



**Henrique Manuel Martins Rodrigues**

Licenciado em Engenharia Informática

**Deteção semi-automática de vidros de  
automóveis e respetivos danos**

Dissertação para obtenção do Grau de Mestre em  
**Engenharia Informática**

Orientador: Prof. Doutor Nuno Manuel Robalo Correia, Professor  
Catedrático, Universidade Nova de Lisboa  
Co-orientador: Prof. Doutor Rui Manuel Feliciano de Jesus, Professor  
Adjunto, Instituto Superior de Engenharia de Lisboa

Júri

Presidente: Doutor Pedro Manuel Corrêa Calvente Barahona  
Arguentes: Doutor Pedro Miguel Torres Mendes Jorge  
Doutor Nuno Manuel Robalo Correia



FACULDADE DE  
CIÊNCIAS E TECNOLOGIA  
UNIVERSIDADE NOVA DE LISBOA

**Março, 2019**



## **Deteção semi-automática de vidros de automóveis e respetivos danos**

Copyright © Henrique Manuel Martins Rodrigues, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.



*À minha família.*



## AGRADECIMENTOS

Em primeiro lugar, gostaria de agradecer ao meu Orientador, Professor Doutor Nuno Correia, por me ter proporcionado esta oportunidade de trabalho, me ter aceite para o desenvolver subordinado ao tema acima explanado, pela ajuda e conselhos proporcionados e também ao professor Rui Jesus durante o decorrer deste estudo. Agradeço também aos colegas do Centro de Inspeção de Vila Nova de Poiares, pela importante ajuda na troca de ideias durante este processo, as quais me proporcionaram excelente contribuição para o seu desenvolvimento e implementação. Ainda o meu agradecimento ao Centro de Inspeções de Castelo Branco - Controlauto e à CarGlass de Castelo Branco, pela disponibilidade e informação prestada, nos testes das soluções propostas neste trabalho.

Ao Departamento de Informática da Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa (DI - FCT/UNL), por ter sido uma segunda casa, onde me foi proporcionado o conhecimento profundo sobre diversos temas da Engenharia Informática e a possibilidade de os aplicar e desenvolver.

Grato ainda a todos os que, durante este período académico, me acolheram, ajudaram na procura do conhecimento e me proporcionaram momentos de alegria, apesar de todas as dificuldades inerentes e que, ao vence-las me tornaram ainda melhor e mais capaz.

Finalmente, mas não menos importante, um agradecimento profundo à minha família por toda a ajuda, paciência e compreensão que mostraram, servindo-me de maior motivação e obrigando-me a um maior empenho, apesar dos diversos e difíceis desafios enfrentados.

A todos os meus colegas, que me fizeram sentir em casa quando esta estava longe, por todos os momentos de alegria que me proporcionaram, pela sua motivação, estímulo e compreensão, que me ajudou bastante a enfrentar todos os desafios desta etapa da minha vida, um grande Bem Hajam.





## RESUMO

---

Como a tecnologia tem vindo a evoluir constantemente ao longo dos anos, até ao ponto de um *smartphone* poder conter uma câmara que permite tirar imagens com informação de profundidade, ou seja, imagens *3D* (tridimensionais), as aplicações e vantagens que esta tecnologia pode acrescentar na resolução de problemas, como a identificação de objetos, ainda não foram muito exploradas.

No processo tradicional de uma inspeção automóvel, a utilização do olho humano é uma das mais importantes metodologias utilizadas. Contudo, o processo poderá ser automatizado de modo a acelerar o processo de inspeção e melhorar a satisfação do cliente, pois já existem diversas técnicas que permitem, com alguma precisão, identificar numa imagem um objeto. Como tal, a integração da informação *3D* com a tecnologia já existente revela grande potencial na melhoria dos resultados neste tipo de ambiente.

Esta dissertação surge como o desenvolvimento para um problema, o qual carece ainda de uma investigação mais profunda, cuja finalidade é a criação de uma biblioteca de operações que permitirão o desenvolvimento de processos semiautomáticos na inspeção automóvel para a deteção não só de peças, mas também de falhas no próprio veículo. Para tal, recorre-se à utilização de sensores de ultrassons, de infravermelhos e de profundidade, tendo o enfoque sido dirigido para os vidros, por se revelarem um dos componentes automóveis que, para além do maior grau de dificuldade, não só na sua deteção como das respetivas falhas, proporcionaram desafios mais aliciantes. As imagens poderão vir a ser captadas por um braço robótico, equipado com câmaras de profundidade e os sensores já referidos, ou outros a integrar, como o laser, o qual se deslocará em torno do veículo, identificando não só os componentes a serem inspecionados bem como eventuais falhas que determinarão, de acordo com o seu grau de perigosidade, a reprovação dum veículo numa inspeção automóvel.

**Palavras-chave:** Inspeção automóvel, algoritmos de classificação, extração de características, processamento de imagem/vídeo, imagens *3D* e deteção de objetos.

---



## ABSTRACT

---

As technology has been constantly evolving over the years, to the point where an ordinary mobile phone can contain a camera that allows you to take depth images, that is, 3D (three-dimensional) images, the applications and advantages that this technology can add in problem solving, such as the identification of objects, have not yet been fully explored.

In the traditional process of an automobile inspection, the use of the visual element is one of the most important. However, the process can be partial automated in order to accelerate the inspection process and improve customer satisfaction, since there are already several techniques that allow, with some precision, to identify in an image an object, such as the integration of 3D information with the existing technology reveals great potential in improving results in an inspection environment.

This dissertation appears as a partial solution for a problem, which still needs a deeper investigation, whose purpose of creating a library of operations that will allow the development of automatic processes in the automobile inspection for the detection not only of parts, but also failures in the vehicle itself. To do so, I used devices such as ultrasonic sensors, infrared sensors and depth sensors. The main focus was centered on the glasses, not only because they give me the opportunity to use new methodologies, but also because of the challenge and the difficulty to detect it and their flaws. As so, the images could be captured by a robotic arm equipped with this new depth cameras and other sensors, such as the laser sensor, that will move around the vehicle to identify not only the parts of the vehicle but also their flaws that could reprove it, according their respective degree of danger.

**Keywords:** Automobile inspection, classification algorithm, feature extraction, image and video processing, 3D images and objects detection.

---



# ÍNDICE

<b>Lista de Figuras</b>	<b>xv</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Contexto . . . . .	1
1.2 Organização . . . . .	2
1.3 Motivação . . . . .	2
1.4 Definição do Problema . . . . .	5
1.5 Contribuições . . . . .	7
<b>2 Trabalho Relacionado</b>	<b>9</b>
2.1 Inspeção automática de Automóveis . . . . .	9
2.2 Detecção de Peças Automóveis . . . . .	10
2.3 Detecção de Falhas . . . . .	13
2.3.1 Deformação . . . . .	14
2.3.2 Vidros . . . . .	14
2.4 Sensores e Dados 2D/3D . . . . .	17
2.5 Extração de Características e Classificação . . . . .	18
2.5.1 Textura . . . . .	18
2.5.2 Forma . . . . .	20
2.5.3 Cor . . . . .	20
2.5.4 Pontos Chave . . . . .	22
2.5.5 Algoritmos e técnicas de Classificação . . . . .	23
2.6 Conclusões . . . . .	25
<b>3 Desenvolvimento</b>	<b>27</b>
3.1 Detecção do vidro . . . . .	28
3.1.1 Através de um reflexo . . . . .	28
3.1.2 Através de multisensor . . . . .	29
3.2 Detecção de defeitos no vidro . . . . .	31
3.2.1 Recurso ao algoritmo SVM . . . . .	31
3.2.2 Recurso a um reflexo . . . . .	31
3.2.3 Recurso à iluminação artificial . . . . .	32
3.3 Bibliotecas usadas . . . . .	33

## ÍNDICE

---

3.3.1	<i>OpenCV</i>	33
3.3.2	<i>Realsense SDK</i>	34
3.3.3	<i>ROS-Kinetic</i>	35
<b>4</b>	<b>Testes e Avaliação</b>	<b>37</b>
4.1	Testes de deteção de vidro	37
4.2	Testes de identificação de defeitos no vidro	44
<b>5</b>	<b>Conclusões e Trabalho Futuro</b>	<b>53</b>
	<b>Bibliografia</b>	<b>57</b>

## LISTA DE FIGURAS

1.1	Exemplo de imagem de profundidade, captada com a câmara/sensor <i>Intel RealSense</i> . . . . .	5
1.2	Exemplo de imagem de cor, captada com a câmara/sensor <i>Intel RealSense</i> . . .	5
1.3	Exemplo de uma deformação pequena. . . . .	7
2.1	Imagem representativa de uma Inspeção Automóvel retirada de <a href="https://www.economista.pt/artigo/precos-da-inspecao-automovel/">https://www.economista.pt/artigo/precos-da-inspecao-automovel/</a> . . . . .	10
2.2	Tabela retirada de “ <i>Going into depth: Evaluating 2D and 3D cues for object classification on a new, large-scale object dataset</i> ”[6130385] . . . . .	11
2.3	Resultados 1 de “ <i>Feature Extraction from Depth Maps for Object Recognition</i> ”[Jordan2013FeatureEF] . . . . .	12
2.4	Resultados 2 de “ <i>Feature Extraction from Depth Maps for Object Recognition</i> ”[Jordan2013FeatureEF] . . . . .	12
2.5	Tabela de resultados retirada de “ <i>Depth Kernel Descriptors for Object Recognition</i> ”[4] . . . . .	13
2.6	Vidro lateral de um veículo que se encontra danificado. . . . .	15
2.7	Vidro dianteiro de um veículo que se encontra danificado. . . . .	16
2.8	Exemplo de câmara Multiespectral, Sensor Câmara Multispectral Parrot Sequoia. . . . .	18
2.9	Exemplos de aplicação filtros de <i>Gabor</i> . . . . .	19
2.10	Imagem original da válvula. . . . .	21
2.11	Exemplo de aplicação do <i>Canny</i> . . . . .	21
2.12	Exemplo de aplicação do <i>Sobel</i> . . . . .	21
2.13	Exemplos de segmentação de uma imagem. . . . .	22
2.14	Exemplo de aplicação de <i>SIFT</i> retirado da documentação do <i>OpenCV</i> . . . . .	23
2.15	Exemplos de resultados do uso da rede neuronal <b>YOLO</b> , retirado de [29]. . . . .	25
3.1	Padrão utilizado durante o trabalho realizado. . . . .	28
3.2	Combinação dos sensores <i>Intel RealSense</i> e <i>TeraRanger DUO</i> . . . . .	29
3.3	Diagrama representativo dos passos no algoritmo. . . . .	30
3.4	Iluminação artificial usada no desenvolvimento. . . . .	32
3.5	Diagrama representativo dos passos no algoritmo de deteção dos defeitos. . . . .	33
3.6	Câmara <i>Intel RealSense D435</i> . . . . .	34

3.7	<i>Teraranger DUO</i> visão dianteira. . . . .	35
3.8	<i>Teraranger DUO</i> visão traseira. . . . .	35
4.1	Vidro com o padrão presente. . . . .	38
4.2	Vidro sem o padrão presente. . . . .	38
4.3	Vidro sem o padrão presente identificado pelo <i>YOLO</i> . . . . .	38
4.4	Vidro com o padrão presente identificado pelo <i>YOLO</i> . . . . .	38
4.5	Outro vidro sem o padrão presente identificado pelo <i>YOLO</i> . . . . .	39
4.6	Outro vidro com o padrão presente identificado pelo <i>YOLO</i> . . . . .	39
4.7	Não existe objeto transparente. . . . .	39
4.8	Presença de objeto transparente. . . . .	39
4.9	Teste no capô do automóvel. . . . .	40
4.10	Teste no vidro dianteiro. . . . .	40
4.11	Teste no vidro lateral. . . . .	40
4.12	Teste na porta do condutor. . . . .	40
4.13	Falso positivo no capô. . . . .	40
4.14	Falso positivo na porta. . . . .	40
4.15	Imagem de profundidade de uma porta danificada. . . . .	41
4.16	Outra imagem de profundidade da porta danificada. . . . .	41
4.17	Infravermelhos numa porta de um automóvel. . . . .	41
4.18	Infravermelhos na porta mas de outro ângulo. . . . .	42
4.19	Teste no vidro lateral (Note o reflexo da iluminação). . . . .	42
4.20	Teste no vidro lateral vidro completamente escondido. . . . .	42
4.21	Teste no vidro traseiro. . . . .	43
4.22	Teste no vidro traseiro de um ângulo diferente. . . . .	43
4.23	Teste no vidro dianteiro. . . . .	43
4.24	Tabelas de resultados <i>SIFT</i> . . . . .	44
4.25	Tabelas de resultados <i>SURF</i> . . . . .	45
4.26	Tabelas de resultados <i>ORB</i> . . . . .	45
4.27	Imagens escala de cinzento sem e com iluminação. . . . .	46
4.28	Imagens depois de aplicado um <i>threshold</i> binário. . . . .	46
4.29	Imagem resultante da diferença das duas imagens anteriores. . . . .	46
4.30	Padrão numa zona com dano não visível 1. . . . .	47
4.31	Padrão numa zona com dano não visível 2. . . . .	47
4.32	Padrão numa zona com dano não visível 3. . . . .	48
4.33	Imagem ampliada na zona onde o padrão se desloca na presença de um defeito relativamente visível. . . . .	48
4.34	Modificação de parâmetros para tornar o defeito mais visível. Janelas com «O» são capturadas da imagem inicial. . . . .	49
4.35	Com os parâmetros nesta imagem os reflexos tomam grande parte do resultado. . . . .	49



4.36 Com os parâmetros quase inalterados mas que neste caso mostram resultados aceitáveis, mas com alguma presença de artefactos causados pelos reflexos. .	50
4.37 Parâmetros modificados para valores altos para analisar se os defeitos são mais visíveis. . . . .	50
4.38 Resultado durante as primeiras iterações. . . . .	51
4.39 Resultado depois de decorridos alguns segundos. . . . .	51



## INTRODUÇÃO

Neste capítulo, é feita a introdução desta dissertação, descrevendo o contexto em que se enquadra, a motivação inerente e os respetivos desafios. No final, será apresentada uma pequena descrição do problema principal e a sua subdivisão em problemas mais pequenos para os quais se tentaram encontrar soluções exequíveis e com potencial de virem a ser aplicadas num ambiente real.

### 1.1 Contexto

Esta dissertação surge no contexto de um projeto, que se insere no programa Portugal 2020, desenvolvido em colaboração com a equipa do Centro de Inspeções de Vila Nova de Poaires. O referido programa consagra, entre outros objetivos, o desenvolvimento económico e o crescimento inteligente do nosso país, no âmbito da competitividade e internacionalização. No mesmo, é referido que “Os constrangimentos existentes no domínio Competitividade e Internacionalização prendem-se com o facto da especialização produtiva assentar em atividades de reduzido valor acrescentado e de baixa intensidade tecnológica e de conhecimento; das fracas competências e estratégias das empresas, inerentes às fragilidades da qualificação dos empregadores e empregados...” [1](pág. 3). No domínio da competitividade e internacionalização são apontados, no programa, dois objetivos fundamentais: “Melhoria do acesso às TIC, bem como a sua utilização e qualidade” e o “Reforço da investigação, do desenvolvimento tecnológico e da inovação”. [1](págs. 126 e 129). Neste contexto, esta dissertação surge da necessidade de se acelerar, tornar consistente e preciso o processo da inspeção automóvel, fazendo uso de uma tecnologia que se tem vindo a desenvolver, para se tornar cada vez acessível ao utilizador comum, sendo esta tecnologia as câmaras de profundidade.

O objetivo deste projeto é especificar, desenvolver e avaliar técnicas e procedimentos

de análise de vídeo e imagem para ajudar numa inspeção automóvel, tornando necessária a criação de uma aplicação que avalie as diversas técnicas de análise de imagem e vídeo e algoritmos desenhados, sendo nela integrada a tecnologia da câmara de profundidade procurando-se, desta forma, melhorar os resultados para os outros algoritmos da aplicação. Esta aplicação poderá ser, posteriormente, integrada num mecanismo que controle um braço robótico, o qual capta as imagens e vídeos automaticamente, acelerando o processo de inspeção e, conseqüentemente, a melhoria dos resultados obtidos.

### 1.2 Organização

Nos capítulos e secções seguintes, irá abordar-se a motivação, os objetivos, a definição dos problemas e a procura de soluções, tendo em consideração o ambiente em que irão ser aplicadas. Pretende-se automatizar os procedimentos na inspeção automóvel, ou seja, criar e/ou desenvolver processos que a tornem mais fiável e competitiva, com recurso a tecnologias mais avançadas. Serão descritas as diversas técnicas e abordagens, que se irão explorar e testar, de forma a se tentar obter soluções para os problemas apresentados. Serão ainda explicados os diversos testes realizados, ao longo do trabalho relacionado, com a análise dos resultados obtidos e de que forma os procedimentos e técnicas testados poderão, ou não, contribuir para encontrar as respetivas soluções.

### 1.3 Motivação

A principal motivação, inerente a esta dissertação, é a criação, utilização e combinação de metodologias e técnicas que aumentem a precisão e diminuam o tempo de processamento na análise das imagens e vídeos. Para tal, tentar-se-á integrar a informação captada por uma câmara de profundidade, possibilitando a recolha de mais e melhor informação que permita, com eficácia, a identificação de defeitos e/ou falhas nos veículos inspecionados. Assim, poder-se-á implementar a automatização da inspeção de veículos automóveis, no que respeita à deteção de defeitos ou falhas, previamente consideradas como fatores de reprovação dos mesmos.

Dado o âmbito do enorme leque de possibilidades que resultam na reprovação de um veículo automóvel, tais como deformações, fugas, problemas no motor, alterações de características, pintura, iluminação, vidros, emissão de gases, etc., cada uma das quais levanta um problema específico e, como tal, requeria uma solução específica, optei pelo enfoque, apenas, na problemática dos vidros. Sendo um componente de difícil análise no âmbito da inspeção automóvel, mesmo para o olho humano, devido às suas características específicas, como a transparência, cromaticidade, reflexão, textura e até o próprio material de construção (vidro, acrílico, revestido por películas, temperado ou não, escurecido ...), considero um desafio aliciante, para o qual procurarei apresentar soluções viáveis. Por outro lado, aquando da sujeição de um veículo à inspeção não é, ainda, obrigatório que

o mesmo esteja devidamente limpo. Dessa forma, no que concerne aos vidros, estes podem estar completamente sujos (pó, dejetos, pingos, óleos de árvores, etc.) o que dificulta, sobremaneira, a detecção de problemas associados, apenas com “olhar para os mesmos”, mesmo nas situações em que o inspetor se coloca dentro do veículo para os observar atentamente. Segundo informação do centro de inspeções, ao qual recorri para efetuar testes, nem mesmo a “visão treinada” dos inspetores consegue, em algumas situações detetar, nessas condições, situações que possam implicar a reprovação do veículo inspecionado. No processo inspetivo, não se podem separar ou desmontar componentes, como tal, também os vidros não podem ser retirados do seu local, para serem devidamente observados e previamente limpos, sobretudo se os defeitos se encontrarem localizados no campo de visão direta do condutor. Na generalidade, a reprovação prende-se com rachas ou punções que, com o veículo em deslocação, causem a degradação total ou parcial do vidro, por vibração. Estas situações aplicam-se não só ao para-brisas, como ao vidro traseiro e aos laterais.

Atualmente, a inspeção aos vidros faz-se de forma visual, pelo inspetor, o qual observa de muito perto e, sempre que necessário, no interior do veículo, todos os vidros, com especial ênfase no para-brisas e no vidro traseiro. No entanto, e tendo em consideração que um defeito num vidro frontal que, de acordo com os critérios definidos pelo IMT nesse âmbito, possa originar perturbações da visão exterior ao veículo, ou que se possa vir a quebrar durante a deslocação do mesmo (por vibração), é motivo grave e origina a respetiva reprovação, mesmo que, durante o resto do processo, não se verifiquem quaisquer outras anomalias. Este tipo de anomalia é classificado como do “tipo 3” [2]. Numa linha de inspeção, a observação dos vidros ocorre no início da mesma, durante o período de registo de emissão de gases, ou seja, logo que o veículo a inspecionar, inicie o respetivo processo. Conforme pude observar localmente, todos os vidros são verificados pelo olhar atento do inspetor, mesmo usando o toque para detetar possíveis defeitos. Conforme imanado pelo IMT, para além de outras verificações ao veículo, é apontada como obrigatória a verificação da “1 - Eficiência dos limpa para-brisas e de vidros partidos;” [3]. Neste contexto, após contacto com o IMT – Instituto da Mobilidade e dos Transportes, I.P., no que concerne ao número de veículos que reprovam por defeitos nos vidros, fui informado que não existe, a nível nacional e até à data, um levantamento eficaz e real sobre esta problemática. De acordo com o referido instituto, os dados existentes referem-se apenas ao tipo de veículos inspecionados (categorias) e por distritos, sendo a taxa de reprovação, referente ao ano de 2017, de 9,89%, dum total de 5.809.207 de veículos inspecionados. Taxa essa que engloba todos os tipos de anomalias, sem distinção, específica, de quantos o foram devidos a deficiências em vidros. No mesmo relatório, não consta qualquer referência às reprovações por defeitos em vidros, mas apenas aos principais tipos de deficiência por categoria de veículo, em 2017 (travões, direção, luzes e equipamento elétrico/eletrónico, suspensão, quadro e acessórios escape e ruídos, diversos). Apesar de estarmos em meados de 2019, cabe ainda constatar que não me foram fornecidos quaisquer dados referentes ao ano de 2018. No que respeita aos dados fornecidos pelo Centro de Inspeções de Vila Nova de

Poiares, entidade com a qual esta Faculdade possui acordo de cooperação e investigação, fui informado via e-mail, de que, e passo a citar: "em Portugal dos que reprovam, a percentagem de deficiências que reprova por danos vidros anda abaixo dos 5%.". "Não existem dados mais fidedignos, porque nesta percentagem incluem-se outros tipos de deficiência que não se relacionam com os vidros". "Por outro lado, um veículo pode reprovar por mais que uma deficiência.". "Posso adiantar que neste centro a percentagem de reprovação de veículos com deficiências nos vidros, espelhos, escovas de limpa vidros, etc. é de 1.27%.". Pode-se assim concluir que, apesar das anomalias em vidros serem consideradas graves, quando impliquem falhas na segurança dos veículos, perturbe a correta visualização do exterior ou esteja em desconformidade com as especificações técnicas, a nível nacional não está ainda aferida qual a taxa real de ocorrência de reprovações por este tipo de anomalia, nem tão pouco a sua implicação. Assim, creio que este estudo pode representar um passo significativo nesse sentido, pois automatizando-se o processo, torna-se mais fácil a recolha da informação necessária, para colmatar a inexistência de dados neste âmbito.

Neste contexto, creio que a automatização deste procedimento, poder ser uma mais valia no âmbito da inspeção automóvel.

Com a evolução tecnológica surgem novas câmaras que não só captam vídeo e imagem, mas também a profundidade, fazendo uso de algoritmos internos e de vários sensores, nelas integrados, para gerar essa informação. Pretende-se, desta forma, a incorporação desta tecnologia para, como acima referido, aumentar a precisão e analisar a melhor forma de utilização, para resolver os problemas a enfrentar. Não só poderá contribuir para o aumento da precisão dos resultados obtidos, através da análise dos dados obtidos, mas também vir a ser utilizada na deteção de falhas em veículos automóveis. Esta tecnologia, não só oferece a capacidade de captar dados em profundidade, mas devido aos diversos sensores presentes na câmara, também poderá ser extraída mais informação, a qual poderá ser usada na resolução dos problemas apresentados.

As diversas tecnologias e técnicas incorporadas, ou desenvolvidas, durante o decorrer desta dissertação têm por objetivo criar uma metodologia para se resolverem as questões formuladas ou propor técnicas que, eventualmente, venham evidenciar abordagens diferentes a explorar, na automatização da inspeção automóvel.




Figura 1.1: Exemplo de imagem de profundidade, captada com a câmara/sensor *Intel RealSense*.



Figura 1.2: Exemplo de imagem de cor, captada com a câmara/sensor *Intel RealSense*.

## 1.4 Definição do Problema

O principal problema abordado por esta dissertação é a capacidade de criar um sistema ou técnicas que permitam, não só detetar várias peças de um veículo, com mais precisão e acuidade, mas que também seja capaz de detetar as suas eventuais falhas, no contexto de uma inspeção automóvel. Como este sistema se revela de elevada dificuldade, podemos dividi-lo em vários problemas subjacentes, dos quais se referem apenas dois, pois estes, só por si, já apresentam elevada dificuldade:

1. **Deteção de de vidros automóveis:** nesta situação, teremos de conseguir detetar se existem vidros nos veículos, isto é, é imprescindível proceder, por exemplo, à deteção de um vidro lateral e se este se encontra subido ou não o que, para o ser humano, é um problema trivial. No entanto, para a tecnologia computacional atual revela-se uma dificuldade acrescida, sem o recurso a sensores especializados, sendo que a maioria dos trabalhos já desenvolvidos, nesta área, recorrem à utilização de sensores que providenciam mais dados.
  
2. **Deteção de falhas e danos em vidros automóveis:** nesta situação, também se procede à deteção de falhas nos vidros. No entanto, na visão computacional revela-se um problema difícil sem a ajuda de fatores externos, existindo falhas que, mesmo numa imagem de alta resolução, a visão humana tem dificuldade em as identificar. Sendo os vidros dos carros complexos na sua estrutura (escurecidos, temperados, antirreflexos ou mesmo acrílicos), nunca se danificam de forma semelhante, sendo necessárias técnicas que permitam identificar esses defeitos sem nos aproximarmos, em extremo detalhe, do vidro do veículo e que não levem muito tempo na inspeção automóvel. Um dos factos que podemos constatar foi a existência de determinadas falhas só poderem ser detetadas quando o inspetor se senta no lugar do condutor. Também se verificou que a própria consistência do vidro utilizado, tanto em para-brisas, como janelas ou mesmo na traseira dos veículos, pode alterar, de forma significativa, a identificação de eventuais falhas que, sendo detetadas, implicariam a reprovação do mesmo. Outra situação é o facto de que um veículo pode ser submetido a uma inspeção sem ser necessário ir limpo, isto é, em relação ao problema dos vidros, em concreto, os mesmos podem ir sujos. Tal situação pode inviabilizar e/ou dificultar significativamente a deteção de pequenas quebras ou rachas, as quais, dependendo da sua extensão e/ou localização, implicariam a reprovação do veículo inspecionado.

Os objetivos deste trabalho são encontrar soluções exequíveis para os problemas acima referidos, mas também que estas possam potenciar o desenvolvimento de novos métodos aplicáveis, noutras situações, no mesmo âmbito da inspeção automóvel. É ainda objetivo a exploração do uso da tecnologia das câmaras de profundidade, para resolução de problemas em ambientes modernos e que possam, futuramente, tornarem-se automatizados, sendo que esta tecnologia é recente, mas evidencia potencialidades neste sentido.





Figura 1.3: Exemplo de uma deformação pequena.

## 1.5 Contribuições

Considerando os objetivos referidos, as principais contribuições desta dissertação são as seguintes:

1. Um sistema que permite automatizar procedimentos no ambiente de uma inspeção automóvel, focado na deteção dos vidros;
2. Algoritmo para detetar defeitos em vidros;
3. Método baseado em vários tipos de sensores para detetar peças de automóvel;

Este ambiente requer, preferencialmente, o recurso visual, pelo que as técnicas a serem abordadas permitirão, fazer com que a tecnologia atualmente utilizada, ou similar, progridam com uso de mais informação, como a das câmaras de profundidade.

Com a incorporação da tecnologia de profundidade pretende-se que, para além da resolução dos problemas apresentados, também providencie novas oportunidades de desenvolvimento e exploração em futuras investigações, que integrem esta tecnologia ou outras em situações semelhantes.



## TRABALHO RELACIONADO

Neste capítulo são apresentados temas e conceitos relacionados com os objetivos desta dissertação. Neste contexto, foi dividido em várias secções que exploram, com maior detalhe, os problemas mencionados na introdução, desde o conceito de inspeções automáticas de automóveis, aos algoritmos de classificação.

### 2.1 Inspeção automática de Automóveis

Neste âmbito, pode dizer-se que esta área não é a mais explorada pois, dos vários documentos analisados, todos os que a focam usam sensores especializados, dentro dos veículos, para informar o operador de que existe um problema num determinado componente, pelo que os restantes procedimentos recorrem ao método tradicional, isto é, o operador a realizar inspeção manualmente e visualmente, carecendo de uma boa instrução prévia e treino visual adequado. Atualmente, a maioria dos veículos automóveis possui “centralinas” (dispositivos eletrónicos utilizados no controlo de uma grande variedade de dispositivos mecânicos e elétricos/eletrónicos de um automóvel) que informam, não só o condutor para situações referentes à própria manutenção do veículo, como fornecem informação útil que pode ser utilizada na deteção de falhas. Tais dados não podem, atualmente, ser ainda considerados para o tema em questão, pois esses dispositivos ainda não monitorizam os vidros das viaturas.



Figura 2.1: Imagem representativa de uma Inspeção Automóvel retirada de <https://www.e-konomista.pt/artigo/precos-da-inspecao-automovel/>

Para automatizar a inspeção de veículos automóveis é necessário conjugar, adequadamente, um conjunto de tecnologias e áreas científicas. É indispensável desenvolver o *software* que se responsabilize pelo controlo, análise e tratamento de dados e os mecanismos automatizados como, por exemplo, um braço robótico ou sensores mais complexos e especializados permitindo, desta forma e eficazmente, a recolha dos dados necessários ao *Software*.

No decorrer das próximas secções é focado o aspeto da análise de imagem por *Software* a desenvolver e a secção 2.4 incidirá no tema dos sensores de recolha de dados pois, sendo os automóveis objetos de elevada complexidade, torna-se imprescindível o recurso a uma diversidade de sensores especializados, eficazes e capazes de identificar, corretamente, cada um dos múltiplos componentes a analisar, centrando-nos, nesta dissertação, nos vidros.

## 2.2 Detecção de Peças Automóveis

Como descrito na secção 1.4 é relevante o tema da deteção de objetos, concretamente, as peças ou componentes automóveis. No entanto, é de salientar o facto do ambiente em que a mesma irá decorrer ser pouco favorável aos recursos tecnológicos atuais no que concerne à respetiva deteção incluindo, por exemplo, as peças que compõem um eixo.

Neste contexto, é necessário analisar, em primeiro lugar, outros problemas inerentes à sua concretização e resolução. Um dos artigos analisados [6130385] explora a deteção de objetos em ambiente doméstico, tais como livros, garrafas, latas, copos, facas, entre outros. Neste artigo foram analisadas diversas técnicas para melhorar a precisão e análise dos resultados, uma vez que para proceder à respetiva identificação foram usados

vários descritores para ambos os dados, 2D e 3D, com o objetivo de se complementarem. Procederam à avaliação da performance de cada descritor usado e da combinação destes comparado com os resultados base de outros já mais conhecidos, pelo que, em primeiro lugar, foram criados e treinados classificadores SVM para uma única característica e para uma única classe de objeto, ou seja, sendo  $n$  número de classes e  $d$  o número de características no total foram criados  $n \cdot d$  classificadores. De seguida foi usado um MLP (*MultiLayer Perceptron*) para o qual os resultados dos classificadores singulares são usados como amostras de treino, sendo os resultados obtidos, na globalidade, os apresentados na tabela seguinte, retirada do trabalho de *Browatzki et al* [6130385]:

Descriptor	Performance
SURF	42.4%
PHOG	69.9%
Self-Similarity	41.7%
Color	26.6%
2D only	66.6%
Shape Distributions	25.4%
Shape Index	34.6%
Shape Context 3D	55.2%
Depth Buffer	72.9%
3D only	74.6%
2D + 3D	82.8%

Figura 2.2: Tabela retirada de “*Going into depth: Evaluating 2D and 3D cues for object classification on a new, large-scale object dataset*”[6130385]

Outro artigo [Jordan2013FeatureEF] mostra a identificação de objetos domésticos usando um conjunto de 51 categorias dos mesmos, com cerca de 300 vídeos de diferentes objetos, onde cada imagem do vídeo associado a cada objeto contém um mapa de profundidade e uma segmentação *Ground-Truth* dos pixels pertencentes ao objeto da imagem. Com esta informação são extraídas duas características de base usando HOG, sobre a escala de cinzento da imagem RGB e sobre o mapa de profundidade associada a cada imagem sendo, seguidamente, extraídas outras duas características, uma com base na geometria local usando janela deslizante e outra baseada na distribuição da forma e de pares de pontos. Cada característica é obtida pela amostra de um par de pontos na nuvem de pontos e é gerado o histograma sobre diferentes atributos. Depois de terem sido gerados os descritores foi usado o algoritmo SVM para realizar a classificação tendo-se, nesta situação, utilizado um subconjunto de treino, com 1000 amostras, de um conjunto de 5000 itens.




Figura 2.3: Resultados 1 de “*Feature Extraction from Depth Maps for Object Recognition*”[Jordan2013FeatureEF]

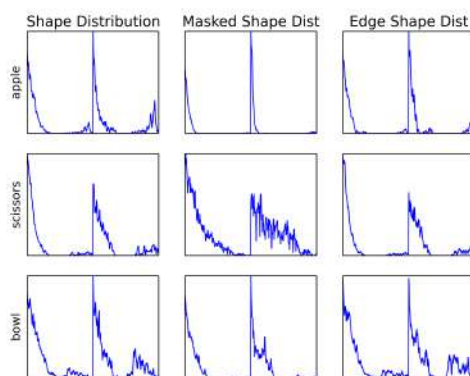


Figura 2.4: Resultados 2 de “*Feature Extraction from Depth Maps for Object Recognition*”[Jordan2013FeatureEF]

Tal como nestes artigos, que analisam a detecção de objetos usando as câmaras de profundidade, existem outros, como o artigo [4], nos quais se exploram a extração de características com recurso à nuvem de pontos e mapas de profundidade para serem usadas na classificação dos objetos. Destas caraterísticas, usando a informação captada pela câmara extraem-se a forma, os contornos, a rotação e o tamanho dos objetos. Como referido no artigo [4], depois de se extraírem as caraterísticas, estas eram testadas usando *SVM* linear pelo que, numa fase posterior, este classificador era outra vez implementado mas, em vez de se usar um descritor com uma única caraterística, eram usados *PyramidEMK* (*Efficiente Match Kernel*) que permitiam agregar a descritores de *kernels* locais, em caraterísticas a nível de objeto. Este procedimento possibilitou que os classificadores lineares tivessem um desempenho muito próximo de um algoritmo não linear, o que também permitiu que o sistema referido trabalhasse com uma grande base de dados.

Approaches	Depth	RGB	Depth+RGB
LinSVM [14]	53.1±1.7	74.3±3.3	81.9±2.8
kSVM [14]	64.7±2.2	74.5±3.1	83.8±3.5
RF [14]	66.8±2.5	74.7±3.6	79.6±4.0
This work	78.8±2.7	77.7±1.9	86.2±2.1

Figura 2.5: Tabela de resultados retirada de “*Depth Kernel Descriptors for Object Recognition*”[4]

Como já foi referido pelo [6130385] não existe grande escolha de descritores para um mapa de profundidade, pelo que muitos recorrem às técnicas de processamento de imagem usadas para processar imagens normais, como citado em [5], onde são explorados diferentes descritores *SIFT* na sua variante para o *3D*. No artigo, a variante do *SIFT* extrai características como o volume ou nuvem de pontos, pois estes dependem, diretamente, da geometria do objeto. Também é focado o problema de reconhecimento genérico de objetos e para o resolver é usado o algoritmo de classificação *SVM*. O conjunto de treino utiliza dois tipos de informação:

1. Representação de modelos *3D* em nuvem de pontos, de diferentes objetos pertencentes a diferentes categorias (classes), sendo identificados pelo descritor *3D SIFT*, adaptado à nuvem de pontos.
2. A inclusão de imagens *2D*, incluindo alguns objetos, previamente categorizados pelo seu descritor *2D SIFT*.

No final, os resultados mostram que a fusão de descritores *2D+3D SIFT* revela os melhores resultados de todas as técnicas exploradas.

## 2.3 Detecção de Falhas

Nesta secção irá ser abordada a necessidade da utilização de diversas técnicas para detetar os diferentes problemas referidos na secção 1.4.

Para se poder detetar os diferentes objetos é necessário usar algoritmos que consigam interpretar a informação *2D* e *3D*. Para tal, existem diversas técnicas de extração de características e criação de descritores, permitindo que a informação, *2D* e *3D*, seja interpretada computacionalmente. A tabela referida em [6130385], apresenta os descritores e características mais comuns no tratamento de informação de imagens *2D*, sendo que, para a informação *3D*, como é referido pelo [6130385] não existem muitas alternativas, originando a extração de características diferentes da norma, como referido em [Jordan2013FeatureEF].

Devido ao facto das situações mencionadas, nos artigos analisados, se focarem na identificação de diferentes objetos e não na detecção das respetivas falhas, torna-se necessário explorar diversas técnicas que permitam não só identificar as diferentes peças, mas também as suas eventuais falhas, como deformações e fissuras.

### 2.3.1 Deformação

A deteção de defeitos ou deformações é, normalmente, realizada em ambiente de fabrico, pelo que, num ambiente mais adverso, essa deteção, na parte inferior do veículo, se revela complicada, até mesmo na identificação das peças, pois estas podem encontrar-se cobertas de materiais, como lama e óleo, que podem fazer com que o processo de identificação não seja bem-sucedido, ou crie falsos positivos.

Devido ao facto da deteção de deformações de peças se revelar de extrema dificuldade, o processo deverá iniciar-se pela análise da carroçaria do veículo, com recurso à informação *3D*, ou seja, mapas de profundidade. Tal como referido em [6], é explorada a deteção de falhas na carroçaria do automóvel com a referida tecnologia, com o objetivo de identificar diferentes tipos de defeitos, desde deformações a marcas de pressão. Para a classificação das diferentes falhas foram explorados diversos algoritmos de classificação que usaram 58 características para cada defeito, extraídas da informação *3D*, sendo depois processadas usando algoritmos de árvores de decisão e o algoritmo “*NEFCLASS*” [7]. Este último foi desenhado com o objetivo de ultrapassar a dificuldade de interpretação das redes neuronais, pois faz uso de um sistema “*fuzzy*” para representar a informação da rede neuronal de uma maneira compreensível, conseguindo superar as principais desvantagens das diferentes abordagens, o que revelou melhorar os resultados da classificação dos defeitos.

### 2.3.2 Vidros

Como já referido na secção 2.1, a deteção de vidros é um problema complexo e de difícil implementação, para a qual nem o recurso à tecnologia de informação *3D* revela ser eficaz pois, na maioria das situações de trabalho, os sensores da câmara de profundidade, os sinais ou ondas emitidas, pelos sensores da câmara de profundidade, atravessam o vidro, sendo necessário recorrer, maioritariamente, à informação *2D* para obter os resultados pretendidos. Quando é aplicado o descritor *SURF* ou *SIFT* num vidro, podemos constatar que os pontos de interesse, calculados pelo algoritmo, são os cantos, um qualquer reflexo, um defeito no vidro e, até mesmo, objetos no interior do veículo.





Figura 2.6: Vidro lateral de um veículo que se encontra danificado.

Esta situação gera outro problema na tentativa da deteção de falhas. Como os descritores e classificadores mostram a presença de diversos pontos de interesse na imagem, não se consegue realizar uma comparação concreta, sem que se criem falsos positivos na deteção da presença do vidro e, ainda mais complicado, na presença de falhas. Um reflexo ou um objeto, no interior do veículo, pode revelar pontos de interesse muito similares aos de um objeto completamente diferente. Por isso, temos de recorrer a técnicas que permitam, em primeiro lugar, remover a informação desnecessária, para se obter, apenas, a que permita obter o resultado pretendido. Frequentemente, recorreu-se ao método de tentativa/erro, como forma de decidir quais os dados a eliminar e a manter, operações que requerem elevado consumo de tempo. Mas como mostra o artigo [8] a deteção de falhas poderá ser realizada usando uma técnica simples como a incidência de uma luz, num determinado ângulo, que faz com que os defeitos tenham um contorno mais definido, permitindo a sua identificação e respetiva classificação, em riscos ou bolhas, usando algoritmos que permitem extrair as arestas presentes numa imagem. Outros mostram que, ao se aplicarem algoritmos simples para se realçar os contornos da imagem, estes podem ajudar a identificar os defeitos presentes num objeto transparente, como mostra o artigo [9] no qual se aplicam operações de contraste, *sharpenning* e finalmente de *thresholding* para os defeitos se mostrarem realçados. Nestes artigos, os testes são realizados em ambientes ideais, quer isto dizer, são testados em ambientes no qual o vidro ou objeto transparente não apresenta nada por detrás de si, o que ajuda, significativamente, na identificação dos defeitos. Não obstante, este procedimento é praticamente inviável num ambiente de inspeção automóvel, pois o vidro não pode ser removido da viatura e analisado separadamente e o mesmo poderá apresentar-se sujo com pó, salpicos de água, lama ou outras substâncias, inviabilizando a identificação e a deteção de eventuais falhas significativas. Tais situações também as pudemos constatar, in loco, tendo os inspetores recorrido à

sua visão experiente e treinada para aferirem a gravidade, ou não, dos problemas apresentados pelos vidros, entrando dentro dos mesmos, de forma a obterem perspectivas de visualização diferentes das do exterior da viatura e decidirem, face ao observado, se as falhas são ou não motivo de reprovação.



Figura 2.7: Vidro dianteiro de um veículo que se encontra danificado.

Contudo, é necessário abordar, em primeiro lugar, o problema de identificação da presença do vidro. Neste contexto, pode-se fazer referência ao trabalho no artigo [10], no qual, para o problema da identificação de um espelho ou de um objeto transparente, se recorre à utilização de um ou mais sensores laser de forma a medir a distância e, dessa forma, identificar a sua presença. Mais concretamente, é utilizado um sensor laser que permite recolher informação nas três dimensões, permitindo ao pequeno autómato desenvolvido navegar pelo espaço.

Existem ainda projetos que permitem realizar uma identificação de zona de reflexos, sendo os vidros uma destas zonas, como o artigo [11], no qual são analisados vídeos e se tentam identificar as zonas com reflexos usando técnicas de separação em camadas. Uma das técnicas de separação de camadas referidas, tenta decompor a imagem que contém o reflexo em duas camadas independentes. Tal procedimento é obtido trocando informação entre as duas camadas, até se conseguir uma independência máxima. Outras, usam informação temporal e um fundo fixo para identificar os reflexos. No artigo [11] usam a independência de cor para criar a separação em camadas, isto é, focam-se na camada da cor vermelha e azul. Desta forma são criadas diversas camadas, sendo apenas escolhidas as que têm um número menor de cantos, detetados pelo método de *Harris* [12]. Esta técnica revela-se interessante, pois requiere apenas uma imagem. Essa técnica é então usada num algoritmo complexo, denominado de *BIRD* (*Bayesian Inference for Reflection Detection*). Este algoritmo mostra-se promissor, pois apresenta uma taxa de identificação

correta do reflexo muito maior e superior às técnicas anteriores.

Existem ainda artigos, como [13], que analisam a detecção de objetos transparentes usando grelhas de gradientes, nas quais são captadas diversas imagens do objeto, em diferentes perspectivas, num fundo preto, sendo depois calculadas as suas orientações de gradientes que, posteriormente, são quantificadas para ajudarem na criação de um modelo, para essa perspectiva, que contém as orientações quantificadas mais presentes. Depois do treino, em que são criados os modelos, é realizada uma passagem numa imagem nova, onde se calculam as orientações dos gradientes e a pontuação de semelhança com os diversos modelos, até se obter uma caixa de limites à volta do objeto transparente.

## 2.4 Sensores e Dados 2D/3D

O sensor principal, no qual esta dissertação se foca, é o de profundidade ou 3D. Este dispositivo permite criar um mapa de pontos com profundidade ou até realizar uma reconstrução tridimensional e possibilita o aumentar a precisão da detecção de componentes, pois permite adicionar características aos descritores que são enviados para os algoritmos de classificação [6130385, Jordan2013FeatureEF]. Este dispositivo é composto por um conjunto de sensores que processam a informação obtida para criar a informação de profundidade. É possível a exploração individual dos sensores, de forma a se recolher mais dados que possam ser úteis na resolução de problemas, focando nos sensores que conseguem captar os infravermelhos emitidos pelas câmaras *Kinect* e *Intel RealSense D435* e *D415*.

Sensores que permitem captar imagens *RGB-D* (*Red, Green, Blue, Depth*), como o *Microsoft Kinect* (*Microsoft, 2011*), são explorados em vários trabalhos relacionados com o reconhecimento facial, sendo um destes trabalhos o [14], no qual são tomados diversos passos para rentabilizar, ao máximo, a informação disponibilizada pela nuvem de pontos. É também explicado que o reconhecimento facial funciona bem se a face estiver diretamente voltada para a câmara. No entanto, é também objetivo da utilização desta tecnologia a identificação nos casos em que não seja possível a identificação frontal, isto é, identificar independentemente do ângulo de visualização. Para tal, é realizado pré processamento sobre a informação *RGB-D*, sendo a profundidade um dos pontos mais focados durante esse procedimento, ao qual são aplicadas diversas técnicas para melhorar esta informação. Trabalhos recentes vêm demonstrando a utilização de imagens *Red, Green, Blue e Depth* (*RGB-D*) para análise de detecção e reconhecimento de faces [15]. Esta conceção pode, potencialmente, vir também a ser utilizada em ambiente de inspeção de veículos automóveis.

Outro sensor que revela ser uma ajuda potencial para a detecção da presença de vidro ou, inclusive, fornecer novas informações para os descritores, é o sensor laser. Sensores laser, normalmente, requerem um recetor o que pode revelar-se inconveniente num ambiente de inspeção automóvel. Como tal, também se pode analisar o uso de ultrassons

pois estes mostram grande precisão na identificação de obstáculos nas suas diversas aplicações, tal como em drones, para sistemas de navegação automática. Existem também câmaras térmicas ou de infravermelhos que podem recolher mais informação sobre a presença de falha num componente automóvel, como a ferrugem. Estes dispositivos optoelectrónicos são destinados a perceber imagens na faixa de radiações infravermelhas do espectro eletromagnético e convertê-las, de forma sistemática, para a faixa visível do espectro. Também se pode recorrer a uma câmara multiespectral pois, como o nome refere, é uma câmara que consegue captar imagens em vários comprimentos de onda e, com esta capacidade, obtêm-se mais dados para serem usados nos algoritmos de classificação e deteção de falhas.



Figura 2.8: Exemplo de câmara Multiespectral, Sensor Câmera Multispectral Parrot Sequoia.

## 2.5 Extração de Caraterísticas e Classificação

Como referido nas secções anteriores, para se poder reconhecer as peças de automóvel e defeitos é necessário extrair caraterísticas da imagem, sendo essa informação colocada numa estrutura de dados a que chamamos descritor, para que os algoritmos possam determinar e, assim, processar a imagem corretamente. É importante referir que os descritores se referem a diversos aspetos da imagem, não apenas pela sua cor.

Existem caraterísticas que podem ser extraídas diretamente da imagem, sem ser aplicada mais do que uma técnica ou algoritmo, pelo que se denominam de caraterísticas de baixo nível (*Low-level Features*). As caraterísticas que só conseguem obter depois da aplicação vários algoritmos ou técnicas são designadas de caraterísticas de alto nível (*High-level Features*).

### 2.5.1 Textura

A textura pode ser usada para discriminar, com maior exatidão, objetos e defeitos nos vidros pois a sua variação pode representar objetos diferentes e diferentes tipos de defeitos

nos vidros. Para extrair esta característica são usadas técnicas como a detecção de arestas, ou seja, técnicas similares às da detecção de forma, mas com modificações que permitem compilar a informação que, realçando-as, podem depois ser comparadas com texturas já conhecidas.

Esta característica é, normalmente, usada em conjunção com outras características para melhorar a precisão das comparações e, assim, poder chegar ao resultado pretendido.

Para se extrair a textura, recorre-se a variações das técnicas usadas para determinar a forma (*Edge Detection*), ou seja, são aplicadas com pequenas alterações de parâmetros ou a detecção de arestas é aplicada a uma porção mais pequena da imagem, para ressaltar arestas que podem ajudar a definir a textura. Como os resultados destas técnicas revelam muitas das arestas presentes na imagem permitindo a recolha desta informação sobre a presença das arestas orientação das mesmas permitindo realizar uma comparação entre as informações recolhidas.

Existem também diversos artigos nos quais se exploram novas metodologias para extrair a textura numa imagem, como referido em [16], onde foi investigado um método baseado num modelo de campo de textura estocástico.

Uma das técnicas mais usadas para a extração da textura é a aplicação dos filtros de *Gabor* [17] que são um conjunto de filtros com várias orientações e frequências que, ao serem aplicados a uma imagem ou vídeo, podem originar várias respostas recolhendo-se, dessa forma, mais informação que pode ser processada.




Figura 2.9: Exemplos de aplicação filtros de *Gabor*.



### 2.5.2 Forma

Uma das características que se pode extrair de uma imagem são as formas que a compõem. Estas podem ser comparadas para determinar se é, ou não, o objeto ou componente pretendido. No entanto, como as imagens não são captadas sempre na mesma perspetiva, a forma não é suficiente para uma correta identificação. Outro problema decorrente de só usar a forma como característica, prende-se com o facto de um objeto, num determinado ângulo de visualização, poder revelar outro objeto diferente, como é referido em [6130385], em que a forma de um pacote de leite se aproximava, visualmente, à de uma lata, causando falsos positivos na identificação. O problema foi resolvido com a incorporação da informação 3D, pois esta informação é colocada no descritor para ajudar a fazer uma melhor distinção entre os objetos.

Existem várias técnicas que nos permitem discriminar a forma de um objeto. Servem, como exemplo, as seguintes:

- **Hough Transforms**[18]: utilizada para isolar características de uma determinada forma numa imagem. Como esta técnica requer que as características pretendidas estejam previamente especificadas, inicialmente, focava-se em encontrar curvas regulares, como linhas, círculos ou elipses. A principal vantagem desta técnica é ser tolerante a lacunas nas descrições do limite das características e pouco afetada pelo ruído da imagem, factos que podem ajudar na obtenção de melhores resultados no âmbito deste estudo;
- **Sobel**[19]: esta técnica e subsequentes implementações são usadas para ressaltar as arestas numa imagem usando dois *kernels*, ou seja, a imagem gerada, depois da aplicação da técnica, resulta numa imagem a preto e branco em que as arestas se encontram a branco, ou preto dependendo de como o filtro seja aplicado, o que permite determinar a forma dos objetos presentes na imagem;
- **Canny**[20]: como no filtro *Sobel*, esta técnica permite fazer sobressair as linhas presentes numa imagem, mas enquanto o *Sobel* apenas realiza a aplicação dos *kernels* pela imagem, o *Canny* usa muitos mais passos para se tentar aproximar de resultados ótimos, passando pela aplicação de filtros para remover ruído e encontrar a intensidade dos gradientes da imagem.

### 2.5.3 Cor

Outra característica de importante relevância é a cor. Esta pode ser usada para determinar se um determinado objeto se encontra presente, realizando a segmentação da imagem de acordo com histogramas para os diferentes componentes da cor, o *RGB*. Revela-se ainda importante na deteção de certas falhas, como a deterioração da pintura e a existência de irregularidades ou riscos, pois permite-nos determinar a zona exata onde se encontram e qual a sua extensão.



Figura 2.10: Imagem original da válvula.




Figura 2.11: Exemplo de aplicação do *Canny*.




Figura 2.12: Exemplo de aplicação do *Sobel*.

Esta característica é usada, na sua máxima potencialidade, na deteção de matrículas automóveis como refere o artigo [21], pois é possível delimitar a zona da matrícula. De acordo com o mesmo documento, pode-se converter a imagem para uma escala de preto e branco, de seguida calcularem-se os histogramas, tanto na vertical como na horizontal e, de acordo com esses histogramas, proceder-se à segmentação para se poder delimitar a zona da matrícula. Finalmente é realizada outra segmentação para conseguir extrair as informações nelas contidas, uma vez que, para se determinar a letra ou número se poderá usar um algoritmo de classificação, como o *SVM*, para a respetiva identificação. Todos estes procedimentos podem ser realizados apenas com a informação da cor e a informação dela derivada.

E como já foi referido no artigo [11] a cor mostrou ser uma das características mais interessantes a explorar, revelando a possibilidade de se extrair e criar nova informação para resolver o problema em comparação às técnicas já existentes proporcionando um aumento da precisão e exatidão dos resultados obtidos.

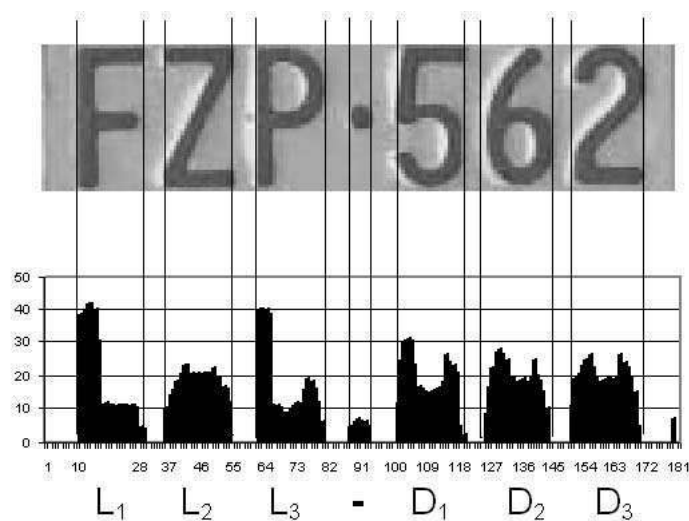


Figura 2.13: Exemplos de segmentação de uma imagem.

### 2.5.4 Pontos Chave

Os *keypoints* ou pontos-chave, numa imagem, são extraídos para ajudar no seu reconhecimento pois, tal como se pode inferir se uma imagem contém o mesmo objeto, também esse deve conter os mesmos pontos de interesse, ou seja, o uso destas técnicas na deteção de pontos de interesse torna-se crucial para a deteção de objetos.

Existem várias técnicas para a extração de pontos-chave numa imagem onde, na maioria dos artigos analisados, são usados os seguintes:

- **SIFT (Scale-invariant feature transform)** [22]: Este algoritmo permite a extração de pontos-chave independente da escala, rotação e localização na imagem, criando um descritor que permite uma comparação mais precisa e independente. O algoritmo tem diversas partes pelo que começa por construir a escala de espaço. Nesta fase é criada uma representação interna da imagem original para assegurar a invariância de escala. De seguida é usado a técnica “*Laplacian of Gaussian*” ou *LoG*, que revela ser eficaz na deteção de pontos-chave. De forma a não ser exigida grande performance computacional é utilizada a representação criada na fase anterior para gerar uma nova imagem. É efetuada a deteção de pontos-chave fazendo a diferença Gaussiana máxima e mínima, com a imagem calculada no passo anterior. São depois eliminados os pontos-chave indesejados, como pontas ou zonas de pouco contraste e, seguidamente, é calculada a orientação dos diversos pontos-chave, tornando assim invariante para a rotação da imagem. No final é gerada mais uma representação, com o objetivo de ajudar a encontrar objetos chave na imagem. Este algoritmo também permite, em tempo real, ver os resultados da identificação de objetos como é mostrado pelo artigo [23], no qual o algoritmo é modificado para acomodar computação em paralelo diminuindo, dessa forma, o tempo de processamento e acelerando a resposta.






Figura 2.14: Exemplo de aplicação de *SIFT* retirado da documentação do *OpenCV*.

- ***SURF (Speeded-up robust features)*** [24]: Este algoritmo foi parcialmente inspirado pelo *SIFT*, mas tentando ser mais rápido e robusto. Para tal, recorre a uma aproximação do detetor de *Blob* que usa o determinante de *Hessian*, que pode ser computado em três operações inteiras, dando origem a um descritor com base na soma das *Haar wavelets* à volta do ponto de interesse. Como descrito, um dos possíveis benefícios do uso deste algoritmo é a possibilidade de acelerar o processamento para a deteção.
- ***ORB (Oriented FAST and rotated BRIEF)*** [25]: Este algoritmo foi desenhado com a conjunção de dois outros, *FAST* e *BRIEF*, tendo como parte crítica a recuperação de variância e por isto faz com que a pesquisa “*Nearest neighbor*” seja mais eficaz. Em testes revelou ter um desempenho, a nível de identificação e de tempo de execução, um pouco superior ao *SIFT* e *SURF*, mas que não tem escala invariante, pelo que o torna indesejado, caso o problema envolva a deteção de objetos em imagens em que estes apareçam em diferentes escalas.

### 2.5.5 Algoritmos e técnicas de Classificação

Durante o decorrer das secções anteriores foram referidos os descritores que se podiam criar para alimentar os algoritmos de classificação. Estes algoritmos permitem, com um específico input e com um conjunto de categorias, saber se o input pertence a uma determinada categoria, com base na existência de um conjunto de treino, do qual sabemos as categorias de cada objeto desse conjunto. Existem diferentes tipos de classificação:

- **Binária:** a classificação é feita com base numa combinação linear das características, ou seja, para um determinado *input* extraem-se as características e, posteriormente, as mesmas informam se ele pertence a uma categoria ou a outra.
- **Multi-Classe:** ao contrário da linear não é só usada uma ou duas categorias, podendo-se utilizar duas ou mais classes. Para este tipo existem implementações que são extensões do binário, ou seja, são construídos com base em várias camadas de modelos binários.

### 2.5.5.1 SVM (*Support vector machine*)

Um dos algoritmos mais usado é o SVM [26] que é um algoritmo de classificação, com modelo de supervisão, o qual analisa informação usada para a classificação. Detalhadamente, um algoritmo SVM tem por base a criação de um *hiperplano*, que é um subespaço do espaço à sua volta, ou seja, imaginando que se pretende classificar pontos num plano 2D em duas categorias como **0** e **1** a *hiperplano* é uma reta, nesse plano, que divide os pontos nas duas categorias. O algoritmo depois determina se os pontos dados por input são colocados por cima ou por baixo da linha de acordo com uma margem, que é calculada como a distância perpendicular da linha até aos pontos mais próximos do input. Os pontos que ajudam na classificação dos outros é que são designados por Vetores de Suporte.

Existem diversas variações do modelo SVM com potencial de exploração e que poderão apresentar diferentes benefícios, como é referido no artigo [4], no qual, para além de usar o modelo linear, utilizam também o modelo não linear. Neste último são usados núcleos de operações mais complexas, que podem incluir uma operação polinomial ou um cálculo de uma tangente hiperbólica.

### 2.5.5.2 Modelo de Rede Neuronal YOLO (*You Only Look Once*)

Uma técnica que tem vindo a revelar resultados excelentes para a classificação de objetos complexos é o YOLO [27]. Esta rede foi desenhada para ser simples, em comparação com outros algoritmos de classificação, a qual se baseia numa *Convolutional Network*, simultaneamente cria múltiplas camadas de enquadramento e calcula as probabilidades das classes desejadas. Revela-se uma técnica rápida [28], pois o problema da deteção é encarado como um problema de regressão, pelo que não é necessário um pipeline complexo. Ao realizar a previsões, o YOLO analisa a imagem na globalidade, ao contrário das técnicas janela deslizante e proposição regional. Este procedimento permite que se guarde, tanto informação contextual sobre as classes, como a sua aparência, proporcionando a representação dos objetos de uma forma generalizada. Embora se mostre mais rápido na identificação, ainda revela falhas na precisão da localização dos objetos.

Esta técnica mostra potencialidade para resolver problemas na área da inspeção automóvel, pois como adquire a capacidade para aprender objetos, numa forma generalizada, pode ajudar na identificação de peças que estejam escondidas ou parcialmente obstruídas por outras peças, permitindo assim, realizar uma identificação, posteriormente, mais precisa. Também poderá ajudar na identificação de defeitos, pois ao analisá-los na sua generalidade, muitos poderão ser identificados.




Figura 2.15: Exemplos de resultados do uso da rede neuronal *YOLO*, retirado de [29].

## 2.6 Conclusões

Tendo em consideração as técnicas referidas no decorrer deste capítulo e nos diversos artigos nele explorados, existem outras que permitem novas abordagens para a resolução do problema da deteção do vidro do automóvel. Uma delas é a utilização do *YOLO* que, como já referido, se tem revelado muito promissora nas áreas de processamento de imagem. Outros procedimentos, que se mostram promissores para a identificação do vidro, passam pelo uso de sensores adicionais, como o de ultrassom, pois muitos dos trabalhos explorados só alcançaram uma solução viável, depois de se ter conseguido extrair mais informação sobre a imagem ou ambiente circundante, incluindo também a informação disponibilizada pela câmara de profundidade. As técnicas exploradas, nos artigos relacionados com a identificação de falhas em superfícies, transparentes ou semitransparentes, apontam métodos que poderão ser aplicados para encontrar a solução deste problema, sendo que estas se enquadram num contexto ainda pouco explorado. Essas técnicas recorrem à extração da forma ou ao tratamento de imagens, usando métodos de binarização, de realce de contornos ou focagem, em determinados tons de cor.



## DESENVOLVIMENTO

Sendo o objetivo principal desta dissertação a deteção dos vidros e respetivos defeitos, tendo em consideração as suas características especiais e já referidas, continua a ser um desafio constante a problemática da sua deteção. Consequentemente, a verificação de defeitos ou falhas que impliquem, em ambiente de inspeção automóvel, a reprovação do veículo a que pertence, é também um problema complexo e ainda pouco estudado. Pretende-se, num automóvel, que os vidros utilizados sejam transparentes, isentos de distorções, ou deformações que inviabilizem a correta visão e perceção, pelo condutor, do que se passa no exterior do veículo que conduz. Por outro lado, têm que ser resistentes à pressão atmosférica exercida pelo movimento do ar em movimento e ainda resistirem às vibrações a que o veículo é sujeito. Podem-se apresentar em várias tonalidades de escurecimento, por vezes, com uma coloração diferente na parte superior do para-brisas. A sua construção é reforçada com duplo laminado, ou seja, duas camadas distintas e sobrepostas, as quais se podem danificar independente uma da outra. Têm ainda que ser resistentes a impactos exteriores, os quais lhes podem causar diversos tipos de danos, consoante a força com que são atingidos: pequenos orifícios (punções), quebras horizontais e/ou verticais, profundas ou não. Qualquer tipo de dano num vidro automóvel, pode repercutir-se apenas numa das camadas de que é composto ou afetar as duas. São, normalmente, os impactos que danificam ambas as camadas, que originam a quebra total ou parcial dos mesmos, ainda que, inicialmente, isto é, no momento do impacto, tal possa não suceder. Sabe-se que tanto os para-brisas como os vidros traseiros dos veículos automóveis têm de ser vidro a 100%, O mesmo pode não suceder com os laterais, nas portas das viaturas, os quais podem ser em acrílico, desde que sejam originais na construção do veículo.

### 3.1 Deteção do vidro

Focando na deteção do vidro, foram aplicados algoritmos que pretendiam trazer a solução para a sua identificação. No entanto, este problema revelou-se mais difícil e complexo que o inicialmente previsto, pois não existem características específicas e significativas que permitam identificar, concretamente, a presença de um vidro numa imagem. Assim, foram experimentados os seguintes procedimentos:

#### 3.1.1 Através de um reflexo




Figura 3.1: Padrão utilizado durante o trabalho realizado.

Um vidro automóvel, para além de ser transparente, possui também um elevado grau de reflexão, donde a maioria das imagens, deles captadas, contêm uma grande quantidade de reflexos, os quais levantaram a hipótese de poderem vir a ser úteis na sua deteção. Neste contexto, foi pensado como se poderiam utilizar como uma ferramenta para encontrar a solução, ao invés de estes provocarem ruído indesejado. Com este intuito, foi idealizada a possibilidade de se utilizar um padrão, o qual, sendo refletido no vidro, seria depois seguido, usando um algoritmo de seguimento, o *KCF* (*Kernelized Correlation Filter*), que, de acordo com [30] se mostrou o mais preciso. Esta abordagem, a de seguir um padrão refletido no vidro, mostrou que era possível fazer o varrimento da área do vidro e, sempre que o mesmo deixasse de ser reconhecido (zonas de não reflexão), seria realizada uma comparação dos modelos (*Template Matching*) com a imagem do padrão, previamente gravada, de forma a se recuperar o respetivo seguimento pela área do vidro, ou seja, no retorno do seu reflexo ao vidro. Esta abordagem tinha como objetivo poder identificar a área completa de qualquer vidro do automóvel.

Com o objetivo de melhorar os resultados da deteção, seguimento e recuperação do reflexo do padrão, na superfície do vidro, recorreu-se aos algoritmos de extração de pontos-chave. Para tal, foi aplicado o *SURF*, pois mostrou ser o mais rápido para desempenhar

essa tarefa. Este procedimento foi explorado com o intuito de se poder melhorar a precisão no seguimento e não ser necessário realizar a respetiva recuperação, isto é, sempre que o padrão deixasse de ser reconhecido pelo algoritmo utilizado. Não obstante os testes realizados, em muitas das implementações efetuadas nos algoritmos de seguimento, na biblioteca *OpenCV*, com exceção do *KCF*, também se verificou que o seguimento do reflexo do padrão era perdido, sobretudo em superfícies refletoras que não os vidros.

Os desenvolvimentos das abordagens anteriores revelaram-se promissores, mas também demonstraram que poderiam ocorrer falsos positivos na identificação do vidro, pois quase todos os automóveis apresentam superfícies não envidraçadas com grande taxa de reflexão (pintura da carroçaria) e muitos dos que apresentam a pintura modificada (antirreflexo), não de origem, não são elegíveis para inspeção automóvel. Perante este desafio, foi explorado o uso da técnica *YOLO* para se demarcar, em primeiro lugar, a área do vidro, sendo, posteriormente, detetada a presença dum padrão nessa área, confirmando assim a sua presença. Para esse efeito foram colecionadas 562 imagens do vidro dianteiro de vários automóveis de diferentes modelos e marcas onde, em aproximadamente metade dessas imagens capturadas, se encontrava refletido o padrão, para se realizar a identificação do vidro, tendo sido depois analisadas uma a uma para criar a base de verdade ou *groundtruth*. Aplicando o *YOLO*, foi executada a fase de treino, usando a caixa de ferramentas "*darknet*", até às 30000 iterações, tendo em consideração que a quantidade de imagens utilizadas era reduzida, para o algoritmo atingir a taxa de erro mínima.

### 3.1.2 Através de multisensor



Figura 3.2: Combinação dos sensores *Intel RealSense* e *TeraRanger DUO*.

Estas abordagens não fazem uso da capacidade da câmara de profundidade para criar o mapa de profundidade, mas só da imagem *RGB*, por esta gerada, para realizar a deteção do vidro. O problema do recurso aos parâmetros de profundidade, num vidro, prende-se com o facto de que os valores obtidos na medição da distância, não são os valores da distância real do sensor ao vidro, mas sim aos objetos atrás deste, ou até mesmo erros de leitura de profundidade. Perante este problema, que os vidros apresentam aos mapas de profundidade, foi necessário acrescentar a captação de informação adicional. Para tal,

foi introduzida a informação proveniente de um sensor de ultrassons, o qual permitiria captar a distância correta, a que o vidro se encontrava.

Com a introdução do sensor de ultrassons, na solução, foram desenhadas abordagens nas quais se utilizou a medida do retorno do mesmo, como dados fidedignos para a determinação da presença, ou não, de vidro. Na primeira abordagem, foi realizada a captação da nuvem dos pontos, sendo depois analisada uma área central desta. Seguidamente, realizou-se uma média dos valores presentes na mesma, sendo o valor resultante comparado com o valor devolvido pelo ultrassom, determinando-se, desta forma, a presença de um objeto transparente, ou vidro, em frente ao conjunto de sensores. A abordagem anterior foi então modificada e melhorada, para se poder realizar a deteção de vidro, não só do dianteiro do automóvel (para-brisas), mas também dos laterais e do traseiro.

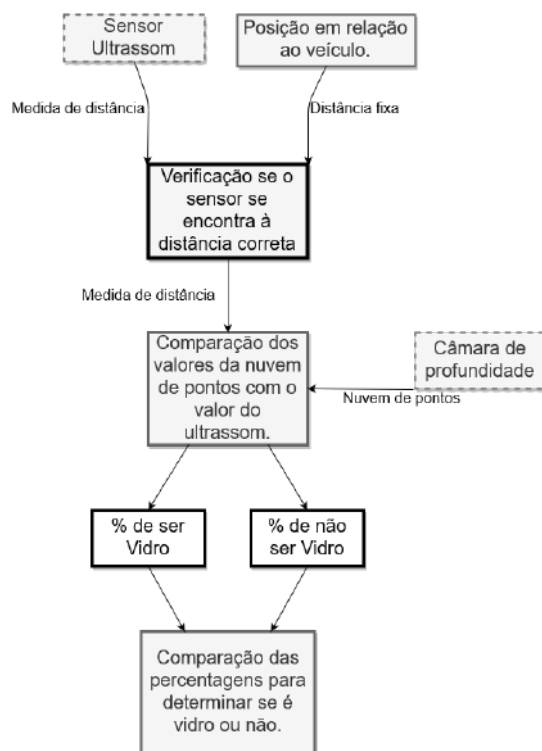


Figura 3.3: Diagrama representativo dos passos no algoritmo.

Para os testes em causa, assumiu-se que os sensores foram posicionados a uma distância fixa dos vidros, nomeadamente: 50cm dos vidros laterais; 1,75m ou 1,70m do para-brisas (consoante a dianteira do veículo) e 75cm do vidro traseiro. Neste contexto, é então captada a nuvem de pontos e a distância medida pelo ultrassom, sendo depois realizada a seleção de valores na área central da nuvem. Conforme o estipulado, é então realizada uma contagem dos valores que se apresentam acima do apresentado pelo ultrassom, obtendo-se assim a percentagem provável de se tratar de uma superfície transparente em frente do mesmo, identificando-se como “vidro”, se a percentagem obtida for acima de um valor pré-definido que, neste estudo, foi de 85% pois poderiam existir erros de leitura na nuvem de profundidade por isso nunca se conseguiria obter uma deteção



de 100%. Ao mesmo este valor tem de garantir que depois da contagem existem valores lidos superior ao medido pelos ultrassons suficientes para a deteção ser confiável.

### 3.2 Deteção de defeitos no vidro

Após a etapa da deteção do vidro, tornou-se necessário explorar como seria possível realizar a identificação de defeitos nos mesmos (quebras e/ou pequenos orifícios). Os estragos provocados nos vidros dos automóveis, aquando da sua circulação pelas vias rodoviárias, podem variar entre pequenos impactos que não são visíveis à vista desarmada, a quebras que podem ter o comprimento do todo o vidro. Para além disso, as quebras variam de ângulo (horizontal e/ou vertical), tornando-as invisíveis em determinadas posições ou mesmo impercetíveis, em condições em que o vidro não esteja limpo, sendo que algumas só são detetáveis pelo interior do veículo. Conforme se pode constatar, os inspetores recorrem, frequentemente, a sentarem-se dentro dos veículos, sobretudo do lado dos condutores, para poderem detetar falhas no para-brisas, as quais só são possíveis de detetar dessa forma e, a ocorrerem, implicam a sua reprovação automática. Muitas das soluções já analisadas para a sua deteção, estão focadas num ambiente quase imaculado, em que só existe o vidro e, por detrás, um painel preto ou branco, de preferência antirreflexos.

#### 3.2.1 Recurso ao algoritmo SVM

A primeira abordagem realizada foi a tentativa de criar um modelo usando um classificador linear, como o SVM, no qual a informação que lhe é fornecida foi extraída usando algoritmos, como o SURF, o ORB e o SIFT, tendo sido necessário colecionar diversas imagens de vidros inteiros, partidos ou danificados sendo estas divididas em 2 classes, vidro não danificado e vidro danificado. Estas foram usadas para treinar diversos modelos do classificador de modo a determinar quais as que mostrariam melhores resultados na identificação e na diferenciação da presença de falhas. Também foi aplicada uma validação cruzada, para se obter maior precisão e êxito na deteção das falhas.

#### 3.2.2 Recurso a um reflexo

Tal como na abordagem anterior referente à deteção do vidro, pensou-se na utilização de um reflexo para detetar falhas. Neste contexto, recorreu-se a esta técnica na tentativa de detetar eventuais defeitos. O recurso ao reflexo baseou-se no princípio de que o comportamento de um vidro normal, quando danificado, causa uma distorção no padrão refletido. No entanto, as características intrínsecas do vidro, utilizado nos veículos automóveis, não equivalem às de um vidro normal e esta hipótese não se confirmou, como demonstrado adiante, no capítulo referente aos Testes e Resultados.

### 3.2.3 Recurso à iluminação artificial



Figura 3.4: Iluminação artificial usada no desenvolvimento.

Como a técnica do recurso ao reflexo não se revelou promissora, não tendo sido detetada qualquer distorção do padrão refletido no vidro, por nenhum dos algoritmos utilizados, foi abandonada e a solução centrou-se no uso da iluminação artificial, como forma de obter a solução do problema. Foi usado, como base, o trabalho do artigo [8] para se poder analisar a deteção de falhas ou danos no vidro, no qual se recorre à iluminação, como potencial ajuda, para se chegar à solução. Inicialmente, foram desenvolvidas técnicas que permitiram realçar a presença de defeitos usando a iluminação, com recurso a um *thresholding* binário, de modo a tentar realçar os defeitos. Esta primeira técnica explorada é implementada numa proximidade extrema e em vidros que não apresentavam as características iguais às dos vidros dos automóveis. Existem muitas imagens desses vidros danificados, retiradas do exterior do veículo, em que não é possível identificar a presença do defeito e, num ambiente de inspeção, não é viável efetuar um varrimento das áreas completas dos vidros à procura dos defeitos, pois tal procedimento implicaria um dispêndio de tempo excessivo, na inspeção dos veículos.

Para tal, foi desenhada uma solução que se foca no vidro dianteiro e do lado do condutor. Esta abordagem começa pela captação de uma imagem *RGB*, produzida pela câmara de profundidade, em que a iluminação mais forte (a que incidirá sobre a superfície do vidro) não se encontra presente, ficando apenas a da iluminação ambiente. A seguir é selecionada uma área de interesse, a qual é dividida em áreas mais pequenas. Após este procedimento, todas as imagens seguintes são captadas já com a iluminação mais forte sendo área selecionada anteriormente.

Para cada uma das áreas mais pequenas, as imagens anteriores (com e sem a iluminação preponderante), são primeiro convertidas para a escala de cinzento. De seguida é-lhes aplicado um filtro gaussiano, com o intuito de remover algum ruído presente. Seguidamente, é-lhes aplicada a operação *top hat* para proporcionar um maior contraste entre os diferentes tons de cinzento, sendo feito um apuramento à imagem, como sugerido no artigo [9], de forma a provocar maior realce das arestas visíveis. Ao resultado obtido é aplicado um *thresholding* binário de forma a se obter a parte da área com o defeito, sendo depois realizada uma subtração, entre o resultado obtido na imagem com iluminação artificial e o da imagem com iluminação natural, obtendo-se assim o que é, possivelmente,

o defeito no vidro.

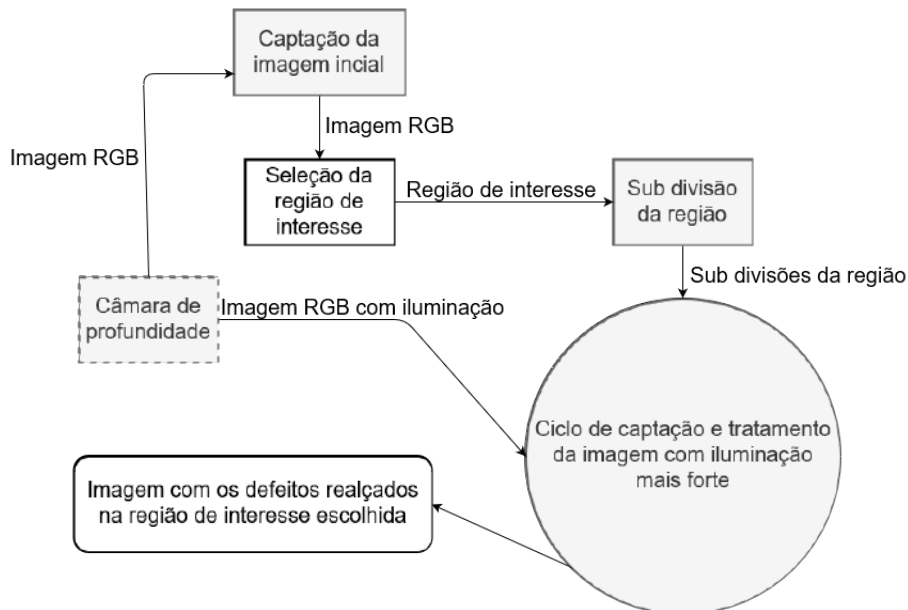


Figura 3.5: Diagrama representativo dos passos no algoritmo de detecção dos defeitos.

Com a aplicação destas técnicas, de um modo iterativo, é possível realizar a identificação de falhas em tempo real permitindo, assim, a detecção de defeitos mais subtis. A identificação da sua presença é de extrema importância, pois a existência de um defeito, ainda que negligenciável, num vidro dianteiro, do lado do condutor, é motivo mais suficiente para que o veículo inspecionado seja reprovado. O mesmo não sucede se o defeito, ainda que mínimo, esteja localizado fora da área direta do condutor. No entanto, implica uma anotação no verbete de inspeção, obrigando o proprietário do veículo à sua reparação/substituição antes da próxima inspeção.

### 3.3 Bibliotecas usadas

No decorrer do desenvolvimento de técnicas para resolver os problemas apresentados, foram usadas diversas bibliotecas que apresentavam, não só a implementação de técnicas necessárias para os testes realizados, mas também simplificações para os processamentos aplicados, sendo estas apresentadas aqui.

#### 3.3.1 *OpenCV*

A maior parte dos algoritmos desenvolvidos utilizam a *framework OpenCV*. A opção por esta tecnologia justifica-se por ser uma das mais utilizadas, para além de possuir uma grande variedade de algoritmos *open source* já implementados. Isto significa que o seu uso implica o pagamento de qualquer taxa ou direitos de autor e o código dos algoritmos implementados pode ser visto e até mesmo alterado, para se ajustar melhor às necessidades do programador. A biblioteca foi e é desenvolvida em C ou C++, pelo que

esta oferece uma variedade de interfaces para diversas outras linguagens de programação e também tem suporte para os principais sistemas operativos como *Windows*, *Linux* e *MacOS*.

Esta biblioteca tem uma estrutura modular que se divide, fundamentalmente, em: Processamento de Imagem, Calibração de câmara e Reconstrução 3D, Detecção e Reconhecimentos de Características 2D, Reconhecimento de Faces, Aprendizagem Computacional (*Machine Learning*) e Redes neuronais profundas, entre outras.

Com a estrutura modular, o sistema faz uso dos módulos de Processamento de Imagem, Detecção e Reconhecimento de Características 2D e Aprendizagem computacional, sendo que estes são usados, frequentemente, em conjunção como, por exemplo, para realizar a classificação de um objeto, tem de se usar o módulo de Detecção e Reconhecimentos de Características 2D, recorrendo aos algoritmos como *SIFT* e *SURF* e ao módulo de Aprendizagem Computacional, utilizando o algoritmo *SVM*.

### 3.3.2 *Realsense SDK*



Figura 3.6: Câmara *Intel RealSense D435*.

Com o enfoque na utilização da tecnologia das câmaras de profundidade é necessária uma biblioteca que consiga capturar a informação fornecida pelas mesmas, pelo que no sistema foi incluída a biblioteca da *Intel*, *Intel® RealSense™ SDK 2.0*, uma biblioteca *open source*, desenvolvida em parceria com a *Microsoft*. Esta escolha resultou do facto de, durante o decorrer desta dissertação, ter sido usada uma câmara *Intel RealSense D435*.

Esta biblioteca permite que se faça *streaming* da informação de cor e profundidade captada pela câmara e providencia informação de calibração intrínseca e extrínseca. Fornece ainda, outras *streams* de informação sintéticas como nuvem de pontos, cor alinhada com profundidade e suporte para gravar e rever a informação. Também mostra ferramentas que permitem identificar problemas e corrigi-los nas próprias câmaras compatíveis.

Contempla também integração com a biblioteca *OpenCV*, o que a torna muito favorável para a realização de testes. Como é desenvolvida em *CC++*, o uso das duas bibliotecas, em simultâneo, tornou-se fácil. Apresenta, não só uma interface em *CC++*, mas também outras compatíveis com linguagens como *Python*, *C#* e *node.js*.

### 3.3.3 ROS-Kinetic




Figura 3.7: *Teraranger DUO* visão dianteira. Figura 3.8: *Teraranger DUO* visão traseira.

Com a introdução do sensor *Teraranger DUO* foi necessário encontrar uma biblioteca que permitisse fazer uso da informação disponibilizada pelo mesmo. Desta forma, a biblioteca *ROS-Kinetic*, já incluía um módulo para o sensor e, como tal, possibilitou que qualquer desenvolvimento relacionado com sensor, fosse mais fácil de implementar.

Esta biblioteca é mais comum para o desenvolvimento de aplicações que pretendem executar em robôs ou hardware como *Arduino*<sup>1</sup>, pois apresenta a capacidade da criação de nós que podem enviar mensagem entre eles, tornando a troca de informação mais simples, se um nó estiver a correr no computador e outro no hardware ou robô.

<sup>1</sup>É uma plataforma de prototipagem eletrónica de hardware livre e de placa única, projetada com um micro-controlador *Atmel AVR* com suporte de entrada/saída embutido.



## TESTES E AVALIAÇÃO

Para cada problema apresentado e abordagem explorada foram realizados testes. Esses testes e respectivos resultados são aqui apresentados de modo a poder determinar quais são as abordagens e técnicas que permitem, de modo satisfatório, resolver os problemas apresentados. A interface usada para se realizar os testes baseia-se no uso de consola sendo, por isso, usados comandos básicos. Sempre que, durante os testes, foi necessário alterar parâmetros dos métodos usados, recorreu-se a barras deslizantes horizontais, permitindo a variação dos valores, até encontrar os que se aproximavam, com maior exatidão, dos resultados pretendidos.

### 4.1 Testes de deteção de vidro

Com as abordagens realizadas no capítulo 3.1 para a deteção da presença do vidro foram criados diversos programas de testes, com o objetivo de confirmar se as mesmas poderiam ser soluções viáveis para este problema.

A primeira abordagem, usando os reflexos como ajuda para detetar a presença do vidro, mostrou, não só que o reflexo poderia ser uma ajuda na identificação da área do vidro, mas também na deteção da sua presença. Não obstante, durante os testes foram identificadas situações que poderiam originar falsos positivos, isto é, que a área do vidro fosse detetada para além da sua real dimensão. Esta situação foi confirmada, pois muitos carros contêm uma pintura que apresenta uma grande taxa de reflexão, resultando na correta identificação do padrão refletido nessas superfícies, conforme se pode verificar na imagem 4.1.

Isto demonstra que, embora o uso de reflexos potencie a identificação da presença do vidro, pode provocar situações de falsa identificação, ao ser detetado nas superfícies com grau de reflexão igual ou superior ao do vidro. Apesar desta contrariedade, durante

os testes, o *SURF* mostrava-se mais rápido no processamento dos pontos, o que permitia efetuar os testes quase em tempo real.

Tendo a abordagem ao reflexo evidenciado que este poderia ser usado para identificar a presença do vidro podendo o padrão ser posicionado no ambiente (pavilhão de inspeção) ou até mesmo fixado ao autômato, foi aplicada a técnica *YOLO*, referido em 2.5.5.2, para se criar um modelo que conseguisse distinguir a área do vidro com a presença de um padrão. Para esse efeito foram usadas no treino imagens, como as imagens 4.1 e 4.2



Figura 4.1: Vidro com o padrão presente. Figura 4.2: Vidro sem o padrão presente.

Após as 30000 iterações do algoritmo, processo que decorreu durante dois meses e meio, com início no final de outubro e término em meados de dezembro de 2018<sup>1</sup>, foi testado o modelo resultante. Neste contexto, foram testados 20 vidros frontais, em ângulo frontal e diagonal direito e esquerdo, no qual o algoritmo falhou apenas na deteção de 1. Após os testes, a identificação do padrão, refletido no vidro, foi de 95%, nas duas classes de imagens utilizadas. Uma classe continha imagens de vidros sem o padrão e a outra vidros com o padrão. Conforme mostram as imagens seguintes, os resultados da aplicação do modelo, nas imagens 4.3, 4.4, 4.5 e 4.6 que não se encontravam no conjunto de treino, foi positivo.



Figura 4.3: Vidro sem o padrão presente identificado pelo *YOLO*. Figura 4.4: Vidro com o padrão presente identificado pelo *YOLO*.

<sup>1</sup>Este grande período de tempo é devido ao hardware disponível no computador que não apresentava capacidade suficiente para tornar o processo de treino mais rápido.





Figura 4.5: Outro vidro sem o padrão presente identificado pelo YOLO.



Figura 4.6: Outro vidro com o padrão presente identificado pelo YOLO.

Os testes foram realizados assumindo-se que, durante a inspeção automóvel, a distância ao vidro se manteria constante, sendo que este modelo, inicialmente treinado, mostrou que também se poderá replicar para os restantes vidros do automóvel.

No seguimento deste estudo, foi então testada a introdução do sensor de ultrassom como parâmetro facilitador na resolução do problema. Nesta abordagem, durante os primeiros testes, não se teve, por base, a distância a que o sensor se encontrava dos objetos, pelo que os testes iniciais foram realizados usando objetos transparentes, de modo a verificar se com a sua aplicação conjunta, se obteriam resultados significativos, para avançar com os testes nas superfícies do automóvel.



Figura 4.7: Não existe objeto transparente.



Figura 4.8: Presença de objeto transparente.

Com os primeiros testes (imagens 4.7 e 4.8) a mostrarem sucesso na identificação da presença de vidro, o programa foi então alterado e o algoritmo, que verifica a sua presença, modificado, de forma ser viável na superfície do veículo, como se pode constatar nas imagens seguintes(4.9, 4.10, 4.11 e 4.12).




Figura 4.9: Teste no capô do automóvel.



Figura 4.10: Teste no vidro dianteiro.



Figura 4.11: Teste no vidro lateral.



Figura 4.12: Teste na porta do condutor.

E embora os testes obtivessem resultados promissores, também se pôde verificar alguns falsos positivos, conforme o demonstram as imagens 4.13 e 4.14, nas quais é identificado vidro, quando a câmara e sensor se encontram direcionadas para outra superfície do carro, também com propriedades refletoras.



Figura 4.13: Falso positivo no capô.




Figura 4.14: Falso positivo na porta.

Estas situações podem explicar-se pela nuvem de pontos, retirada de uma porta do mesmo automóvel e utilizada como modelo, que se encontrava danificada e por isso estava removida do veículo, apresentada nas imagens 4.15 e 4.16, onde se observavam zonas negras e das quais não foi possível obter quaisquer parâmetros de profundidade.




Figura 4.15: Imagem de profundidade de uma porta danificada.




Figura 4.16: Outra imagem de profundidade da porta danificada.

Tal facto ocorre devido ao tipo de pintura e à presença de reflexos fortes, capazes de enganar o sensor, o que faz com que, no calculo da profundidade realizado pela câmara, ocorram «zonas negras» onde não existem medidas e, se o emissor de infravermelhos da câmara estiver ativo, os resultados não melhoram, pois como se constatar nas imagens 4.17 e 4.18, quase todos os pontos são absorvidos pela cor.




Figura 4.17: Infravermelhos numa porta de um automóvel.





Figura 4.18: Infravermelhos na porta mas de outro ângulo.

Perante este problema, foi definida a condição em que a câmara não se deslocaria, mas se manteria numa posição fixa, ainda que ajustável, quanto à distância em relação aos diferentes vidros. Estas condições permitiram alterações ao algoritmo, obtendo-se resultados muito mais evidentes e precisos na deteção do vidro, como se pode constatar nas imagens 4.19, 4.20, 4.21, 4.22 e 4.23.



Figura 4.19: Teste no vidro lateral (Note o reflexo da iluminação). Figura 4.20: Teste no vidro lateral vidro completamente escondido.



Figura 4.21: Teste no vidro traseiro.



Figura 4.22: Teste no vidro traseiro de um ângulo diferente.



Figura 4.23: Teste no vidro dianteiro.

Métodos correntes para a identificação da presença de vidro, que não utilizem sensores adicionais, como laser e até mesmo ultrassom, não são muitos, principalmente no ambiente de inspeção automóvel e muitos dos métodos existentes baseiam-se na detecção de objetos transparentes, analisando a distorção causada pelos mesmos na restante imagem. Não obstante, tal não se consegue aplicar no vidro do automóvel, pois este tem que, obrigatoriamente, estar isento de qualquer distorção, a não ser que esteja danificado. O método aqui criado baseia-se na capacidade de a câmara de profundidade, com o sensor de infravermelhos a emitir, conseguir obter medidas de profundidade do que se encontra atrás do vidro. Um problema que poderia surgir seria se os valores do ultrassom sofressem alterações, em situação real, devido ao ruído causado por um automóvel. Neste contexto,

foram realizados testes in loco, apenas com o sensor de ultrassom, no Centro de Inspeção Automóvel de Castelo Branco - Controlauto, com o objetivo de se aferir se o ruído provocado pelos motores de vários veículos, a trabalhar ao mesmo tempo, teria ou não influência nos dados emitidos e recebidos pelo sensor em causa, isto é, que alterassem, significativamente, os valores esperados em relação às medições das distâncias entre o sensor e os vidros em teste. Tal hipótese não se confirmou, tendo-se constatado que o sensor era imune ao ruído ambiente, mesmo em situação de elevada aceleração do motor do veículo de teste. Assim, os valores aferidos estiveram sempre dentro das distâncias previstas do sensor aos vidros, não tendo sido os mesmos alterados pela presença de ruído. Os testes foram realizados em 6 vidros distintos do automóvel (dianteiro, traseiro e nos 4 laterais), tendo o algoritmo mostrado sucesso de 90% e 10% de falhas em todas as situações testadas, isto é, independentemente do vidro em teste. A percentagem de falhas deveu-se ao ângulo em que o conjunto de sensores foi colocado, causando erros da medição das distâncias do mesmo ao vidro. Esta situação teve origem no facto da existência de zonas de absorção, das quais não resultaram dados de medição que não permitiram, ao algoritmo, a correta identificação do vidro em teste. Apenas em situações ideais de colocação dos sensores como, por exemplo, frontalmente e evitando reflexos ou fontes de luz, se obtinham valores que permitiram o sucesso de 100%.

## 4.2 Testes de identificação de defeitos no vidro

Depois de avaliar os algoritmos da deteção de vidro, foram realizados testes para avaliar a deteção de defeitos nos vidros.

Como já referido inicialmente, foram treinados diversos modelos com o algoritmo SVM usando a informação extraída através de algoritmos como *SIFT*, *SURF* ou *ORB*, para verificar se era possível fazer uma diferenciação entre um vidro intacto e um vidro danificado. Conforme se pode verificar, nos resultados seguintes, tal procedimento não apresentou uma grande precisão, pois muitas das imagens que inicialmente pertenciam a uma determinada categoria, foram identificadas como pertencentes a outra, que não a correta, conforme os dados apresentados nas imagens de tabelas 4.24, 4.25 e 4.26.

Label	1	2	Total
Predicted 1	6	1	7
Predicted 2	29	34	63
	35	35	70

Acuracy	57%
Recall	17%
Miss	3%
Precision	86%

Figura 4.24: Tabelas de resultados *SIFT*.

Label	1	2	Total
Predicted 1	9	3	12
Predicted 2	26	32	58
	35	35	70

Acuracy	59%
Recall	26%
Miss	9%
Precision	75%

Figura 4.25: Tabelas de resultados SURF.

Label	1	2	Total
Predicted 1	17	9	26
Predicted 2	18	26	44
	35	35	70

Acuracy	61%
Recall	49%
Miss	26%
Precision	65%

Figura 4.26: Tabelas de resultados ORB.

Embora os resultados obtidos apresentem uma precisão superior a 50%, não nos permite tomar uma decisão conclusiva, de forma a se concluir, com eficácia, que numa imagem analisada do vidro, o mesmo apresente, ou não, defeitos. Pôde-se constatar que quase todos os defeitos analisados em vidros comuns, antes de se começar a trabalhar nesta situação, maioritariamente revelaram estruturas muito similares e de fácil identificação, factos que não se verificaram nos defeitos presentes nos vidros dum automóvel. Esta situação deve-se à estrutura dupla, laminada, temperada e, quase sempre reforçada, dos vidros utilizados nos veículos automóveis, de que não usufruem os vidros normais.

Perante o facto de esta abordagem não ter apresentado resultados que potenciassesem a sua exploração e aplicação nas condições da inspeção automóvel, foi analisada a possibilidade de se usar uma fonte de iluminação para tentar realçar os defeitos que, eventualmente, existissem num vidro dum veículo. Partindo desta hipótese, foram realizados testes iniciais para verificar se a iluminação complementar poderia ajudar na solução da identificação da presença de defeitos neste tipo de vidros. As imagens seguintes mostram como a simples operação de *thresholding* e de subtração de imagens podem revelar a presença de defeitos no vidro.






Figura 4.27: Imagens escala de cinzento sem e com iluminação.




Figura 4.28: Imagens depois de aplicado um *threshold* binário.



Figura 4.29: Imagem resultante da diferença das duas imagens anteriores.

Não obstante os resultados promissores, as imagens foram captadas numa proximidade ao vidro que não seria aplicável na inspeção automóvel. Perante este problema, foi pensada uma nova abordagem: o uso de um padrão, refletido no vidro, para se verificar



## 4.2. TESTES DE IDENTIFICAÇÃO DE DEFEITOS NO VIDRO

a presença de defeitos no mesmo. Assumindo que os defeitos causariam distorção no padrão, foram realizados testes de passagem do padrão num vidro dianteiro danificado dum automóvel, com diferentes fendas que o percorrem de cima e a baixo e de um lado ao outro, conforme as imagens 4.30, 4.31, 4.32 e 4.33.




Figura 4.30: Padrão numa zona com dano não visível 1.



Figura 4.31: Padrão numa zona com dano não visível 2.



Figura 4.32: Padrão numa zona com dano não visível 3.




Figura 4.33: Imagem ampliada na zona onde o padrão se desloca na presença de um defeito relativamente visível.

Como se pode observar nas imagens anteriores, ao passar o padrão por zonas que apresentam a presença de defeitos, não é notável a presença de alguma distorção do mesmo. Após a análise à área marcada de interesse, não foi possível realizar a extração de informação que pudesse contribuir para a deteção da presença de defeitos no vidro. Também se constatou que, só com uma elevada ampliação da imagem, seriam detetáveis ou visíveis alguns defeitos, o que implicaria a condição de os sensores se encontrarem numa posição fixa, em relação ao vidro, de difícil implementação, pois o varrimento, com seguimento do padrão no vidro, tornaria o todo o processo muito mais demorado.

Retomou-se a abordagem com ajuda da iluminação complementar mas, desta vez, com a alteração de que a mesma incidisse numa área previamente definida, sendo esta dividida em várias áreas mais pequenas, recolhendo assim informação mais restrita e precisa, até

## 4.2. TESTES DE IDENTIFICAÇÃO DE DEFEITOS NO VIDRO

se encontrarem parâmetros que permitissem extrair a informação para todas as diferentes áreas focadas. Durante os primeiros testes, as imagens com iluminação eram só captadas de acordo com o input do utilizador, tendo-se obtido os resultados, nas imagens 4.34, 4.35, 4.36 e 4.37.

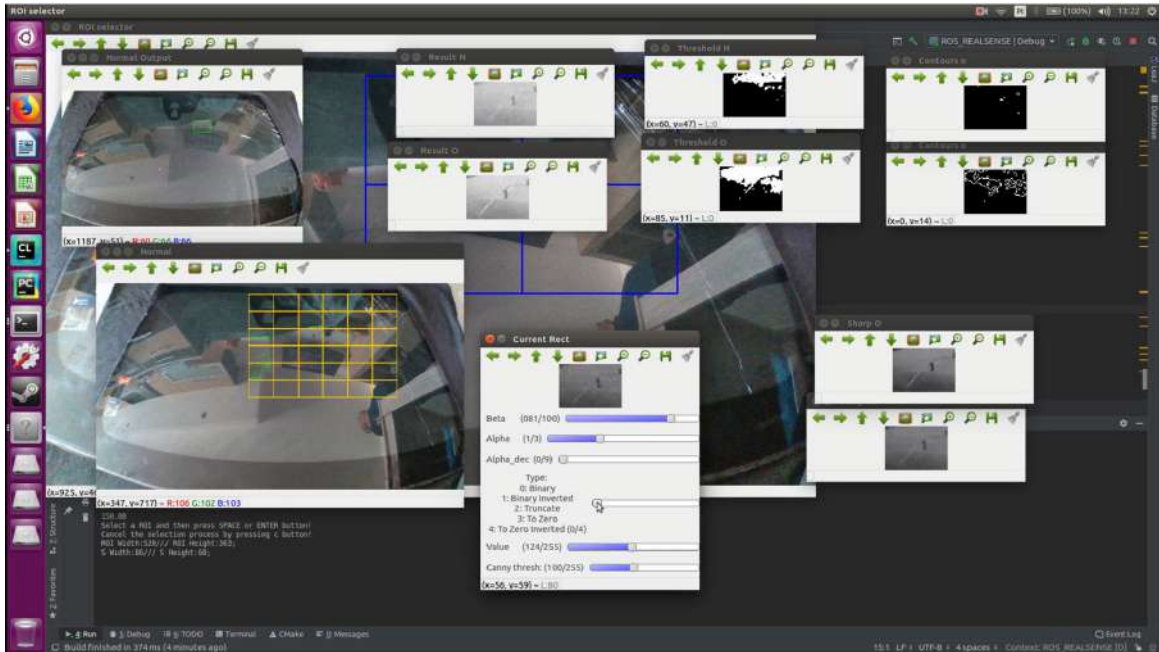


Figura 4.34: Modificação de parâmetros para tornar o defeito mais visível. Janelas com «O» são capturadas da imagem inicial.

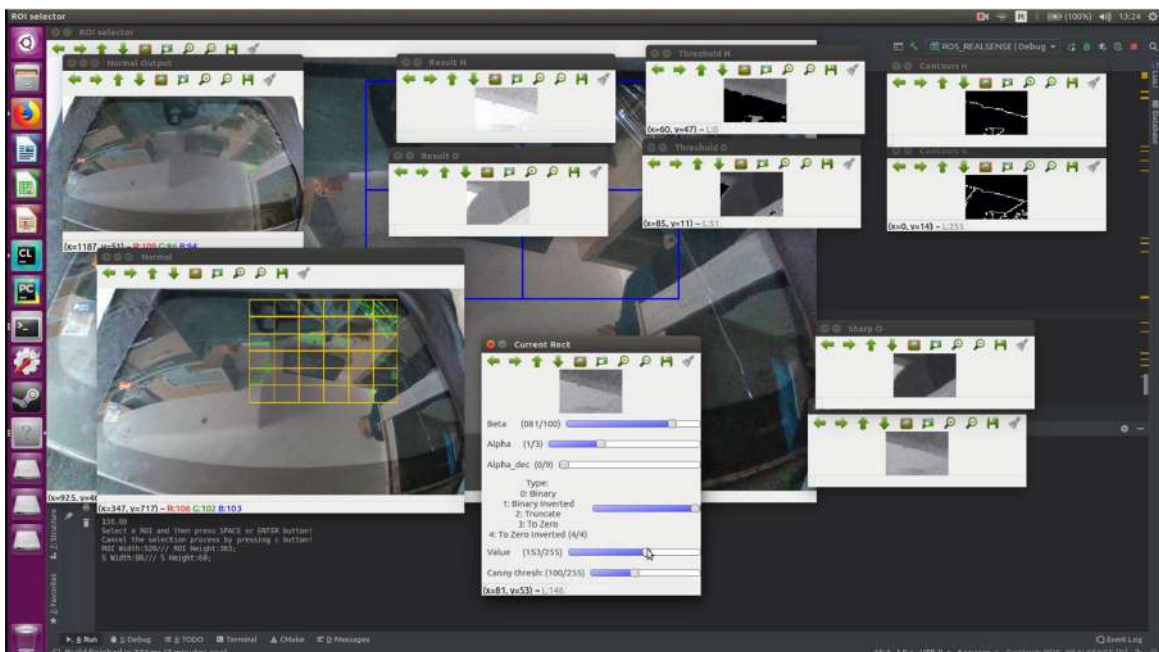


Figura 4.35: Com os parâmetros nesta imagem os reflexos tomam grande parte do resultado.



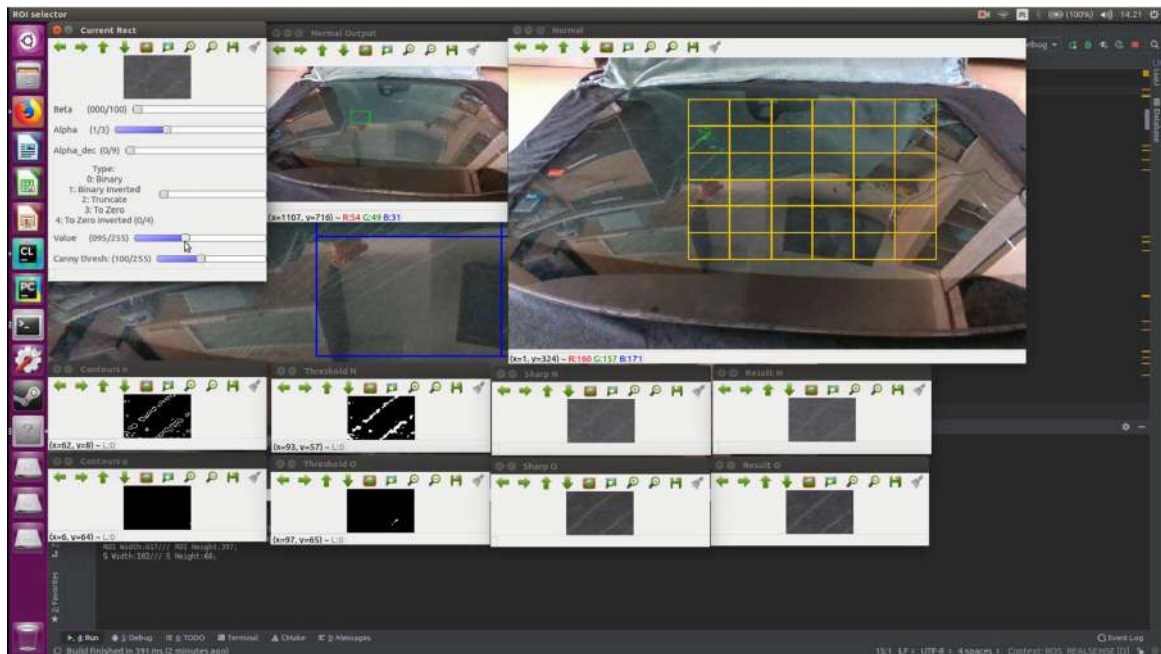


Figura 4.36: Com os parâmetros quase inalterados mas que neste caso mostram resultados aceitáveis, mas com alguma presença de artefactos causados pelos reflexos.

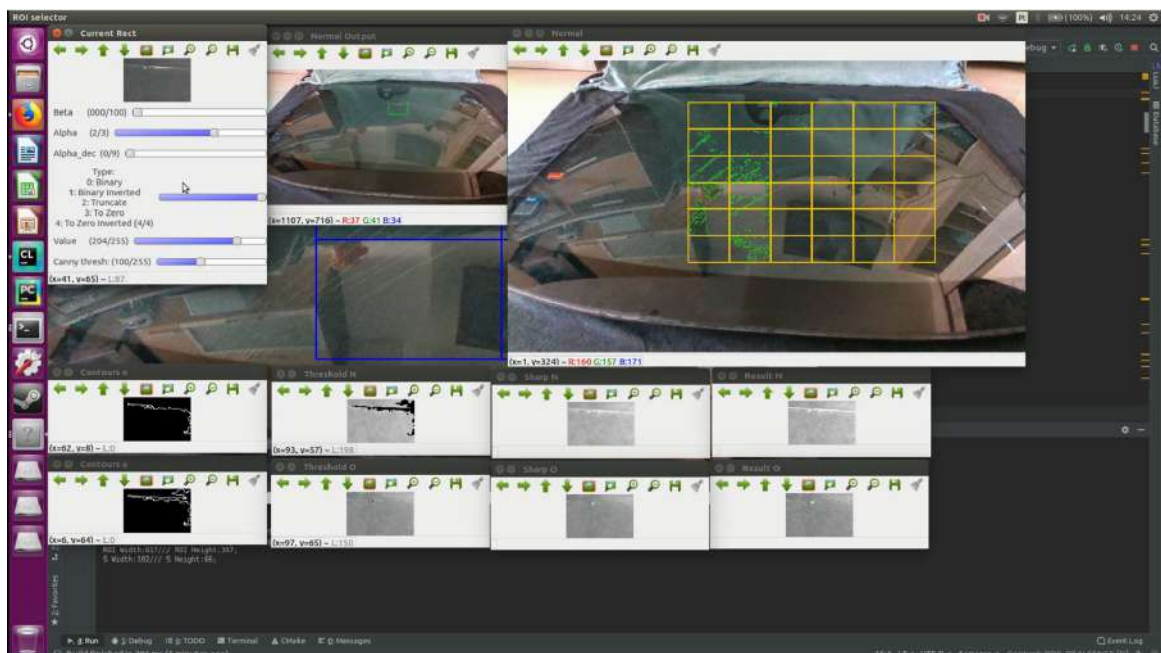


Figura 4.37: Parâmetros modificados para valores altos para analisar se os defeitos são mais visíveis.

Como se pôde constatar nas imagens apresentadas, foi necessária a alteração de muitos parâmetros (variáveis), para tornar possível a obtenção de valores que permitiram realizar a extração de informação necessária, para identificar a presença de falhas. Após a realização de testes preliminares, foram então aferidos quais os parâmetros necessários

## 4.2. TESTES DE IDENTIFICAÇÃO DE DEFEITOS NO VIDRO

que potenciassesem a extração da informação correta, em relação ao problema em estudo.

O programa criado anteriormente foi devidamente modificado e corrigido, de acordo com os dados obtidos anteriormente, de forma a poder captar imagens em tempo real e mostrar os defeitos realçados. Este procedimento é ilustrado nas imagens 4.38 e 4.39, onde se pode observar o “aparecimento” dos diferentes defeitos, existentes no vidro de teste.




Figura 4.38: Resultado durante as primeiras iterações.



Figura 4.39: Resultado depois de decorridos alguns segundos.

Atualmente existem técnicas para a deteção de defeitos em vidros, mas requerem

imagens de grande proximidade e nitidez, normalmente obtidas em ambientes de fabrico e que não apresentem grandes reflexos ou motivos causadores da obtenção de falsa informação. Tais condições não aplicáveis no ambiente em que se pretende implementar uma solução viável. Neste contexto, pode-se concluir que o procedimento, acima apresentado, evidencia maior probabilidade de ser implementado, como solução, na automatização do ambiente de inspeção automóvel. Pode ser viável não só na deteção dos vidros, mas também de defeitos que, por si só, sejam significativos para a reprovação do veículo inspecionado.

Com o recurso a este método foi possível efetuar a deteção, de forma mais rápida e eficaz, da presença de defeitos, não sendo necessária uma aproximação extrema do dispositivo ao vidro. Para tal, recorreu-se a uma fonte de iluminação intensa e uniforme e ao uso da câmara de *RGB* incorporada na de profundidade, de forma a tentar realçar os defeitos existentes, tornando-os mais visíveis. Este procedimento permitiu a aplicação de técnicas de processamento de imagem simples, mas muito eficazes, para obter a informação necessária à deteção de defeitos. Daí, resultaram as imagens acima apresentadas, onde são evidentes as zonas que apresentam defeitos.

## CONCLUSÕES E TRABALHO FUTURO

O trabalho realizado durante o decorrer desta dissertação foi idealizado com o objetivo de trazer soluções a problemas existentes no ambiente de inspeção automóvel, com a introdução de novas tecnologias e metodologias que poderão ajudar na sua automatização. Este trabalho é essencialmente focado nos problemas da deteção de vidros nos automóveis e a deteção de danos nos mesmos. Os métodos desenvolvidos e testados mostraram a capacidade de se automatizar parte da inspeção automóvel e também de serem desenvolvidos e alterados/adaptados, de forma a serem utilizados noutras áreas, para além da inspeção automóvel. Foi desenvolvido um algoritmo para deteção de vidro, num contexto de uma inspeção automóvel, baseado em informação capturada por diversos sensores, nomeadamente, *TeraRanger DUO* (ultrassom) e *Intel RealSense D435* (infravermelhos e câmara RGB). Este algoritmo obteve bons resultados nas seguintes condições: ambientes com elevado ruído; pouca luminosidade como, por exemplo, uma garagem; em condições de iluminação forte ou iluminação natural, como testado num centro de inspeções automóvel.

A deteção da presença de um objeto transparente, já foi estudada por diversos outros trabalhos, onde se apresentaram soluções viáveis à sua deteção. Não obstante, a maioria apresenta abordagens ao problema numa perspetiva de situações ideais, as quais não são exequíveis num ambiente que é objeto desta dissertação. Neste contexto, os métodos criados e apresentados neste trabalho, os quais recorrem à utilização dos sensores introduzidos durante o seu desenvolvimento, vêm trazer uma solução prática, exequível e de pouco consumo de tempo, na inspeção automóvel. O uso da técnica **YOLO**, em conjunção com um reflexo, também proporciona outra perspetiva de solução, não só na identificação de objetos transparentes, mas também na identificação de objetos refletores, no qual é possível detetar-se a presença dum padrão.

No que diz respeito à deteção da presença de defeitos num objeto transparente, existem trabalhos que também já foram muito explorados para ambientes de fabrico, mas raramente em situações reais, sujeitas ao «ruído» provocado por reflexos, focos ou pontos de luz, sombras ou outros motivos que provoquem a obtenção de dados inapropriados para a resolução dos problemas em causa. Assim, no contexto do ambiente de inspeção automóvel e onde, recentemente, está a ser explorada, não existem estudos que abordem esta problemática, tendo-se revelado a utilização da iluminação um fator primordial na obtenção de uma solução simples e eficaz. A solução aqui apresentada também mostra como não é necessário recorrer à utilização de uma câmara de alta resolução, para se obterem resultados satisfatórios e inequívocos na deteção de vidros e respetivas falhas, nem será necessário colocar o dispositivo de deteção demasiado perto do vidro, para que os eventuais defeitos sejam devidamente detetados. Esta apresentou bons resultados nas seguintes condições: em vidros automóveis dianteiros, traseiros ou laterais, sujeitos a uma iluminação artificial neutra (branco) e isenta de radiação infravermelha (LED 4,8W, 480 lumens, até 30 metros de eficácia); ambiente com iluminação natural, sem reflexos por detrás do vidro em teste; utilização de um pano escuro e antirreflexos, como forma de evitar reflexões excessivas, quer de luz quer de outros objetos presentes no ambiente de teste. Como sensor, foi utilizada a câmara *Intel RealSense D435*, apenas na sua componente *RGB*. Os testes foram efetuados com a câmara fixa, colocada à distância entre 70 cm a 75 cm do vidro, com o enfoque no lado do condutor, onde as falhas detetadas, ainda que mínimas, implicam a imediata reprovação do veículo inspecionado. Optou-se pela deslocação da fonte de iluminação artificial, variando-se o respetivo ângulo de incidência (horizontalmente e/ou verticalmente), bem como a sua aproximação ao vidro (entre 60 cm a 65 cm), de forma a realçar as eventuais falhas por distorção na reflexão da luz, ao mesmo tempo que corria o algoritmo de deteção. A escolha pela posição fixa da câmara, teve por objetivo evitar oscilações excessivas na distância ao vidro, facto que inviabilizava, constantemente, a deteção das falhas pelo algoritmo. É ainda de salientar o facto de que, apesar de o vidro ser detetado, conforme já referido anteriormente, a uma distância bastante superior, as suas falhas não o são, requerendo assim a redução, significativa, da distância do sensor ao vidro, sendo os valores apontados os que melhores resultados se obtiveram, com a câmara utilizada e atendendo às suas características de obtenção de imagens.

O trabalho realizado poderá ser modificado e aplicado noutros contextos a automatizar, nos quais sejam necessárias soluções similares e que, apesar da tecnologia de câmaras de profundidade ser recente, mostra grande potencialidade para se aplicar na resolução de problemas modernos, para além da inspeção automóvel.

Neste contexto, a utilização conjunta de sensores de ultrassons e infravermelhos, com recolha de informação por software específico e desenhado para o efeito, poderá tornar, num futuro próximo, a inspeção automóvel totalmente automatizada. No entanto, devido ao facto de os veículos automóveis não serem obrigados, aquando da sujeição à inspeção, a estarem devidamente isentos de sujidade, isto é, vidros limpos, carroçaria e *chassi* lavados, etc. é, por enquanto, um dos principais motivos inibidores dessa automatização. Poderão,



---

eventualmente, máquinas equipadas com Inteligência Artificial igualarem, ou mesmo suplantarem, a capacidade humana de separar o essencial do acessório e, dessa forma, distinguirem, num veículo a ser inspecionado, os defeitos e falhas existentes, daquilo que não o é. Por outro lado, há ainda que tomar em consideração que, num ambiente de inspeção automóvel, os inspetores recorrem, frequentemente, ao tato com as mãos, não só para detetarem deformações em componentes de veículos, mas também para «limpar sujidade» presente nos mesmos, como forma de verificarem o seu estado de conservação. Esta modalidade é essencialmente utilizada na parte inferior dos veículos, para a qual ainda não existe uma solução robotizada fiável.

É evidente que as propostas aqui apresentadas sugerem um trabalho ainda mais aprofundado, nomeadamente no que concerne ao hardware utilizado e à obtenção dos dados necessários ao tratamento da informação, de forma a se obterem resultados 100% precisos. Não obstante, o mesmo hardware não possui, ainda, as características essenciais (definição, sensibilidade e resolução) capazes de fornecer, eficazmente, aos algoritmos testados nesta dissertação, a informação precisa e inequívoca para se obter uma solução viável, independentemente das condições em que for utilizado. Os fatores extrínsecos, como falta ou excesso de luz, sombras, pintura, reflexos, sujidade (óleos, lama, pó, marcas de água, dejetos, insetos, etc.) são fornecedores de ruído perturbador na informação obtida, inviabilizando o correto funcionamento dos algoritmos testados e, conseqüentemente, a obtenção de uma solução fiável.

Como sugestão para um desenvolvimento futuro, considera-se a possibilidade da junção, aos sensores atrás referidos, do sensor laser, cuja informação recolhida pudesse ajudar, em situações em que as condições do veículo inspecionado não fossem as ideais, a distinguir a informação que é ou não essencial para, não só identificar, mas também detetar, os componentes e suas respetivas falhas.



## BIBLIOGRAFIA

- [1] A. DE e PARCERIA. PORTUGAL. 2020. URL: [https://www.portugal2020.pt/sites/default/files/1.\\_ap\\_portugal\\_2020\\_28julho\\_0.pdf](https://www.portugal2020.pt/sites/default/files/1._ap_portugal_2020_28julho_0.pdf).
- [2] *Reprovação de Veículo na Inspeção*. URL: <https://controlauto.pt/inspecao-automovel/reprovacao>.
- [3] URL: <http://www.imt-ip.pt/sites/IMTT/Portugues/Veiculos/Inspecao/TiposInspeccoes/Paginas/TiposdeInspecoes.aspx>.
- [4] L. Bo, X. Ren e D. Fox. “Depth kernel descriptors for object recognition”. Em: *2011 IEEE/RSJ International Conference on Intelligent Robots and Systems*. 2011, pp. 821–826. DOI: 10.1109/IR0S.2011.6095119.
- [5] M. Liu, X. Li, J. Dezert e C. Luo. “Generic object recognition based on the fusion of 2D and 3D SIFT descriptors”. Em: *2015 18th International Conference on Information Fusion (Fusion)*. 2015, pp. 1085–1092.
- [6] Döring, Christian, Eichhorn, Andreas, Girimonte, Daniela, Kruse e Rudolf. “Improving surface defect detection for quality assessment of car body panels.” eng. Em: vol. 11. 2-3. 2004, pp. 163–177. URL: <http://eudml.org/doc/39264>.
- [7] D. D. Nauck. “Fuzzy data analysis with NEFCLASS”. Em: *International Journal of Approximate Reasoning* 32.2 (2003). *Soft Computing in Information Mining*, pp. 103 –130. ISSN: 0888-613X. DOI: [https://doi.org/10.1016/S0888-613X\(02\)00079-8](https://doi.org/10.1016/S0888-613X(02)00079-8). URL: <http://www.sciencedirect.com/science/article/pii/S0888613X02000798>.
- [8] Nishu e S. Agrawal. “Glass Defect Detection Techniques using Digital Image Processing –A Review”. Em: *International Journal of Computer Applications* (fev. de 2018).
- [9] Y. Bandyopadhyay. “Glass Defect Detection and Sorting Using Computational Image Processing”. Em: *International Journal of Emerging Technologies and Innovative Research (www.jetir.org | UGC and issn Approved)*. Vol. 2. 10. 2015, pp. 73–75. URL: <http://www.jetir.org/papers/JETIR1510014.pdf>.
- [10] R. Koch, S. May e A. Nüchter. “Effective distinction of transparent and specular reflective objects in point clouds of a multi-echo laser scanner”. Em: *2017 18th International Conference on Advanced Robotics (ICAR)* (2017), pp. 566–571.

- [11] M. A. Ahmed, F. Pitie e A. Kokaram. "Reflection detection in image sequences". Em: *CVPR 2011*. 2011, pp. 705–712. DOI: [10.1109/CVPR.2011.5995670](https://doi.org/10.1109/CVPR.2011.5995670).
- [12] J. Malik e K. R. Dahiya. "Harris Operator Corner Detection using Sliding Window Method". Em: 2011.
- [13] J. Guo. "Transparent Object Recognition Using Gradient Grids". Em: ().
- [14] R. Ajmera, A. Nigam e P. Gupta. "3D Face Recognition Using Kinect". Em: *Proceedings of the 2014 Indian Conference on Computer Vision Graphics and Image Processing*. ICVGIP '14. Bangalore, India: ACM, 2014, 76:1–76:8. ISBN: 978-1-4503-3061-9. DOI: [10.1145/2683483.2683559](https://doi.org/10.1145/2683483.2683559). URL: <http://doi.acm.org/10.1145/2683483.2683559>.
- [15] G. Goswami, S. Bharadwaj, M. Vatsa e R. Singh. "On RGB-D face recognition using Kinect". Em: *2013 IEEE Sixth International Conference on Biometrics: Theory, Applications and Systems (BTAS) (2013)*, pp. 1–6.
- [16] O. D. Faugeras e W. K. Pratt. "Decorrelation Methods of Texture Feature Extraction". Em: *IEEE Transactions on Pattern Analysis and Machine Intelligence PAMI-2.4* (1980), pp. 323–332. ISSN: 0162-8828. DOI: [10.1109/TPAMI.1980.4767031](https://doi.org/10.1109/TPAMI.1980.4767031).
- [17] R. Mehrotra, K. Namuduri e N. Ranganathan. "Gabor filter-based edge detection". Em: *Pattern Recognition* 25.12 (1992), pp. 1479–1494. ISSN: 0031-3203. DOI: [https://doi.org/10.1016/0031-3203\(92\)90121-X](https://doi.org/10.1016/0031-3203(92)90121-X). URL: <http://www.sciencedirect.com/science/article/pii/003132039290121X>.
- [18] J. Illingworth e J. Kittler. "A survey of the hough transform". Em: *Computer Vision, Graphics, and Image Processing* 44.1 (1988), pp. 87–116. ISSN: 0734-189X. DOI: [https://doi.org/10.1016/S0734-189X\(88\)80033-1](https://doi.org/10.1016/S0734-189X(88)80033-1). URL: <http://www.sciencedirect.com/science/article/pii/S0734189X88800331>.
- [19] Z. Jin-Yu, C. Yan e H. Xian-Xiang. "Edge detection of images based on improved Sobel operator and genetic algorithms". Em: *2009 International Conference on Image Analysis and Signal Processing*. 2009, pp. 31–35. DOI: [10.1109/IASP.2009.5054605](https://doi.org/10.1109/IASP.2009.5054605).
- [20] W. McIlhagga. "The Canny Edge Detector Revisited". Em: *International Journal of Computer Vision* 91.3 (2011), pp. 251–261. ISSN: 1573-1405. DOI: [10.1007/s11263-010-0392-0](https://doi.org/10.1007/s11263-010-0392-0). URL: <https://doi.org/10.1007/s11263-010-0392-0>.
- [21] E. R. Lee, P. K. Kim e H. J. Kim. "Automatic recognition of a car license plate using color image processing". Em: *Proceedings of 1st International Conference on Image Processing*. Vol. 2. 1994, 301–305 vol.2. DOI: [10.1109/ICIP.1994.413580](https://doi.org/10.1109/ICIP.1994.413580).
- [22] D. G. Lowe. "Distinctive Image Features from Scale-Invariant Keypoints". Em: *Int. J. Comput. Vision* 60.2 (nov. de 2004), pp. 91–110. ISSN: 0920-5691. DOI: [10.1023/B:VISI.0000029664.99615.94](https://doi.org/10.1023/B:VISI.0000029664.99615.94). URL: <https://doi.org/10.1023/B:VISI.0000029664.99615.94>.

- 
- [23] Z. Wang, H. Xiao, W. He, F. Wen e K. Yuan. “Real-time SIFT-based object recognition system”. Em: *2013 IEEE International Conference on Mechatronics and Automation*. 2013, pp. 1361–1366. DOI: [10.1109/ICMA.2013.6618111](https://doi.org/10.1109/ICMA.2013.6618111).
- [24] H. Bay, A. Ess, T. Tuytelaars e L. V. Gool. “Speeded-Up Robust Features (SURF)”. Em: *Computer Vision and Image Understanding* 110.3 (2008). Similarity Matching in Computer Vision and Multimedia, pp. 346–359. ISSN: 1077-3142. DOI: <https://doi.org/10.1016/j.cviu.2007.09.014>. URL: <http://www.sciencedirect.com/science/article/pii/S1077314207001555>.
- [25] E. Rublee, V. Rabaud, K. Konolige e G. Bradski. “ORB: An efficient alternative to SIFT or SURF”. Em: *2011 International Conference on Computer Vision*. 2011, pp. 2564–2571. DOI: [10.1109/ICCV.2011.6126544](https://doi.org/10.1109/ICCV.2011.6126544).
- [26] C. Cortes e V. Vapnik. “Support-vector networks”. Em: *Machine Learning* 20.3 (1995), pp. 273–297. ISSN: 1573-0565. DOI: [10.1007/BF00994018](https://doi.org/10.1007/BF00994018). URL: <https://doi.org/10.1007/BF00994018>.
- [27] J. Redmon, S. K. Divvala, R. B. Girshick e A. Farhadi. “You Only Look Once: Unified, Real-Time Object Detection”. Em: *CoRR* abs/1506.02640 (2015). arXiv: [1506.02640](https://arxiv.org/abs/1506.02640). URL: <http://arxiv.org/abs/1506.02640>.
- [28] J. Redmon e A. Farhadi. “YOLOv3: An Incremental Improvement”. Em: *CoRR* abs/1804.02767 (2018). arXiv: [1804.02767](https://arxiv.org/abs/1804.02767). URL: <http://arxiv.org/abs/1804.02767>.
- [29] J. Redmon. URL: <https://pjreddie.com/darknet/yolo/>.
- [30] J. F. Henriques, R. Caseiro, P. Martins e J. Batista. “High-Speed Tracking with Kernelized Correlation Filters”. Em: *CoRR* abs/1404.7584 (2014). arXiv: [1404.7584](https://arxiv.org/abs/1404.7584). URL: <http://arxiv.org/abs/1404.7584>.

