

Modelação de Dados LiDAR para Apoio à Condução Autónoma

Pedro de Vasconcelos Faria Cadete Leite


Mestrado em Engenharia Matemática

Departamento de Matemática

2023

Orientador

Prof. Dr. André Marçal, Professor Auxiliar, Faculdade de Ciências da
Universidade do Porto



Agradecimentos

Aos Professores que mais influenciaram a minha vida académica. Ao Professor André Marçal por todo o acompanhamento nesta dissertação e em todo o Projeto. À professora Alexandra Marçal por ter acordado um gosto há algum tempo esquecido pela matemática.

Aos meus pais, por não terem desistido, nem me terem deixado desistir de um percurso por vezes turbulento.

Aos meus avós, os que estão e os que não estão, pela inspiração.

Ao meu irmão, que tantas vezes vejo o papel de exemplo ser invertido.

Aos meus colegas e amigos, por toda a ajuda nesta caminhada.

À Mercedes, Silvana e Maria José, pelo carinho demonstrado todos os dias.

E, por fim, à Mariana, porque não é coincidência o número de conquistas dos últimos dois anos.

Este trabalho foi financiado pelos Fundos Europeus Estruturais e de Investimento na componente FEDER, através do Programa Operacional Competitividade e Internacionalização (COMPETE 2020) [Projeto nº 047264; Referência: POCI-01-0247-FEDER-047264].

UNIVERSIDADE DO PORTO

Abstract

Faculdade de Ciências da Universidade do Porto

Departamento de Matemática

Mestrado em Engenharia Matemática

Modelação de Dados LiDAR para Apoio à Condução Autónoma

by [Pedro Vasconcelos Leite](#)

The analysis of point clouds in the context of autonomous driving is a mandatory task for the good performance of this function. The search for an algorithm that can detect and classify objects of interest, quickly and concisely, will greatly contribute to the advancement of this new technology.

With this dissertation we try to help along this path. We analyze how objects can be classified and which metrics are useful in this task. We compared the different internal validation indices in 5 segmentation algorithms, DBSCAN, K-Means, Spectral Clustering, Hierarchical Clustering - minimum and median linkage.

We conclude that the number of points on an object appears to follow a distribution depending on its distance from the sensor. DBSCAN proved to be the best segmentation algorithm, followed by Hierarchical Clustering. K-Means, as expected, due to its difficulty in analyzing partitions with arbitrary shapes, performed poorly. Introducing the "intensity" of the points as a fourth variable in the segmentation did not improve the data. The intensity varies depending on the reflective capacity of the object, however objects, despite having a concise shape, may have variations in the material from which they are made, causing a disparity in intra-object intensity values.

UNIVERSIDADE DO PORTO

Resumo

Faculdade de Ciências da Universidade do Porto

Departamento de Matemática

Mestrado em Engenharia Matemática

Modelação de Dados LiDAR para Apoio à Condução Autónoma

por [Pedro Vasconcelos Leite](#)

A análise de nuvens de pontos em contexto de condução autónoma é uma tarefa obrigatória para o bom desempenho desta função. A busca por um algoritmo que consiga detetar e classificar objetos de interesse, de forma rápida e concisa, contribuirá a largos passos para o avanço desta nova tecnologia.

Com esta dissertação tentamos ajudar nesse caminho. Analisamos de que forma os objetos podem ser classificados e que métricas são úteis nesta tarefa. Comparamos os diferentes índices de validação interna em 5 algoritmos de segmentação, DBSCAN, K-Means, Agrupamento espectral, Agrupamento Hierárquico - ligação mínima e mediana.

Concluimos que o número de pontos de um objeto aparenta seguir uma distribuição consoante a distância a que está do sensor. O DBSCAN comprovou ser o melhor algoritmo de segmentação, seguido dos Agrupamentos Hierárquicos. K-Means, como era expectável, devido à sua dificuldade em analisar partições com formas arbitrárias, teve um mau desempenho. Introduzir a "intensidade" dos pontos como uma quarta variável na segmentação não veio a melhorar os dados. A intensidade varia consoante a capacidade refletiva do objeto, no entanto os objetos apesar de terem uma forma concisa, podem ter variações no material de que são feitos, originando uma disparidade nos valores de intensidade intra-objeto.

Conteúdo

Agradecimentos	iii
Abstract	v
Resumo	vii
Conteúdo	ix
Lista de Figuras	xiii
Lista de Tabelas	xv
Glossário	xvii
1 Introdução	1
1.1 Motivação	1
1.2 Condução Autónoma	1
1.2.1 Definição	1
1.2.2 Evolução da Condução Autónoma	3
1.3 LiDAR + Condução Autónoma	3
1.4 Objetivos	3
1.5 Estrutura do documento	4
2 Materiais e Métodos	5
2.1 LiDAR	5
2.2 Aprendizagem Automática	6
2.2.1 Aprendizagem Não Supervisionada	6
2.2.1.1 K-Means	7
2.2.1.2 DBSCAN	7
2.2.1.3 Agrupamento Hierárquico - Hierarchical Clustering	8
2.2.1.4 Ligação Mínima - <i>Single Linkage</i>	9
2.2.1.5 Ligação Mediana - <i>Median Linkage</i>	9
2.2.1.6 Agrupamento Espectral - Spectral Clustering	10
2.2.2 Aprendizagem Supervisionada	10
2.2.2.1 Árvores de Decisão	10
2.3 Distâncias	11

2.4	Índices de Validação Interna	12
2.4.1	Silhouette	12
2.4.2	Calinski-Harabasz	12
2.4.3	DBCV - Density-Based Clustering Validation	13
2.4.4	Harrell's C	13
2.4.5	COP	13
2.4.6	CS	13
2.4.7	CVDD	13
2.4.8	Davies-Boudin	14
2.4.9	Dunn	14
2.4.10	<i>Auto-CVI-Tool</i>	14
3	Conjuntos de Dados	17
3.1	Bases de Dados	17
3.1.1	Alguns exemplos de Bases de Dados	17
3.1.2	H3D	18
3.1.3	Dados Bosch	18
3.2	Pré-Processamento dos Dados	19
3.2.1	Remoção do chão	19
3.2.2	Obtenção de objetos	21
3.2.3	Intensidade	23
3.3	Criação das Situações de Estudo	26
4	Análise de Dados LiDAR de Objetos	29
4.1	Segmentação dos objetos	29
4.2	Métricas	30
4.2.1	Variáveis de Forma	32
4.2.1.1	Altura	32
4.2.1.2	Área	32
4.2.1.3	Altura pela Área	34
4.2.1.4	Volume	36
4.2.2	Variáveis Pontuais	37
4.2.2.1	Número de Pontos e Número de Pontos Interiores do Objeto	37
4.2.2.2	Relação entre a Distância e o Número de Pontos	39
4.2.2.3	Distância média aos pontos vizinhos mais próximos	42
4.3	Classificação de Objetos	42
5	Resultados	47
5.1	Análise dos algoritmos	47
5.2	Análise dos índices	48
5.3	Intensidade como <i>threshold</i> dos pontos	50
5.4	Intensidade como 4ª variável na segmentação	52
6	Conclusões e Trabalho Futuro	53
	Bibliografia	54

7 Anexos	61
7.1 Imagens	61
7.2 Tabelas	67

Lista de Figuras

1.1	Níveis de Autonomia definidos pela SAE [1]	2
2.1	Esquema simples da tecnologia LiDAR, [10]	5
2.2	Exemplo dde clustering por DBSCAN (CIE) e K-Means (CID) para um conjunto de dados (CSE) a duas dimensões.	8
2.3	Exemplo de um dendrograma retirado de [18].	9
2.4	Imagem ilustrativa de uma árvore de decisão, adaptado de [22].	11
2.5	Imagem ilustrativa da métrica d_k , neste caso d_5	11
3.1	Imagem com dados H3D antes da remoção do chão, cena "060" e cenário cenário "001".	20
3.3	Imagem com dados H3D antes da remoção do chão e segmentação dos objetos, cena "060" e cenário cenário "001".	24
3.4	Exemplo de dados Bosch com a escala de cor associada à altura dos pontos.	24
3.5	Exemplo de dados Bosch com a escala de cor associada à distância ao veículo de captação dos dados.	25
3.6	Exemplo de dados Bosch com a escala de cor associada à intensidade dos pontos.	25
3.7	Canto inferior esquerdo da imagem 3.6 ampliado.	25
3.8	Imagem exemplo de dois pedestres retirada do cenário 65, cena 121, do H3D.	26
4.1	Exemplo da <i>Bounding Box</i> usada para a variável NPercentage.	30
4.2	Boxplot da variável Altura relativa a cada classe.	32
4.3	Boxplot da variável Área relativa a cada classe.	33
4.4	Boxplots da variável Área das classes Pequenas.	33
4.5	Boxplot da variável área dividida pela altura relativa a cada classe.	34
4.6	Gráfico de Dispersão da Altura pelo Logaritmo da Área, por classes.	35
4.7	Gráfico de Dispersão da Altura pelo Logaritmo da Área, por Grupos.	35
4.8	Exemplo de objeto da classe 'Outros veículos' - Empilhadora.	36
4.9	Exemplo de objeto da classe 'Outros veículos' - Escavadora.	36
4.10	Boxplot da variável Volume relativa a cada classe.	37
4.11	Boxplots das métricas pontos por objeto e pontos interiores por objeto.	37
4.12	Histograma da distribuição do logaritmo do número de pontos por objeto de cada classe.	38
4.13	Comparação entre dois veículos retirados da base de dados H3D, à esquerda Carro 1, e à direita Carro2.	38
4.14	Gráfico de dispersão do número de pontos por objetos pela sua distância ao EGO-Vehicle.	39

4.15	Gráfico de dispersão do logaritmo do número de pontos por objetos pelo logaritmo da sua distância ao EGO-Vehicle.	40
4.16	Gráfico de dispersão do logaritmo do número de pontos por objetos pelo logaritmo da sua distância ao EGO-Vehicle, por Classes.	40
4.17	Gráfico de dispersão do Número de Pontos por objetos pela sua Distância ao EGO-Vehicle, por classes com a sua curva de adaptação.	41
4.18	Boxplots das métricas de densidade D5 e D10 das classes Pedestre, Animais, Ciclistas e Motociclistas.	42
4.19	Resultados da primeira tentativa de modelo de separação em 3 grupos.	43
4.20	Resultados da segunda tentativa de modelo de separação em 3 grupos, sem as métricas pontuais nem distância ao <i>Ego-Vehicle</i>	43
4.21	Resultados da primeira tentativa de modelo de separação entre todas as classes e com todas as métricas.	44
4.22	Resultados da primeira tentativa de modelo de separação entre todas as classes e sem métricas pontuais.	45
7.1	Gráfico de Dispersão da Altura pelo Logaritmo da Área dos objetos por Classes.	62
7.2	Gráfico de dispersão do número de pontos por objetos pela sua distância ao EGO-Vehicle.	63
7.3	Gráfico de dispersão do logaritmo do número de pontos por objetos pelo logaritmo da sua distância ao EGO-Vehicle.	64
7.4	Gráfico de dispersão do logaritmo do número de pontos por objetos pelo logaritmo da sua distância ao EGO-Vehicle, por Classes.	65
7.5	Gráfico de dispersão do Número de Pontos por objetos pela sua Distância ao EGO-Vehicle, por classes com a sua curva de adaptação.	66

Lista de Tabelas

3.1	Bases de dados de condução autónoma adaptada de [46]. ¹ Bases de dados geradas virtualmente.	18
3.2	Objetos selecionados para as situações de estudo.	27
4.1	Número de objetos e pontos por classes.	29
4.2	Média das variáveis usadas por classes.	31
5.1	Exemplo de classificação dos algoritmos através do valor de <i>Ground Truth</i>	48
5.2	Resultados da análise aos algoritmos em comparação com o <i>Ground Truth</i>	48
5.3	Exemplo de classificação dos Índices através do valor de <i>Ground Truth</i>	49
5.4	Resultados do estudo dos índices de validação interna.	49
5.5	Resultados do estudo da intensidade como <i>threshold</i>	51
5.6	Resultados do estudo da segmentação usando a intensidade como quarta variável.	52
7.1	Situação 1	67
7.2	Situação 2	67
7.3	Situação 3	67
7.4	Situação 4	67
7.5	Situação 5	68
7.6	Situação 6	68
7.7	Situação 7	68
7.8	Situação 8	68
7.9	Situação 9	69
7.10	Situação 10	69
7.11	Situação 11	69
7.12	Situação 12	70
7.13	Situação 13	70
7.14	Situação 14	70
7.15	Situação 15	70
7.16	Situação 16	71
7.17	Situação 17	71
7.18	Situação 18	71
7.19	Situação 19	71
7.20	Situação 20	72
7.21	Situação 21	72
7.22	Situação 22	72

7.23 Situação 23	72
7.24 Situação 24	73
7.25 Situação 25	73
7.26 Situação 26	73
7.27 Situação 27	73
7.28 Situação 28	74
7.29 Situação 29	74
7.30 Situação 30	74
7.31 Situação 31	75
7.32 Situação 32	75
7.33 Situação 33	75
7.34 Situação 34	75
7.35 Situação 35	76
7.36 Situação 36	76
7.37 Situação 37	76
7.38 Situação 38	76
7.39 Situação 39	77
7.40 Situação 40	77
7.41 Situação 41	77
7.42 Situação 42	77

Glossário

ADS	Automated Driving Systems
ALV	Autonomous Land Vehicle
AUC-ROC	Area Under the ROC curve
DARPA	Defence Advanced Research Projects Agency
DBCV	Density-Based Clustering Validation
DBSCAN	Density-based spatial clustering of application with noise
EGO-Vehicle	Veículo de captação dos dados
FOV	Field of View
LiDAR	Light Detection and Ranging
SAE	Society of Automotive Engineers International
TOF	Time Of Flight

1 - Introdução

1.1 Motivação

A condução autónoma veio revolucionar a indústria automóvel. O rápido avanço nesta área destacou a importância que os algoritmos de perceção e identificação adquirem nesta tarefa. Estes algoritmos vão ser os "olhos" dos veículos, e o grande objetivo é que estes sistemas consigam detetar, identificar e prever todos os objetos e situações melhor que os seres humanos. No entanto, a grande diversidade de condições atmosféricas ou mesmo a forma dos objetos pode criar bastantes dificuldade e tornar a tarefa de condução autónoma mais desafiante.

Nesta dissertação pretende-se dar mais um passo neste grande objetivo que é o da criação de veículos totalmente capazes de conduzir autonomamente.

1.2 Condução Autónoma

1.2.1 Definição

Em 2014 a *Society of Automotive Engineers International* (SAE), definiu a nomenclatura a usar nas áreas dedicadas à condução autónoma, [1].

"Um Sistema de Condução Autónomo, do inglês *Automated Driving System* (ADS), é um conjunto de hardware e software que coletivamente é capaz de realizar uma tarefa dinâmica de condução, independentemente de estar afetada a um domínio específico, este que pode ser limitado por condições atmosféricas, hora do dia, área geográfica ou até

mesmo presença ou ausência de sinais ou marcas de trânsito.”

A SAE definiu também 6 níveis de automação, apresentados na sua forma original, em inglês, na figura 1.1:

SAE J3016™ LEVELS OF DRIVING AUTOMATION™
 Learn more here: [sae.org/standards/content/j3016_202104](https://www.sae.org/standards/content/j3016_202104)

Copyright © 2021 SAE International. The summary table may be freely copied and distributed AS-IS provided that SAE International is acknowledged as the source of the content.

	SAE LEVEL 0™	SAE LEVEL 1™	SAE LEVEL 2™	SAE LEVEL 3™	SAE LEVEL 4™	SAE LEVEL 5™
What does the human in the driver's seat have to do?	You are driving whenever these driver support features are engaged – even if your feet are off the pedals and you are not steering			You are not driving when these automated driving features are engaged – even if you are seated in “the driver's seat”		
	You must constantly supervise these support features; you must steer, brake or accelerate as needed to maintain safety			When the feature requests, you must drive	These automated driving features will not require you to take over driving	
Copyright © 2021 SAE International.						
What do these features do?	These are driver support features			These are automated driving features		
	These features are limited to providing warnings and momentary assistance	These features provide steering OR brake/acceleration support to the driver	These features provide steering AND brake/acceleration support to the driver	These features can drive the vehicle under limited conditions and will not operate unless all required conditions are met	This feature can drive the vehicle under all conditions	
Example Features	<ul style="list-style-type: none"> • automatic emergency braking • blind spot warning • lane departure warning 	<ul style="list-style-type: none"> • lane centering OR • adaptive cruise control 	<ul style="list-style-type: none"> • lane centering AND • adaptive cruise control at the same time 	<ul style="list-style-type: none"> • traffic jam chauffeur 	<ul style="list-style-type: none"> • local driverless taxi • pedals/steering wheel may or may not be installed 	<ul style="list-style-type: none"> • same as level 4, but feature can drive everywhere in all conditions

FIGURA 1.1: Níveis de Autonomia definidos pela SAE [1]

O nível zero de condução autónoma descrito pela SAE corresponde ao de condução sem qualquer automatismo, contudo apenas com avisos de apoio à condução, tais como o aviso de ângulo morto ou travão de emergência. A maior alteração acontece do nível 2 para o nível 3 em que o veículo passa a ter características de condução ao invés de características de apoio à condução, assemelhando-se a um táxi, pseudo-autónomo, ao invés de prover ajudas tais como o “*cruise control* adaptado” ou a “centralização na faixa”. Sumariamente, do nível 2 para o nível 3 de automação, o papel de condução passa do condutor para o veículo.

1.2.2 Evolução da Condução Autónoma

Os primeiros passos na condução autónoma já datam a década de 1980, com trabalhos realizados pela *Carnegie Mellon University* [2] e pela *Bundeswehr University Munich* [3]. Ainda na década de 1980, os avanços nos sensores e nas tecnologias usadas foram impulsionados pelas várias competições organizadas, primeiramente a *Autonomous Land Vehicle (ALV)* organizada pela *Defense Advanced Research Projects Agency (DARPA)* [4] e a *PROMETHEUS (PROgram for a European Traffic with Highest Efficiency and Unprecedented Safety)* organizado pela EUREKA, [5]. Já no século XXI, a DARPA lança uma nova competição chamada *DARPA Grand Challenge*, [6], no sentido de impulsionar a inovação nesta área [7].

1.3 LiDAR + Condução Autónoma

Apesar de serem utilizados na década de 1930, para a determinação da densidade atmosférica, [8], os princípios de *Light Detection and Ranging (LiDAR)* só foram estabelecidos na década de 1960, firmemente suportados pelas suas aplicações fossem elas atmosféricas, oceanográficas, ou mesmo de mapeamento do território.

Porém foi só na década de 2000 que os sensores LiDAR começaram a ser usados na condução autónoma. O seu primeiro uso foi, tanto quanto se pôde aferir, em 2004, numa competição organizada pela *DARPA*, pela equipa *Starfire*, [9]. Foi usado um sensor LiDAR fabricado pela empresa *SICK*, com 80 metros de alcance e um *Field Of View (FOV)* horizontal de 180°. Contrariamente aos dos sensores utilizados hoje em dia, que possuem simultaneamente FOV horizontal e vertical, este sensor registava apenas uma linha horizontal de 180° que corresponderia à distância a que os pontos estavam do equipamento. Este veículo continha assim vários sensores LiDAR de linha, inclusivé um com FOV vertical, com a única função de detetar desníveis no terreno.

1.4 Objetivos

O objetivo deste trabalho consiste em identificar que métricas poderão ser eficazes na tarefa de identificação dos objetos segmentados. Testar-se-á que algoritmos de segmentação

se adequam melhor a este tipo de dados. Outro dos objetos de estudo incidirá sobre os diversos índices de validação interna, para aferir quais se enquadram melhor a estes dados e objetos.

1.5 Estrutura do documento

No capítulo 2, é explicado, de forma breve o funcionamento da tecnologia LiDAR, e são introduzidos os algoritmos de aprendizagem não supervisionada, que serão necessários para a tarefa de segmentação dos objetos. Serão enumerados e resumidos os Índices de Validação Interna a usar para comparação dos algoritmos.

No capítulo 3, serão abordadas as diferentes bases de dados criadas ao longo dos últimos anos, e discutidas as suas diferenças. Especial foco incidirá nas que serão objeto estudo neste documento, H3D e Bosch. Será explicado o pré-processamento necessário para a obtenção dos objetos, as etiquetas que contêm o "*Ground Truth*" e a característica que faz diferir a base de dados Bosch da H3D, a intensidade. Por fim, no capítulo 5 serão discutidas as situações de conflito como objetos de estudo.

Começaremos assim os dois capítulos de estudo dos dados, no capítulo 4 iremos analisar algumas métricas escolhidas para representar os objetos, alguns resultados, assim como a aplicação dos algoritmos de decisão com vista à identificação de classes. Já no capítulo 5 vamos aplicar os algoritmos de segmentação nas situações de conflito e perceber quais são os que se adequam mais, bem como quais os índices de validação interna que melhor se adequam. Finalmente resumiremos alguns resultados mais importantes no capítulo 6 assim como sugerir algumas linhas de trabalho futuro.

2 - Materiais e Métodos

Neste capítulo serão introduzidos os materiais necessários para o estudo efetuado. Divide-se em três secções, a primeira orientada para o Sensor LiDAR e como este capta os objetos, a segunda à aprendizagem não supervisionada, *Unsupervised Learning* no original, esta segunda secção está por sua vez dividida em quatro secções, cada uma das quais correspondendo às diferentes técnicas de agrupamento usadas. E finalmente uma terceira em que serão resumidos os diferentes índices de validação interna usados.

2.1 LiDAR

LiDAR, proveniente de "*Light Detection And Ranging*" é uma tecnologia de deteção remota que utiliza luz na forma de feixes para medir distâncias. Estes feixes de luz juntamente com equipamentos de geolocalização são capazes de criar nuvens de pontos de precisão assim como extrair algumas características. Este sistema é composto por um emissor e um recetor de laser. O emissor emite um feixe de luz que é por sua vez refletido no objeto e recebido pelo recetor.

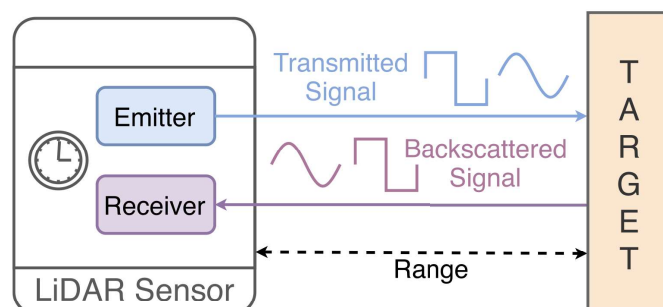


FIGURA 2.1: Esquema simples da tecnologia LiDAR, [10]

A diferença temporal entre a emissão e a receção do laser, é chamada de "time of flight" (TOF), aqui representada por Δ . A distância, d , a que o objeto se encontra do equipamento será então calculada conhecendo a velocidade, v , do feixe de luz, através da equação 2.1:

$$d = \frac{v \times \Delta}{2} \quad (2.1)$$

Tipicamente um sensor LiDAR contém um *Field of View* - FOV horizontal e outro vertical. Assim cada ponto será composto por dois ângulos e uma distância, similar às coordenadas esféricas, e uma intensidade (nos casos em que o sensor capta a intensidade do ponto). É necessário assim passar de coordenadas esféricas para coordenadas euclidianas por forma a aplicar os algoritmos usados.

A conversão de coordenadas esféricas $[\alpha, \beta, d]$ para coordenadas Euclidianas $[x, y, z]$ é feita pela equação 2.2.

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} d \cdot \sin(\alpha) \cdot \cos(\beta) \\ d \cdot \sin(\alpha) \cdot \sin(\beta) \\ d \cdot \cos(\alpha) \end{bmatrix} \quad (2.2)$$

Em que α corresponde ao ângulo entre o plano xy e o eixo dos z's, e β o ângulo no plano xy, entre o eixo dos x's e o eixo dos y's.

2.2 Aprendizagem Automática

A aprendizagem automática pode ser dividida em 3 áreas: aprendizagem não supervisionada, aprendizagem supervisionada ou aprendizagem com reforço. Neste trabalho dar-se-á uso a métodos de aprendizagem supervisionada e não supervisionada.

2.2.1 Aprendizagem Não Supervisionada

A aprendizagem supervisionada, ao contrário das restantes, não depende de uma solução previamente introduzida como objeto de entrada, não sendo necessário qualquer reforço ou uma "classe solução" dos resultados [11]. Em suma, a aprendizagem não supervisionada visa encontrar características ou padrões em comum entre os objetos, ignorando por

vezes algum *ruído* que os dados possam revelar.

Durante este estudo foram utilizados vários métodos de aprendizagem não supervisionada, nomeadamente K-Means, *Density-based spatial clustering of applications with noise* (DBSCAN), Agrupamento Hierárquico, Agrupamento Espectral - *Spectral Clustering*.

2.2.1.1 K-Means

Tendo sido publicado em 1957, [12], e depois em 1967 [13], o K-Means é um dos algoritmos de agrupamento mais utilizados e pelas mais diversificadas áreas de análise de dados [14]. A ideia do método K-Means consiste em escolher previamente um número K de pontos, esse será o número de partições final. Seguidamente calculam-se os pontos mais próximos de cada um desses pontos iniciais e juntam-se a cada subconjunto. Posteriormente recalcula-se o centro de cada subconjunto e reatribui-se cada ponto a cada subconjunto. Repete-se iterativamente este processo até que se cumpra um critério de convergência previamente definido (seja o número de iterações ou a diferença entre conjuntos).

2.2.1.2 DBSCAN

O DBSCAN, proposto em 1996 [15], é um algoritmo não paramétrico de agrupamento por densidade. Serviu como base para a criação de variadíssimos algoritmos que usam a densidade, tendo sido já implementado em inúmeras linguagens de programação e utilizado nas mais diversas áreas do conhecimento, [16]. Uma das grandes vantagens deste algoritmo é ser capaz de captar objetos com forma arbitrária. Ou seja, ao invés de K-Means em que se aglomeram os objetos que estão mais próximos de um determinado ponto, tomando assim uma forma circular/esférica, o DBSCAN analisa apenas a distância entre pontos e os seus vizinhos conseguindo aglomerar formas completamente arbitrárias. A título de exemplo apresenta-se a figura 2.2, utilizada uma pequena base de dados retirada de kaggle.com/datasets/joonasyoon/clustering-exercises. Esta base de dados consiste em pontos de duas dimensões.

A figura 2.2 representa os dados da base de dados. No gráfico do canto superior esquerdo, apresentam-se os pontos sem qualquer partição (CSE). Já no canto superior direito, (CSD), o *ground truth*, isto é, a informação que previamente sabemos ser verdadeira,

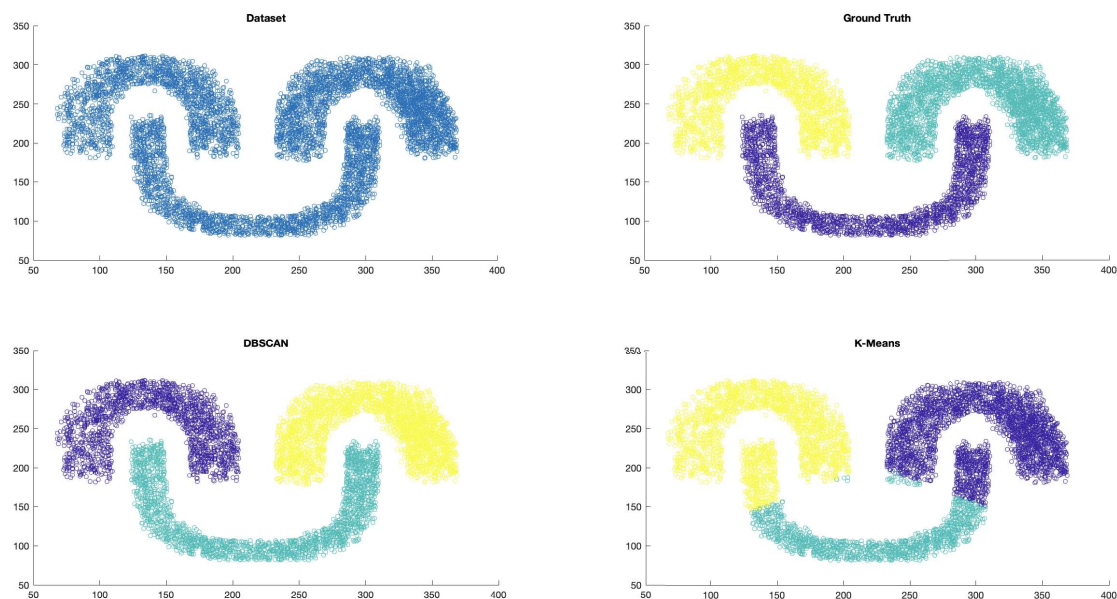


FIGURA 2.2: Exemplo de clustering por DBSCAN (CIE) e K-Means (CID) para um conjunto de dados (CSE) a duas dimensões.

neste caso a partição correta. Nos gráficos em baixo temos à esquerda a partição realizada pelo algoritmo DBSCAN (CIE) e à direita a segmentação realizada pelo algoritmo K-Means (CID).

Como se pode observar na figura 2.2, o algoritmo DBSCAN, por aglomerar pontos através da densidade, consegue separar claramente os 3 grupos de pontos, ao invés do K-Means que por, ter de selecionar para cada conjunto um ponto central, acaba por incluir pontos que pertencem a outro objeto.

2.2.1.3 Agrupamento Hierárquico - Hierarchical Clustering

O agrupamento hierárquico, é uma técnica de *machine learning* que gera uma sequência de partições de objetos [17]. Estas partições podem ser alcançadas aglomerando objetos sucessivamente de acordo com critérios de semelhança, em inglês, *agglomerative clustering*, ou começando com o dataset todo e ir separando em partições de acordo com critérios de dissemelhança, em inglês, *divisive clustering*. O resultado será uma árvore de partições que demonstra como as partições foram obtidas, o dendrograma. Cortando o dendrograma a um nível específico pode obter-se um variado número de grupos consoante as divisões/aglomerações já efetuadas. Como exemplo apresenta-se o dendrograma da figura 2.3:

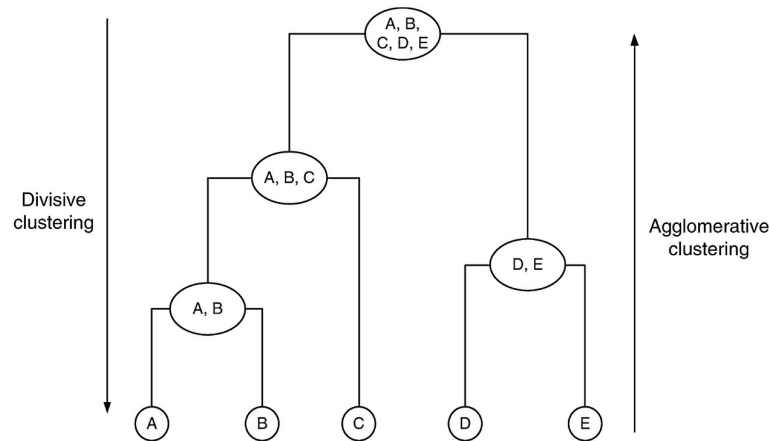


FIGURA 2.3: Exemplo de um dendrograma retirado de [18].

Para a implementação dos algoritmos de *clustering* tem que se escolher previamente um critério/função de ligação. Este critério de ligação será usado para definir a distância entre duas partições. Existem várias funções de ligação, mediana/*median*, máxima, mínima/*single*, média, no entanto optou-se por trabalhar apenas com as funções de ligação mediana e mínima.

2.2.1.4 Ligação Mínima - *Single Linkage*

Na função de ligação mínima d_s , serão agrupados os objetos que se encontram mais perto, isto é, dois *clusters* serão aglomerados se a distância entre dois pontos for mínima. A função de ligação mínima é dada pela equação 2.3.

$$d_s(X, Y) = \min_{x \in X, y \in Y} d(x, y) \quad (2.3)$$

Em que X, Y são duas partições, e d é a distância euclidiana.

2.2.1.5 Ligação Mediana - *Median Linkage*

Ao contrário das funções de ligação mínima e máxima, que se fixam pelos extremos das distâncias, existe a ligação mediana, d_m , [19]. Esta usa uma ligação intermédia, a sua equação é demonstrada pela equação 2.4.

$$d_m(X, Y) = \frac{1}{2} \cdot d(Y_1, X) + d(Y_2, X) - \frac{1}{4} \cdot d(Y_1, Y_2) \quad (2.4)$$

Onde, X e Y , são duas partições e Y_1 e Y_2 são duas partições de Y , $Y = Y_1 \cup Y_2$, novamente d é a distância euclidiana.

2.2.1.6 Agrupamento Espectral - Spectral Clustering

O agrupamento espectral é um dos métodos mais eficazes para separar partições mais complexas e que não possuem formas geometricamente simples e definidas [20]. Através de matrizes de semelhança, valores e vetores próprios e redução de dimensionalidade obtém-se um método algo mais complexo que os vistos anteriormente, porém com resultados bastante satisfatórios. É de notar que este método é um dos mais exigentes a nível computacional.

2.2.2 Aprendizagem Supervisionada

Ao contrário da aprendizagem não supervisionada, a aprendizagem supervisionada tem como apoio os dados previamente etiquetados. Tipicamente estas etiquetas existem sob a forma de classes. O seu principal papel é o de encontrar padrões ou fronteiras de decisão que possam guiar aos dados às etiquetas apontadas anteriormente. Este modelo pode ser criado com dados de treino, para no futuro ser usado com dados sobre os quais o modelo não tem qualquer conhecimento. Neste trabalho foi utilizado um método bastante conhecido de aprendizagem supervisionada - as "Árvores de Decisão".

2.2.2.1 Árvores de Decisão

Constituindo um dos modelos de classificação mais fáceis de entender, as árvores de decisão são também dos modelos mais eficientes [21]. O método é simples, atribui-se uma decisão por cada nó da árvores que se passa. Estes nós estão relacionados com os atributos dos objetos. No final cada folha da árvore será uma decisão final sobre a que classe o objeto pertence. Na figura 2.4 apresenta-se um exemplo de uma árvore de decisão, traduzida de [22]. Esta imagem representa uma árvore de decisão com o intuito de saber se será possível ou não jogar ténis em função das previsões meteorológicas. Como se pode verificar, através de várias condições consegue-se facilmente tomar a decisão de Sim/Não. Esta árvore pode ter no entanto mais classes e não ser necessariamente binária.

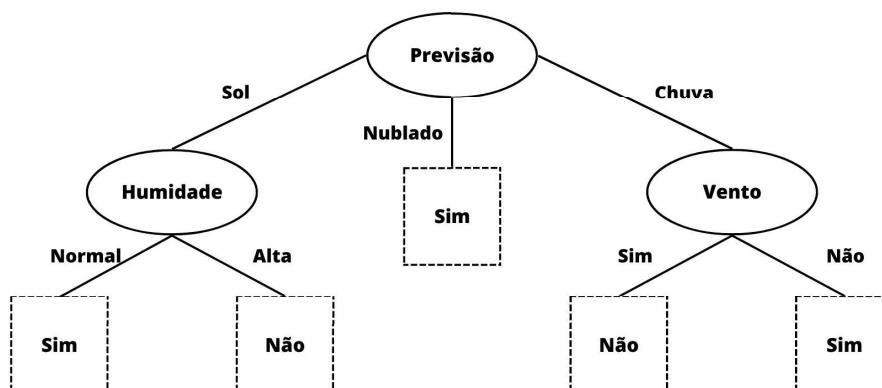


FIGURA 2.4: Imagem ilustrativa de uma árvore de decisão, adaptado de [22].

2.3 Distâncias

Define-se uma métrica, baseada nos algoritmos de densidade, para o estudo dos objetos. Esta métrica, D_k , de cada objeto, será calculada como a média da média da distância aos k pontos vizinhos mais próximos. A título de exemplo, apresenta-se a figura 2.5, antes de mostrar a formalização da mesma.




FIGURA 2.5: Imagem ilustrativa da métrica d_k , neste caso d_5 .

Seja d_k a distância média de um ponto p aos seus vizinhos mais próximos, esta distância é feita seguindo a equação 2.5.

$$d_k(p) = \frac{1}{k} \cdot \sum_{i=1, i \in UI}^k d(a, i) \quad (2.5)$$

onde p é um ponto, d é a distância euclidiana, k será o número de vizinhos mais próximos, e I o conjunto dos k vizinhos mais próximos. Sendo assim a sua forma é definida pela equação 2.6.

$$D_k(h) = \frac{1}{n} \sum_{i=1}^n d_k(i) \quad (2.6)$$

Onde h é o objeto a ser analisado, e n o número de pontos do objeto, e i os pontos do objeto.

2.4 Índices de Validação Interna

Para se proceder à comparação dos algoritmos de segmentação anteriormente apresentados, serão necessários índices de validação interna. Neste subcapítulo serão sumariamente apresentados os índices utilizados. No final será introduzida a ferramenta de *software* utilizada para o cálculo desses índices.

2.4.1 Silhouette

Silhouette é um dos índices mais usados para o cálculo do número ideal de *clusters*. Este índice calcula o desempenho de uma partição através da relação entre a dissemelhança e semelhança entre um ponto e não só todos os da mesma partição como todos os restantes, [23]. Sendo o seu valor ideal 1, o seu intervalo varia entre $[-1, 1]$. A sua equação é apresentada pela equação 2.7.

$$S(i) = \frac{(b(i) - a(i))}{\max(a(i), b(i))} \quad (2.7)$$

Em que $a(i)$ é a distância média *intra-cluster* e $b(i)$ a distância média *inter-cluster*.

2.4.2 Calinski-Harabasz

O índice de Calinski-Harabasz assenta na variância *inter-cluster* e *intra-cluster*. Este valor será maior nos casos em que a variância *intra-cluster* é menor e *inter-cluster* é maior [24]. O seu intervalo pode variar entre $[0, \infty]$, em que quanto maior for o valor melhor será a partição.

2.4.3 DBCV - Density-Based Clustering Validation

Proposto em 2014 [25], o DBCV é um índice de validação interna adaptado para *clusters* que usam como segmentação a densidade. Este usa como ferramentas tanto a separação como a dispersão da densidade. Apesar de ser um bom índice para grupos com formas arbitrárias, pode ter um mau desempenho se os grupos não forem bem separados [26]. Este índice tem como intervalo de valores entre $[0, 1]$ sendo que 1 é o valor ideal.

2.4.4 Harrell's C

O índice Harrell's C, também conhecido como Índice de Concordância ou *Area Under the ROC curve (AUC-ROC)* [27], é uma métrica usada para calcular o desempenho de modelos de classificação principalmente em *machine learning* e investigação médica. O seu intervalo é $[0, 1]$ sendo que os valores abaixo de 0.5 indicam que o modelo não tem um desempenho melhor do que se fosse aleatório, já valores acima de 0.5 até 1, em que este é o mais favorável, revelam uma melhor discriminação.

2.4.5 COP

O algoritmo COP, proposto em [28], usa como indicadores para a coesão, a distância dos pontos de uma dada partição com o seu centroide e para a separação é calculada através da distância ao vizinho mais longínquo [29]. O seu valor varia no intervalo $[0, \infty]$ em que 0 corresponde ao valor mais adequado.

2.4.6 CS

O índice CS, publicado em 2004 [30], varia entre $[0, \infty]$, em que o objetivo visa minimizar o seu valor. Estima a coesão e separação dos *clusters* através da distância ao vizinho mais próximo [29].

2.4.7 CVDD

O índice CVDD, publicado em [31], utiliza na sua medida de distância métricas como a intensidade. Varia de 0 a ∞ , sendo o máximo o seu valor ideal. Este índice, assim como o DBCV, apresentado em 2.4.3, consegue lidar com partições com formas arbitrárias não esféricas. O índice CVDD segue a equação 2.8.

$$CVDD = \frac{\sum_{i=1}^K sep(C_i)}{\sum_{i=1}^K com(C_i)} \quad (2.8)$$

Em que as funções *sep* e *com* são as funções de separação e compacidade respectivamente.

2.4.8 Davies-Boudin

Um dos índices de validação interna mais utilizados é o *Davies-Boudin index*, *DB*. Publicado em 1939 [32], este índice avalia a similaridade entre duas partições e a partição mais próxima desta. Pode apresentar-se este índice pela equação 2.9.

$$DB = \frac{1}{c} \cdot \sum_c \max_{i \neq j} \left\{ \frac{d(x_i) + d(x_j)}{d(c_i, c_j)} \right\} \quad (2.9)$$

Em que c é o número de partições, i e j são etiquetas das partições, $d(i)$ é a média da distância de cada ponto de i ao seu centróide, respetivamente $d(j)$ e finalmente $d(c_i, c_j)$ é a distância entre o centróide da partição i e j . O seu leque de valores pode ir de 0 a $+\infty$, porém será na sua minimização que serão obtidos os melhores resultados [33].

2.4.9 Dunn

O índice Dunn foi proposto em 1973 por Joseph Dunn [34]. Este índice calcula a razão entre a mais pequena distância *inter-cluster* e a maior distância *intra-cluster*. É definido pela equação 2.10.

$$Dunn = \min_{1 \leq i \leq c} \left\{ \min \left\{ \frac{d(C_i, C_j)}{\max_{1 \leq k \leq c} diam(C_k)} \right\} \right\} \quad (2.10)$$

Em que $d(c_i, c_j)$ é a distância entre as partições C_i e C_j , que tipicamente pode ser a distância mínima entre pontos de cada conjunto. Já $diam(C_k)$ representa o diâmetro da partição C_k e c é o número de partições existentes. Este índice varia entre 0 e $+\infty$ e deve ser maximizado.

2.4.10 Auto-CVI-Tool

An Automatic Cluster Validity Index Toolbox, [35], criada por Farhad Abedinzadeh, é uma compilação de índices de validação interna. Teve como base o artigo *A Survey of Cluster Validity Indices for Automatic Data Clustering Using Differential Evolution* [36], em que foram

analisados 22 índices de validação interna. Esta *toolbox* foi implementada para o *software Matlab*, versão R2020b, foi usada para calcular os índices de validação interna.

3 - Conjuntos de Dados

3.1 Bases de Dados

Na campo da condução autónoma, um dos grandes pilares para a melhoria e criação de novas tecnologias são as bases de dados. Servindo como treino, validação e teste, as bases de dados desempenham um papel importantíssimo para treinar os modelos de *machine learning*. A busca por bases de dados mais completas e por sua vez mais complexas, obriga à constante criação e aglomeração de dados novos, em condições atmosféricas ou mesmo ambientes diferentes. Não obstante, foi observado que na área de *Semantic Segmentation*, isto é, segmentação por classes, o desempenho dos algoritmos testados, aumenta logaritmicamente com o aumento do número elementos dos dados [37].

Neste capítulo serão enunciadas várias bases de dados criadas ao longo dos últimos anos, e realçadas algumas das suas diferenças, nomeadamente nos sensores que usam ou em relação às condições atmosféricas em que foram os dados obtidos. Serão também exploradas com maior detalhe e profundidade as bases de dados H3D [38], e Bosch, uma vez que foram as escolhidas como material de estudo neste trabalho.

3.1.1 Alguns exemplos de Bases de Dados

Uma das primeiras bases de dados disponibilizadas ao público foi o *KITTI Dataset*, em 2012, numa parceria entre o *Karlsruhe Institute of Technology* e a *Toyota Technological Institute* em Chicago [39]. Como exemplo de mais recentes desenvolvimentos existe a Oxford RobotCar Dataset [40], a Waymo Dataset [41], a nuScenes Dataset [42], a H3D Dataset [38] e a A2D2 Dataset da Audi [43]. Além de bases de dados reais existem igualmente bases de dados obtidas através de dados virtuais, são elas a VKITTI, proveniente de *Virtual*

KITII [44], e a *SYNTHIA* [45].

Estes dados são diferentes em várias categorias, sejam condições atmosféricas ou mesmo nos sensores que usam. A tabela 3.1 adaptada de [46], visa a facilitar esta comparação.

Nome	Ano	Sensores				Condições Atmosféricas			
		Camera	LiDAR	GPS	Radar	Sol	Chuva	Neve	Nevoeiro
KITTI [39]	2012	✓	✓	✓	-	✓	-	-	-
RobotCar [40]	2016	✓	✓	✓	-	✓	✓	✓	-
Waymo [41]	2019	✓	✓	-	-	✓	✓	-	-
nuScenes [42]	2019	✓	✓	✓	✓	✓	✓	-	-
H3D [38]	2019	✓	✓	✓	-	✓	-	-	-
A2D2 [43]	2020	✓	✓	✓	-	✓	✓	✓	-
Bosch	2023	✓	✓	✓	-	✓	✓	✓	-
VKITTI ¹ [44]	2016	✓	✓	✓	✓		✓	✓	✓
SYNTHIA ¹ [45]	2016	✓	✓	✓	✓	✓	✓	✓	✓

TABELA 3.1: Bases de dados de condução autônoma adaptada de [46].

¹Bases de dados geradas virtualmente.

3.1.2 H3D

Em 2019, com o intuito de capturar ambientes de trânsito intenso, a *Honda Research Institute* lançou a H3D Dataset [38]. Aglomerando 160 cenas, mais de 27.000 momentos e cerca de 1.000.000 de anotações esta é uma das bases de dados de nuvens de pontos para condução autônoma mais completas. Os dados foram captados em 4 cidades dos Estados Unidos da América, nomeadamente *San Francisco*, *Mountain View*, *Santa Cruz* e *San Mateo*, todas no Estado da Califórnia. Foi usado um sensor *Velodyne HDL-64E* com um FOV horizontal de 360° e um FOV vertical de 26,9°, com um alcance máximo de 100 metros. Este sensor está colocado no ponto mais alto do veículo a 1,65 metros do chão.

3.1.3 Dados Bosch

Adquirida ao longo dos dois últimos anos, a base de dados *Bosch* contém mais de 184.632 nuvens de pontos distribuídas por cerca de 539 cenas. Toda a informação acerca desta base de dados, nomeadamente FOV horizontal e vertical, assim como alcance e resolução poderá ser consultada em [47]. Além das nuvens de pontos em 3 dimensões, os dados Bosch possuem um parâmetro em cada ponto correspondente à intensidade do sinal. Este valor de intensidade varia entre 0 e 1, e mede a capacidade refletiva do ponto, as superfícies

mais refletoras como, por exemplo, sinais de trânsito possuem os valores de intensidade mais elevados.

Foram escolhidas as bases de dados *H3D* e *Bosch* para o estudo por serem bastante diferentes nos dados que contêm. Por um lado a base de dados *H3D* é das mais completas que se conhece, seja a nível de situações ou mesmo de etiquetas. Por outro lado a base de dados *Bosch*, apesar de não ter um sensor com 360° de amplitude horizontal, consegue um alcance de 300 metros com uma resolução elevada. A juntar a este ponto existe também questão da intensidade do sinal, que é disponibilizado nos dados *Bosch*. Os valores de intensidade, poderão ser úteis na distinção entre objetos, nomeadamente superfícies bastante refletivas.

3.2 Pré-Processamento dos Dados

Os dados são disponibilizados em coordenadas cartesianas, e agrupados em conjuntos (cenas) com diferentes características. Cada cena será um conjunto de nuvens de pontos (cenários) que retratam um pedaço da trajetória efetuada pelo *EGO-Vehicle*. No estudo, exigem-se outros procedimentos de preparação dos dados para que se possa retirar toda a informação necessária a uma análise mais aprofundada. Essas tarefas são descritas em seguida, ilustradas com exemplos de cenas dos dados *H3D* e *Bosch*. Nas 3 secções é utilizado o cenário "001" da cena "060" da base de dados *H3D*. Para demonstrar a intensidade é usada uma cena da base de dados *Bosch*.

3.2.1 Remoção do chão

Observando uma cena como a apresentada na figura 3.1, pode notar-se a existência de um grande número de pontos no chão da nuvem de pontos, tipicamente com formas elípticas. Este grupo de pontos penaliza bastante a tarefa de agrupamento criando ligações que não existem entre os objetos.

Utilizou-se então o método MLESAC [48] que usa um princípio melhorado de RANSAC [49]. Em suma estes métodos funcionam da seguinte forma:

1. Selecionar um conjunto inicial de 3 pontos.
2. Determinar um plano que contem este conjunto inicial.




FIGURA 3.1: Imagem com dados H3D antes da remoção do chão, cena "060" e cenário cenário "001".

3. Determinar o número de *outliers* do plano na nuvem de pontos completa.
4. Guardar o número de *outliers*.
5. Repetir os passos 1-4 o número de vezes previamente definido.

O plano da nuvem de pontos que tiver menos *outliers*, será portanto o que compreende ao chão. Estes pontos são então retirados da nuvem de pontos, eliminando assim o chão. O resultado pode ser visto na figura 3.2. Nesta imagem já se está perante objetos separados e sem as linhas circulares.




FIGURA 3.2: Imagem com dados H3D após a remoção do chão, cena "060" e cenário cenário "001".

3.2.2 Obtenção de objetos

Como já foi anteriormente referido, a escolha incidiu sobre estas bases de dados por terem objetos identificados com as respetivas caixas delimitadoras/*bounding boxes* delineadas. No entanto, será necessário alguma preparação por forma a separar os objetos já identificados. As duas bases de dados utilizadas, estas têm por sua vez etiquetas diferentes, que a seguir se descrevem.

Tipicamente uma etiqueta da base de dados H3D estará representada da seguinte forma:

1. Classe
2. Identificador para monitorização do objeto - Id
3. Estado (Estático ou Dinâmico)
4. Cordenadas do centro do objeto - $C_{xyz} = [C_x, C_y, C_z]$
 - (a) C_x - Coordenada no eixo dos x 's
 - (b) C_y - Coordenada no eixo dos y 's
 - (c) C_z - Coordenada no eixo dos z 's
5. Comprimento do objeto - $L_{xyz} = [L_x, L_y, L_z]$
 - (a) L_x - Comprimento no eixo dos x 's
 - (b) L_y - Comprimento no eixo dos y 's
 - (c) L_z - Comprimento no eixo dos z 's
6. Ângulo sobre o eixo dos z 's - Yaw

Já as etiquetas da base de dados Bosch apresentam as seguintes características:

1. Classe
2. Identificador para monitorização do objeto - Id
3. Cordenadas do centro do objeto - $C_{xyz} = [C_x, C_y, C_z]$
 - (a) C_x - Coordenada no eixo dos x 's
 - (b) C_y - Coordenada no eixo dos y 's
 - (c) C_z - Coordenada no eixo dos z 's

4. Comprimento do objeto - $L_{xyz} = [L_x, L_y, L_z]$
 - (a) L_x - Comprimento no eixo dos x 's
 - (b) L_y - Comprimento no eixo dos y 's
 - (c) L_z - Comprimento no eixo dos z 's
5. Orientação sobre o eixo dos z 's - Yaw
6. Orientação sobre o eixo dos y 's - Pitch
7. Orientação sobre o eixo dos x 's - Roll

Ora, por forma a isolar os objetos para procedermos ao seu estudo é necessária, alguma manipulação da nuvem de pontos.

O algoritmo usado foi:

1. Subtrair o centro do objeto.
2. Rodar o objeto.
3. Excluir pontos que estejam fora do comprimento do objeto.
4. Rodar o objeto para a orientação inicial.
5. Adicionar o centro do objeto para que este volte para a posição inicial.

Para cálculos futuros será considerada a nuvem de pontos como uma matriz $m \times n$ denominada por A , e considerada uma matriz de $m \times 3$, C , em que todas as linhas são iguais ao vetor C_{xyz} . São igualmente utilizadas as seguintes matrizes de rotação 3.1, 3.2 e 3.3.

$$R_x = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\alpha) & -\sin(\alpha) \\ 0 & \sin(\alpha) & \cos(\alpha) \end{bmatrix} \quad (3.1)$$

$$R_y = \begin{bmatrix} \cos(\beta) & 0 & \sin(\beta) \\ 0 & 1 & 0 \\ -\sin(\beta) & 0 & \cos(\beta) \end{bmatrix} \quad (3.2)$$

$$R_z = \begin{bmatrix} \cos(\gamma) & -\sin(\gamma) & 0 \\ \sin(\gamma) & \cos(\gamma) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.3)$$

Estas 3 matrizes multiplicadas por forma a obter apenas uma matriz de rotação dada pela matriz 3.4:

$$R_{xyz} = \begin{bmatrix} \cos(\alpha)\cos(\beta) & \cos(\alpha)\sin(\beta)\sin(\gamma) - \sin(\alpha)\cos(\gamma) & \cos(\alpha)\sin(\beta)\cos(\gamma) + \sin(\alpha)\sin(\gamma) \\ \sin(\alpha)\cos(\beta) & \sin(\alpha)\sin(\beta)\sin(\gamma) + \cos(\alpha)\cos(\gamma) & \sin(\alpha)\sin(\beta)\cos(\gamma) - \cos(\alpha)\sin(\gamma) \\ -\sin(\beta) & \cos(\beta)\sin(\gamma) & \cos(\beta)\cos(\gamma) \end{bmatrix} \quad (3.4)$$

Assim, para se centrar a nuvem de pontos no centro do objeto, e com a mesma orientação do objeto, aplica-se a equação 3.5, em que se substituí os valores de α , β e γ pelo *Yaw*, *Pitch* e *Roll* do objeto, em 3.4.

$$(A - C) \times R_{xyz} \quad (3.5)$$

É de notar que no caso da base de dados H3D, existindo apenas os valores de *Yaw*, assume-se que os valores de *Pitch* e *Roll* são zero, o que substituindo na matriz R_{xyz} dará uma matriz igual à R_z , 3.3.

De seguida são excluídos todos os pontos cujo módulo é superior a $\frac{1}{2}L_{xyz}$. Desta forma limitam-se todos os pontos da nuvem aos compreendidos no interior do objeto.

Para se reposicionar o objeto para a sua posição inicial na nuvem de pontos, tem que se reorientar o objeto para a orientação inicial, multiplicando-se novamente por R_{xyz} , 3.4, mas desta vez com os valores *-Yaw*, *-Pitch* e *-Roll*, e somar-lhe o vetor C_{xyz} .

Este passo é importante quando se pretende filtrar todos os objetos da nuvem em simultâneo. Neste caso teria de se tratar cada objeto singularmente e guardar numa nuvem de pontos temporária. No final, somar-se-ia todas as nuvens de pontos correspondentes a cada objeto singular, ficando os objetos na sua posição e orientação inicial na mesma nuvem de pontos. Na figura [3.3] pode observar-se a mesma imagem usada nos métodos de pré-processamento anteriores, mas desta vez apenas os objetos etiquetados.

3.2.3 Intensidade

Uma das vantagens da base de dados Bosch é a componente "intensidade". Como referido anteriormente, a intensidade de um ponto é medido através do recetor, e este varia consoante o material no qual o feixe de luz é refletido ou ainda conforme as condições atmosféricas. Como exemplo, selecionou-se uma imagem retirada da base de dados *Bosch*, mais concretamente do conjunto "olivia_202208", cena "20220829_174839", cenário



FIGURA 3.3: Imagem com dados H3D antes da remoção do chão e segmentação dos objetos, cena "060" e cenário cenário "001".

"1661788325572527000". Por forma a realçar a importância visual dos valores de intensidade serão disponibilizadas 3 imagens da mesma cena. A primeira imagem, 3.4, terá os pontos com a cor relativa à cota. A segunda, 3.5, apresenta a distância radial (distância ao veículo), enquanto a terceira apresenta os valores de intensidade, 3.6.




FIGURA 3.4: Exemplo de dados Bosch com a escala de cor associada à altura dos pontos.

Apesar de à primeira vista a figura 3.6 aparentar ser a mais confusa consegue notar-se as divisões entre paredes dos edifícios. Isto devido ao facto de a intensidade estar intrinsecamente relacionada com o material no qual o objeto é refletido. Logo, sempre que há alguma alteração nesse campo, sejam esquinas ou janelas, no caso de edifícios, ou mesmo, no caso dos veículos, frisos, estas são bastante perceptíveis.

Na imagem 3.7 procedeu-se à ampliação da zona no canto inferior esquerdo da imagem 3.6, para ser possível a visualização com mais detalhe de alguns destes casos. Pode observar-se uma distinção clara das janelas dos edifícios, telhados e veículos.




FIGURA 3.5: Exemplo de dados Bosch com a escala de cor associada à distância ao veículo de captação dos dados.




FIGURA 3.6: Exemplo de dados Bosch com a escala de cor associada à intensidade dos pontos.




FIGURA 3.7: Canto inferior esquerdo da imagem 3.6 ampliado.

3.3 Criação das Situações de Estudo

O conjunto de dados disponível tem um tamanho considerável. Analisar 27000 cenas de trânsito pode ser computacionalmente exigente. Por outro lado, nem todas as situações são interessantes para análise dos algoritmos de segmentação ou dos índices de validação interna. Analisar objetos que estejam bastante separados torna a tarefa de segmentação fácil e não comparamos verdadeiramente os algoritmos. Por esta razão decidiu-se isolar com apenas 2 e 3 objetos que fossem propícias a que os algoritmos tivessem um desempenho pior. Isto é, situações em que os objetos cruzam ou estão muito perto uns dos outros. Selecionaram-se assim 41 situações de conflito.




FIGURA 3.8: Imagem exemplo de dois pedestres retirada do cenário 65, cena 121, do H3D.

Na tabela 3.2, enumeram-se todas as situações de estudo usadas, que objetos as compõem e de que base de dados foram retiradas.

Com cerca de 34 situações retiradas da base de dados *Bosch* e 7 retiradas da base de dados *H3D*. O objetivo foi selecionar várias situações protagonizadas pelos diversos intervenientes de trânsito. Destas situações, 22 são protagonizadas apenas por veículos ligeiros de quatro rodas, 1 por veículos motorizados de duas rodas, 10 por pedestres, e 8 situações protagonizadas por diversos tipos de intervenientes, sejam pedestres ou veículos.

Sit.	Dataset	Cenário	Cena	Combinação Objeto				
				Obj	Obj	Obj	Classe	Nº
1	Bosch	20220826142754	1661517313505267000	5	17	20	Carro	3
2	Bosch	20220826142754	1661517313505267000	5	17	-	Carro	2
3	Bosch	20220826142754	1661517313505267000	5	20	-	Carro	2
4	Bosch	20220826142754	1661517313505267000	3	12	-	Mota	2
5	Bosch	20220826142754	1661517313505267000	4	13	-	Carro	2
6	Bosch	20220826145328	1661518726160804000	8	5	-	Carro	2
7	Bosch	20220902194411	1662140868114057000	3	6	8	Mix	3
8	Bosch	20220902194411	1662140868114057000	3	8	-	Mix	2
9	Bosch	20220902194411	1662140868114057000	6	8	-	Mix	2
10	Bosch	20220902194411	1662141008164047000	1	2	5	Carro	3
11	Bosch	20220902194411	1662141008164047000	1	2	-	Carro	2
12	Bosch	20220902194411	1662141008164047000	1	5	-	Carro	2
13	Bosch	20220902194411	1662141008164047000	2	4	-	Carro	2
14	Bosch	20220902194411	1662141008164047000	1	2	4	Carro	3
15	Bosch	20220902194411	1662141153093336000	7	11	-	Carro	2
16	Bosch	20220902194411	1662141153093336000	3	9	-	Mix	2
17	Bosch	20220902194411	1662141153093336000	4	10	-	Carro	2
18	Bosch	20220831124559	1661942796673016000	6	12	-	Peão	2
19	Bosch	20220831124559	1661942796673016000	3	27	-	Peão	2
20	Bosch	20220831124559	1661942796673016000	5	9	-	Peão	2
21	Bosch	20220826143950	1661517751058221000	3	14	-	Carro	2
22	Bosch	20220826143950	1661517976688225000	10	11	-	Carro	2
23	Bosch	20220826143950	1661517751058221000	3	4	-	Carro	2
24	Bosch	20220826143950	1661517976688225000	8	16	-	Mix	2
25	Bosch	20220826143950	1661517976688225000	9	18	-	Carro	2
26	Bosch	20220826143950	1661517976688225000	4	18	-	Carro	2
27	Bosch	20220826143950	1661517976688225000	8	13	-	Carro	2
28	Bosch	20220826143950	1661518001469351000	7	13	-	Carro	2
29	Bosch	20220826143950	1661518041479844000	2	4	-	Mix	2
30	Bosch	20220826143950	1661518041479844000	2	23	-	Mix	2
31	Bosch	20220826143950	1661518041479844000	19	22	-	Carro	2
32	Bosch	20220826143950	1661518041479844000	19	22	25	Carro	3
33	Bosch	20220826143950	1661518041479844000	16	24	-	Mix	2
34	Bosch	20220826143950	1661518041479844000	6	13	-	Carro	2
35	H3D	080	174	031	042	-	Peão	2
36	H3D	081	128	007	020	-	Peão	2
37	H3D	076	125	001	007	-	Peão	2
38	H3D	227	131	034	040	-	Peão	2
39	H3D	170	181	012	013	-	Peão	2
40	H3D	080	003	005	013	-	Peão	2
41	H3D	065	121	013	014	-	Peão	2

TABELA 3.2: Objetos selecionados para as situações de estudo.

4 - Análise de Dados LiDAR de Objetos

4.1 Segmentação dos objetos

Usando as técnicas apresentadas na secção 3.2.2, procedeu-se à segmentação dos objetos para estudo das suas formas. Extraíram-se assim da base de dados H3D, 1129807 objetos, distribuídos pelas seguintes classes:

Classe	Número de Objetos	Número médio de pontos por objeto
Animais	1206	132,62
Motociclos	1897	542,58
Bicicletas	11678	640,94
Autocarros	12696	4462,66
Outros veículos	30340	903,9
Camiões	97684	1495,91
Pedestres	458024	277,54
Automóveis	516282	963,44
Total	1129807	-

TABELA 4.1: Número de objetos e pontos por classes.

Analisando brevemente a tabela, verifica-se que as classes com maior amostra de dados serão os Automóveis e os Pedestres, fator que poderá ter influência nos algoritmos de identificação que se seguem, uma vez que estas classes juntas representam cerca de 85% dos dados. Algo que também poderá ter impacto é o número médio de pontos por objeto. As classes Camiões e Autocarros apresentam um número médio de pontos por

objeto com uma grandeza maior que as restantes classes.

4.2 Métricas

Para o estudo das formas dos objetos usaremos as seguintes variáveis:

- Largura - *Width*
- Comprimento - *Length*
- Altura - *Height*
- Número de Pontos no Objeto - *NPoints*
- Número de Pontos no Interior do Objeto - *NPercentage*

Para esta variável, *NPercentage*, recorre-se a uma Caixa Delimitadora, ou em inglês, *Bounding Box* de proporções iguais à de cada objeto com o mesmo centro que a original porém com 80% do tamanho da *Bounding Box* anterior, como pode ser vista na figura 4.1. Esta variável tem como objetivo estudar se há diferença entre classes na discrepância entre os pontos exteriores e interiores da *Bounding Box*.




FIGURA 4.1: Exemplo da *Bounding Box* usada para a variável *NPercentage*.

- Área - *Area*
- Altura pela Área - *Height by Area*
- Volume

- Número de total pontos a dividir pelo número de pontos no interior do objeto - $NbyNPercentage$
- Distância média de cada ponto aos 5 vizinhos mais próximos - D5 (Ver sub-capítulo 2.3)¹
- Distância média de cada ponto aos 10 vizinhos mais próximos - D10 (Ver sub-capítulo 2.3)¹
- Distância ao Emissor na coordenada X - CenterX
- Distância ao Emissor na coordenada Y - CenterY
- Distância ao Emissor na coordenada Z - CenterZ
- Distância ao Emissor - DistanceToEgo

¹ As variáveis D5 e D10, devido ao seu elevado tempo computacional não foram calculadas para as classes Autocarros, Outros veículos, Camiões e Automóveis.

Podem ser observadas as médias das variáveis usadas em cada classe na tabela 4.2:

Classe	Largura - <i>m</i>	Comp - <i>m</i> .	Altura - <i>m</i>	NPercentage	D5 - <i>m</i>	D10 - <i>m</i>	Área - <i>m</i> ²	Volume - <i>m</i> ³
Animais	0,47	1,09	0,68	78,67	0,01	0,02	0,51	0,35
Motociclos	0,93	2,26	1,77	346,01	0,02	0,05	2,10	3,72
Bicicletas	0,86	1,97	1,86	342,39	0,21	0,05	1,69	3,14
Autocarros	3,25	12,77	3,55	2569,33	-	-	41,61	147,75
Outros veic.	1,67	5,27	2,12	518,28	-	-	9,78	18,57
Camiões	2,62	6,66	2,53	1010,22	-	-	17,46	44,13
Pedestres	0,72	0,78	1,78	146,80	0,01	0,03	0,57	1,01
Automóveis	2,14	4,74	1,78	628,94	-	-	10,15	18,11

TABELA 4.2: Média das variáveis usadas por classes.

Analisando brevemente a tabela nota-se imediatamente existir uma grande diferença entre as Áreas e Volumes de dois grupos de veículos. Autocarros, Outros Veículos, Camiões e Automóveis, têm claramente um leque de valores muito mais alto de Área e Volume, respetivamente [9,78;41,61] e [18,11;147,75] que os objetos considerados mais pequenos, nomeadamente Animais, Motociclos, Bicicletas e Pedestres cujas médias de Área e Volume estão compreendidas entre [0,51;2,10] e [0,35;3,72] respetivamente. Algo também já identificado na primeira análise, as classes Autocarros e Camiões continuam a destacar-se na variável NPercentage.

De seguida analisar-se-ão algumas das variáveis mais promissoras com vista a distinguir as classes.

4.2.1 Variáveis de Forma

Decidimos dividir o estudo das métricas em dois grupos, variáveis de forma e variáveis pontuais. As primeiras, que dizem respeito à forma do objeto, ao seu tamanho, área, volume assim como a relação entre estas variáveis, apresentadas nesta secção.

4.2.1.1 Altura

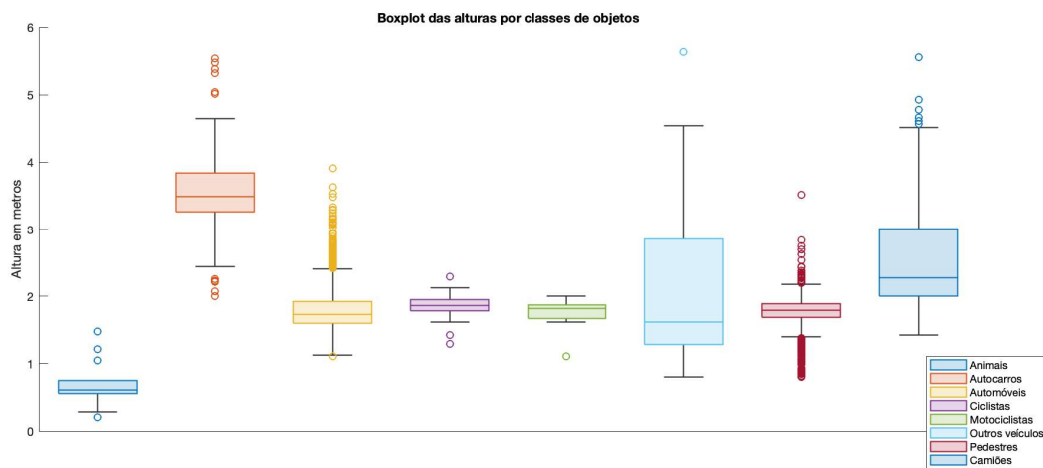


FIGURA 4.2: Boxplot da variável Altura relativa a cada classe.

Na figura 4.2 são apresentados o diagramas de caixa (*boxplot*) da variável altura para as 8 classes de objetos. Pela observação da variável altura conseguem destacar-se 3 situações. Em primeiro lugar, a classe Animais, tem uma distribuição da altura significativamente mais baixa que as restantes classes. Por outro lado, a classe Autocarros, tem uma distribuição da altura claramente mais alta que as demais. No entanto, as restantes classes estão equilibradas. Nessa medida, esta métrica poderá constituir um fator de diferenciação destas duas classes para as restantes.

4.2.1.2 Área

Nas figuras 4.3 e 4.4 apresenta-se os *boxplots* da variável área. Apesar de se estar perante uma variável que tem como componente a variável usada no subcapítulo anterior, esta já apresenta alguma diferença entre outras classes. Inicialmente continuava-se com um isolamento entre a classe Autocarros e as restantes. No entanto, as classes correspondentes




FIGURA 4.3: Boxplot da variável Área relativa a cada classe.

a veículos de quatro rodas claramente se destacam das demais, tendo as restantes valores muito próximos de 1. É de referir também que, ao contrário da figura 4.2, a classe Outros Veículos, apresenta um intervalo de valores muito superior a qualquer outra classe estudada. Devido à grande diferença da distribuição dos valores entre as classes "Autocarro", "Carro", "Outros" e "Camiões" para as mais pequenas, nomeadamente "Pedestres", "Ciclistas", "Motociclistas" e "Animais", decidiu-se isolar as classes mais pequenas por forma a perceber se existem grandes diferenças entre elas.

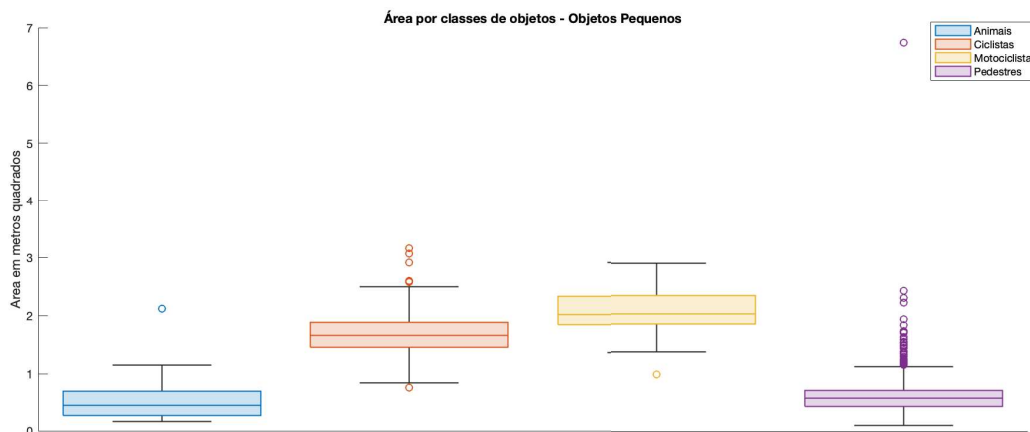


FIGURA 4.4: Boxplots da variável Área das classes Pequenas.

Como se pode constatar na figura 4.4, correspondente ao boxplot da área das classes mais pequenas, as classes "Motociclistas" e "Ciclistas" apresentam uma distribuição bastante semelhante, algo que porventura já acontecia na métrica altura vista no subcapítulo anterior. Devido também à forma destes veículos faria sentido no futuro considerar esta classe como uma só.

4.2.1.3 Altura pela Área

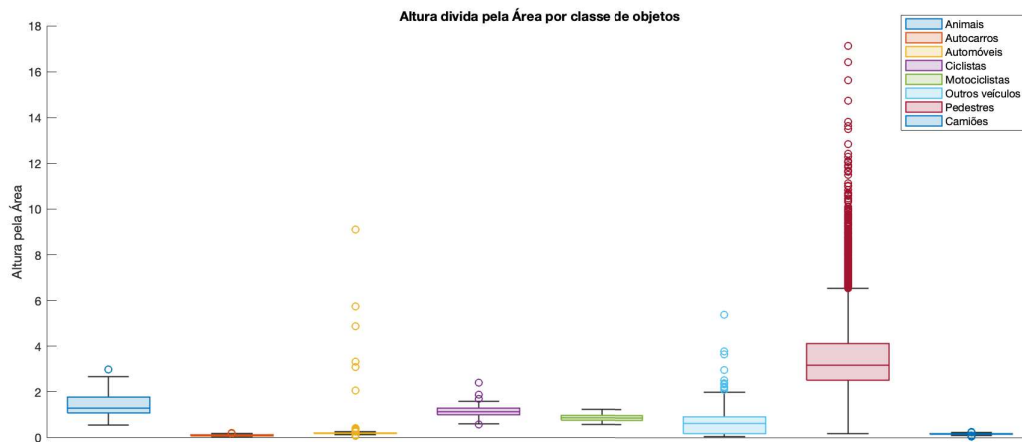


FIGURA 4.5: Boxplot da variável área dividida pela altura relativa a cada classe.

Na figura 4.5 pode observar-se os diagramas de caixa da variável *Altura pela Área*. Apesar de inicialmente os valores de *Altura* e *Área* da classe "Pedestres", figuras 4.2 e 4.3, individualmente não apresentarem grande distinção em relação às restantes classes, a métrica *Altura pela Área* revela um isolamento claro da classe "Pedestres" em relação às demais. Os valores de altura dos pedestres não diferem muito dos valores de um automóvel, como se pode ver na tabela 4.2. No entanto, a área que ocupa é substancialmente inferior à ocupada pelos restantes veículos. Apesar desta classe ser a que claramente mais se distingue, as classes que na variável *Área* apresentavam valores perto de 0, agora aproximam-se de 2, ao contrário das classes como "Autocarro", "Automóvel" e "Camião", que se aproximaram de 0. Já a classe "Outros Veículos" continua a apresentar valores bastante variados. Ainda quanto ao mesmo tópico, para entender melhor a relação entre estas duas variáveis, e se perceber se haverá maior distinção entre as classes, decidiu visualizar-se o gráfico de dispersão da *Altura* pelo logaritmo da *Área*, figura 4.6. Foi utilizado o logaritmo da área uma vez que diminui o intervalo máximo entre o objeto com a área mínima e o que contém a área máxima.

Numa primeira observação é possível identificar uma clara separação entre dois grupos. O grupo maioritariamente composto por objetos mais pequenos, tais como "Pedestres", "Motociclos", "Ciclistas" e "Animais" concentra-se mais à esquerda, enquanto que o grupo maioritariamente composto por objetos de maiores dimensões compreende-se mais à direita. No entanto, é visível no gráfico 4.6 a classe *Outros* a ocupar um intervalo

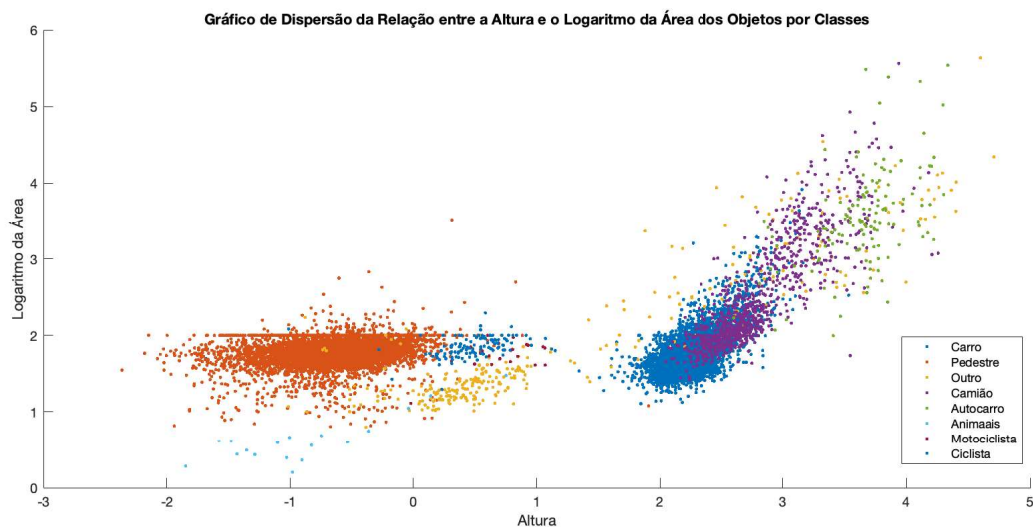


FIGURA 4.6: Gráfico de Dispersão da Altura pelo Logaritmo da Área, por classes.

de valores quase abrangendo todo o gráfico. Na figura 4.7, são apresentadas apenas as classes "Outros Veículos", "Pequenos" e "Grandes".

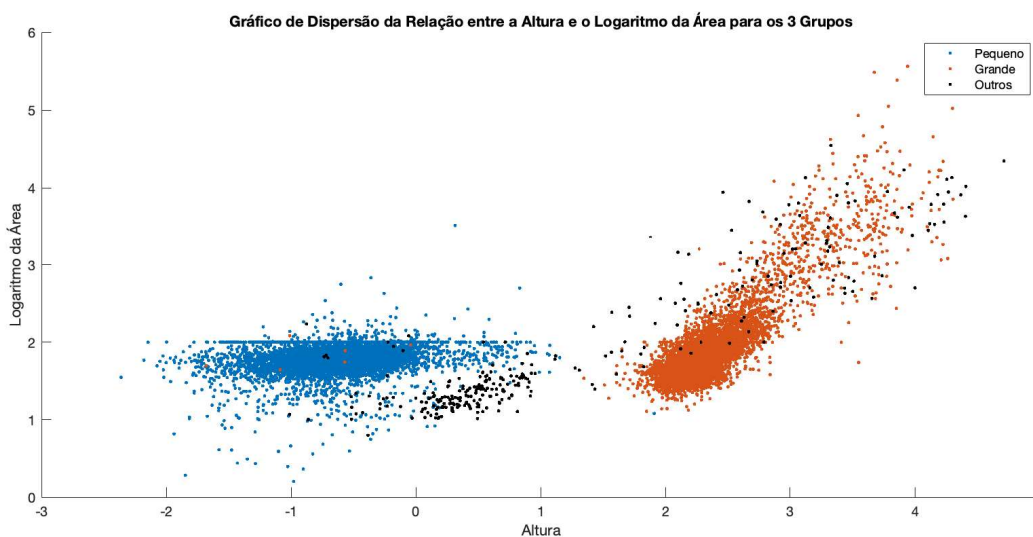


FIGURA 4.7: Gráfico de Dispersão da Altura pelo Logaritmo da Área, por Grupos.

É possível observar com maior nitidez que na figura 4.6, a classe "Outros Veículos", ao contrário dos restantes grupos, que ocupam um espaço do plano distinto, apresenta uma maior dispersão por todo o gráfico. Terão de ser analisados alguns objetos desta classe para perceber de que se tratam e de que forma estão inseridos na nuvem de pontos. Já os grupos de objetos "Pequenos" e "Grandes" apresentam uma clara separação, fator que pode vir a ser útil na tarefa de identificação de classes através destas variáveis.

Será interessante observar que tipo de objetos podemos encontrar na classe "Outros Veículos" e que possam causar toda esta dispersão. Retirou-se dois exemplos do cenário "075",

da base de dados H3D com vista a demonstrar a variedade de objetos que estão inseridos nesta classe. Na imagem 4.8, está representada uma máquina de construção, nomeadamente uma empilhadora. Já na imagem 4.9 é possível observar uma escavadora. Ora abrangendo a classe "Outros veículos" os veículos de construção, justifica a dispersão nos dados observados.




FIGURA 4.8: Exemplo de objeto da classe 'Outros veículos' - Empilhadora.



FIGURA 4.9: Exemplo de objeto da classe 'Outros veículos' - Escavadora.

4.2.1.4 Volume

Presente na figura 4.10, serão analisados os diagramas de caixa correspondentes à variável Volume relativa a cada classe.

Em primeira análise, e comparando com a Área, figura 4.3, verifica-se que os gráficos são bastante similares. Era de esperar que as classes relacionadas com os veículos de 4 rodas tivessem um maior volume que as restantes, e é precisamente isso que é demonstrável neste gráfico. No entanto, na classe "Outros", é possível detetar mais *outliers* que na figura 4.3.



FIGURA 4.10: Boxplot da variável Volume relativa a cada classe.

4.2.2 Variáveis Pontuais

Até este momento todas as métricas usadas foram baseadas na forma das *Bounding Boxes* dos objetos, tais como a largura, comprimento e altura. No entanto, devido a ser uma nuvem de pontos podem ser utilizadas métricas que contem ou comparem o número de pontos que cada objeto tem, ou mesmo a distância entre os pontos de cada objeto.

4.2.2.1 Número de Pontos e Número de Pontos Interiores do Objeto

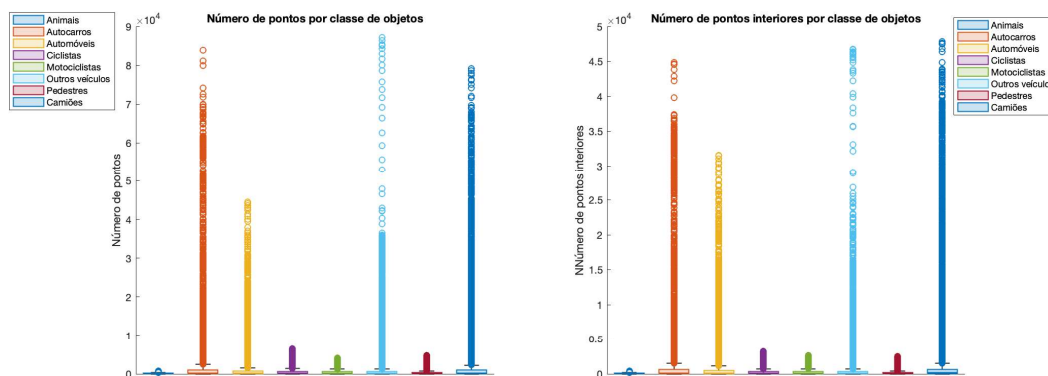


FIGURA 4.11: Boxplots das métricas pontos por objeto e pontos interiores por objeto.

Ir-se-á analisar a variável Número de Pontos e e Número de Pontos Interiores do Objeto na figura 4.11. Apesar de se ter visto que a média do número de pontos presentes em cada objeto e no seu interior poder ser um fator diferenciador entre as classes, analisando a figura 4.11, os boxplots destas classes apresentam demasiados *outliers*. Examinando brevemente a distribuição do logaritmo do número de pontos por objeto em cada classe, figura 4.12, não é possível observar grandes distinções entre classes. Todas

apresentam um elevado número de *outliers*, porém as classes "Animais", "Ciclistas", "Motociclistas" e "Pedestres" aparentam apresentar um número de pontos muito inferior às restantes. Conclui-se portanto que não será um bom fator de distinção usar estas métricas futuramente.




FIGURA 4.12: Histograma da distribuição do logaritmo do número de pontos por objeto de cada classe.

A título de exemplo, retirou-se, da base de dados H3D, a imagem de dois veículos, figura 4.13, um presente no cenário 101, cena 010, Carro 1, e outro do cenário 136, cena 017, Carro 2.




FIGURA 4.13: Comparação entre dois veículos retirados da base de dados H3D, à esquerda Carro 1, e à direita Carro2.

A forma destes dois veículos é semelhante. Ambos os carros apresentam cerca de 4.20 metros de comprimento e 1.90 metros de largura, variando apenas a altura que no Carro

1 é de 0.87 metros e no Carro 2 de 1.51 metros. No entanto, a sua distância ao veículo de captação dos dados varia de 12 metros para o Carro 1, para 5 metros para o Carro 2. Ora o número de pontos da nuvem dos dois veículos em questão é de 624 e 3372, respetivamente para o Carro 1 e Carro 2. Este ponto levanta uma questão, como será que evolui o número de pontos de um objeto com a distância ao Ego-Vehicle?

4.2.2.2 Relação entre a Distância e o Número de Pontos

Por forma a analisar esta questão colocada no final do subcapítulo anterior, decidiu-se colocar os valores de Número de Pontos por Objeto e a sua distância ao EGO-Vehicle num gráfico de dispersão, como pode ser visto na figura 4.14:




FIGURA 4.14: Gráfico de dispersão do número de pontos por objetos pela sua distância ao EGO-Vehicle.

Numa primeira análise nota-se que os pontos estão organizados numa curva aparentemente exponencial. É visível também não existirem pontos no canto superior direito do gráfico, indicando claramente a falta de objetos com um elevado número de pontos e simultaneamente longe do sensor. Decidiu-se visualizar também o gráfico de dispersão relativo ao logaritmo do número de pontos por objeto e o logaritmo da sua distância ao EGO-Vehicle, figura 4.15, para tentar entender melhor a sua dispersão, uma vez que o gráfico 4.14 sugeria uma relação de potências.

Como se pode observar na figura 4.15, os pontos do gráfico de dispersão, apesar de algo dispersos aparentam apresentar-se em cima de uma linha, respetiva a cada classe, a figura 4.16, apresenta os mesmos dados que a figura 4.15 no entanto separaram-se os mesmos por classes, com vista à melhor perceção dos mesmos.

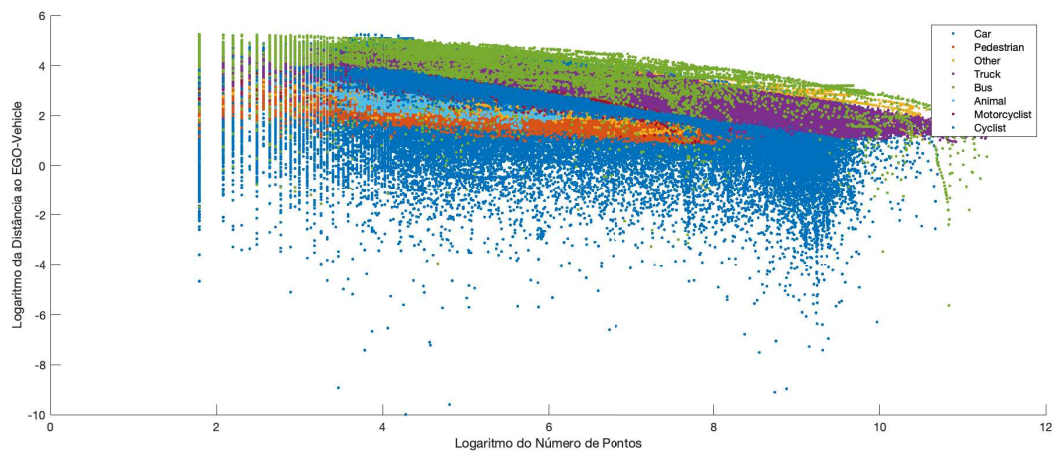


FIGURA 4.15: Gráfico de dispersão do logaritmo do número de pontos por objetos pelo logaritmo da sua distância ao EGO-Vehicle.

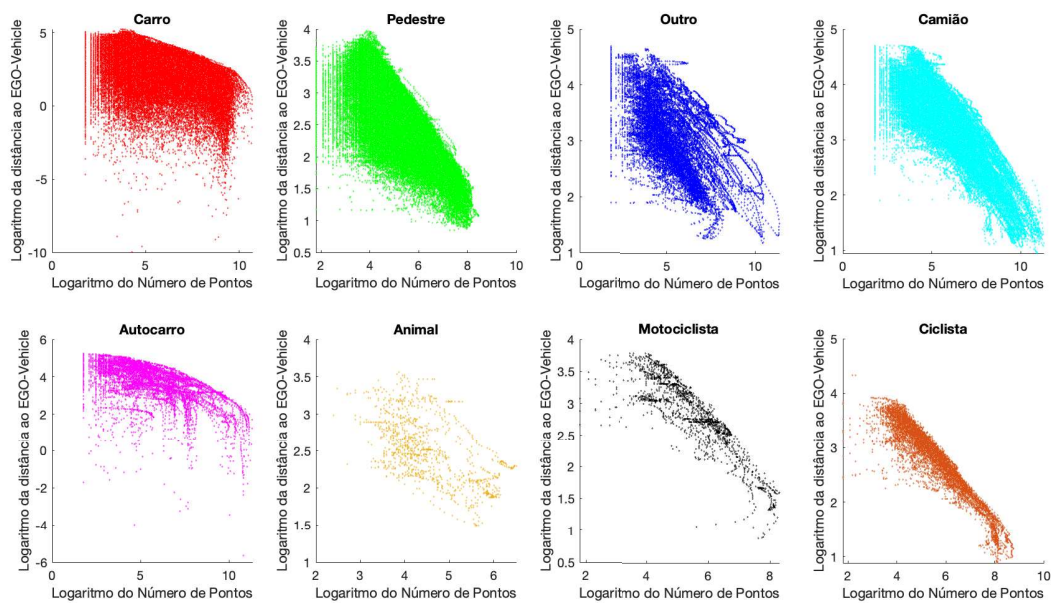


FIGURA 4.16: Gráfico de dispersão do logaritmo do número de pontos por objetos pelo logaritmo da sua distância ao EGO-Vehicle, por Classes.

Devido a notar-se alguma diferença na dispersão dos dados das classes "Outros Veículos" e "Animais" relativamente às restantes, decidiu-se portanto isolar cada uma das classes e modelar através da Relação de Potências. O objetivo será adequar uma reta da forma:

$$y = \beta \cdot x^\alpha \quad (4.1)$$

Em que se tentará prever a Distância ao EGO-Vehicle (y) através do Número de Pontos do Objeto (x). Foi usada a aplicação *fitmodel* do software *Matlab* para encontrar os coeficientes α e β necessários para o cálculo das curvas [50].

Grupo	Classe	α	β
Grande	Carro	-0,3127	4,960
Grande	Camião	-0,3019	5,026
Grande	Autocarro	-0,3127	5,500
Pequeno	Pedestre	-0,4263	4,924
Pequeno	Motociclos	-0,4234	5,135
Pequeno	Ciclistas	-0,4793	5,461
Disperso	Outro	-0,2408	4,345
Disperso	Animais	-0,2925	3,835

Decidiu-se organizar a tabela por grupos. Devido à dispersão apresentada nos gráficos anteriores, nomeadamente das Classes "Outro" e "Animais" optou-se por agrupá-las. As restantes classes foram agrupadas por "Grande" e "Pequeno". É interessante observar que o coeficiente α parece ter uma clara distinção entre estes grupos de objetos, sendo que o Grupo "Grande" está compreendido entre $[-0,30; -0,32]$, enquanto o Grupo "Pequeno" se situa no intervalo $[-0,42; -0,48]$. Na figura 4.17, apresentam-se os gráficos de dispersão relativos a cada uma das classes, assim como as curvas resultantes do modelo usado.

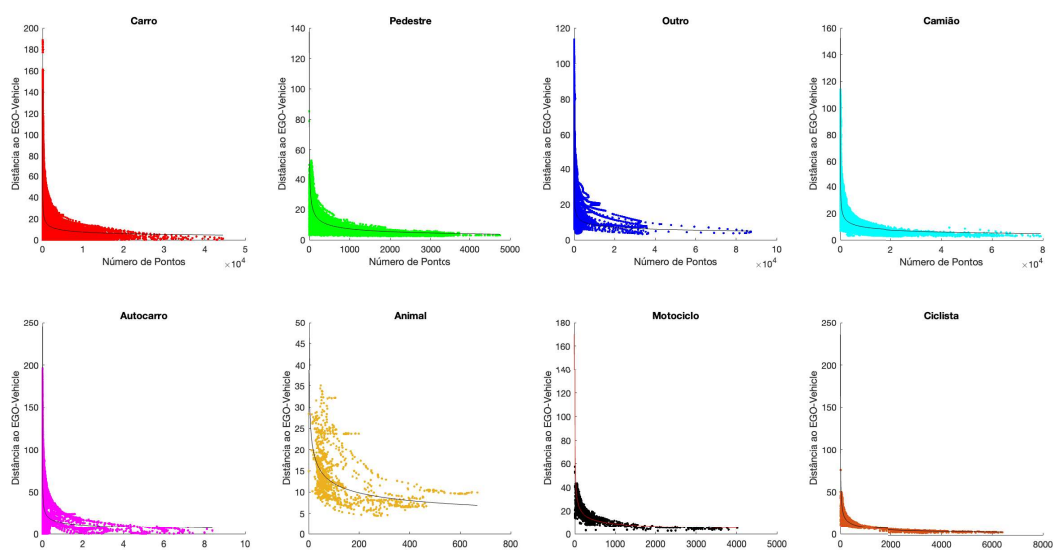


FIGURA 4.17: Gráfico de dispersão do Número de Pontos por objetos pela sua Distância ao EGO-Vehicle, por classes com a sua curva de adaptação.

Pode concluir-se assim que a relação entre o número de pontos de um objeto e a sua distância ao EGO-Vehicle segue uma relação de potências. Os piores resultados aparentam ser os das Classes "Outro" e "Animais", possivelmente devido a terem uma grande diversidade de formas.

4.2.2.3 Distância média aos pontos vizinhos mais próximos

Como foi referido, face à elevada complexidade computacional, apenas foi possível calcular estas métricas para o grupo de classes mais pequenas. Apresenta-se na figura 4.18 os *boxplots* correspondentes às métricas D5 e D10 para as classes Pedestres, Animais, Ciclistas e Motociclistas.

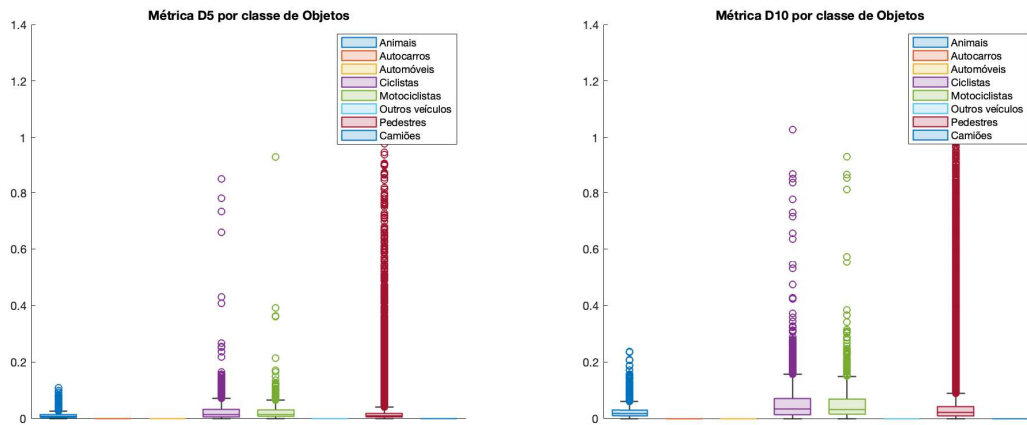


FIGURA 4.18: Boxplots das métricas de densidade D5 e D10 das classes Pedestre, Animais, Ciclistas e Motociclistas.

Como se pode observar, o número de *outliers* da classe com mais objetos, Pedestres, é enorme, o que mais uma vez prova que estas métricas de densidade podem não contribuir para a distinção entre classes.

4.3 Classificação de Objetos

Nesta secção dar-se-á uso às métricas estudadas neste capítulo para classificar os objetos. Começar-se-á pelos casos mais simples, devido a se ter detetado uma grande diferença no gráfico de dispersão da área com a altura, entre os grupos "Pequenos", "Grandes" e "Outros". Proceder-se-á então à divisão dos objetos em 70% treino, 30% teste e, por sua vez, à primeira tentativa do primeiro modelo. Para este efeito usou-se a função *fitctree* do software *Matlab* [50]. Esta função cria uma árvore de classificação binária.

Na figura 4.19, apesar de ser uma primeira tentativa os resultados revelaram-se bastante promissores. Foram usadas neste modelo todas as variáveis enumeradas na secção anterior, exceto as variáveis de distância ao *EGO-Vehicle*, uma vez que estas não fazem sentido no contexto do problema pois a posição do objeto em relação ao veículo não contribui

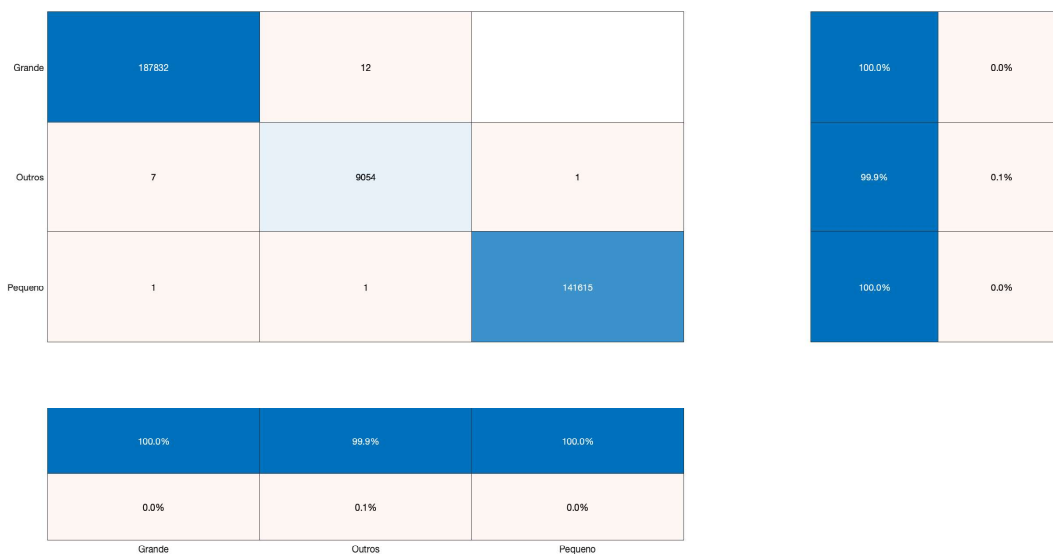


FIGURA 4.19: Resultados da primeira tentativa de modelo de separação em 3 grupos.

para a sua classificação. No entanto, como foi discutido, existiam várias variáveis que podem não ser tão diferenciadoras como outras. Foram vistos exemplos como a NPoints, NPercentage e NbyNPercentage. Serão portanto retiradas essas variáveis e novamente analisado o modelo, os resultados podem ser observados na figura 4.20.

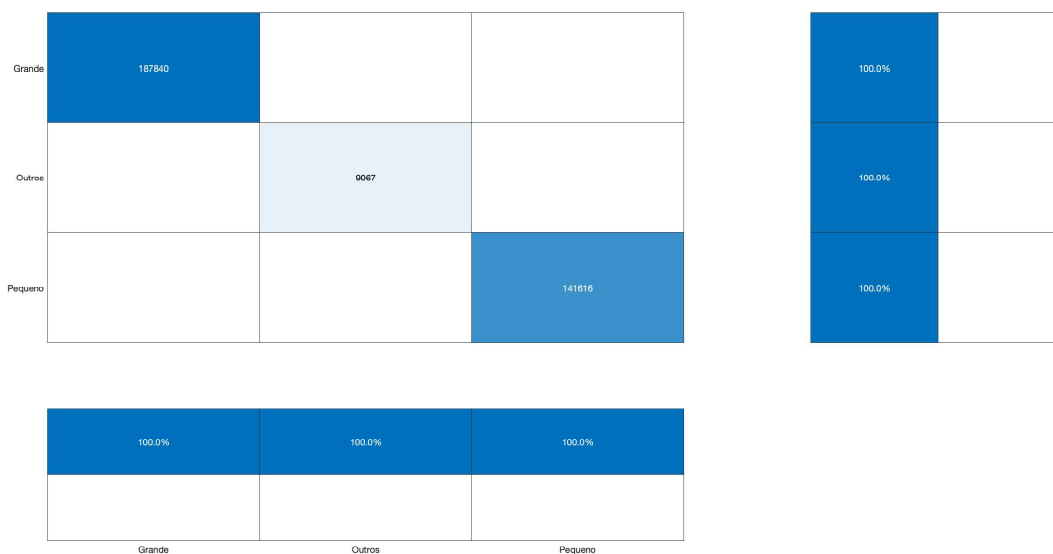


FIGURA 4.20: Resultados da segunda tentativa de modelo de separação em 3 grupos, sem as métricas pontuais nem distância ao *Ego-Vehicle*.

Como era expectável, estas variáveis baseadas em métricas pontuais, acabam por penalizar o modelo. Retirando-lhe variáveis acaba por se dar maior ênfase àquelas que realmente atingem uma maior distinção entre as classes. Também é curioso que, apesar do grupo "Outros" ter uma distribuição ao longo de todo o plano, como foi visto no gráfico da figura 4.7, ainda assim a árvore de decisão consegue resultados muito satisfatórios nesta



FIGURA 4.22: Resultados da primeira tentativa de modelo de separação entre todas as classes e sem métricas pontuais.

5 - Resultados

Neste capítulo, serão apresentados e analisados os resultados obtidos da análise dos algoritmos de segmentação e, por sua vez, dos índices de validação interna. Inicialmente é analisado o desempenho dos algoritmos e o resultado dos índices de validação interna para cada algoritmo. Para servir de comparação a primeira linha das tabelas consiste na melhor classificação possível do respectivo índice de validação, enquanto que a segunda linha será o desempenho do "Ground Truth". Posteriormente é analisada de que forma a intensidade impacta na tarefa de segmentação. São usados dois métodos distintos nesta segunda parte. Num primeiro momento trata-se a "Intensidade" como uma quarta variável. Assim cada ponto passa de 3 dimensões (x, y, z) para 4, (x, y, z, i) em que i é a intensidade. Numa segunda análise estuda-se algumas situações criando um *threshold* nos valores da intensidade.

É importante clarificar que são apenas apresentados alguns resultados. No entanto todas as tabelas usadas para a análise são disponibilizadas em anexo.

5.1 Análise dos algoritmos

Por forma a analisar os algoritmos de segmentação, tem de se comparar o resultado dos índices de cada segmentação, não no seu valor ideal, mas sim ao valor que o índice atribui ao *Ground Truth*. Desta forma, conseguem destacar-se situações em que claramente o índice favorece um algoritmo em particular. Procedeu-se da seguinte maneira: após a segmentação de cada algoritmo procedeu-se à avaliação dos índices. Fixou-se o valor que o índice atribui à referência *Ground Truth*. Posteriormente é atribuída uma classificação a

cada algoritmo consoante a sua proximidade ao valor obtido pelo *Ground Truth*. A tabela 5.1 apresenta um exemplo desta classificação.

CI/CVI	Silhouette	Classificação
Objective	1	-
GT	0,8966	0
DBSCAN	0,8966	1
K-Means	0,7951	3
Spectral	0,7855	4
Hier-S	0,6433	5
Hier-M	0,8687	2

TABELA 5.1: Exemplo de classificação dos algoritmos através do valor de *Ground Truth*.

O procedimento é repetido para todos os índices. No final soma-se a classificação de todas as situações, de todos os algoritmos e divide-se pelo valor máximo possível de ser atingido por forma a normalizar o índice, 1845, que é o número máximo na classificação, 5, multiplicado pelo número de índices que temos, e pelo número de situações que temos, 41. O algoritmo que tiver o valor mais baixo será aquele que melhor se aproxima do *GroundTruth*. A tabela 5.2 apresenta resultados da classificação dos índices.

Algoritmo	Resultado	Normalização
DBSCAN	553	0,300
K-Means	993	0,538
Spectral	1121	0,608
Hier-S	698	0,378
Hier-M	674	0,365

TABELA 5.2: Resultados da análise aos algoritmos em comparação com o *Ground Truth*.

Pode constatar-se ser o desempenho do DBSCAN, 0,300, o melhor entre os algoritmos de segmentação testados. Sendo um algoritmo que ao invés de usar distâncias ao centro ou distâncias entre partições e foca apenas na densidade das partições, conclui-se ser o algoritmo que melhor se adapta a estes dados. Em segundo lugar temos os algoritmos de agrupamento hierárquico com ligação mediana e mínima, com 0,365 e 0,378 respetivamente.

5.2 Análise dos índices

Procedeu-se em seguida a uma análise inversa. Em 5.1, foram comparados os algoritmos de segmentação através do valor dos índices, classificados por ordem de proximidade ao *Ground Truth* e comparado o resultado no final. Concluiu-se que 3 algoritmos, DBSCAN,

agrupamento hierárquico com ligação mínima e Mediana se destacam claramente entre os 5 testados.

No entanto, por forma a se poder analisar os índices, tem de se comparar a classificação atribuída por um índice ao *Ground Truth* com a classificação atribuída a um algoritmo de segmentação aleatório. No final, a distância normalizada entre o valor obtido pelo *Ground Truth* e o algoritmo aleatório é somada, e o índice que revelar um valor mais baixo é o que tem um melhor desempenho. Sumariando, quanto menor for a diferença entre o desempenho de um índice no conjunto de dados e um conjunto aleatório pior será o índice. Apresenta-se na tabela 5.3 um exemplo deste processo:

Dados/CVI	Silhouette
Objective	1
GT	0,897
Aleatório	-0,012
Diferença Normalizada	0,4545

TABELA 5.3: Exemplo de classificação dos Índices através do valor de *Ground Truth*.

Somam-se então os valores da diferença normalizada de cada índice. Aquele que tiver um valor mais alto, ou seja, cujo valor entre o aleatório e o *Ground Truth* for maior é considerado o melhor índice. A normalização foi feita, nos casos em que há um limite definido, como por exemplo *Silhouette*, DBCV e C-Index, pelo máximo do intervalo que estes valores podem assumir. No caso dos índices em que o intervalo está compreendido entre um número e infinito, a normalização é feita pelo máximo entre o valor do *ground truth* ou o atribuído à segmentação aleatória. O total é dividido por 41, sendo 41 o valor máximo que a soma das Diferenças Normalizadas pode assumir. A tabela 5.4 apresenta os atribuídos a cada índice.

CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Resultado	0,429	0,998	0,868	0,451	0,789	0,983	0,984	0,779	0,985

TABELA 5.4: Resultados do estudo dos índices de validação interna.

Como se pode ver, os índices Calinski-Harabaz, DBCV, CS, CVDD e Dunn foram os que obtiveram melhores resultados. Já *Silhouette*, C, COP e Davies-Boudin estão entre os piores índices. Recorde-se que índices como o DBCV e CVDD calculam o desempenho através da densidade das partições e o *Silhouette* calcula as distâncias *intra-cluster* e *inter-cluster*. Já os algoritmos que tiveram o pior desempenho, como COP e Davies-Boudin,

usam métricas como a distância ao ponto mais longínquo das partições e a similaridade entre partições.

5.3 Intensidade como *threshold* dos pontos

Nesta secção analisa-se de que forma é que, aplicando um *threshold* aos valores de intensidade, influencia os resultados da segmentação. Foram selecionados dois valores de mínimo e dois valores de máximo e alternadamente calculados os pontos compreendidos nesses intervalos. Assim, os pontos pertencentes ao grupo 1 são aqueles que estão abaixo do valor mínimo escolhido. Os do grupo 2 serão aqueles cujos valores de intensidade estão entre o mínimo e o máximo, e finalmente o grupo 3 contém os pontos com valores acima do máximo. É analisada a performance destes grupos usando apenas os índices que melhor desempenho tiveram na secção 5.2, nomeadamente, Calinski-Harabaz, DBCV, CS, CVDD e Dunn. A tabela 5.3 apresenta a média dos resultados dos índices nos grupos admitidos pelo *threshold*.

Min	Max	Grupo 1	Grupo 2	Grupo 3	CH-Index	DBCV	CS-Index	CVDD	Dunn
0,04	0,1	1	0	0	1690	0,8776	0,4739	187	0,5752
0,04	0,1	0	1	0	3843	0,9235	0,5223	959	0,3893
0,04	0,1	0	0	1	5728	0,9757	0,492	3985	0,3709
0,04	0,1	1	1	0	5258	0,9244	0,5353	1914	0,3799
0,04	0,1	1	0	1	7412	0,9431	0,5114	4122	0,3634
0,04	0,1	0	1	1	9452	0,9274	0,5182	11303	0,3708
0,04	0,15	1	0	0	1690	0,8776	0,4739	187	0,5752
0,04	0,15	0	1	0	6513	0,9392	0,5156	4666	0,3893
0,04	0,15	0	0	1	3458	0,8296	0,4978	317	0,3805
0,04	0,15	1	1	0	7958	0,9361	0,5283	6746	0,3799
0,04	0,15	1	0	1	5138	0,8847	0,5305	753	0,3634
0,04	0,15	0	1	1	9452	0,9274	0,5182	11303	0,3708
0,06	0,1	1	0	0	3878	0,9393	0,4896	1009	0,4167
0,06	0,1	0	1	0	1855	0,9106	0,5024	290	0,3956
0,06	0,1	0	0	1	5728	0,9757	0,492	3985	0,3709
0,06	0,1	1	1	0	5258	0,9167	0,5353	1914	0,3799
0,06	0,1	1	0	1	9574	0,9112	0,5251	5566	0,3634
0,06	0,1	0	1	1	7342	0,8773	0,5043	7118	0,3709
0,06	0,15	1	0	0	3878	0,9393	0,4896	1009	0,4167
0,06	0,15	0	1	0	4489	0,9299	0,498	2436	0,3942
0,06	0,15	0	0	1	3458	0,8296	0,4978	317	0,3805
0,06	0,15	1	1	0	7958	0,9296	0,5283	6746	0,3799
0,06	0,15	1	0	1	7206	0,8371	0,5454	1498	0,3634
0,06	0,15	0	1	1	7342	0,8773	0,5043	7118	0,3709
0,06	0,15	1	1	1	10984	0,9227	0,5288	12462	0,362

TABELA 5.5: Resultados do estudo da intensidade como *threshold*.

É interessante notar que os valores dos índices, apesar de limitados por um máximo e/ou mínimo se mantêm regulares. Registou-se um máximo no índice DBCV quando o objeto tem os pontos com valores de intensidade acima de 0,1, já os piores valores serão aqueles em que os pontos têm um valor de intensidade acima de 0,15. Já no índice CVDD os melhores valores foram obtidos quando se isolam todos os pontos com intensidade superior a 0,4 e ao mesmo tempo quando estão na mesma presentes todos os pontos dos objetos.

5.4 Intensidade como 4^a variável na segmentação

Foi analisado também que efeito teria a introdução da intensidade como uma quarta variável na segmentação dos objetos. Neste caso, devido à extensão dos dados, calculou-se uma média dos resultados analisados pelos melhores índices de validação interna. Apresentam-se também as médias dos valores obtidos da primeira análise aos algoritmos de segmentação para se ter uma comparação válida. Os resultados podem ser consultados na tabela 5.6.

Algoritmo/CVI	CH-Index	DBCv	CS	CVDD	Dunn
Resultado Sem intensidade	43157,3	0,902	0,401	5427,4	0,789
Resultado Com Intensidade	3485,9	0,8193	0,501	3018,1	0,345

TABELA 5.6: Resultados do estudo da segmentação usando a intensidade como quarta variável.

Apesar de se ter introduzido mais informação nos algoritmos, a intensidade demonstrou ser um fator que piora o desempenho dos mesmos. Esta falha no desempenho deve-se principalmente ao detalhe enunciado em 3.2.3. Os mesmo objetos podem diferir bastante nos valores de intensidade dos seus pontos, variando com a refletividade dos materiais que os compõem. Um exemplo deste efeito pode ser observado na imagem apresentada na figura 3.6, em que se pode distinguir entre vidros e metal de veículos apesar de eles fazerem todos parte do mesmo objeto.

6 - Conclusões e Trabalho Futuro

As bases de dados de nuvens de pontos para condução autónoma estão em constante crescimento. O facto de a identificação e segmentação de objetos para o *ground truth*, com vista a treinar os modelos, ser ainda um processo bastante manual, faz com que esta tarefa seja cada vez mais demorada. A criação de algoritmos de segmentação e índices de validação interna que possam auxiliar nesta tarefa, ainda que, muito superficialmente, poupará tempo que pode ser canalizado para, por exemplo, a análise dos mesmos.

Neste trabalho foram efetuados vários estudos aos objetos gerados por nuvens de pontos LiDAR. Concluiu-se que o número de pontos num objeto varia consoante a sua distância ao *EGO-Vehicle*, e se comporta segundo uma função de potências. Foram analisados tanto os algoritmos de segmentação como os diversos índices de validação interna. O DBSCAN assim como o Agrupamento Hierárquico revelaram ser os melhores algoritmos para a segmentação destes conjuntos de dados. No que concerne aos índices de validação interna, os que apresentaram melhor desempenho foram o Calinski-Harabaz, DBCV, CVDD e Dunn. Quando se analisa a implementação da intensidade na segmentação dos objetos, como 4ª variável, piora o desempenho de quase todos os algoritmos, contribuindo para uma maior dispersão dos pontos. No entanto, utilizar a intensidade como *threshold* (usando apenas os valores mais elevados de intensidade, acima de 0,1 por exemplo) pode ser vantajoso na medida em que diminui a quantidade de pontos e ainda assim se garante uma boa segmentação.

Sugere-se como linha de trabalho futuro aprofundar a relação entre o número de pontos e a distância ao *EGO-Vehicle*, designadamente o estudo de novos algoritmos para a

segmentação, ou a modificação de alguns dos já existentes com o intuito de melhor se adaptarem aos dados disponibilizados. O desenvolvimento de novos índices de validação interna com intuito de classificar a segmentação será, sem dúvida, crucial para a automatização desta tarefa.

Os dados Bosch usados neste trabalho revelaram-se inovadores. O uso da intensidade dos objetos constituiu inequivocamente um fator diferenciador na análise dos mesmos. Esta componente é bastante promissora, podendo ser ainda aprofundada e introduzida nos índices de validação interna ou algoritmos de segmentação.

Bibliografia

- [1] O.-R. A. D. O. Committee, *Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles*, apr 2021. [Online]. Available: https://doi.org/10.4271/J3016_202104 [Cited on pages [xiii](#), [1](#), and [2](#).]
- [2] C. Thorpe, M. Hebert, T. Kanade, and S. Shafer, "Vision and navigation for the carnegie-mellon navlab," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 10, no. 3, pp. 362–373, 1988. [Cited on page [3](#).]
- [3] E. Dickmanns and A. Zapp, "Autonomous high speed road vehicle guidance by computer vision1," *IFAC Proceedings Volumes*, vol. 20, no. 5, Part 4, pp. 221–226, 1987, 10th Triennial IFAC Congress on Automatic Control - 1987 Volume IV, Munich, Germany, 27-31 July. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1474667017553203> [Cited on page [3](#).]
- [4] R. D. Leighty, "Darpa alv (autonomous land vehicle) summary," 1986. [Online]. Available: <https://api.semanticscholar.org/CorpusID:107516053> [Cited on page [3](#).]
- [5] M. Williams, "The prometheus programme," in *IEE Colloquium on Towards Safer Road Transport - Engineering Solutions*, 1992, pp. 4/1–4/3. [Cited on page [3](#).]
- [6] M. Buehler, K. Iagnemma, and S. Singh, *The 2005 DARPA grand challenge: the great robot race*. springer, 2007, vol. 36. [Cited on page [3](#).]
- [7] M. Campbell, M. Egerstedt, J. How, and R. Murray, "Autonomous driving in urban environments: Approaches, lessons and challenges," *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences*, vol. 368, pp. 4649–72, 10 2010. [Cited on page [3](#).]

- [8] J. C. Fernandez Diaz, W. E. Carter, R. L. Shrestha, and C. L. Glennie, *Lidar Remote Sensing*. New York, NY: Springer New York, 2013, pp. 757–808. [Online]. Available: https://doi.org/10.1007/978-1-4419-7671-0_44 [Cited on page 3.]
- [9] R. Behringer, S. Sundareswaran, B. Gregory, R. Elsley, B. Addison, W. Guthmiller, R. Daily, and D. Bevely, “The darpa grand challenge-development of an autonomous vehicle,” in *IEEE Intelligent Vehicles Symposium, 2004*. IEEE, 2004, pp. 226–231. [Cited on page 3.]
- [10] R. Roriz, J. Cabral, and T. Gomes, “Automotive lidar technology: A survey,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 7, pp. 6282–6297, 2022. [Cited on pages [xiii](#) and 5.]
- [11] Z. Ghahramani, *Unsupervised Learning*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004, pp. 72–112. [Online]. Available: https://doi.org/10.1007/978-3-540-28650-9_5 [Cited on page 6.]
- [12] S. Lloyd, “Least squares quantization in pcm,” *IEEE transactions on information theory*, vol. 28, no. 2, pp. 129–137, 1982. [Cited on page 7.]
- [13] J. MacQueen *et al.*, “Some methods for classification and analysis of multivariate observations,” in *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, vol. 1, no. 14. Oakland, CA, USA, 1967, pp. 281–297. [Cited on page 7.]
- [14] X. Jin and J. Han, *K-Means Clustering*. Boston, MA: Springer US, 2017, pp. 695–697. [Online]. Available: https://doi.org/10.1007/978-1-4899-7687-1_431 [Cited on page 7.]
- [15] M. Ester, H.-P. Kriegel, J. Sander, and X. Xu, “A density-based algorithm for discovering clusters in large spatial databases with noise,” in *KDD*, 1996. [Cited on page 7.]
- [16] E. Schubert, J. Sander, M. Ester, H. P. Kriegel, and X. Xu, “Dbscan revisited, revisited: Why and how you should (still) use dbscan,” *ACM Trans. Database Syst.*, vol. 42, no. 3, jul 2017. [Online]. Available: <https://doi.org/10.1145/3068335> [Cited on page 7.]

- [17] F. Nielsen, *Hierarchical Clustering*. Cham: Springer International Publishing, 2016, pp. 195–211. [Online]. Available: https://doi.org/10.1007/978-3-319-21903-5_8 [Cited on page 8.]
- [18] M. Halkidi, *Hierarchical Clustering*. New York, NY: Springer New York, 2018, pp. 1684–1689. [Online]. Available: https://doi.org/10.1007/978-1-4614-8265-9_604 [Cited on pages xiii and 9.]
- [19] J. Bu, W. Liu, Z. Pan, and K. Ling, “Comparative study of hydrochemical classification based on different hierarchical cluster analysis methods,” *International Journal of Environmental Research and Public Health*, vol. 17, no. 24, 2020. [Online]. Available: <https://www.mdpi.com/1660-4601/17/24/9515> [Cited on page 9.]
- [20] U. von Luxburg, “A tutorial on spectral clustering,” *Statistics and Computing*, vol. 17, no. 4, pp. 395–416, 2007. [Online]. Available: <https://doi.org/10.1007/s11222-007-9033-z> [Cited on page 10.]
- [21] C. Sammut and G. I. Webb, Eds., *Classification Tree*. Boston, MA: Springer US, 2010, pp. 171–171. [Online]. Available: https://doi.org/10.1007/978-0-387-30164-8_114 [Cited on page 10.]
- [22] C. Sammut and G. I. Webb, *Encyclopedia of machine learning*. Springer Science & Business Media, 2011. [Cited on pages xiii, 10, and 11.]
- [23] P. J. Rousseeuw, “Silhouettes: A graphical aid to the interpretation and validation of cluster analysis,” *Journal of Computational and Applied Mathematics*, vol. 20, pp. 53–65, 1987. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/0377042787901257> [Cited on page 12.]
- [24] T. Caliński and H. JA, “A dendrite method for cluster analysis,” *Communications in Statistics - Theory and Methods*, vol. 3, pp. 1–27, 01 1974. [Cited on page 12.]
- [25] D. Moulavi, P. Andretta Jaskowiak, R. Campello, A. Zimek, and J. Sander, “Density-based clustering validation,” 04 2014. [Cited on page 13.]
- [26] B. Tavakkol, J. Choi, M. K. Jeong, and S. L. Albin, “Object-based cluster validation with densities,” *Pattern Recognition*, vol. 121, p. 108223, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0031320321004040> [Cited on page 13.]


- [27] J. Davis and M. Goadrich, "The relationship between precision-recall and roc curves," vol. 06, 06 2006. [Cited on page 13.]
- [28] I. Gurrutxaga, I. Albisua, O. Arbelaitz, J. I. Martín, J. Muguerza, J. M. Pérez, and I. Perona, "Sep/cop: An efficient method to find the best partition in hierarchical clustering based on a new cluster validity index," *Pattern Recognition*, vol. 43, no. 10, pp. 3364–3373, 2010. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0031320310001974> [Cited on page 13.]
- [29] O. Arbelaitz, I. Gurrutxaga, J. Muguerza, J. M. Pérez, and I. Perona, "An extensive comparative study of cluster validity indices," *Pattern Recognition*, vol. 46, no. 1, pp. 243–256, 2013. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S003132031200338X> [Cited on page 13.]
- [30] C. H. Chou, M. C. Su, and E. Lai, "A new cluster validity measure and its application to image compression," *Pattern Analysis and Applications*, vol. 7, no. 2, pp. 205–220, 2004. [Online]. Available: <https://doi.org/10.1007/s10044-004-0218-1> [Cited on page 13.]
- [31] L. Hu and C. Zhong, "An internal validity index based on density-involved distance," *IEEE Access*, vol. 7, pp. 40 038–40 051, 2019. [Cited on page 13.]
- [32] D. Davies and D. Bouldin, "A cluster separation measure," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. PAMI-1, pp. 224 – 227, 05 1979. [Cited on page 14.]
- [33] A. E. Ezugwu, A. M. Ikotun, O. O. Oyelade, L. Abualigah, J. O. Agushaka, C. I. Eke, and A. A. Akinyelu, "A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects," *Engineering Applications of Artificial Intelligence*, vol. 110, p. 104743, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S095219762200046X> [Cited on page 14.]
- [34] J. C. Dunn, "A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters," 1973. [Cited on page 14.]
- [35] F. Abedinzadeh. (2022, 10) Auto-cvi-tool. [Online]. Available: <https://github.com/farhadabedinzadeh/Auto-CVI-Tool/releases/tag/v1.0.0> [Cited on page 14.]

- [36] A. José-García and W. Gómez-Flores, "A survey of cluster validity indices for automatic data clustering using differential evolution," in *Proceedings of the Genetic and Evolutionary Computation Conference*, ser. GECCO '21. New York, NY, USA: Association for Computing Machinery, 2021, pp. 314–322. [Online]. Available: <https://doi.org/10.1145/3449639.3459341> [Cited on page 14.]
- [37] C. Sun, A. Shrivastava, S. Singh, and A. Gupta, "Revisiting unreasonable effectiveness of data in deep learning era," in *2017 IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 843–852. [Cited on page 17.]
- [38] A. Patil, S. Malla, H. Gang, and Y.-T. Chen, "The h3d dataset for full-surround 3d multi-object detection and tracking in crowded urban scenes," 2019. [Online]. Available: <https://arxiv.org/abs/1903.01568> [Cited on pages 17 and 18.]
- [39] A. Geiger, P. Lenz, C. Stiller, and R. Urtasun, "Vision meets robotics: The kitti dataset," *International Journal of Robotics Research (IJRR)*, 2013. [Cited on pages 17 and 18.]
- [40] W. Maddern, G. Pascoe, M. Gadd, D. Barnes, B. Yeomans, and P. Newman, "Real-time kinematic ground truth for the oxford robotcar dataset," *arXiv preprint arXiv: 2002.10152*, 2020. [Online]. Available: <https://arxiv.org/pdf/2002.10152> [Cited on pages 17 and 18.]
- [41] P. Sun, H. Kretzschmar, X. Dotiwalla, A. Chouard, V. Patnaik, P. Tsui, J. Guo, Y. Zhou, Y. Chai, B. Caine, V. Vasudevan, W. Han, J. Ngiam, H. Zhao, A. Timofeev, S. Etinger, M. Krivokon, A. Gao, A. Joshi, S. Zhao, S. Cheng, Y. Zhang, J. Shlens, Z. Chen, and D. Anguelov, "Scalability in perception for autonomous driving: Waymo open dataset," 2020. [Cited on pages 17 and 18.]
- [42] H. Caesar, V. Bankiti, A. H. Lang, S. Vora, V. E. Liong, Q. Xu, A. Krishnan, Y. Pan, G. Baldan, and O. Beijbom, "nusenes: A multimodal dataset for autonomous driving," in *CVPR*, 2020. [Cited on pages 17 and 18.]
- [43] J. Geyer, Y. Kassahun, M. Mahmudi, X. Ricou, R. Durgesh, A. S. Chung, L. Hauswald, V. H. Pham, M. Mühlegg, S. Dorn, T. Fernandez, M. Jänicke, S. Mirashi, C. Savani, M. Sturm, O. Vorobiov, M. Oelker, S. Garreis, and P. Schuberth, "A2d2: Audi autonomous driving dataset," 2020. [Cited on pages 17 and 18.]
- [44] A. Gaidon, Q. Wang, Y. Cabon, and E. Vig, "Virtual worlds as proxy for multi-object tracking analysis," in *CVPR*, 2016. [Cited on page 18.]

- [45] G. Ros, L. Sellart, J. Materzynska, D. Vazquez, and A. M. Lopez, "The synthia dataset: A large collection of synthetic images for semantic segmentation of urban scenes," in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2016. [Cited on page 18.]
- [46] W. Liu, Q. Dong, P. Wang, G. Yang, L. Meng, Y. Song, Y. Shi, and Y. Xue, "A survey on autonomous driving datasets," in *2021 8th International Conference on Dependable Systems and Their Applications (DSA)*, 2021, pp. 399–407. [Cited on pages xv and 18.]
- [47] T. A. P. Driving, "Theia deliverable sp1 requirements," 04 2022. [Cited on page 18.]
- [48] P. Torr and A. Zisserman, "Mlesac: A new robust estimator with application to estimating image geometry," *Computer Vision and Image Understanding*, vol. 78, no. 1, pp. 138–156, 2000. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1077314299908329> [Cited on page 19.]
- [49] M. A. Fischler and R. C. Bolles, "Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography," *Commun. ACM*, vol. 24, no. 6, pp. 381–395, jun 1981. [Online]. Available: <https://doi.org/10.1145/358669.358692> [Cited on page 19.]
- [50] T. M. Inc., "Matlab version: 9.13.0 (r2022b)," Natick, Massachusetts, United States, 2022. [Online]. Available: <https://www.mathworks.com> [Cited on pages 40, 42, and 44.]

Anexos

7.1 Imagens






FIGURA 7.2: Gráfico de dispersão do número de pontos por objetos pela sua distância ao EGO-Vehcle.




FIGURA 7.3: Gráfico de dispersão do logaritmo do número de pontos por objetos pelo logaritmo da sua distância ao EGO-Vehicle.

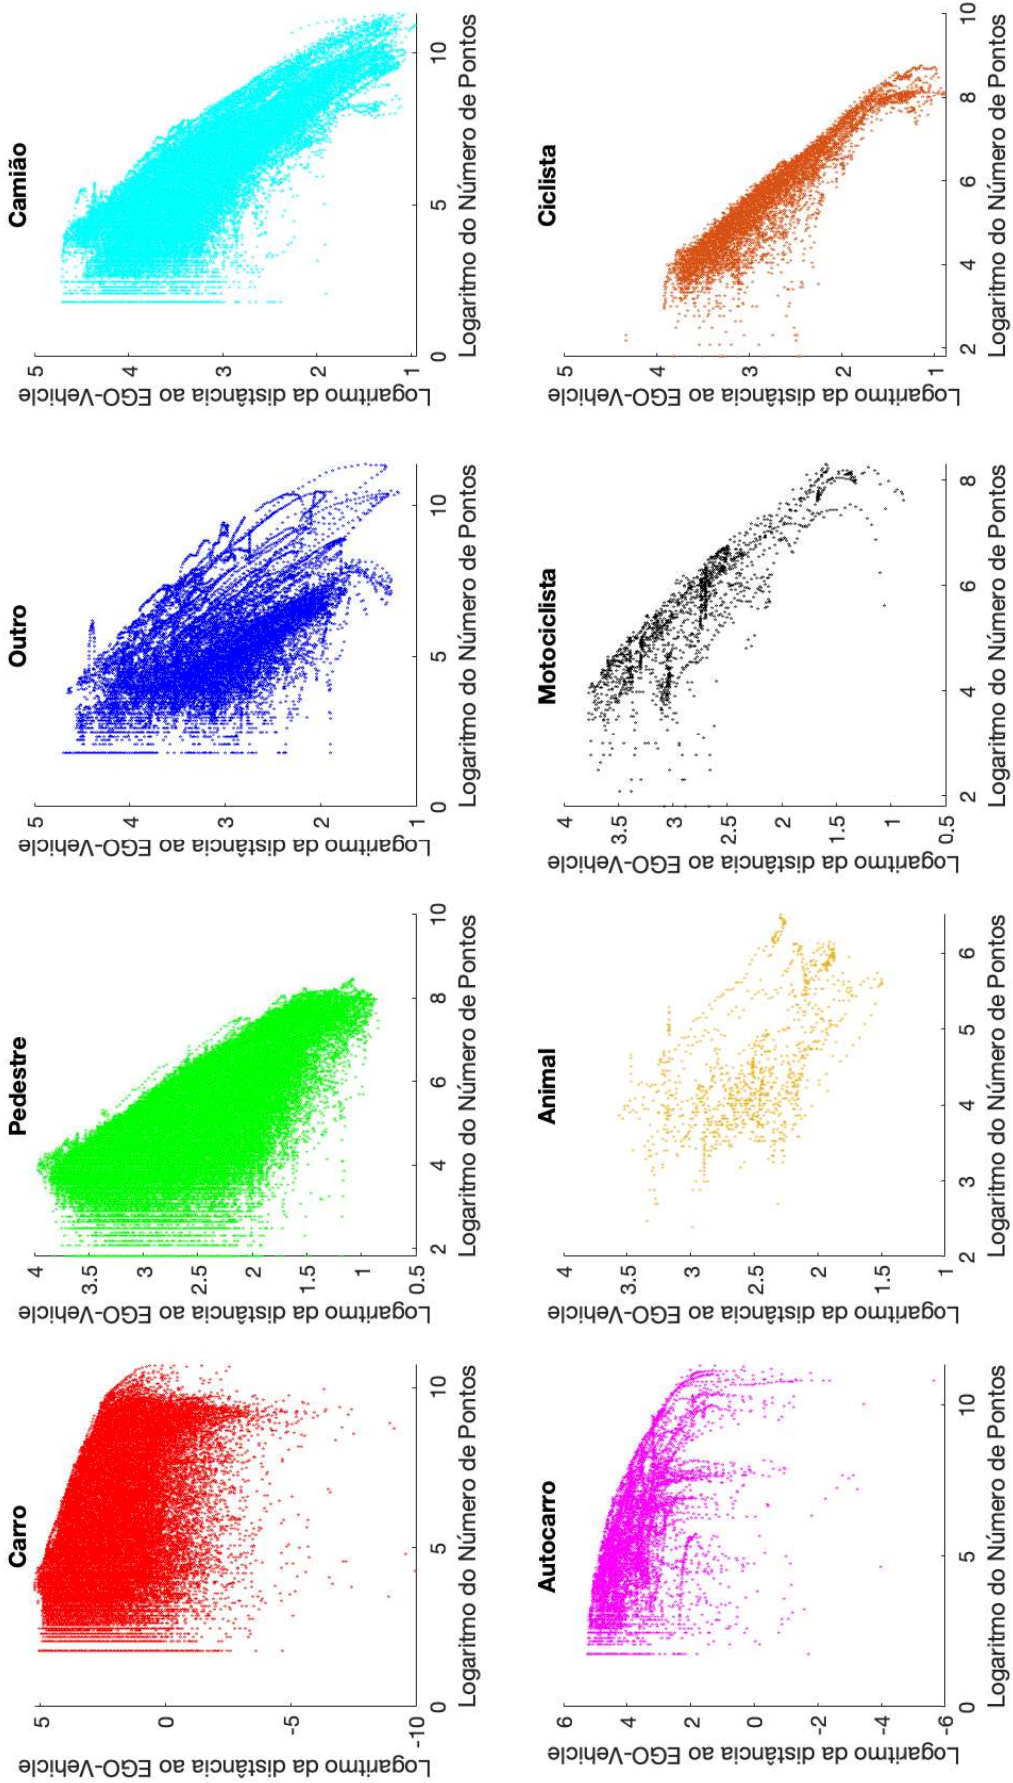


FIGURA 7.4: Gráfico de dispersão do logaritmo do número de pontos por objetos pelo logaritmo da sua distância ao EGO-Vehicle, por Classes.

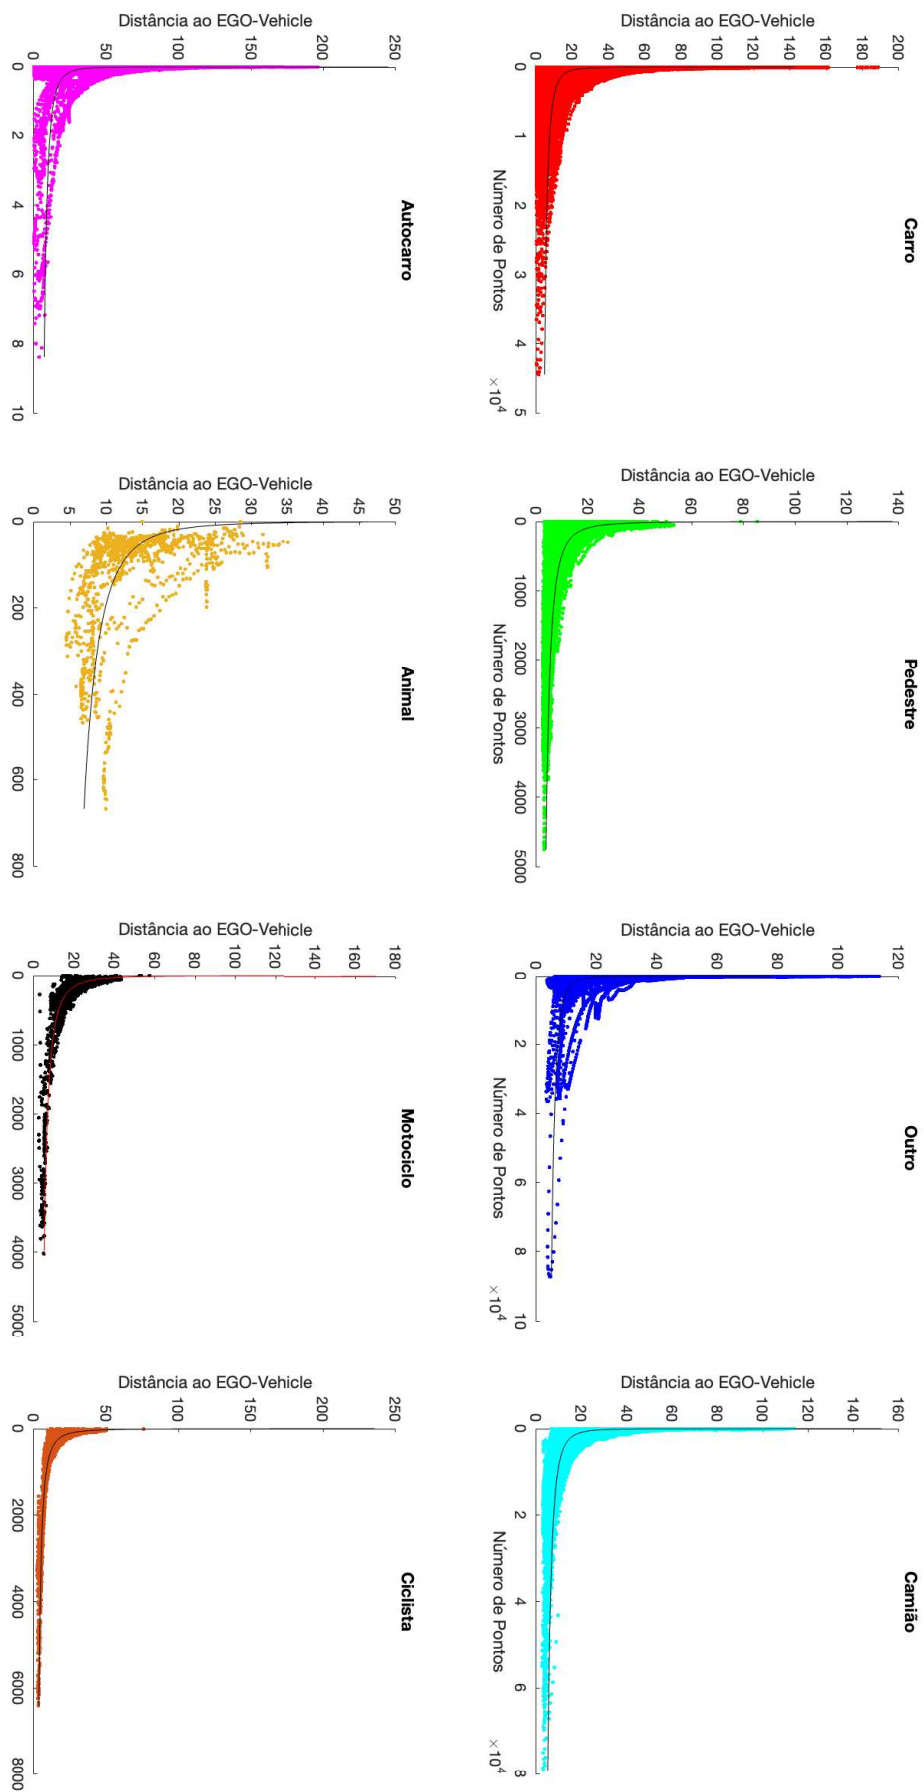


FIGURA 7.5: Gráfico de dispersão do Número de Pontos por objetos pela sua Distância ao EGO-Vehicle, por classes com a sua curva de adaptação.

7.2 Tabelas

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8966	45214	0,8628	0,0026	0,2149	0,5815	5050	0,3696	0,3511
DBSCAN	0,8966	45170	0,9303	0,0026	0,2148	0,5817	7142	0,3694	0,3511
K-Means	0,7951	49446	-0,9863	0,0134	0,2397	0,8052	26	0,5281	0,0076
Spectral	0,7855	48873	-0,3785	0,0172	0,2475	0,7793	3272	0,5197	0,0074
Hier-S	0,6433	30149	0,5854	0,0027	0,6390	0,7279	64	0,6773	0,2022
Hier-M	0,8687	31195	0,7252	0,0032	0,2472	0,6655	257	0,4781	0,0297

TABELA 7.1: Situação 1

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8613	9974	0,708	0,0189	0,264	0,6025	3623	0,3852	0,3511
DBSCAN	0,8612	9959	0,8981	0,019	0,2639	0,6028	5131	0,385	0,3511
K-Means	0,7831	11927	-0,5409	0,018	0,2494	0,8729	931	0,5817	0,0044
Spectral	0,7367	10242	-0,4082	0,0159	0,4413	0,8159	1386	0,4756	0,0086
Hier-S	0,163	4990	-0,0734	0,0199	1	0,8489	56	0,7903	0,2022
Hier-M	0,7805	5516	0,3203	0,0263	0,3549	0,7456	165	0,5247	0,0297

TABELA 7.2: Situação 2

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9212	44538	0,9035	0,0027	0,2106	0,5491	26271	0,3384	0,4394
DBSCAN	0,9212	44487	0,9463	0,0027	0,2106	0,5492	45018	0,3383	0,4394
K-Means	0,8548	29950	-0,9527	0,0137	0,2385	0,8354	254	0,5321	0,0174
Spectral	0,7956	38914	-0,4528	0,0235	0,2539	0,911	8741	0,5645	0,0074
Hier-S	0,6178	22274	0,5572	0,0028	0,6787	0,8314	54	0,7747	0,2022
Hier-M	0,8022	39097	-0,4569	0,0215	0,2445	0,9041	5163	0,5524	0,0137

TABELA 7.3: Situação 3

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9247	5703	0,9599	0,0003	0,0883	0,4993	8077	0,347	0,7128
DBSCAN	0,9247	5703	0,9599	0,0003	0,0883	0,4993	8077	0,347	0,7128
K-Means	0,9247	5703	0,9599	0,0003	0,0883	0,4993	8077	0,347	0,7128
Spectral	0,9247	5703	0,9599	0,0003	0,0883	0,4993	8077	0,347	0,7128
Hier-S	0,9247	5703	0,9599	0,0003	0,0883	0,4993	8077	0,347	0,7128
Hier-M	0,9247	5703	0,9599	0,0003	0,0883	0,4993	8077	0,347	0,7128

TABELA 7.4: Situação 4

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9334	358	0,8873	0,0043	0,1389	0,5146	28	0,274	0,6352
DBSCAN	0,9745	780	0,9681	0	0,0639	0,2666	240	0,1923	2
K-Means	0,8821	316	0,8587	0,0211	0,1552	0,682	9	0,4346	0,1764
Spectral	0,8582	308	0,8441	0,0268	0,1748	0,6952	10	0,4613	0,1209
Hier-S	0,9031	241	0,8655	0,002	0,1796	0,3529	177	0,232	0,724
Hier-M	0,9031	241	0,8655	0,002	0,1796	0,3529	177	0,232	0,724

TABELA 7.5: Situação 5

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9853	407159	0,9985	0	0,0776	0,2869	593094	0,1499	2
DBSCAN	0,9853	407159	0,9985	0	0,0776	0,2869	593094	0,1499	2
K-Means	0,9853	407159	0,9985	0	0,0776	0,2869	593094	0,1499	2
Spectral	0,9853	407159	0,9985	0	0,0776	0,2869	593094	0,1499	2
Hier-S	0,9853	407159	0,9985	0	0,0776	0,2869	593094	0,1499	2
Hier-M	0,9853	407159	0,9985	0	0,0776	0,2869	593094	0,1499	2

TABELA 7.6: Situação 6

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9092	24736	0,9324	0,0022	0,3079	0,6631	15060	0,3397	0,6138
DBSCAN	0,8501	17170	0,893	0,0019	0,9449	0,6392	87	0,325	0,0953
K-Means	0,8722	24805	-0,5882	0,0019	0,2509	0,7146	236	0,5457	0,018
Spectral	0,582	18682	-0,609	0,0339	0,4088	1	595	0,9995	0,0054
Hier-S	0,8239	12544	0,8989	0,0023	0,961	0,6632	1470	0,3289	0,1535
Hier-M	0,877	24673	-0,2076	0,0014	0,2565	0,701	238	0,5229	0,0317

TABELA 7.7: Situação 7

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,906	16637	0,931	0,0035	0,3094	0,8774	16989	0,3838	0,6728
DBSCAN	0,8302	8681	0,8758	0,0032	1	0,7097	58	0,3503	0,0953
K-Means	0,8576	13056	-0,897	0,003	0,2709	0,8027	52	0,5791	0,018
Spectral	0,5055	9192	-0,9219	0,0565	0,4652	2	34	1	0,0054
Hier-S	0,8021	5643	0,8909	0,0037	1	0,8729	1229	0,3483	0,1535
Hier-M	0,8635	12969	-0,4414	0,0022	0,2783	0,7789	65	0,5517	0,0317

TABELA 7.8: Situação 8

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9382	23259	0,9397	0,0018	0,2901	0,5106	25116	0,2513	0,6138
DBSCAN	0,8451	12113	0,8571	0,0018	1	0,5619	57	0,2814	0,0953
K-Means	0,6542	19024	-0,4807	0,0255	0,2733	0,9109	643	0,7649	0,0078
Spectral	0,6442	18504	-0,4696	0,0266	0,3022	0,958	684	0,7731	0,0058
Hier-S	0,8265	8083	0,5512	0,0019	2	0,6636	30	0,2768	0,0953
Hier-M	0,7409	13300	-0,0212	0,0019	0,7388	0,7736	166	0,6091	0,0561

TABELA 7.9: Situação 9

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9291	53965	0,9141	0,0013	0,2167	0,5167	9678	0,3053	0,3673
DBSCAN	0,9291	53965	0,9141	0,0013	0,2167	0,5167	9678	0,3053	0,3673
K-Means	0,9289	54217	-0,6932	0,0013	0,2121	0,5481	1959	0,3099	0,0195
Spectral	0,9291	53965	0,9141	0,0013	0,2167	0,5167	9678	0,3053	0,3673
Hier-S	0,9291	53965	0,9141	0,0013	0,2167	0,5167	9678	0,3053	0,3673
Hier-M	0,9291	53965	0,9141	0,0013	0,2167	0,5167	9678	0,3053	0,3673

TABELA 7.10: Situação 10

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9369	14517	0,9561	0,0005	0,1874	0,4728	10406	0,3147	0,6154
DBSCAN	0,9369	14517	0,9561	0,0005	0,1874	0,4728	10406	0,3147	0,6154
K-Means	0,9369	14517	0,9561	0,0005	0,1874	0,4728	10406	0,3147	0,6154
Spectral	0,2077	96	-0,9751	0,3224	12	0,7241	44	0,5491	0,0256
Hier-S	0,9369	14517	0,9561	0,0005	0,1874	0,4728	10406	0,3147	0,6154
Hier-M	0,9369	14517	0,9561	0,0005	0,1874	0,4728	10406	0,3147	0,6154

TABELA 7.11: Situação 11

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9323	34904	0,9106	0,0028	0,2174	0,5183	14586	0,2867	0,3673
DBSCAN	0,9323	34904	0,9106	0,0028	0,2174	0,5183	14586	0,2867	0,3673
K-Means	0,9323	35104	-0,8611	0,0028	0,2187	0,5702	543	0,2931	0,0195
Spectral	0,9323	34904	0,9106	0,0028	0,2174	0,5183	14586	0,2867	0,3673
Hier-S	0,9323	34904	0,9106	0,0028	0,2174	0,5183	14586	0,2867	0,3673
Hier-M	0,9323	34904	0,9106	0,0028	0,2174	0,5183	14586	0,2867	0,3673

TABELA 7.12: Situação 12

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9771	18525	0,9943	0	0,114	0,2762	19260	0,1885	2
DBSCAN	0,9771	18525	0,9943	0	0,114	0,2762	19260	0,1885	2
K-Means	0,9771	18525	0,9943	0	0,114	0,2762	19260	0,1885	2
Spectral	-0,5607	2	-0,9725	0,6786	27	5	4	3	0,0176
Hier-S	0,9771	18525	0,9943	0	0,114	0,2762	19260	0,1885	2
Hier-M	0,9771	18525	0,9943	0	0,114	0,2762	19260	0,1885	2

TABELA 7.13: Situação 13

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9433	29436	0,9619	0,0002	0,1734	0,3782	11431	0,2726	0,6154
DBSCAN	0,9433	29436	0,9619	0,0002	0,1734	0,3782	11431	0,2726	0,6154
K-Means	0,9433	29436	0,9619	0,0002	0,1734	0,3782	11431	0,2726	0,6154
Spectral	-0,1123	61	-0,8993	0,4116	6	3	11	2	0,0121
Hier-S	0,9433	29436	0,9619	0,0002	0,1734	0,3782	11431	0,2726	0,6154
Hier-M	0,9433	29436	0,9619	0,0002	0,1734	0,3782	11431	0,2726	0,6154

TABELA 7.14: Situação 14

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9234	9566	0,9259	0,0045	0,2391	0,5769	12857	0,34	0,257
DBSCAN	0,9234	9566	0,9259	0,0045	0,2391	0,5769	12857	0,34	0,257
K-Means	0,9234	9566	0,9259	0,0045	0,2391	0,5769	12857	0,34	0,257
Spectral	0,9234	9566	0,9259	0,0045	0,2391	0,5769	12857	0,34	0,257
Hier-S	0,9234	9566	0,9259	0,0045	0,2391	0,5769	12857	0,34	0,257
Hier-M	0,9234	9566	0,9259	0,0045	0,2391	0,5769	12857	0,34	0,257

TABELA 7.15: Situação 15

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9266	515	0,9932	0,0285	0,2917	0,8538	58	0,2499	0,4886
DBSCAN	0,9511	859	0,9932	0	0,1762	0,3186	2435	0,2359	1
K-Means	0,6114	453	-0,0645	0,0445	0,3833	1	3	0,7392	0,0147
Spectral	0,9515	469	0,9861	0	0,1759	0,1989	1902	0,1914	1
Hier-S	0,9515	469	0,9861	0	0,1759	0,1989	1902	0,1914	1
Hier-M	0,9515	469	0,9861	0	0,1759	0,1989	1902	0,1914	1

TABELA 7.16: Situação 16

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9529	1222	0,947	0	0,158	0,4892	216	0,2695	1
DBSCAN	0,8972	1617	0,9443	0,0009	0,1108	0,3788	378	0,4056	0,5635
K-Means	0,7232	536	0,5819	0,0615	0,2418	0,6169	31	0,716	0,034
Spectral	0,5703	867	0,2874	0,0279	0,3056	1	22	1	0,0422
Hier-S	0,7543	541	0,953	0,0028	0,565	0,4376	64	0,3363	0,356
Hier-M	0,8502	1046	0,9121	0,0016	0,1939	0,6065	31	0,4736	0,45

TABELA 7.17: Situação 17

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,909	64887	0,9886	0,002	0,2166	0,6458	159262	0,3091	0,5878
DBSCAN	0,909	64887	0,9886	0,002	0,2166	0,6458	159262	0,3091	0,5878
K-Means	0,909	64887	0,9886	0,002	0,2166	0,6458	159262	0,3091	0,5878
Spectral	0,909	64887	0,9886	0,002	0,2166	0,6458	159262	0,3091	0,5878
Hier-S	0,909	64887	0,9886	0,002	0,2166	0,6458	159262	0,3091	0,5878
Hier-M	0,909	64887	0,9886	0,002	0,2166	0,6458	159262	0,3091	0,5878

TABELA 7.18: Situação 18

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8272	3215	0,8119	0,033	0,235	0,9568	2467	0,5409	0,4414
DBSCAN	0,8272	3210	0,8119	0,033	0,2349	0,9571	4607	0,5403	0,4414
K-Means	0,8006	3488	-0,4896	0,0149	0,2019	0,8946	109	0,6232	0,0373
Spectral	0,4637	2299	-0,5216	0,1215	0,328	1	937	1	0,0061
Hier-S	0,7284	1609	0,8115	0,0332	0,3981	0,9964	8720	0,5406	0,2401
Hier-M	0,6367	2518	-0,5453	0,0549	0,2966	1	283	1	0,0208

TABELA 7.19: Situação 19

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9997	1758471	0,9999	0	0,0102	0,0485	102798	0,025	16
DBSCAN	0,9997	1758471	0,9999	0	0,0102	0,0485	102798	0,025	16
K-Means	0,9997	1758471	0,9999	0	0,0102	0,0485	102798	0,025	16
Spectral	0,9997	1758471	0,9999	0	0,0102	0,0485	102798	0,025	16
Hier-S	0,9997	1758471	0,9999	0	0,0102	0,0485	102798	0,025	16
Hier-M	0,9997	1758471	0,9999	0	0,0102	0,0485	102798	0,025	16

TABELA 7.20: Situação 20

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,665	48	-0,0415	0,3316	1	0,9341	226	0,4143	0,3103
DBSCAN	0,6191	309	0,31	0,0333	0,6218	0,4288	304	0,4785	0,2133
K-Means	0,5608	370	-0,715	0,0729	0,4373	0,8721	25	0,7199	0,03
Spectral	0,4824	326	-0,628	0,0941	0,5413	0,7661	26	0,7302	0,0175
Hier-S	0,8341	185	-0,2892	0,0126	0,7236	0,4914	91	0,2939	0,2528
Hier-M	0,6923	257	-0,4758	0,009	0,7312	0,6303	13	0,5183	0,1415

TABELA 7.21: Situação 21

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8917	85105	0,8211	0,0134	0,2158	0,6871	63383	0,3536	0,2317
DBSCAN	0,8917	85105	0,8211	0,0134	0,2158	0,6871	63383	0,3536	0,2317
K-Means	0,9	90101	-0,9869	0,0102	0,2356	0,6605	149	0,3479	0,0025
Spectral	0,8859	80881	-0,7094	0,0174	0,2977	0,8359	28593	0,3581	0,0484
Hier-S	0,8917	85105	0,8211	0,0134	0,2158	0,6871	63383	0,3536	0,2317
Hier-M	0,8917	85105	0,8211	0,0134	0,2158	0,6871	63383	0,3536	0,2317

TABELA 7.22: Situação 22

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8924	40065	0,8683	0,0101	0,2164	0,6242	22288	0,3545	0,3578
DBSCAN	0,8924	40041	0,9054	0,0102	0,2163	0,6242	26998	0,3544	0,3578
K-Means	0,7949	28061	-0,9845	0,0178	0,2609	0,903	48	0,6414	0,009
Spectral	0,1428	20128	-0,0056	0,0158	1	0,9817	754	0,8658	0,0738
Hier-S	0,695	20046	0,8167	0,0103	0,6331	0,8609	32	0,6444	0,197
Hier-M	0,818	25142	0,3608	0,0231	0,2833	0,8431	1985	0,5549	0,013

TABELA 7.23: Situação 23

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9589	284	0,9137	0	0,135	0,2549	36	0,2076	2
DBSCAN	0,995	2137	0,9978	0	0,0122	0,1001	1078	0,0878	6
K-Means	0,9859	1864	0,9939	0	0,0178	0,149	342	0,1385	3
Spectral	0,9859	1864	0,9939	0	0,0178	0,149	342	0,1385	3
Hier-S	0,9859	1864	0,9939	0	0,0178	0,149	342	0,1385	3
Hier-M	0,9859	1864	0,9939	0	0,0178	0,149	342	0,1385	3

TABELA 7.24: Situação 24

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8773	36851	0,9529	0,0118	0,2954	0,6115	58184	0,4263	0,2675
DBSCAN	0,8773	36851	0,9529	0,0118	0,2954	0,6115	58184	0,4263	0,2675
K-Means	0,8773	36851	0,9529	0,0118	0,2954	0,6115	58184	0,4263	0,2675
Spectral	0,8773	36851	0,9529	0,0118	0,2954	0,6115	58184	0,4263	0,2675
Hier-S	0,8773	36851	0,9529	0,0118	0,2954	0,6115	58184	0,4263	0,2675
Hier-M	0,8773	36851	0,9529	0,0118	0,2954	0,6115	58184	0,4263	0,2675

TABELA 7.25: Situação 25

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,89	21892	0,9282	0,0044	0,1657	0,8855	19679	0,4847	0,4593
DBSCAN	0,89	21892	0,9282	0,0044	0,1657	0,8855	19679	0,4847	0,4593
K-Means	0,89	21892	0,9282	0,0044	0,1657	0,8855	19679	0,4847	0,4593
Spectral	0,89	21892	0,9282	0,0044	0,1657	0,8855	19679	0,4847	0,4593
Hier-S	0,89	21892	0,9282	0,0044	0,1657	0,8855	19679	0,4847	0,4593
Hier-M	0,89	21892	0,9282	0,0044	0,1657	0,8855	19679	0,4847	0,4593

TABELA 7.26: Situação 26

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8609	69669	0,9517	0,0152	0,2592	0,8096	19164	0,4374	0,2605
DBSCAN	0,8609	69669	0,9517	0,0152	0,2592	0,8096	19164	0,4374	0,2605
K-Means	0,7668	72005	-0,736	0,0363	0,2997	1	680	0,6099	0,004
Spectral	0,8609	69669	0,9517	0,0152	0,2592	0,8096	19164	0,4374	0,2605
Hier-S	0,8609	69669	0,9517	0,0152	0,2592	0,8096	19164	0,4374	0,2605
Hier-M	0,8609	69669	0,9517	0,0152	0,2592	0,8096	19164	0,4374	0,2605

TABELA 7.27: Situação 27

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427
DBSCAN	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427
K-Means	0,6946	10555	-0,9927	0,0927	0,4279	1	592	0,7772	0,008
Spectral	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427
Hier-S	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427
Hier-M	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427

TABELA 7.28: Situação 28

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427
DBSCAN	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427
K-Means	0,6946	10555	-0,9927	0,0927	0,4279	1	592	0,7772	0,008
Spectral	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427
Hier-S	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427
Hier-M	0,3097	1512	0,4885	0,3939	2	1	20857	0,6791	0,1427

TABELA 7.29: Situação 29

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8937	6413	0,3282	0,0167	0,1961	0,8801	968	0,3884	0,1834
DBSCAN	0,8761	4608	0,5453	0,0055	0,2349	0,6874	172	0,3777	0,2357
K-Means	0,8092	3594	-0,7713	0,007	0,2264	0,9965	12	0,8357	0,0553
Spectral	0,7692	4294	0,0316	0,0084	0,2273	1	34	0,7795	0,0359
Hier-S	0,7689	2245	0,1787	0,0163	0,4741	0,9234	5	0,5387	0,181
Hier-M	0,7572	3875	0,0038	0,0042	0,3658	0,8734	37	0,5592	0,0834

TABELA 7.30: Situação 30

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9988	136901	0,9998	0	0,0289	0,0709	6171	0,0451	11
DBSCAN	0,9297	81847	0,9541	0,0011	0,099	0,1367	1915	0,4148	0,2373
K-Means	0,7343	102455	-0,1882	0,001	0,271	0,9009	29	0,685	0,0514
Spectral	0,5455	82474	-0,2545	0,005	0,441	1	68	0,8771	0,0156
Hier-S	0,6301	56240	0,9101	0,0012	0,9915	0,7283	316	0,5103	0,2373
Hier-M	0,7295	97805	0,1814	0,001	0,3212	0,8875	67	0,6399	0,0637

TABELA 7.31: Situação 31

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9831	4050	0,9964	0	0,0396	0,2367	11220	0,163	3
DBSCAN	0,9831	4050	0,9964	0	0,0396	0,2367	11220	0,163	3
K-Means	0,9831	4050	0,9964	0	0,0396	0,2367	11220	0,163	3
Spectral	0,9831	4050	0,9964	0	0,0396	0,2367	11220	0,163	3
Hier-S	0,9831	4050	0,9964	0	0,0396	0,2367	11220	0,163	3
Hier-M	0,9831	4050	0,9964	0	0,0396	0,2367	11220	0,163	3

TABELA 7.32: Situação 32

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,8869	361	0,9594	0,0004	0,4805	0,4292	985	0,2989	0,9036
DBSCAN	0,8312	497	0,9379	0,0021	0,4046	0,3678	406	0,3542	0,5107
K-Means	0,5266	450	-0,4642	0,0511	0,4387	0,62	72	0,9697	0,0378
Spectral	0,6788	588	0,077	0,0197	0,3094	0,5954	135	0,7211	0,205
Hier-S	0,406	317	0,3829	0,014	0,9704	0,4515	41	0,5893	0,2037
Hier-M	0,4354	338	0,5173	0,0107	0,9083	0,4403	38	0,5867	0,2303

TABELA 7.33: Situação 33

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9986	21869	0,9997	0	0,0119	0,0723	2140	0,0431	11
DBSCAN	0,9987	23290	0,9997	0	0,0109	0,0525	22141	0,04	11
K-Means	0,796	21626	0,2036	0,003	0,0726	0,142	815	0,5017	0,1604
Spectral	0,783	21149	0,1553	0,0029	0,0871	0,1442	781	0,5063	0,0933
Hier-S	0,9688	11985	0,9857	0,0003	0,0311	0,0916	6098	0,1327	0,5739
Hier-M	0,9688	11985	0,9857	0,0003	0,0311	0,0916	6098	0,1327	0,5739

TABELA 7.34: Situação 34

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9962	23558	0,999	0	0,0349	0,1259	1286	0,0916	4
DBSCAN	0,9625	15100	0,9817	0,0004	0,0417	0,2247	242	0,386	0,4702
K-Means	0,7931	22435	0,2672	0,0016	0,1277	0,7991	34	0,6158	0,0892
Spectral	0,7376	13497	0,5064	0,0039	0,183	0,9249	36	0,6324	0,0617
Hier-S	0,9298	12432	0,9393	0,0008	0,076	0,2452	263	0,4653	0,373
Hier-M	0,9389	12647	0,8379	0,0006	0,0679	0,2392	180	0,4407	0,3067

TABELA 7.35: Situação 35

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,884	549	0,6413	0,0167	0,3128	0,6269	64	0,4222	0,5144
DBSCAN	0,5976	431	0,3346	0,0149	0,3413	0,6518	108	0,5189	0,1595
K-Means	0,5854	495	-0,3214	0,0375	0,2735	1	15	0,7909	0,0346
Spectral	0,5423	423	0,3912	0,0336	0,3905	1	28	0,8074	0,121
Hier-S	0,5201	150	0,6238	0,0356	2	0,7557	15	0,465	0,1908
Hier-M	0,6776	388	0,1746	0,0083	0,3721	0,8756	9	0,7164	0,1889

TABELA 7.36: Situação 36

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9997	262611	1	0	0,0058	0,0313	132816	0,0218	22
DBSCAN	0,9997	262611	1	0	0,0058	0,0313	132816	0,0218	22
K-Means	0,9997	262611	1	0	0,0058	0,0313	132816	0,0218	22
Spectral	0,9997	262611	1	0	0,0058	0,0313	132816	0,0218	22
Hier-W	0,9997	262611	1	0	0,0058	0,0313	132816	0,0218	22
Hier-M	0,9997	262611	1	0	0,0058	0,0313	132816	0,0218	22

TABELA 7.37: Situação 37

CI/CVI	Silhouette	CH-Index	DBCV	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9963	83196	0,9996	0	0,0223	0,1002	214997	0,0705	6
DBSCAN	0,9963	83196	0,9996	0	0,0223	0,1002	214997	0,0705	6
K-Means	0,9963	83196	0,9996	0	0,0223	0,1002	214997	0,0705	6
Spectral	-0,5504	9	-0,9518	0,656	66	2	3	1	0,0205
Hier-S	0,9963	83196	0,9996	0	0,0223	0,1002	214997	0,0705	6
Hier-M	0,9963	83196	0,9996	0	0,0223	0,1002	214997	0,0705	6

TABELA 7.38: Situação 38

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9631	4926	0,9954	0	0,1966	0,2605	8145	0,1856	2
DBSCAN	0,9631	4926	0,9954	0	0,1966	0,2605	8145	0,1856	2
K-Means	0,9631	4926	0,9954	0	0,1966	0,2605	8145	0,1856	2
Spectral	-0,1687	78	-0,8406	0,5336	8	1	5	0,9071	0,0441
Hier-S	0,9631	4926	0,9954	0	0,1966	0,2605	8145	0,1856	2
Hier-M	0,9631	4926	0,9954	0	0,1966	0,2605	8145	0,1856	2

TABELA 7.39: Situação 39

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9434	8367	0,9486	0	0,1249	0,6214	2093	0,2924	0,8579
DBSCAN	0,9461	8725	0,971	0	0,1231	0,4919	4803	0,278	1
K-Means	0,7173	5782	-0,3819	0,0241	0,1944	0,9611	675	0,84	0,0234
Spectral	0,5481	5461	0,1652	0,0475	0,3993	0,9998	1223	0,7243	0,0896
Hier-S	0,9118	4523	0,8999	0,0007	0,1923	0,5705	27	0,359	0,2856
Hier-M	0,9118	4523	0,8999	0,0007	0,1923	0,5705	27	0,359	0,2856

TABELA 7.40: Situação 40

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9141	18914	0,9578	0,0046	0,1963	0,6079	9123	0,2979	0,441
DBSCAN	0,9141	18914	0,9578	0,0046	0,1963	0,6079	9123	0,2979	0,4410
K-Means	0,9148	19161	-0,7740	0,0040	0,1990	0,6208	294	0,3068	0,0289
Spectral	0,7805	6441	-0,8682	0,0867	0,8351	0,7818	831	0,3584	0,0562
Hier-S	0,9141	18914	0,9578	0,0046	0,1963	0,6079	9123	0,2979	0,4410
Hier-M	0,9141	18914	0,9578	0,0046	0,1963	0,6079	9123	0,2979	0,4410

TABELA 7.41: Situação 41

CI/CVI	Silhouette	CH-Index	DBC	C-Index	COP-Index	CS-Index	CVDD-Index	DB-Index	Dunn
Objective	1	∞	1	1	0	0	∞	0	∞
GT	0,9135	21968	0,9513	0,0025	0,1902	0,6473	1881	0,296	0,441
DBSCAN	0,9142	21785	0,9577	0,0025	0,19	0,5645	4255	0,2912	0,441
K-Means	0,8405	26098	-0,4205	0,0043	0,1854	0,7751	1196	0,4966	0,014
Spectral	0,7761	15375	0,7371	0,014	0,3699	0,9062	1571	0,612	0,0835
Hier-S	0,9045	14867	0,9373	0,0025	0,2096	0,6128	25	0,3476	0,2275
Hier-M	0,9045	14867	0,9373	0,0025	0,2096	0,6128	25	0,3476	0,2275

TABELA 7.42: Situação 42

