado do teste ao parâmetro d_l , com -50% do valor utilizado na configuração escolhida. Na imagem, na zona A, é visível um falso positivo, representado pelo conjunto de pontos marcados a vermelho, assinalado por uma seta representada com a cor preta; na zona B, também assinalados por uma seta representada com a cor preta, alguns pontos a verde que deveriam ter sido filtrados.

A Figura 4.15a mostra o resultado obtido utilizando a nuvem de pontos 31.pcd, para os valores atribuídos aos parâmetros na configuração escolhida. A Figura 4.15b mostra o resultado obtido, utilizando a mesma nuvem de pontos, para -50% do valor utilizado na configuração escolhida. Na zona A, assinalado por uma seta a preto, é visível um conjunto de pontos marcados a vermelho, que representam um falso positivo, ou seja, uma porção do chão erroneamente classificada pelo algoritmo como obstáculo. Também, na zona B, assinalado por uma seta a preto, existe um pequeno número de pontos a verde, que deveriam ter sido filtrados como ruído. Isto deve-se ao facto de a distância ao chão ter diminuído e, como tal, originando falsos positivos, ou seja, uma porção do chão é erroneamente classificada pelo

algoritmo como obstáculo. Para os restantes valores atribuídos aos parâmetros, obtiveram-se os resultados esperados, i.e., todos os obstáculos foram detetados corretamente.

Os valores dos parâmetros que são K_A , K_B , K_C , α_A , α_B e α_C , variaram dentro do intervalo definido, nas três nuvens de pontos em teste. Os testes com a nuvem de pontos 31.pcd, mostram que na zona B, o parâmetro K_B é muito sensível, i.e., variando o valor atribuído na configuração escolhida em 10%, para cima ou para baixo produz falsos positivos. Os outros parâmetros mostram que não são sensíveis à variação dos valores que lhes são atribuídos, uma vez que admitem outros valores sem comprometer o resultado final. A Figura 4.16a mostra o resultado obtido, utilizando a nuvem de pontos 31.pcd, para o parâmetro K_B com -10% do valor utilizado na configuração escolhida. A Figura 4.16b mostra o resultado obtido, utilizando a nuvem de pontos 31.pcd, para o parâmetro α_B com -50% do valor utilizado na configuração escolhida




FIGURA 4.16: Resultados dos testes de sensibilidade aos parâmetros K_B e α_B utilizando a nuvem de pontos 31.pcd: (a) Resultado do teste ao parâmetro K_B com -10% do valor utilizado na configuração escolhida. A imagem mostra a verde, na zona B, assinalados por uma seta a preto, alguns pontos que deveriam ter sido filtrados. (b) Resultado do teste ao parâmetro α_B , com -50% do valor utilizado na configuração escolhida. A imagem mostra a verde, na zona B, assinalados por uma seta a preto, alguns pontos que deveriam ter sido filtrados.

Os valores dos parâmetros $resol_A$, $resol_B$ e $resol_C$, variaram dentro do intervalo definido, nas três nuvens de pontos em teste. Os testes mostram que estes parâmetros não são sensíveis à variação dos valores que lhes são atribuídos, pelo que, os resultados obtidos foram os esperados.

Os valores dos parâmetros d_p^A , d_p^B e d_p^C , variaram dentro do intervalo definido, nas três nuvens de pontos em teste. Os testes mostram que a variação dos valores atribuídos aos parâmetros, utilizando as nuvens de pontos 11.pcd e 31.pcd, não alterou os resultados anteriormente obtidos. Já com a nuvem de pontos 21.pcd, quando a variação dos valores atribuídos ao parâmetro da zona A é superior ou igual a +20%, então, nem todos os obstáculos são detectados, com assinalado na Figura 4.17b, originando um falso negativo. Isto deve-se ao facto de a distância

em relação ao chão ter aumentado e, por esse facto, o cesto de papéis não é visto.




FIGURA 4.17: Resultado do teste de sensibilidade ao parâmetro d_p^A utilizando a nuvem de pontos 21.pcd: (a) Resultado do teste ao parâmetro d_p^A utilizando os valores atribuídos aos parâmetros na configuração escolhida. A imagem mostra: a vermelho, na zona A, dois homens e um cesto de papéis (assinalados por uma seta a preto); a verde, na zona B, um jerrican; e a ciano, na zona C, um homem. (b) Resultado do teste ao parâmetro d_p^A , com +20% do valor utilizado na configuração escolhida. Na zona A, o cesto de papéis não foi detectado dando lugar a um falso negativo, estando o local assinalado por uma seta a preto.

Os valores dos parâmetros d_{min}^A , d_{min}^B e d_{min}^C , variaram dentro do intervalo definido, nas três nuvens de pontos em teste. Os testes mostram que estes parâmetros não são sensíveis à variação dos valores que lhes são atribuídos, pelo que, os resultados obtidos foram os esperados.

Os valores dos parâmetros n_{min}^A , n_{min}^B e n_{min}^C , variaram dentro do intervalo definido, nas três nuvens de pontos em teste. Os testes mostram que, para a nuvem de pontos 31.pcd, a variação dos valores atribuídos a estes parâmetros não altera os resultados. Para as nuvens de pontos 11.pcd e 21.pcd, a variação dos valores atribuídos a estes parâmetros, na zona A, produz falsos positivos para valores iguais o inferiores a -10% do valor utilizado na configuração escolhida.

Na Figura 4.18b e na Figura 4.19, estão assinalados, por uma seta a preto, conjuntos de pontos que não são obstáculos mas foram classificados pelo algoritmo como tal. Isto deve-se ao facto de o número mínimo de pontos necessários para se poder constituir um agrupamento ter diminuído.

4.5.4.1 Considerações

Os testes mostram que alguns dos parâmetros utilizados para a deteção dos obstáculos com uma elevada sensibilidade à variação dos valores que lhes são atribuídos,




FIGURA 4.18: Resultado do teste de sensibilidade ao parâmetro n_{min}^A utilizando a nuvem de pontos 21.pcd: (a) Resultado do teste ao parâmetro n_{min}^A utilizando os valores atribuídos aos parâmetros na configuração escolhida. (b) Resultado do teste ao parâmetro n_{min}^A , com -10% do valor utilizado na configuração escolhida. A seta a preto assinala um conjunto de pontos a vermelho, na zona A, que deveria ter sido filtrado.



FIGURA 4.19: Resultado do teste de sensibilidade ao parâmetro n_{min}^A , com -10% do valor utilizado na configuração escolhida, utilizando a nuvem de pontos 11.pcd, que está vazia de obstáculos. As setas a preto assinalam conjuntos de pontos, nas Zonas A e B, que deveriam ter sido filtrados.

originado falsos positivos ou falsos negativos.

- O parâmetro K_B revelou uma elevada sensibilidade, uma vez que para valores diferentes do valor utilizado na configuração escolhida produz falsos positivos.
- O parâmetro d_p^A revelou uma elevada sensibilidade com a nuvem de pontos 21.pcd, uma vez que para valores iguais ou superiores a +20% do valor utilizado na configuração escolhida produz falsos negativos.
- O parâmetro n_{min} revelou uma elevada sensibilidade com as nuvens de pontos 11.pcd e 21.pcd, uma vez que para valores iguais ou superiores a -10% do valor utilizado na configuração escolhida produz falsos positivos.

Para os restantes parâmetros os testes mostraram que são poucos sensíveis à variação dos valores que lhes foram atribuídos.

Capítulo 5

Conclusões e Trabalho Futuro

Este capítulo apresenta as conclusões obtidas, avalia os objetivos propostos, discute os resultados obtidos e propõe desenvolvimentos futuros que visam colmatar as limitações encontradas.

5.1 Conclusões

O trabalho realizado no âmbito desta dissertação consistiu no desenvolvimento de um algoritmo capaz de detetar obstáculos com uma volumetria inferior a 1 m^3 , no contexto de uma passagem de nível equipada com um sensor LIDAR.

Os resultados experimentais mostram que o algoritmo é capaz de automaticamente detetar corretamente a posição das MB e dos carris nas nuvens de pontos testadas. A partir da localização das MB são estimadas 3 zonas de supervisão e a partir da localização dos carris é estimado o eixo da via. A partir da definição das zonas de supervisão e do eixo da via obtém-se o gabarito para cada uma das zonas, definindo uma região de interesse e, assim, diminuindo a complexidade do problema na deteção de obstáculos.

Os resultados experimentais também mostram que o algoritmo é capaz de detetar corretamente os obstáculos, num conjunto de 41 nuvens de pontos com vários obstáculos de várias dimensões presentes. A parametrização do algoritmo que faz a deteção dos obstáculos, foi definida em função das zonas de supervisão, o que tornou possível individualizar e fazer um melhor ajuste dos valores atribuídos aos parâmetros para cada uma das zonas de deteção.

A definição do gabarito permite detetar apenas os obstáculos dentro da área que obrigatoriamente não se altera ao longo do tempo, ou seja, qualquer alteração que exista dentro dessa área deve ser entendido como sendo um obstáculo e devendo

ser tratado como tal. A principal vantagem desta abordagem é a de poder permitir diferenciar os alarmes, i.e., a detecção de um obstáculo dentro do limite de gabarito de uma qualquer zona de supervisão obriga à paragem do comboio antes de este atingir a PN, já a detecção de um obstáculo dentro de uma qualquer zona de supervisão mas fora do limite da gabarito não obriga à paragem do comboio. Neste caso pode ser emitido um alarme sobre a existência de um obstáculo na proximidade do limite de gabarito e que é necessário verificar da sua perigosidade.

Os objetos que estão localizados na zona C (mais afastada do sensor) têm pouca definição, i.e., a densidade de pontos que os define é esparsa. Por essa razão o algoritmo teve dificuldade em detetar obstáculos de baixa volumetria. Também, por isso, só é possível detetar os objetos a uma distância acima do solo de cerca de 0.7 m, afim de evitar obter falsos positivos. Obstáculos com uma altura inferior a 0.7 m não são detetados, dando origem a falsos negativos. Esta dificuldade pode ser colmatada colocando um sensor LIDAR nesta zona para permitir recolher a informação dos objetos com uma maior densidade de pontos.

O tempo médio de processamento das nuvens de pontos para detecção de alterações entre o mapa volumétrico referência e o mapa volumétrico instantâneo, no instante que precede a passagem do comboio, e a obtenção do resultado final é de ≈ 603 ms. O tempo obtido para a detecção dos obstáculos é suficiente para responder aos requisitos da PN, considerando que o algoritmo deteta os obstáculos de baixa volumetria em 3 zonas de supervisão de igual dimensão cada, cobrindo uma área por zona de aproximadamente $7 \text{ m} \times 10 \text{ m}$.

O sistema proposto nesta dissertação apesar de gastar ligeiramente mais tempo para detetar os obstáculos, a volumetria dos obstáculos detetados é inferior a 0.5 m^3 , ao contrário de soluções anteriores que estão limitadas a detetar objetos com uma volumetria igual ou superior a 1 m^3 .

A PN do Sabugo tem instalado um sistema de detecção de obstáculos por RADAR, que deteta objetos com uma dimensão superior a 0.5 m^3 em cerca de 8 s. O sistema proposto nesta dissertação gasta menos tempo para detetar os obstáculos e a volumetria dos obstáculos detetados é inferior a 0.5 m^3 , como mostram os testes de validação do sistema.

Resumidamente, o sistema apresentado nesta dissertação consegue fazer a detecção de obstáculos no contexto de uma PN, contribuindo desta forma para aumentar o nível de segurança da PN. Além disso, quando comparado com outras soluções aqui descritas, este sistema consegue detetar obstáculos mais pequenos ($\approx 10 \text{ dm}^3$), ou seja, faz a detecção de obstáculos de baixa volumetria e permite

distinguir o nível de perigosidade dos alarmes. Pode-se concluir que este trabalho pode ser utilizado para fazer a detecção de obstáculos no contexto de uma passagem de nível.

5.2 Trabalho Futuro

Nesta secção são apresentadas melhorias e complementos que poderiam ser implementadas em trabalhos futuros, dotando o sistema de novas capacidades e maior robustez.

Nas nuvens de pontos testadas onde existem obstáculos de baixa volumetria, todos eles foram detetados corretamente. Para melhorar a validação do sistema seria necessário obter mais nuvens de pontos com obstáculos de volumetria inferior a 0.5 m^3 , dispostos nas 3 áreas de supervisão e com sensor LIDAR colocado noutra ponto da PN.

Os testes foram realizados em condições ambientais sem chuva ou nevoeiro. O conjunto de dados apesar de conter objetos de variada dimensão, não era muito extenso. Portanto uma melhoria importante seria obter um conjunto de dados mais vasto, com objetos de várias dimensões, dispostos em vários pontos da PN e em diferentes condições ambientais, como por exemplo, dias de chuva, nevoeiro, durante a noite, em dias de sol, etc., que permitisse testar o comportamento do algoritmo mais exaustivamente.

Uma melhoria passaria também pela detecção dos objectos e fazer o seu seguimento automático, desde a entrada na PN até à sua saída. Esta melhoria permitiria prever rotas possíveis que o objeto pode tomar. O reconhecimento dos objetos permitiria estudar a morfologia dos objetos detetados, classificando-os e catalogando-os. Isto permitiria diferenciar os alarmes, dando a possibilidade de definir que tipo de objeto é considerado um obstáculo, ou como deve o sistema reagir perante o objeto detetado.

Um outro aspeto a melhorar é o tempo que o algoritmo gasta para detetar os obstáculos. O tempo médio gasto pelo algoritmo proposto nesta dissertação é de cerca 0.6s. Será possível reduzir este tempo introduzindo melhorias no modo de construção do mapa volumétrico instantâneo e utilizando novos algoritmos de otimização das *octrees*.

Neste trabalho foi utilizado o sensor LIDAR SICK LMS 111, contudo a possibilidade de testar o algoritmo utilizando um sensor LIDAR VELODYNE [39], traria melhorias ao nível da qualidade dos resultados e do desempenho. Os sensores da

Velodyne diferem do sensor SICK porque têm vários emissores/recetores laser a operar em paralelo, permitindo recolher nuvens de pontos completas num curto espaço de tempo.

Anexos

Anexo A

Descrição das Nuvens de Pontos

A Tabela A.1 apresenta o conjunto de nuvens de pontos utilizadas para efetuar os testes do algoritmo para detecção de obstáculos em passagens de nível. Para cada nuvem de pontos, é apresentado o número de obstáculos, o número de pontos, bem como a descrição do tipo de obstáculo por zona de detecção.

TABELA A.1: Descrição das nuvens de pontos utilizadas para teste do Sistema

Nuvem de pontos	Núm. de obst.	Núm. de pontos	Obstáculos na nuvem de pontos
10.pcd	1	253 901	Carro a passar na zona A
11.pcd	0	240 052	Sem obstáculos
12.pcd	1	240 289	Carro a passar na zona A
13.pcd	1	243 975	Carro a passar na zona A
14.pcd	1	198 063	Camião a passar na zona A
15.pcd	0	236 493	Sem obstáculos
16.pcd	0	240 651	Sem obstáculos
17.pcd	3	193 207	Três pessoas na zona A
18.pcd	4	217 721	Quatro pessoas na zona A
19.pcd	4	242 480	Quatro pessoas na zona A
20.pcd	4	227 766	Duas pessoas e um cesto de papéis na zona A e um jerrican na zona B
21.pcd	5	238 833	Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C

Continua na página seguinte

Tabela A.1 – *Continuação da página anterior*

Nuvem de pontos	Núm. de obst.	Núm. de pontos	Obstáculos na nuvem de pontos
22.pcd	5	236 297	Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C
23.pcd	3	237 751	Um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C
24.pcd	3	230 559	Um cesto de papéis e a cauda de um carro na zona A e uma pessoa ajoelhada na zona B
25.pcd	2	238 845	Um cesto de papéis na zona A e uma pessoa ajoelhada na zona B
26.pcd	1	242 869	Um cesto de papéis na zona A
27.pcd	2	236 983	Um cesto de papéis na zona A e uma pessoa ajoelhada na zona B
28.pcd	2	246 760	Um carro a passar na zona A e uma pessoa e uma pedra junto a um dos carris na zona B
29.pcd	1	241 192	Uma pessoa na zona B
30.pcd	2	234 801	Uma pedra encostada ao carril e ao estrado da PN e uma pessoa do lado de fora da via na zona
31.pcd	3	259 488	Uma pessoa na zona A, uma pessoa e uma pedra encostada ao carril e ao estrado da PN na zona B
32.pcd	2	247 920	Duas pessoas na zona B
33.pcd	1	255 678	Um carro a passar na zona A
34.pcd	1	259 546	Um carro a passar na zona A
35.pcd	1	247 903	Um carro a passar na zona A
36.pcd	1	250 640	Traseira de um carro a sair na zona A
37.pcd	2	214 692	Uma pessoa e um jerrican na zona B
38.pcd	1	240 478	Uma pedra encostada ao carril na zona B
39.pcd	1	236 295	Uma pedra encostada ao carril na zona B
40.pcd	0	238 036	Sem obstáculos
41.pcd	1	238 110	Uma pedra encostada ao carril na zona B

Anexo B

Tempos de processamento

A Tabela B.1, apresenta os tempos intermédios gastos pelo Sistema em cada uma das fases de processamento das nuvens de pontos. A tabela está dividida em duas partes:

- o lado esquerdo da tabela apresenta o tempo de leitura da nuvem de pontos a partir do disco e o tempo de processamento da nuvem de pontos para obtenção do gabarito de cada uma das zonas de supervisão;
- o lado direito da tabela apresenta para cada uma das zonas de supervisão, o tempo de processamento para obtenção das diferenças entre o mapa volumétrico referência e o mapa volumétrico instantâneo.

TABELA B.1: Tempos gastos pelo algoritmo no processamento das nuvens de pontos utilizadas para teste do Sistema

Nuvens de pontos	Ler do disco	Gabarito			Detecção de Alterações		
		A	B	C	A	B	C
	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)
10.pcd	3 560	203	295	29	70	22	1
11.pcd	3 611	223	301	29	69	18	1
12.pcd	3 659	227	320	29	73	18	1
13.pcd	3 693	249	295	29	73	18	1
14.pcd	3 080	230	265	20	78	17	0
15.pcd	3 588	197	287	29	67	17	1
16.pcd	3 640	210	291	29	67	17	1
17.pcd	2 894	214	289	22	71	17	1

Continua na página seguinte

Tabela B.1 – *Continuação da página anterior*

Nuvens de pontos	Ler do disco	Gabarito			Detecção de Alterações		
		A	B	C	A	B	C
	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)	t (ms)
18.pcd	3 291	178	248	23	71	18	1
19.pcd	3 866	227	293	30	71	17	1
20.pcd	3 482	214	273	23	69	18	1
21.pcd	3 611	212	288	32	69	17	1
22.pcd	3 956	209	279	28	69	18	1
23.pcd	4 072	205	294	28	68	17	1
24.pcd	4 167	228	267	24	70	19	1
25.pcd	3 779	215	270	29	68	19	1
26.pcd	4 053	226	268	29	67	18	1
27.pcd	3 656	193	257	24	68	18	1
28.pcd	3 783	248	278	29	72	18	1
29.pcd	3 776	198	255	25	68	19	1
30.pcd	3 625	159	226	23	67	20	1
31.pcd	4 163	236	296	31	69	17	1
32.pcd	3 821	200	296	26	69	18	1
33.pcd	3 923	217	220	25	74	18	1
34.pcd	4 002	214	281	26	68	17	1
35.pcd	3 832	252	276	29	68	17	1
36.pcd	4 040	202	276	31	68	17	1
37.pcd	4 153	154	249	22	68	18	1
38.pcd	3 891	210	286	30	69	19	1
39.pcd	3 949	193	286	24	69	17	1
40.pcd	4 211	206	285	24	67	17	1
41.pcd	3 781	205	295	25	67	17	1

t = tempo de processamento; (ms) = milisegundos; A, B, C = zonas de supervisão.

Anexo C

Visualização dos obstáculos existentes por nuvem de pontos

Seguidamente é apresentada uma impressão de cada uma das nuvens de pontos que contém obstáculos, utilizando os valores atribuídos aos parâmetros na configuração escolhida.




FIGURA C.1: Nuvem de pontos 10 - Carro a passar na zona A




FIGURA C.2: Nuvem de pontos 12 - Carro a passar na zona A




FIGURA C.3: Nuvem de pontos 13 - Carro a passar na zona A




FIGURA C.4: Nuvem de pontos 14 - Camião a passar na zona A




FIGURA C.5: Nuvem de pontos 17 - Três pessoas na zona A




FIGURA C.6: Nuvem de pontos 18 - Quatro pessoas na zona A




FIGURA C.7: Nuvem de pontos 19 - Quatro pessoas na zona A




FIGURA C.8: Nuvem de pontos 20 - Duas pessoas e um cesto de papéis na zona A e um jerrican na zona B




FIGURA C.9: Nuvem de pontos 21 - Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C




FIGURA C.10: Nuvem de pontos 22 - Duas pessoas e um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C



FIGURA C.11: Nuvem de pontos 23 - Um cesto de papéis na zona A, um jerrican na zona B e uma pessoa na zona C



FIGURA C.12: Nuvem de pontos 24 - Um cesto de papéis e a cauda de um carro na zona A e uma pessoa ajoelhada na zona B




FIGURA C.13: Nuvem de pontos 25 - Um cesto de papéis na zona A e uma pessoa ajoelhada na zona B




FIGURA C.14: Nuvem de pontos 26 - Um cesto de papéis na zona A




FIGURA C.15: Nuvem de pontos 27 - Um cesto de papéis na zona A e uma pessoa ajoelhada na zona B




FIGURA C.16: Nuvem de pontos 28 - Um carro a passar na zona A e uma pessoa e uma pedra junto a um dos carris na zona B



FIGURA C.17: Nuvem de pontos 29 - Uma pessoa na zona B




FIGURA C.18: Nuvem de pontos 30 - Uma pedra encostada ao carril e ao estrada da PN e uma pessoa do lado de fora da via na zona B




FIGURA C.19: Nuvem de pontos 31 - Uma pessoa na zona A, uma pessoa e uma pedra encostada ao carril e ao estrada da PN na zona B




FIGURA C.20: Nuvem de pontos 32 - Duas pessoas na zona B




FIGURA C.21: Nuvem de pontos 33 - Um carro a passar na zona A




FIGURA C.22: Nuvem de pontos 34 - Um carro a passar na zona A




FIGURA C.23: Nuvem de pontos 35 - Um carro a passar na zona A




FIGURA C.24: Nuvem de pontos 36 - Traseira de um carro a sair na zona A




FIGURA C.25: Nuvem de pontos 37 - Uma pessoa e um jerrican na zona B




FIGURA C.26: Nuvem de pontos 38 - Uma pedra encostada ao carril na zona B




FIGURA C.27: Nuvem de pontos 39 - Uma pedra encostada ao carril na zona B




FIGURA C.28: Nuvem de pontos 41 - Uma pedra encostada ao carril na zona B

Bibliografia

- [1] REFER. Relatório de Gestão, Demonstrações Financeiras, Governo Societário e Sustentabilidade. Technical report, REFER, 2013.
- [2] Decreto-Lei nº 568/99, 23 de Dezembro de 1999.
- [3] REFER. Passagens de Nível. [Em Linha]. URL <http://passagensdenivel.infraestruturasdeportugal.pt>. [Acedido em: 15-jan-2015].
- [4] ERA. Railway Safety Performance in the European Union. Technical report, European Railway Agency, 2014.
- [5] REFER. Segurança no Atravessamento da Via Férrea – Relatório de Actividades 2010. Technical report, REFER, 2010.
- [6] California operation lifesaver. [Em Linha]. URL <http://www.caol.us/rail-safety-education-engineering-enforcement.html>. [Acedido em: 05-mar-2015].
- [7] M. Woods. Public road level crossings in Great Britain. *Mechanics Transport Communications - Academic journal*, vol. 3:pages 12–20, 2007.
- [8] M. OHTA. Level crossings obstacle detection system using stereo cameras. *Quarterly Report of RTRI*, vol. 46(2):pages 110–117, 2005.
- [9] I. Yoda, K. Sakaue, and D. Hosotani. Multi-point stereo camera system for controlling safety at railroad crossings. In *Proceedings of the IEEE International Conference on Computer Vision Systems (ICVS). IEEE, 2006*, pages 51–51, 2006.
- [10] N. Fakhfakh, L. Khoudour, E. El-Koursi, J. Jacot, and A. Dufaux. A video-based object detection system for improving safety at level crossings. *Open transportation journal, supplement on 'safety at Level Crossings'*, pages 1–15, 2010.

- [11] N. Fakhfakh, L. Khoudour, E. El-Koursi, J. L. Bruyelle, A. Dufaux, and J. Jacot. 3D Objects localization using fuzzy approach and hierarchical belief propagation: application at level crossings. *Journal on Image and Video Processing*, vol. 2011:pages 1–4, 2011.
- [12] Y. Hisamitsu, K. Sekimoto, K. Nagata, M. Uehara, and E. Ota. 3D Laser Radar level crossing obstacle detection system. In Bentham Science Publishers, editor, *Industrial Applications of Laser Remote Sensing*, page 143, 2012.
- [13] K. Peffers, T. Tuunanen, M. A. Rothenberger, and S. Chatterjee. A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, vol. 24(3):pages 45–77, 2007.
- [14] REFER. Segurança no Atravessamento da Via Férrea – Relatório de Actividades 2012. Technical report, REFER, 2012.
- [15] F. Vendas. Sistema de radar de micro-ondas para deteção de obstáculos em passagens de nível automatizadas. In *Ferbritas – 30 anos ao serviço do sector ferroviário*, volume N 33, pages 104–109. FER XXI, Setembro 2006.
- [16] A. D. Little. Obstacle detection at level crossing (T522). Technical report, Rail Safety and Standard Board (RSSB), October 2006.
- [17] H. Takeuchi and T. Shozawa. Development of advanced obstacle-detecting methods for level crossings. In *Proceedings of the World Congress on Railway Research (WCRR), 2006*, pages 1–6. Central Japan Railway Company, 2006.
- [18] Y. Ikeda T. Shozawa, H. Takeuchi. Object detection in railways by sensing geomagnetic field. Technical report, Central Japan Railway Company.
- [19] Infraestruturas de portugal - léxico. [Em Linha]. URL <http://infraestruturasdeportugal.pt/negocios-e-servicos/lexico>. [Acedido em: 04-jun-2015].
- [20] G. Kim, J. Baek, H. Jo, Lee K, and J.Lee. Design of safety equipment for railroad level crossings using laser range finder. In *Proceedings of the 9th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD). 2012*, pages 2909–2913, 2012.
- [21] N. Fakhfakh, L. Khoudour, J. L. Bruyelle, and E. El-Koursi. Intelligent surveillance system based on stereo vision for level crossings safety applications.

- Chapter of book 'Recent Developments in Video Surveillance'*, pages 978–953, 2012.
- [22] N. Fakhfakh, L. Khoudour, E. El-Koursi, J. L. Bruyelle, A. Dufaux, and J. Jacot. Background subtraction and 3D localization of moving and stationary obstacles at level crossings. In *Proceedings of the 2nd International Conference on Image Processing Theory Tools and Applications (IPTA). IEEE, 2010*, pages 72–78, 2010.
- [23] A.H. Narayanan, P. Brennan, R. Benjamin, N. Mazzino, G. Bochetti, and A. Lancia. Railway level crossing obstruction detection using mimo radar. In *Proceedings of the Radar Conference (EuRAD), 2011*, pages 57–60, 2011.
- [24] SICK LIDAR - Technical Description. [Em Linha]. URL <http://www.wv.inf.tu-dresden.de/~wiki/Robotics/TechDocs/SICK-LMS-TechDoc.pdf>. [Acedido em: 07-mai-2015].
- [25] G. L. Foresti. A real-time system for video surveillance of unattended outdoor environments. *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 8(6):pages 697–704, October 1998.
- [26] H. Salmane, L. Khoudour, and Y. Ruichek. Improving safety of level crossings by detecting hazard situations using video based processing. In *Proceedings of the IEEE International Conference of Intelligent Rail Transportation (ICIRT). IEEE, 2013*, pages 179–184, 2013.
- [27] R. B. Rusu. *Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments*. PhD thesis, Computer Science department, Technische Universitaet Muenchen, Germany, October 2009.
- [28] M. Fischler and R. Bolles. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, vol. 24(6):pages 381–395, 1981.
- [29] D. A. E. G. Borges. Reconstrução de objectos 3D usando Kinect. Master's thesis, IST - Instituto Superior Técnico, Outubro 2013.
- [30] C. Silpa-Anan and R. Hartley. Optimised kd-trees for fast image descriptor matching. In *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2008*, pages 1–8, 2008.

- [31] K. M. Wurm, A. Hornung, M. Bennewitz, C. Stachniss, and W. Burgard. Octomap: A probabilistic, flexible, and compact 3D map representation for robotic systems. In *Proceedings of the ICRA 2010 workshop on best practice in 3D perception and modeling for mobile manipulation*, volume 2, 2010.
- [32] J. Elseberg, D. Borrmann, and A. Nüchter. One billion points in the cloud—an octree for efficient processing of 3D laser scans. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 76:pages 76–88, 2013.
- [33] D. Meagher. Geometric modeling using octree encoding. *Computer graphics and image processing*, vol. 19(2):pages 129–147, 1982.
- [34] R. B. Rusu, M. Beetz, Z. C. Marton, N. Blodow, and M. Dolha. Towards 3D point cloud based object maps for household environments. *Robotics and Autonomous Systems*, vol. 56(11):pages 927–941, 2008.
- [35] J. Kammerl, N. Blodow, R. B. Rusu, S. Gedikli, M. Beetz, and E. Steinbach. Real-time compression of point cloud streams. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, pages 778–785. IEEE, 2012.
- [36] PCL – Point Cloud Library. [Em Linha]. URL <http://pointclouds.org>. [Acedido em: 07-mai-2015].
- [37] S.O.H. Madgwick, A.J.L. Harrison, and R. Vaidyanathan. Estimation of imu and marg orientation using a gradient descent algorithm. In *Proceedings of the IEEE International Conference on Rehabilitation Robotics (ICORR)*. IEEE, 2011, pages 1–7, 2011.
- [38] R. B. Rusu and S. Cousins. 3D is here: Point cloud library (pcl). In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, 2011, pages 1–4, 2011.
- [39] Velodyne Lidar. [Em Linha]. URL <http://velodynelidar.com/lidar/lidar.aspx>. [Acedido em: 07-mai-2015].