



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Thiago Rateke

Deteccção de caminho navegável em estradas de baixa qualidade

Florianópolis

2020

Thiago Rateke

Detecção de caminho navegável em estradas de baixa qualidade

Tese submetida ao Programa de Pós-Graduação
em Ciência da Computação para a obtenção do
título de doutor em Ciência da Computação.
Orientador: Prof. Aldo von Wangenheim, Dr.

Florianópolis

2020

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Rateke, Thiago
Detecção de caminho navegável em estradas de baixa
qualidade / Thiago Rateke ; orientador, Aldo von
Wangenheim, 2020.
136 p.

Tese (doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Ciência da Computação, Florianópolis, 2020.

Inclui referências.

1. Ciência da Computação. 2. Detecção de Caminho. 3.
Detecção de Danos. 4. Detecção de Superfícies. 5. Detecção de
Obstáculos. I. von Wangenheim, Aldo. II. Universidade
Federal de Santa Catarina. Programa de Pós-Graduação em
Ciência da Computação. III. Título.

Thiago Rateke
Detecção de caminho navegável em estradas de baixa qualidade

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Mauro Roisenberg, Dr.
Universidade Federal de Santa Catarina

Prof. Alexandre Gonçalves Silva, Dr.
Universidade Federal de Santa Catarina

Prof. Marcelo Ricardo Stemmer, Dr.
Universidade Federal de Santa Catarina

Prof. Eros Comunello, Dr.
Universidade do Vale do Itajaí

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de doutor em Ciência da Computação.

Prof. Vania Bogorny, Dr.^a
Coordenadora do Programa

Prof. Aldo von Wangenheim, Dr.
Orientador

Florianópolis, 2020.

Este trabalho é dedicado à minha companheira Karla Aparecida
Justen e aos meus pais Gilberto Rateke e Maria Helena Lemos
Rateke. Dedico também as diferentes versões de meu Eu do
futuro.

AGRADECIMENTOS

À minha namorada Karla Aparecida Justen, pessoa que admiro muito, por todo o apoio durante essa jornada, não somente emocional mas também técnico. Me motivou e ainda motiva a evoluir cada vez mais como ser humano em diversos aspectos.

Aos meus pais, Gilberto Rateke e Maria Helena Lemos Rateke pelo incentivo e suporte que sempre me deram em toda a minha vida.

À minha irmã, irmãos, cunhado, cunhadas, afilhada, afilhados e sobrinhos que sempre demonstraram apoio e por saber que posso sempre contar com vocês.

Ao meu orientador, professor Aldo von Wangenheim, não só pela orientação nesta tese de doutorado, mas pela parceria, aprendizado e oportunidades ao longo de mais de 10 anos.

Aos professores que durante toda minha jornada acadêmica tiveram alguma influência na minha formação.

Aos amigos e colegas de Lapix, além do apoio, mas também pelo conhecimento compartilhado.

Aos demais amigos e familiares que demonstraram apoio durante minha formação acadêmica.

À Anita, minha amiga de quatro patas que não está mais entre nós, mas esteve presente durante quase toda minha vida acadêmica, e mesmo sem saber sempre me ajudou a distrair e esquecer um pouco as dificuldades. Foi o único ser que não importava meu humor, sempre me recebia exageradamente feliz.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Também foi apoiado pelo Instituto Nacional para Convergência Digital (INCoD), uma unidade de pesquisa do Instituto Nacional de Ciência e Tecnologia (INCT) do Conselho Nacional Brasileiro de Ciência e Tecnologia (CNPq).

RESUMO

Identificar um caminho navegável é uma função importante em um sistema de navegação visual, podendo ter diferentes aplicações práticas, como: veículos autônomos, sistemas de assistência ao motorista ou localização e mapeamento. Para essa tarefa há dois objetivos principais que são: encontrar o caminho à frente do veículo e identificar obstáculos nesse caminho. Isso pode ser alcançado por diferentes tipos de sensores, sejam de visão ativa (lasers) ou visão passiva (câmeras). Alguns desafios devem ser considerados: ambiente em constante alteração, mudanças de iluminação, alterações no tipo de terreno, presença de diferentes obstáculos, buracos ou poças de água no caminho. Além disso, é possível observar pelo estado da arte que a grande maioria dos trabalhos tem como cenário estradas de países desenvolvidos, Europa ou América do Norte, apresentando poucos danos e variações na superfície da estrada. Esse trabalho tem como objetivo utilizar visão passiva, com base em imagens, para a identificação de um caminho navegável, considerando variações na superfície do terreno como tipo de pavimento e danos. Esta tese propõe o uso de técnicas específicas de Visão Computacional e Aprendizado de Máquina para a resolução desses problemas. Como resultados deste trabalho foram geradas duas revisões sistemáticas da literatura, uma com foco na detecção de caminho e outra com foco na detecção de obstáculos. Uma base de imagens para testes e validação também foi criada para os experimentos, com mais de 60 mil frames. Utilizando imagens dessa nova base, foram criados três novos *Ground Truth* (GT), sendo dois GTs para abordagens de classificação de imagens como: tipos de superfície e qualidade da superfície, e o último GT para abordagem de segmentação de imagem, com foco na segmentação da estrada e das características da estrada. Também foram feitas anotações em imagens de outras bases, principalmente para um GT com foco na detecção dos objetos com informações de movimento e profundidade. Foram consideradas três abordagens experimentais. A primeira visou identificar as características de obstáculos não relacionados à superfície da estrada, como por exemplo: outros veículos e pedestres. Nessa abordagem foram utilizadas informações obtidas por um detector de objetos gerado pela arquitetura de rede neural Mask R-CNN, e com base nos objetos detectados foram extraídos os dados de distância e movimento com a utilização de Visão Estéreo e *Optical Flow*. Na segunda abordagem com foco na superfície da estrada, foi desenvolvido um classificador de tipos de superfície e qualidade de estrada. Nessa abordagem foi realizado um pré-processamento das imagens, definindo uma Região de Interesse (ROI) e também replicando as imagens com variações de iluminação, de modo a implementar *data augmentation* para melhoria dos resultados. Em seguida, foi utilizada uma estrutura de rede neural convolucional (CNN) simples para treinar e classificar as imagens nos rótulos de tipo de superfície e também de qualidade de superfície. A terceira abordagem, também com foco na superfície do caminho, foi a aplicação do GT de segmentação de superfícies em uma arquitetura CNN conhecida (U-NET com ResNet) com parametrização dos pesos de cada classe. Os resultados obtidos mostram que é possível utilizar visão passiva para detecção de caminho em estradas com variações na superfície e com danos.

Palavras-chave: Detecção de Caminho. Detecção de Danos. Detecção de Superfícies. Detecção de Obstáculos. Visão Passiva.

ABSTRACT

Identifying a navigable path is an important function in a visual navigation system and can have different practical applications, such as: autonomous vehicles, driver assistance systems or location and mapping. There are two main goals for this task: finding the path ahead of the vehicle and identifying obstacles along the way. This can be achieved by different types of sensors, whether they are active vision (lasers) or passive vision (cameras). Some challenges must be considered: changing environment, changes in lighting, changes in the type of terrain, presence of different obstacles, potholes or water puddles on the road. In addition, it is possible to observe from the state of the art that the vast majority of the works are on the roads of developed countries, Europe or North America, with little variation in the road surface and with little damage to the road surface. This work aims to use passive vision, based on images, for the identification of a navigable path, considering variations in the road surface such as type of pavement and damage. This thesis proposes the use of specific techniques of Computer Vision and Machine Learning to solve these problems. As a result of this work, two systematic literature reviews were generated, one focusing on path detection and the other focusing on obstacle detection. An image dataset for testing and validation was also created for the experiments, with more than 60 thousand frames. Using images from this new dataset, three new Ground Truth (GT) were created, two GTs for image classification approaches such as: surface types and surface quality, and the last GT for image segmentation approach, focusing on road segmentation and the road features. Annotations were also made in images from other datasets, mainly for a GT with a focus on detecting objects with movement and depth information. Three main approaches were carried out in experiments. The first one aimed to identify the features of obstacles not related to the road surface, such as: other vehicles and pedestrians. In this approach, information obtained by an object detector generated by the Mask R-CNN neural network architecture was used, and based on the detected objects, distance and movement data were extracted using Stereo Vision and Optical Flow. In the second approach focusing on the road surface, a classifier for surface types and road quality was developed. In this approach, pre-processing of the images was performed, defining a Region of Interest (ROI) and also replicating the images with different lighting variations, such as data augmentation, then a simple convolutional neural network (CNN) structure was used to train and classify the images on the surface type and surface quality labels. The third approach, also focusing on the road surface, was the application of the surface segmentation GT in a known CNN architecture (U-NET with ResNet) with parameterization of the weights of each class. The obtained results show that it is possible to use passive vision for road detection on roads with variations in the surface and with damage.

Keywords: Road Detection. Damage Detection. Surface Detection. Obstacle Detection. Passive Vision.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplos de cenário de aplicação	26
Figura 2 – Parte do circuito para criação da nova base de casos	31
Figura 3 – Tipos de Detecção de caminho. (a) Baseado em Características; (b) Baseado em Regiões; (c) Baseado em Modelos.	34
Figura 4 – Exemplo de imagem segmentada. (a) Imagem original do <i>dataset</i> da KITTI. (b) Resultado de segmentação.	36
Figura 5 – Detecção de descontinuidades. a) Imagem original. b) Limites da estrada pela detecção de bordas.	37
Figura 6 – Exemplo de segmentação superpixel. (a) Imagem original do dataset KITTI. (b) Segmentação superpixel.	39
Figura 7 – Exemplo de detecção de ponto de fuga.	40
Figura 8 – Exemplo de Visão Estéreo. (a) Imagem original da base KITTI. (b) Mapa de Disparidade.	40
Figura 9 – Exemplo de Fluxo Ótico em imagem da base KITTI.	42
Figura 10 – a) Segmentação por instâncias. b) Segmentação semântica.	45
Figura 11 – Arquitetura UNet	46
Figura 12 – Cenários - Tipos de Terreno. Asfalto(<i>Asphalt</i>) (78). Sem pavimento (<i>Unpaved</i>) (13). Qualquer tipo de terreno (<i>Different surfaces</i>) (43).	52
Figura 13 – Exemplo de falhas na detecção do caminho em pequenas variações de iluminação usando imagens do conjunto de dados KITTI (GEIGER et al., 2013).	55
Figura 14 – Tipos de Detecção de Obstáculos. Obstáculos em geral (78). Veículos (18). Pedestres (12). Obstáculos Negativos (2).	59
Figura 15 – Exemplo da detecção de obstáculo negativo (KARUNASEKERA et al., 2017)	62
Figura 16 – Exemplo de imagem em detecção de buraco com imagem aérea e muito próxima do buraco.	65
Figura 17 – Exemplo da Mask R-CNN no dataset KITTI.	68
Figura 18 – Os passos da abordagem.	69
Figura 19 – Amostras do dataset RTK.	70
Figura 20 – Amostras do GT segmentado.	72
Figura 21 – Os modelos e a sequência de utilização.	73
Figura 22 – Os passos e a estrutura CNN utilizados.	73
Figura 23 – Regiões de Interesse. Primeira linha: RTK dataset. Segunda linha: KITTI dataset. Terceira linha: CaRINA dataset.	74
Figura 24 – Passos da bordagem de segmentação.	77
Figura 25 – Resultados da detecção e extração de movimento e distância de obstáculos na base KITTI.	81
Figura 26 – Resultados da detecção e extração de movimento e distância de obstáculos na base CaRINA.	81

Figura 27 – Destaque na análises de movimento, velocidade e distância.	82
Figura 28 – Destaque na análises de movimento, velocidade e distância.	83
Figura 29 – Classificação de tipos de superfície na base RTK	86
Figura 30 – Classificação de tipos de superfície na base CaRINA	87
Figura 31 – Classificação de tipos de superfície na base KITTI	87
Figura 32 – Resultados da classificação de qualidade na RTK	90
Figura 33 – Resultados da classificação de qualidade na CaRINA	91
Figura 34 – Resultados da classificação de qualidade na KITTI	91
Figura 35 – Matriz de confusão para r34-DW	96
Figura 36 – Resultados no dataset de validação. Estradas de asfalto com variações na superfície, e transições asfalto-terra e asfalto-lajota. Esquerda: original, centro: GT, direita: resultados	97
Figura 37 – Resultados no dataset de validação. Estradas de terra com variações na superfície, e transições terra-asfalto e lajota-terra. Esquerda: original, centro: GT, direita: resultados	98
Figura 38 – Resultados no dataset de validação. Estradas de lajota com variações na superfície, e exemplo em asfalto com falha na detecção de lombada. Esquerda: original, centro: GT, direita: resultados	99

LISTA DE TABELAS

Tabela 1 – Detecção de Caminho - Definição da busca	49
Tabela 2 – Detecção de Caminho - Execução ACM	50
Tabela 3 – Detecção de Caminho - Execução IEEE	50
Tabela 4 – Detecção de Caminho - Execução Science Direct	51
Tabela 5 – Detecção de Caminho - Execução Springer	51
Tabela 6 – Seleção Final	51
Tabela 7 – Tipos de Superfície - Asfalto	53
Tabela 8 – Tipos de Superfície - Sem pavimento	53
Tabela 9 – Tipos de Superfície - Qualquer tipo	54
Tabela 10 – Detecção de Obstáculos - Definição da busca	57
Tabela 11 – Detecção de Obstáculos - Execução ACM	57
Tabela 12 – Detecção de Obstáculos - Execução IEEE	58
Tabela 13 – Detecção de Obstáculos - Execução Science Direct	58
Tabela 14 – Detecção de Obstáculos - Execução Springer	58
Tabela 15 – Tipos de Obstáculos - Veículos	61
Tabela 16 – Tipos de Obstáculos - Pedestres	61
Tabela 17 – Tipos de Obstáculos - Obstáculos Negativos	61
Tabela 18 – Tipos de Obstáculos - Obstáculos em Geral	63
Tabela 19 – Acurácia da extração de características dos obstáculos.	79
Tabela 20 – Matriz de confusão da profundidade	79
Tabela 21 – Matriz de confusão do eixo-x	80
Tabela 22 – Matriz de confusão do eixo-y	80
Tabela 23 – Matriz de confusão da intensidade de movimento	80
Tabela 24 – Resultados da classificação de tipos de superfície. Apenas RTK	84
Tabela 25 – Resultados da classificação de tipos de superfície. RTK, KITTI e CaRINA	84
Tabela 26 – Resultados da classificação de tipos de superfície. RTK, KITTI, CaRINA e com balanceamento	84
Tabela 27 – Matriz de confusão do dataset RTK	84
Tabela 28 – Matriz de confusão do dataset KITTI	85
Tabela 29 – Matriz de confusão do dataset CaRINA	85
Tabela 30 – Resultados da classificação de qualidade	88
Tabela 31 – Matriz de confusão da classificação de qualidade na RTK	88
Tabela 32 – Matriz de confusão da classificação de qualidade na KITTI	89
Tabela 33 – Matriz de confusão da classificação de qualidade na CaRINA	89
Tabela 34 – Resultados de acurácia em diferentes configurações	93
Tabela 35 – Resultado de acurácia final com a configuração r34-DW durante 100 épocas	94
Tabela 36 – Comparativo de detecções da tese com outros trabalhos	95
Tabela 37 – Lista dos trabalhos gerados, publicados, submetidos e em correção.	101

LISTA DE ABREVIATURAS E SIGLAS

PDI	Processamento Digital de Imagens
VC	Visão Computacional
ADAS	<i>Advanced Driver-Assistance Systems</i>
SLAM	<i>Simultaneous Localization and Mapping</i>
LIDAR	<i>Light Detection and Ranging</i>
VP	Visão Passiva
CNT	Confederação Nacional do Transporte
SNV	Sistema Nacional de Viação
DL	<i>Deep Learning</i>
CNN	<i>Convolutional Neural Network</i>
RSL	Revisão Sistemática da Literatura
GT	<i>Ground Truth</i>
VE	Visão Estéreo
MD	Mapa de Disparidade
ANN	<i>Artificial Neural Networks</i>
YOLO	<i>You only Look Once</i>
SSD	<i>Single Shot Detector</i>
FPN	<i>Feature Pyramid Network</i>
RTK	<i>Road Traversing Knowledge</i>
ROI	<i>Region of Interest</i>

SUMÁRIO

1	INTRODUÇÃO	23
1.1	CONTEXTUALIZAÇÃO DO PROBLEMA	23
1.2	OBJETIVOS	25
1.2.1	Objetivos Específicos	25
1.3	CENÁRIO DE APLICAÇÃO	25
1.4	JUSTIFICATIVA	26
1.4.1	Inovação do Trabalho	27
1.4.2	Contribuições	27
1.4.3	Adequação ao PPGCC	28
1.5	ESTRUTURA DA TESE	28
2	METODOLOGIA	29
2.1	LEVANTAMENTO DO ESTADO DA ARTE	29
2.2	MATERIAIS	29
2.3	ESTRATÉGIA DE VALIDAÇÃO	31
3	FUNDAMENTAÇÃO TEÓRICA	33
3.1	DETECÇÃO DE CAMINHO	33
3.2	DETECÇÃO DE OBSTÁCULOS	35
3.3	MÉTODOS E ABORDAGENS	35
3.3.1	Segmentação de Imagens	36
3.3.1.1	<i>Detecção de Descontinuidades</i>	36
3.3.1.2	<i>Segmentação por Crescimento de Regiões</i>	37
3.3.1.3	<i>Segmentação por Corte em Grafos</i>	38
3.3.1.4	<i>Segmentação por Agrupamentos</i>	38
3.3.1.5	<i>Segmentação Superpixel</i>	38
3.3.1.6	<i>Outros Métodos de Segmentação</i>	39
3.3.2	Detecção de Pontos de Fuga	39
3.3.3	Visão Estéreo	40
3.3.4	Fluxo Ótico	41
3.3.4.1	<i>Lucas-Kanade</i>	42
3.3.4.2	<i>Gunnar-Farneback</i>	43
3.3.5	Redes Neurais Convolucionais	43
4	REVISÃO DA LITERATURA	47
4.1	DETECÇÃO DE CAMINHO	48
4.1.1	Definição da Busca - Detecção de Caminho	49
4.1.2	Execução da Busca - Detecção de Caminho	50

4.1.3	Análise dos Trabalhos Correlatos - Detecção de Caminho	51
4.2	DETECÇÃO DE OBSTÁCULOS	56
4.2.1	Definição da Busca - Detecção de Obstáculos	56
4.2.2	Execução da Busca - Detecção de Obstáculos	57
4.2.3	Análise dos Trabalhos Correlatos - Detecção de Obstáculos	59
4.3	OUTROS TRABALHOS	64
4.4	CONCLUSÕES SOBRE O ESTADO DA ARTE	66
5	DESENVOLVIMENTO	67
5.1	EXTRAÇÃO DE CARACTERÍSTICAS DE OBSTÁCULOS	67
5.2	BASE DE CASOS COM ESTRADAS DE BAIXA QUALIDADE	69
5.3	CLASSIFICAÇÃO DE SUPERFÍCIE E QUALIDADE DE ESTRADA	72
5.4	SEGMENTAÇÃO SEMÂNTICA DE SUPERFÍCIE DE ESTRADAS	75
6	RESULTADOS	79
6.1	RESULTADOS DA EXTRAÇÃO DE CARACTERÍSTICAS DE OBSTÁCULOS	79
6.2	RESULTADOS DA CLASSIFICAÇÃO DE SUPERFÍCIE E QUALIDADE DE ESTRADA	83
6.3	RESULTADOS SEGMENTAÇÃO SEMÂNTICA DE SUPERFÍCIE DE ESTRADAS	91
6.4	RESPOSTA A QUESTÃO DE PESQUISA	100
6.5	PUBLICAÇÕES	100
7	CONCLUSÕES E DISCUSSÕES	103
7.1	TRABALHOS FUTUROS	104
	REFERÊNCIAS	105

1 INTRODUÇÃO

Técnicas de Processamento Digital de Imagens (PDI) e Visão Computacional (VC) têm aplicação em diversas atividades e segmentos da sociedade, contribuindo de forma considerável na coleta, interpretação e análise dos dados em imagens. Apesar de normalmente serem utilizados em conjunto, é necessário discernir seus conceitos. PDI refere-se a um processo, baseado em imagens e operações, podendo gerar um resultado que possibilite a interpretação do usuário. Já VC é a análise de imagens por um equipamento eletrônico com o objetivo de realizar uma interpretação, ou seja, simulando a visão humana. As aplicações que utilizam técnicas de PDI e VC são desenvolvidas em áreas como: sensoriamento remoto, astronomia, área militar, esportes, segurança, biomedicina e robótica (PEDRINI; SCHWARTZ, 2007).

Diversos trabalhos, acadêmicos e comerciais, dedicam-se a cenários e problemas relacionados à navegação, e podem ter objetivos militar, industrial e civil. Mais especificamente, as aplicações podem ser para Veículos Autônomos, Sistemas Avançados de Assistência aos Motoristas (*Advanced Driver-Assistance Systems - ADAS*) e Localização e Mapeamento Simultâneos (*Simultaneous Localization and Mapping - SLAM*). Análises podem ser feitas com base nas imagens do trânsito em estradas para a identificação de placas de automóveis, verificação da velocidade dos veículos em uma determinada faixa, ou até mesmo para verificar a necessidade de manutenção de determinado trecho de alguma rodovia, por exemplo. Usando PDI e VC é possível detectar o caminho que pode ser percorrido e os obstáculos que apareçam; sendo que o ideal é que a detecção de caminho ocorra mesmo com alterações nas características do caminho, ou seja, não importando o tipo de terreno.

1.1 CONTEXTUALIZAÇÃO DO PROBLEMA

A navegação autônoma de veículos já tem destaque há alguns anos e diversos estudos e pesquisas são feitos com este enfoque. Mas ainda é uma área desafiadora, pois como o veículo autônomo pode saber se um terreno é mesmo seguro para ir adiante? Se há uma mudança nos padrões do terreno, como o veículo pode ter certeza de seguir adiante sem que precise de uma interferência manual? Outra etapa importante na navegação autônoma é a detecção de obstáculos, evitando assim acidentes ou colisões.

O objetivo de um sistema de detecção de estrada baseado em VC é possibilitar a detecção da estrada (caminho) com uma fonte de captura que esteja na frente do veículo. Um sistema de detecção baseado em VC é bastante desafiador, pois lida com cenários abertos e com o veículo em constante movimento, ocasionando assim problemas de iluminação, mudança constante do fundo da cena (*background*), presença de diferentes objetos (veículos, pessoas, etc.), diferentes cenários e tipos de terrenos (urbanos, rodovias, estradas de terra) (ÁLVAREZ; GEVERS; LÓPEZ, 2009).

Guo, Mita e McAllester (2012) embasam a dificuldade na detecção de caminho pela VC, justamente pelo grande número de fatores (tipos de terreno, iluminação, condições de

tempo e clima) que não são facilmente medidos e que influenciam consideravelmente e tem um grande impacto na detecção de estrada.

Além disso, uma das tarefas mais importante em um sistema de navegação autônoma é a percepção do ambiente e dos obstáculos contidos neste ambiente. Então um sistema robusto de veículos inteligentes deve levantar as informações necessárias para a detecção e rastreamento dos obstáculos, como: posição, tamanho e velocidade que cada obstáculo detectado possui (DANESCU et al., 2012).

Muitos métodos de detecção de obstáculos baseados em visão objetivam identificar apenas certos tipos de obstáculos, como por exemplo: somente carros ou somente pedestres. Isso acaba por ocasionar sistemas com um índice considerável de falsos alarmes de detecção e que perdem obstáculos que deveriam ser detectados (WON; JUNG, 2012).

Atualmente os casos de grande destaque na navegação autônoma utilizam diversos sensores, não somente câmera (URMSON et al., 2008), (URMSON, 2014b), (URMSON, 2014a) e (FERNANDES et al., 2014). Sendo que um desses sensores, e talvez o principal, é o LIDAR (*Light Detection and Ranging*), que é um laser óptico utilizado para detecção remota de propriedades da luz refletida, de modo a medir distâncias entre o sensor e o objeto alvo (LIDAR, 2015). Nos projetos citados o LIDAR é considerado *Class I*, que é a categoria de menor impacto e com comprimentos de onda de 905nm. Em Commission (2001) e STANDARD (2005) é dito que lasers *Class I* quando não têm contato direto com o olho humano durante um período mais extenso, não representam perigo à retina. Entretanto, em Commission (2001) é apresentado uma tabela com a categorização dos lasers e os possíveis riscos com o excesso de exposição a cada um dos níveis. Os lasers com comprimento de onda entre 780nm e 1400nm, que é a faixa de abrangência do LIDAR, podem causar catarata e queimar a retina. Assim, caso os veículos autônomos sejam uma realidade no dia a dia civil, LIDAR pode não ser uma solução segura para uma grande quantidade de veículos, devido ao excesso de exposição sem proteção.

A Visão Passiva (VP) pode ser uma alternativa nesse cenário futuro e pesquisas realizadas com este enfoque, utilizando somente a informação da câmera (imagem capturada) são feitas a bastante tempo (pelo menos 25 anos (BROGGI; BERTÈ, 1995)), porém são normalmente testadas em estradas de asfalto em boa qualidade (frequentemente na América do Norte ou Europa), e quando avaliadas em outros tipos de terreno, como lajotas ou estrada de terra, não avaliam as transições entre os tipos de superfície. Essas estradas de boa qualidade também deixam de lado outros problemas que são encontrados em cenários de baixa qualidade e falta de manutenção da estrada, como por exemplo: buracos e poças de água.

Segundo a Confederação Nacional do Transporte (CNT) no Brasil, com mais de 107.000 km de rodovias analisadas em 2018 (abrangendo toda a malha rodoviária federal e as principais rodovias estaduais pavimentadas), 37,0% receberam classificação como Regular, 9,5% como Ruim e 4,4% como Péssimo em relação ao pavimento. A pesquisa destaca que 75,9% da extensão analisada apresentou algum problema na superfície da estrada (desgastes, remendos, ondulações, buracos, etc). Além disso, de acordo com o mesmo material, com base em dados do Sistema Nacional de Viação (SNV), do total da malha rodoviária do Brasil, 87,6% não são

pavimentadas (CNT, 2018).

Um outro exemplo, um estudo sobre as estradas do Timor-Leste (CABRAL et al., 2018), mostra que 50% das estradas não são pavimentadas. Esse estudo foi feito como um mapeamento das rodovias do país, similar ao feito pela CNT no Brasil, com o auxílio de diferentes sensores, como: acelerômetro, giroscópio, GPS e outros.

De acordo com um estudo feito pela União Europeia (UE) (FRISONI et al., 2014), as principais causas de acidentes nas estradas estão relacionadas ao comportamento humano ao dirigir, como por exemplo: dirigir sem atenção, dirigir alcoolizado, dirigir agressivamente, etc. Mas mesmo não sendo a principal causa, as condições de superfície de estrada e a falta de manutenção também podem ser responsáveis por acidentes e grande parte relacionado com a reação dos motoristas ao encontrarem alguma variação ou dano na superfície do terreno.

Pergunta de Pesquisa: Como identificar um caminho navegável em estradas de baixa qualidade utilizando apenas visão passiva?

1.2 OBJETIVOS

O objetivo geral deste trabalho é demonstrar a factibilidade de detecção de caminho navegável em estradas de baixa qualidade, identificando buracos e poças de água, utilizando captura com base em VP e métodos de VC, PDI e *Deep Learning* (DL). Adicionalmente, são definidos os seguintes objetivos específicos:

1.2.1 Objetivos Específicos

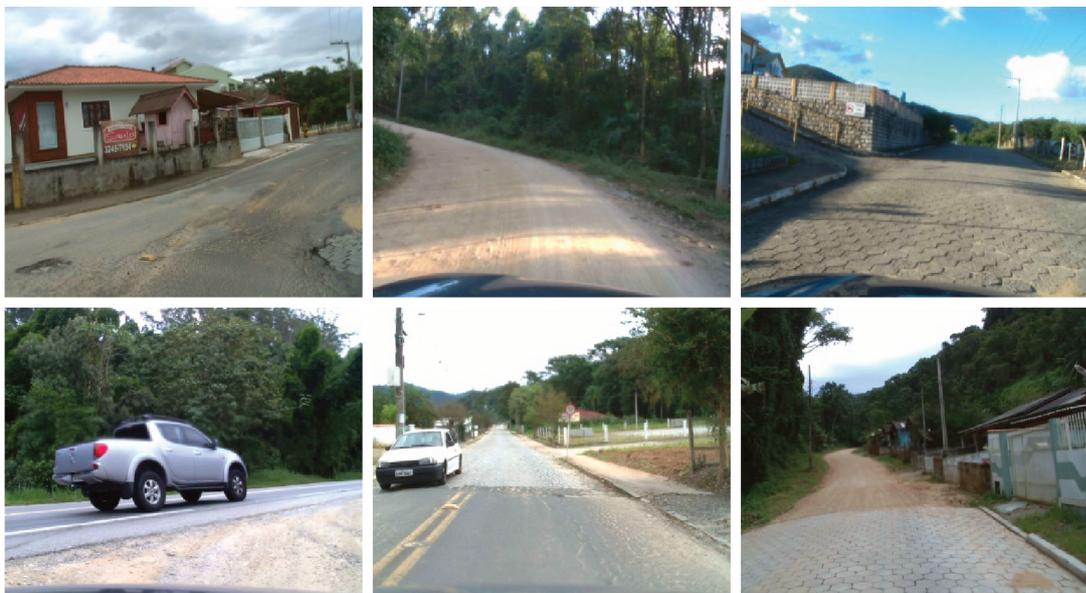
- **OE1**, Identificar o estado da arte em detecção de caminho;
- **OE2**, Identificar o estado da arte em detecção de obstáculos;
- **OE3**, Detectar o caminho independente de mudanças no tipo de terreno (ex.: asfalto, terra e lajota) e mudanças de iluminação (ex.: sombras);
- **OE4**, Detectar obstáculos no caminho (ex.: carros, pessoas, buracos e poças de água) e seus movimentos em relação a fonte de captura;
- **OE5**, Avaliar e Validar os resultados em diferentes bases de casos;
- **OE6**, Criar uma nova base de casos com mais exemplos de transições de tipos de terrenos, buracos e poças de água;

1.3 CENÁRIO DE APLICAÇÃO

- **Tipos de Terreno e Iluminação:** O caminho navegável deve ser detectado em cenários urbanos e rurais, levando em consideração diferentes tipos de terreno (Figura 1) com base

em imagens frontais e inclusive em transições bruscas de tipo de terreno, como por exemplo de asfalto para terra. A detecção do caminho também deve ocorrer independente das condições de iluminação, que fazem variar as informações de cor nos *pixels* da imagem, tendo como situação mais crítica as ocorrências de sombras no caminho.

Figura 1 – Exemplos de cenário de aplicação



Fonte: Desenvolvido pelo autor.

- **Obstáculos:** Para que se obtenha de forma completa um caminho navegável, visando um sistema de navegação, é importante a detecção de obstáculos nesse caminho, considerando inclusive a movimentação em relação à fonte de captura. Além de veículos e pedestres, é importante ressaltar o cenário em estradas de baixa qualidade e que tenham ocorrências de buracos e poças de água.

1.4 JUSTIFICATIVA

Levando em consideração que a navegação autônoma está cada vez mais próxima de tornar-se uma realidade, e os trabalhos atuais de maior sucesso utilizam sensores a laser, então em um futuro onde a navegação autônoma seja utilizada em grande escala, pode ser prejudicial à saúde humana. Desta forma, esta tese pretende verificar que a visão passiva (somente câmeras) seja o suficiente para a identificação de um caminho navegável. Para isso serão utilizadas técnicas de Visão Computacional e Aprendizado de Máquina para a detecção de caminho e de obstáculos de forma adaptativa.

Outro argumento para essa tese é o fato de que os trabalhos relacionados à detecção de caminho ou de obstáculos normalmente são específicos para uma determinada tarefa, como por exemplo: detecção de pessoas, ou detecção de outros carros. E os trabalhos têm focado

em situações de estradas em boas condições de manutenção, deixando de lado problemas na superfície do caminho, como buracos.

Para realizar a detecção de caminho, serão aplicadas arquiteturas de rede neural convolucional (*Convolutional Neural Network* - CNN) para classificação e segmentação de imagem, definindo desta forma, a parte da imagem que é considerada um caminho que pode ser seguido, e separando do restante da imagem. E isso deve ocorrer de forma adaptativa, ou seja, não importando as mudanças no caminho (cor, tipo de terreno, etc.) a detecção deve continuar acontecendo.

A detecção de obstáculos se dará principalmente pela utilização de técnicas de visão estéreo (utilização de duas câmeras) para medir a distância de obstáculos em relação às fontes de captura. E a visão estéreo pode ser útil também para melhorar ou dar robustez à detecção de caminho. Além do uso de Fluxo Ótico para verificar a direção e intensidade de movimento. Tudo isso em conjunto com arquitetura de CNN.

1.4.1 Inovação do Trabalho

Com base nos levantamentos do estado da arte, dos últimos dez anos, na área de detecção de caminho navegável, foi possível observar que, apesar de uma considerável quantidade de trabalhos utilizando VP tanto para a detecção do caminho como para a detecção de obstáculos, o foco é em estradas em boas condições. Nos poucos trabalhos onde há algum experimento em estradas de pior qualidade, problemas como buracos na estrada são desconsiderados.

Desta forma, a inovação deste trabalho está na identificação de buracos e poças de água (como possíveis obstáculos) em um sistema de detecção de caminho navegável, mas principalmente na identificação do tipo e qualidade do terreno, sem prejudicar as demais características e informações relevantes, ou seja, ao detectar um buraco, não comprometer a detecção do restante do caminho navegável e nem mesmo deixar de detectar outros possíveis obstáculos no caminho.

1.4.2 Contribuições

A principal contribuição deste trabalho está justamente em uma abordagem para a detecção de buracos e poças de água em um sistema de detecção de caminho navegável em imagens frontais e horizontais com variações nos tipos de pavimento, identificando essas variações. As contribuições secundárias são os resultados das duas revisões sistemáticas da literatura (caminho e obstáculos) e também a construção de uma nova base de casos com diferentes tipos de terreno (incluindo as transições nesses tipos de terreno) e principalmente estradas com buracos e poças de água.

1.4.3 Adequação ao PPGCC

Esta tese está inserida na linha de pesquisa em Inteligência Computacional do Programa de Pós-Graduação em Ciência da Computação (PPGCC) na Universidade Federal de Santa Catarina (UFSC), que descreve como objetivo: “desenvolver pesquisas na área de criação de teorias e modelos para a capacidade cognitiva e a implementação de sistemas computacionais baseados nestes modelos, visando a resolução de problemas que necessitam de inteligência para serem resolvidos.” (PPGCC, 2017).

Mais especificamente esta tese está na Visão Computacional, que permite tanto a capacidade cognitiva com a percepção do ambiente ao seu redor como a implementação de sistemas computacionais com base nessa percepção. Deste modo, a identificação de caminho navegável em estradas de baixa qualidade, com método para identificação de buracos, se enquadra nas metas do PPGCC.

1.5 ESTRUTURA DA TESE

Essa tese está dividida em 7 capítulos. Inicialmente, com a introdução (capítulo 1), apresentando a contextualização do problema, os objetivos, os cenários de aplicação, a justificativa, a inovação do trabalho, adequação ao programa de pós-graduação e por fim esta estrutura geral. O capítulo 2 apresenta a metodologia utilizada nesta tese, mais especificamente sobre o método utilizado para o levantamento do estado da arte, os materiais utilizados e por fim a forma de validação. A fundamentação teórica é apresentada no capítulo 3. No capítulo 4 são apresentados os trabalhos relacionados, obtidos principalmente através de duas revisões sistemáticas da literatura (RSL). O capítulo 5 apresenta as abordagens utilizadas nesta tese para cada problema, sendo ao todo três diferentes abordagens, também apresenta a nova base de casos utilizada em duas das abordagens nesta tese. Os resultados obtidos são apresentados no capítulo 6, seguido pela conclusão da tese no capítulo 7.

2 METODOLOGIA

O método científico utilizado neste trabalho é o hipotético-dedutivo, proposto pelo filósofo austríaco Karl Popper (POPPER, 2002). Onde a partir de uma hipótese estabelece-se uma situação ou resultados experimentais que possam negar a hipótese (PENSAMENTO, 2013). As etapas necessárias são basicamente: **1)** O problema, seguido pela **2)** solução provisória proposta (teoria-tentativa), onde então pode-se **3)** criticar a solução buscando a eliminação de erros, o que por fim, **4)** pode gerar novos problemas e o processo se reinicia (PENSAMENTO, 2013). Exemplificando o método com o trabalho proposto nesta tese temos por exemplo: A detecção de caminho (o problema) por VC, que após os resultados em (RATEKE et al., 2014) (solução provisória) mostrou-se problemática em situações com sombras no caminho (críticas a solução), e sem analisar problemas como buracos (novos problemas), permitiu um novo ciclo no método hipotético-dedutivo.

2.1 LEVANTAMENTO DO ESTADO DA ARTE

Esta etapa tem como objetivo levantar o estado da arte na percepção visual para navegação veicular. Deste modo, são realizadas duas Revisões Sistemáticas da Literatura (RSL) conduzidas com base nos procedimentos descritos em (KITCHENHAM, 2004). A RSL sobre Detecção de Caminho objetiva identificar os métodos utilizados, tipos de terreno utilizados nos experimentos, se é adaptivo em mudanças de terreno, se trata sombras e se identifica buracos e poças de água. A RSL sobre Detecção de Obstáculos objetiva identificar os métodos, quais tipos de obstáculos detecta e se detecta buracos ou poças como obstáculos.

As RSL são divididas em três fases: **1)** Definição, onde os objetivos da pesquisa são identificados e um protocolo é definido, especificando os procedimentos, bases de dados utilizadas e critérios de inclusão e exclusão. **2)** Execução, etapa que inclui a busca e seleção dos trabalhos relevantes de acordo com o protocolo estabelecido na etapa de definição. **3)** Análise, etapa final, que consiste na análise de cada trabalho selecionado na etapa de execução dentro dos objetivos definidos para RSL.

2.2 MATERIAIS

Para os experimentos foram utilizadas bases de casos com imagens frontais e horizontais de caminhos. Uma das mais utilizadas e citadas em trabalhos relacionados com detecção de caminho é a base KITTI¹ (GEIGER; LENZ; URTASUN, 2012; FRITSCH; KÜHNLE; GEIGER, 2013; GEIGER et al., 2013; MENZE; GEIGER, 2015) da *Karlsruhe Institute of Technology*, que contém imagens estéreo em tons de cinza e coloridas filmadas na região de Karlsruhe na Alemanha em áreas rurais, urbanas e rodovias. A base da KITTI apresenta imagens que variam entre pouca movimentação de veículos e pedestres até situações com muita movimentação.

¹ http://www.cvlibs.net/datasets/kitti/raw_data.php

Apresenta situações com sombras no caminho e variações de iluminação e é, em sua maioria, em estradas de asfalto com algumas variações com estrada de lajota. Apesar de ser útil para a detecção de caminho e de obstáculos, de apresentar imagens com sombras e de ser um paralelo para outros trabalhos correlatos que a utilizaram, a base da KITTI peca em situações de danos na estrada. Nas imagens da base as estradas estão em boas condições o que dificulta a principal meta desta tese, detectar um caminho navegável em estradas de baixa qualidade.

Deste modo, uma outra base de casos também é necessária, e a base CaRINA² (SHINZATO et al., 2016) do Laboratório de Robótica Móvel (ICMC/USP - São Carlos) tem exatamente esse intuito, lidar com cenários mais desafiadores e que representam a realidade de países em desenvolvimento. Os dados foram obtidos na cidade de São Carlos no estado de São Paulo. Assim como a base da KITTI também é composta por imagens estéreo, a diferença está justamente na superfície das estradas, com estradas de baixa qualidade e com falta de manutenção. As imagens foram coletadas durante o dia e com boas condições de iluminação, também há bastante sombras e transições em tipo de superfície como desafio para a detecção do caminho.

Outras bases de casos foram encontradas, porém não serão utilizadas para os experimentos. A CamVid (BROSTOW; FAUQUEUR; CIPOLLA, 2009) por exemplo, do *Computer Vision Group* da *University of Cambridge* contém somente imagens monoculares, o que impossibilita o uso de métodos de visão estéreo e estimativa da distância de objetos em relação à fonte de captura. Outra base descartada foi a CityScapes (CORDTS et al., 2015), (CORDTS et al., 2016), pois assim como a KITTI, são imagens de boa qualidade de estradas na Alemanha e, além disso, os dados que foram possíveis acessar não estavam com *frames* sequenciais. Uma base mais antiga, feita na Itália, a DIPLODOC (ZANIN et al., 2004), também com imagens estéreo, e com estradas em boas condições, sendo, desta forma, também descartada. Por fim, a OffRoadScene (SHANG et al., 2013) da China, que apesar de ser somente com estradas de terra, carece de transições e a falta de estradas de asfalto ruins também pode ser sentida. No entanto, o endereço para acessar essa base de casos está fora do ar e houve tentativas de contato com os autores para se obter os dados, sem resposta.

Além dos dados da KITTI, que apesar de serem em estradas de boa qualidade, é um paralelo com diversos trabalhos encontrados no levantamento do estado da arte e dos dados do CaRINA que apresenta estradas de baixa qualidade. Uma nova base de casos também foi criada, buscando ter mais dados de estradas em baixa qualidade (principalmente com buracos) e com variações de terreno de diferentes tipos: asfalto-lajota, asfalto-terra, terra-lajota. Para isso, um circuito foi definido nas regiões de Águas Mornas - SC (Figura 2), Santo Amaro da Imperatriz - SC e Palhoça - SC. Esse circuito conta com trechos de asfalto em boa qualidade, trechos de asfalto de baixa qualidade, incluindo buracos, trechos em lajotas e trechos de estrada de terra, contando com todas transições entre os diferentes tipos de terreno. Para a coleta foi utilizada uma câmera de baixo custo, HP Webcam HD-4110.

² <http://www.lrm.icmc.usp.br/dataset>

3 FUNDAMENTAÇÃO TEÓRICA

Um sistema de detecção de caminho navegável tem duas tarefas principais que são: detectar o caminho e detectar os obstáculos nesse caminho. Esse capítulo objetiva apresentar os principais métodos de VC e Aprendizado de Máquina que são utilizados para essas duas tarefas.

3.1 DETECÇÃO DE CAMINHO

Pode-se definir caminho como: rota, trajeto, rua, estrada, ou seja, uma superfície onde os veículos podem transitar. Uma estrada pode ser definida como uma estrutura atravessável, linear e, na maioria das vezes, com uma cor que é distinta dos arredores que a envolvem, também se deve estender por uma certa distância em frente ao veículo e ser suficientemente larga. Ou seja, pode-se utilizar as seguintes propriedades para a detecção de caminho: superfície, borda e direção. Entretanto, a dificuldade na detecção de caminho reside justamente nas variações que essas propriedades podem ter, como por exemplo iluminação (sol, sombra) ou alterações na superfície do caminho (OSOSINSKI; LABROSSE, 2013).

A detecção de caminho é uma das questões-chave no desenvolvimento de um veículo inteligente, por isso muita pesquisa vem sendo feita neste enfoque, inclusive verificando a viabilidade da utilização de métodos baseados em VC (GUO; YAMABE; MITA, 2013). Na extração de características do caminho com base nas imagens, pode-se utilizar técnicas de VC e PDI, mais especificamente, métodos de segmentação, permitindo assim separar toda a região considerada como caminho do restante da imagem.

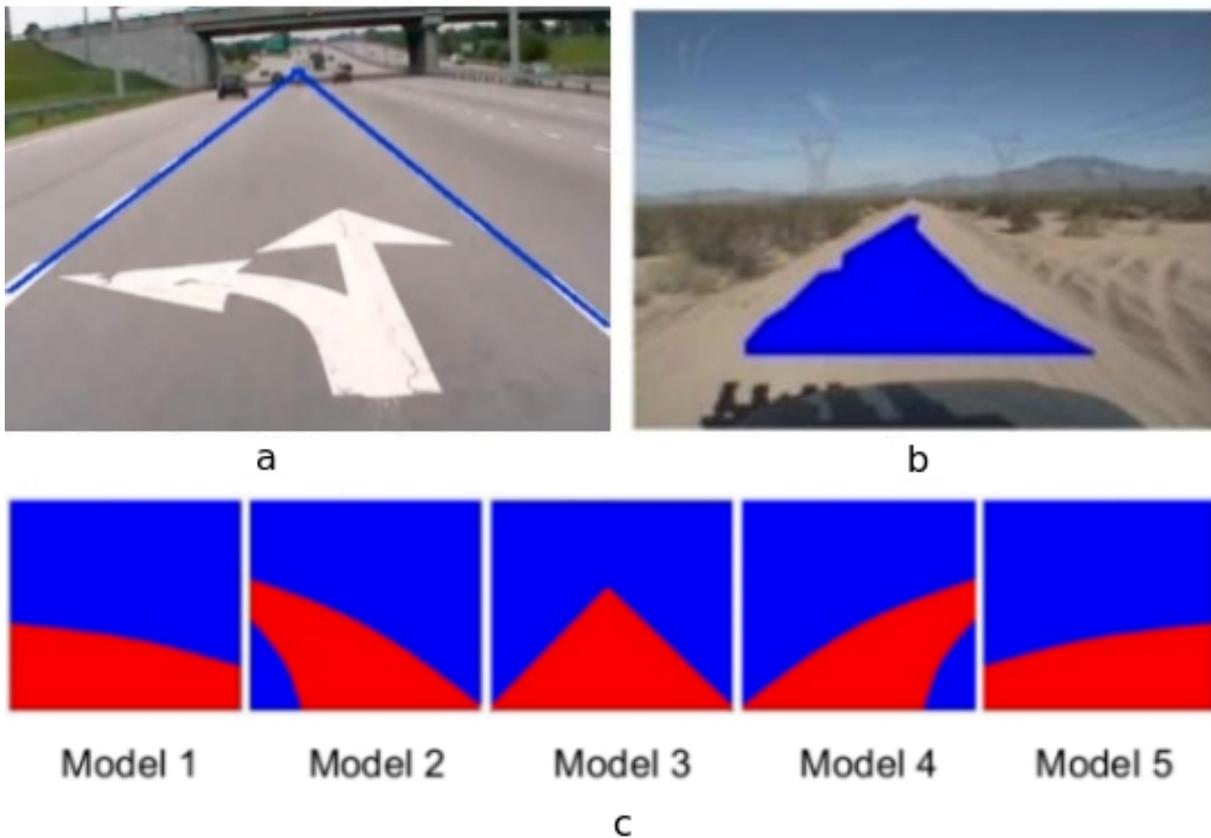
Segundo um levantamento feito por Ososinski e Labrosse (2013), devido a grande variabilidade que as superfícies, bordas e direções que um caminho pode ter, alguns trabalhos propõem a utilização de redes neurais treinadas para reconhecer características específicas do caminho diretamente das imagens, como por exemplo os trabalhos de: (JOCHER; POMERLEAU; THORPE, 1995) e (POMERLEAU, 1993). Entretanto, conforme Ososinski e Labrosse (2013) esses trabalhos que tentaram utilizar redes neurais apresentaram dificuldades em construir um conjunto representativo de formação de imagens ou treinar as redes neurais para aprenderem as variabilidades das propriedades na detecção de caminho. Buscando superar essas dificuldades, alguns métodos dependem de processos com treinamentos individuais e que utilizam diferentes parâmetros de rede neural com base no tipo de caminho a ser conduzido (ROSENBLUM, 2000).

Ainda segundo Ososinski e Labrosse (2013), alguns autores buscando maior segurança e confiabilidade na detecção de caminho optaram por métodos que realizam a extração de características do caminho, marcações geralmente pintadas nas estradas estruturadas e recentemente também com relação as bordas de estradas não estruturadas. Esses métodos, no entanto, necessitam de caminhos que tenham marcações ou bordas bem definidas, e isso, em muitos casos não é possível.

O trabalho de Zhou et al. (2010) categoriza os algoritmos de detecção de estrada em

três tipos (Figura 3), que consideram diferentes informações para obter o resultado: técnicas baseadas em características (Figura 3 a), técnicas baseadas em modelo (Figura 3 c) e técnicas baseadas em regiões (Figura 3 b). As soluções baseadas em características são mais eficazes, mas requerem que as estradas tenham marcações bem definidas e de fácil identificação, e ruídos podem interromper todo o processo de detecção. Os baseados em modelo são mais robustos, entretanto, têm uma grande restrição justamente pela geometria dos modelos. Os mais eficazes das técnicas baseadas em regiões podem ser vistos como problemas de aprendizado de máquina. Utilizando o aprendizado de máquina, pode-se lidar com problemas de ruídos e com as constantes alterações no ambiente. Nesse caso a maior dificuldade é realizar o treinamento da máquina para que ela consiga realizar o aprendizado de um novo ambiente.

Figura 3 – Tipos de Detecção de caminho. (a) Baseado em Características; (b) Baseado em Regiões; (c) Baseado em Modelos.



Fonte: (a) (OZGUNALP; KAYMAK, 2017). (b) (LOOKINGBILL et al., 2007). (c) (ZUO; YAO, 2013).

As técnicas baseadas em regiões tratam, mais especificamente, da extração de informações de cor e textura dos *pixels* na imagem capturada, onde se deve, com base na cor dos *pixels*, segmentar a imagem em regiões consideradas ou não do caminho.

3.2 DETECÇÃO DE OBSTÁCULOS

Uma das tarefas mais importantes em sistemas de percepção visual para navegação autônoma é a percepção do ambiente e os obstáculos contidos nesse ambiente. Isso é importante não apenas para o veículo navegar adequadamente, mas também para evitar acidentes. Um sistema robusto de veículo inteligente deve ser capaz de coletar as informações necessárias para a detecção e rastreamento de obstáculos, como: posição, tamanho e velocidade relativa que cada obstáculo detectado apresenta (DANESCU et al., 2012).

Muitos métodos de detecção de obstáculos baseados em visão objetivam identificar apenas certos tipos de obstáculos, como carros ou pedestres. Isso pode levar a sistemas que apresentam um número considerável de perdas de obstáculos que devem ser detectados (WON; JUNG, 2012).

Para a detecção de obstáculos os métodos de Visão Estereoscópica podem ser utilizados, são técnicas que utilizam as informações capturadas por duas câmeras (fontes de captura) onde, após uma calibração preliminar, estima-se as relações espaciais entre as duas câmeras (ZUREIKI; DEVY; CHATILA, 2007). Conhecimento este que permite o cálculo das coordenadas 3D de um determinado ponto e sua projeção nas imagens por intermédio de uma triangulação simples. Com base nessa projeção, Bleyer (2013) diz que é possível calcular a disparidade entre os *pixels*, ou seja, o quanto cada *pixel* é deslocado de uma imagem em relação à outra.

Além disso, pode-se detectar o movimento dos objetos na cena, buscando prever o destino de um objeto ou, ainda, se está se aproximando ou se afastando da fonte de captura. Segundo Sengar e Mukhopadhyay (2017) o objetivo de uma detecção de movimento de objetos é discriminar os *pixels* de objetos se movendo em primeiro plano do plano de fundo. Fortun, Bouthemly e Kervrann (2015) consideram que a análise de movimento é uma das principais tarefas na VC, pois a informação trazida pelo comportamento dinâmico dos objetos observados, ou pelo movimento da própria câmera é um elemento decisivo para a interpretação dos fenômenos observados. Para essa tarefa pode-se utilizar o fluxo ótico (*optical flow*), que se refere aos deslocamentos dos padrões de intensidade.

3.3 MÉTODOS E ABORDAGENS

Nesta seção são apresentados alguns dos métodos e abordagens comumente utilizados nas realizações das tarefas de detecção de caminho e detecção de obstáculos. Variando entre métodos de VC clássica até os modelos e arquiteturas mais recentes de CNN. Desses métodos, alguns tem aplicação mais comum para uma das duas tarefas (caminho ou obstáculo) como por exemplo a segmentação para a detecção de caminho ou visão estéreo para detecção de obstáculos, mas isso não significa que não possam ser aplicados na outra tarefa, e há trabalhos que o fazem. O trabalho de (WEDEL et al., 2007) utiliza segmentação para a detecção de obstáculos. E em (WU; LAM; SRIKANTHAN, 2015) os autores utilizam visão estéreo para a segmentação do caminho.

3.3.1 Segmentação de Imagens

Na área de processamento digital de imagem (PDI), segmentar significa dividir a imagem de entrada I em partes, sabendo-se que a quantidade de divisões efetuadas depende do contexto do problema. Geralmente a segmentação é uma das tarefas mais difíceis em PDI, mas recompensa por tornar mais simples a análise computacional da imagem (NEVES; PELAES, 2001). Uma segmentação permite rotular os *pixels* em pertencentes à região da estrada ou que não pertencem à região da estrada (Figura 4). Também pode ser utilizada na detecção de obstáculos, rotulando os *pixels* pertencentes a uma classe de obstáculo específica ou mesmo diferentes rótulos para diferentes obstáculos.

Figura 4 – Exemplo de imagem segmentada. (a) Imagem original do *dataset* da KITTI. (b) Resultado de segmentação.



Fonte: (a) (GEIGER et al., 2013). (b) Desenvolvido pelo autor.

A segmentação de imagem consiste basicamente em separar a imagem por regiões (e suas fronteiras). A segmentação de imagem é comumente fundamentada em homogeneidade do sinal (características em comum que os *pixels* compartilham, tais como: níveis de intensidade, textura ou cor) e continuidade (combinação de padrões de homogeneidade ao longo do domínio espacial da imagem). Esses critérios permitem a localização de regiões homogêneas e das fronteiras que são compartilhadas entre as regiões adjacentes. Com o processo de segmentação, a análise da imagem torna-se mais simples, uma vez que existe uma redução no campo de busca devido aos agrupamentos dos *pixels* em segmentos (GONZALEZ; WOODS, 2001).

A segmentação pode seguir duas propriedades: descontinuidade e similaridade. No caso da descontinuidade a partição da imagem é feita com base nas alterações bruscas de intensidade, como por exemplo, a detecção de contornos (bordas), detecção de pontos isolados e detecção de linhas. Para a similaridade a partição da imagem é feita com base na similaridade entre os *pixels*, seguindo um critério definido como: binarização, crescimento de regiões (*Region Growing*), divisão e junção de regiões (*Split & Merge*), aglomeração (*Clustering*) e limiares (*Thresholding*) (NEVES; PELAES, 2001).

3.3.1.1 Detecção de Descontinuidades

Na tarefa de detecção de caminho, essa abordagem é comumente utilizada como um pré-processamento. De acordo com Neves e Pelaes (2001) a detecção de descontinuidades divide-se em três tipos: detecção de pontos isolados, detecção de linhas e detecção de bordas.

Sendo que as mais utilizadas no contexto de detecção de caminho são as detecções de linhas e de bordas.

A detecção de bordas deve obter todas fronteiras possíveis na imagem, ou seja, quando ocorre mudanças bruscas no valor de intensidade entre um *pixel* e outro, tentando ao máximo evitar que ruídos na imagem sejam considerados bordas. E podem ajudar, por exemplo, a encontrar os limites laterais da estrada (Figura 5).

Figura 5 – Detecção de discontinuidades. a) Imagem original. b) Limites da estrada pela detecção de bordas.



Fonte: (AHMED et al., 2008)

3.3.1.2 Segmentação por Crescimento de Regiões

Um dos métodos de similaridade mais usados é a segmentação por crescimento de regiões. Agrupa *pixels* ou sub-regiões em regiões maiores. O crescimento de regiões inicia em relação às coordenadas de entrada sobre uma imagem $I(x,y)$ ou em relação a um ou mais valores de cor ou intensidade. Essa inicialização é conhecida como *seed points* (pontos sementes), e a partir desses pontos crescem as regiões próximas e similares (GONZALEZ; WOODS, 2001). Os algoritmos de crescimento de regiões dependem muito do contexto da aplicação e também da métrica de similaridade usada no agrupamento de regiões. O critério de parada para o método de crescimento por regiões pode variar de acordo com a área da região ou até que não tenha mais *pixels* vizinhos que possam ser incluídos na sub-região (GONZALEZ; WOODS, 2001). Na detecção de estrada os *seed points* geralmente são coletados na parte inferior da imagem (4 (b), retângulo vermelho), onde é esperado que haja *pixels* suficientes pertencentes à estrada.

Entretanto, há trabalhos que realizam a captura dos *seed points* de forma diferente. Por exemplo, em (NETO; RITTNER, 2006) a imagem é dividida em dez partes com alturas iguais, em seguida, uma análise é iniciada com a fatia inferior da imagem e passa para cada fatia em uma sequência ascendente. A técnica Otsu, que busca os limiares ideais de uma imagem, é utilizada nas porções da imagem. Em (ALVAREZ; SALZMANN; BARNES, 2013) um processo de treinamento manual é realizado previamente, selecionando os *pixels* pertencentes a estrada. Em seguida o modelo com base nos *pixel* selecionados é utilizado para verificar a similaridade com a estrada.

3.3.1.3 Segmentação por Corte em Grafos

Aqui a imagem é representada como um grafo, os *pixels* são os nós, a distância está relacionada com o peso, aresta sendo a vizinhança/conectividade entre os *pixels*. A semelhança sendo representada pelos pesos das arestas, que podem ser definidas como: (nodo1, nodo2, peso) ou seja: (pixel1, pixel2, distância). Há também dois nodos terminais especiais, podendo ser o objeto segmentado ou um pixel de fundo (*background*). Normalmente, os *pixels* vizinhos são conectados por bordas e um mapeamento por grades. As bordas entre os *pixels* são chamadas de *n-links*, onde o *n* representa os vizinhos. A definição de vizinhança é arbitrária, podendo ser vertical, horizontal e/ou diagonal (BOYKOV; FUNKA-LEA, 2006).

Em (WANG; REN; YANG, 2016), é proposto um método de detecção de estradas baseado em uma relação de fronteira previamente calculada, usando também informações de cores. Este modelo anterior é calculado pela medição de uma distância geodésica com base em um grafo.

3.3.1.4 Segmentação por Agrupamentos

Refere-se ao agrupamento de um dado conjunto de objetos em subconjuntos de acordo com as propriedades de cada objeto. Atua sobre um espaço chamado de espaço de atributos, que representa um espaço de dimensão elevada, onde cada ponto da imagem é representado por um vetor de atributos, esses atributos são medidas feitas sobre a imagem, como tamanho dos objetos. A segmentação por aglomeração é dividida em duas etapas, sendo a primeira uma etapa onde são computados os vetores de atributos e na segunda é determinada um número ótimo de aglomerados (NEVES; PELAES, 2001). Este método define um rótulo para cada pixel usando dados diferentes, como: média de cores, valores de brilho e informações de textura (CARAFFI; CATTANI; GRISLERI, 2007).

Em (LIU et al., 2014), os autores usaram um agrupamento de médias com lógica *Fuzzy*. O cálculo da distância entre o centro do agrupamento e um *pixel* considera o fator de impacto da vizinhança.

3.3.1.5 Segmentação Superpixel

Em vez de trabalhar apenas no nível de *pixel* único, a segmentação superpixel permite reduzir a quantidade de dados, reduzindo a redundância de imagem, para os próximos métodos no pipeline de detecção, porque considera grupos de *pixels* semelhantes como uma única entidade, conforme mostrado na Figura 6 (b). Essa técnica é normalmente utilizada como pré-processamento e deixa as etapas seguintes mais eficientes, trabalhando com grupos de regiões e não com os *pixels* individuais (REN; MALIK, 2003) e (ZHANG et al., 2017).

Figura 6 – Exemplo de segmentação superpixel. (a) Imagem original do dataset KITTI. (b) Segmentação superpixel.



Fonte: (a) (GEIGER et al., 2013). (b) Desenvolvido pelo autor

3.3.1.6 Outros Métodos de Segmentação

Na segmentação *Mean-Shift*, primeiro é calculada uma medida da distância entre *pixels* por uma função de distância. Após essa medição de distância, um raio é definido e, em seguida, todos os pixels dentro desse raio são usados para verificar a diferença de valor, e a média é alcançada por *pixels* cujos valores estão dentro dessa diferença.

Na segmentação por *Splitting and Merging* a imagem de entrada I é subdividida em um conjunto de regiões disjuntas, podendo então, mesclar ou separar essas regiões. Esse método é baseado em duas etapas. *Splitting*, que subdivide uma imagem de entrada em quadrantes menores. E a etapa *Merging*, que ocorre depois da realização da etapa *Splitting*. Esse processo é repetido enquanto nenhum *merging* ou *splitting* for possível (GONZALEZ; WOODS, 2001).

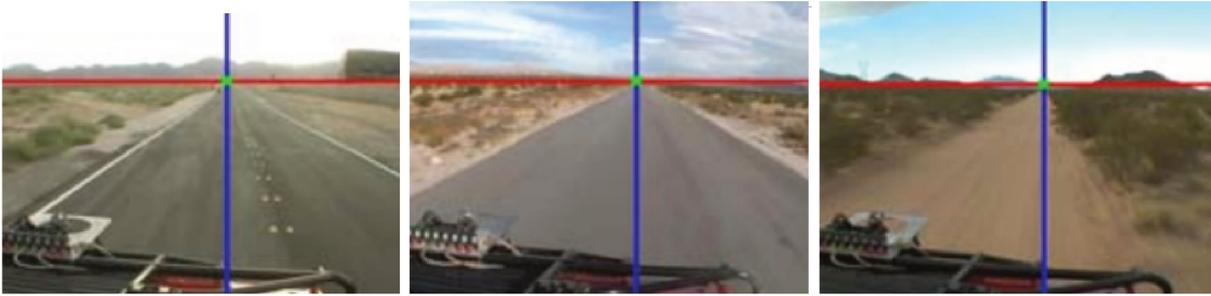
3.3.2 Detecção de Pontos de Fuga

De acordo com Kong, Sarma e Tang (2013), a detecção de ponto de fuga pode ser tanto com base em textura ou com base em bordas. Nos métodos baseados em textura, uma votação para o provável ponto de fuga é realizada com base nas orientações de textura em cada *pixel*. Nas abordagens baseadas em bordas, um ponto de fuga é encontrado quando duas ou mais linhas retas dominantes, quase paralelas, parecem convergir e cruzar.

Essas linhas são aceitas para coincidir com os limites da estrada, como uma borda ou até as marcações da estrada. A interseção entre esses limites da estrada é aceita como o fim da estrada, o ponto em que o veículo provavelmente está indo. Para ilustrar detecções de ponto de fuga, exemplos de (RASMUSSEN, 2008) são apresentados na Figura 7.

A detecção de ponto de fuga pode ser utilizada não só para estimar o caminho, mas também é utilizada para outras tarefas na visão computacional que podem ser úteis para um veículo inteligente, como: calibração da câmeras, estimativa de pose, medição de altura, detecção de objetos e reconstrução 3D da cena (ZHOU; FARHAT; WANG, 2017; LEZAMA; RANDALL; GIOI, 2017). Percebe-se, porém, a dependência de se encontrar bordas ou linhas na imagem para que o ponto de fuga seja calculado.

Figura 7 – Exemplo de detecção de ponto de fuga.



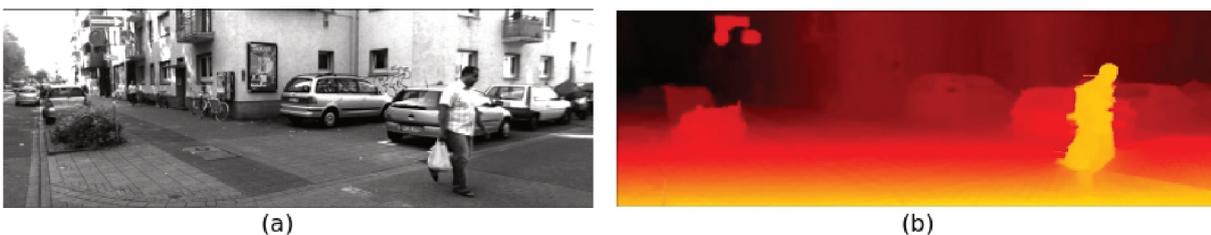
Fonte: (RASMUSSEN, 2008)

3.3.3 Visão Estéreo

A visão estéreo (VE) é uma técnica de extração de características de imagem que visa a extração de informações 3D de conjuntos de imagens adquiridas simultaneamente de diferentes pontos de vista, permitindo identificar a profundidade da cena e dos objetos na cena através do cálculo da disparidade entre essas imagens. A disparidade é o valor de deslocamento de um *pixel*, que representa um ponto no mundo real, correspondente entre duas imagens. Gu et al. (2008) descrevem a correspondência estéreo como o processo de encontrar pontos correspondentes entre duas ou mais imagens.

As técnicas de VE são as abordagens mais usadas para a tarefa de detecção de obstáculos baseada na visão passiva. Na VE, a captura da cena é geralmente realizada por duas câmeras para estimar a profundidade dos objetos, onde, após uma calibração preliminar, as relações espaciais entre essas duas câmeras são estimadas (ZUREIKI; DEVY; CHATILA, 2007). Isso permite o cálculo de coordenadas 3D de um determinado ponto e sua retroprojeção nas imagens por meio de uma triangulação simples. Com base nessa projeção, é possível calcular a disparidade entre os *pixels* (BLEYER, 2013). Na Figura 8 é apresentado um exemplo de Mapa de Disparidade (MD) de uma cena. A disparidade de cada *pixel* é inversamente proporcional à sua profundidade na cena, portanto, disparidade é comumente utilizada como sinônimo de profundidade (BLEYER, 2013).

Figura 8 – Exemplo de Visão Estéreo. (a) Imagem original da base KITTI. (b) Mapa de Disparidade.



Fonte: (a) (GEIGER et al., 2013). (b) Desenvolvido pelo autor.

A correspondência de imagens estéreo é um dos principais desafios encontrados na visão computacional, pois ela tem que lidar com: inconsistência de cores (ruídos na imagem,

diferentes condições de iluminação entre as câmeras etc.), regiões sem textura, problemas de oclusão de objetos, entre outros. outros desafios (AYDIN; AKGUL, 2010). Normalmente, alguns pressupostos são levados em consideração para a correspondência estéreo:

- **Pressuposto de Consistência de Cores:** *Pixels* correspondentes têm a mesma intensidade (cor) nas duas imagens.
- **Pressuposto Epipolar:** O ponto de correspondência de um *pixel* tem que ficar na mesma linha de varredura (horizontal) da outra imagem.
- **Pressuposto de Suavidade:** Um MD correto, normalmente consiste de regiões de disparidade constantes (ou muito similares), por exemplo, lâmpada, cabeça, mesa. Pode-se dar esse conhecimento à priori para um algoritmo estéreo na forma de um pressuposto de suavidade (BLEYER, 2013).
- **Segundo Pressuposto de Suavidade:** Espacialmente, *pixels* próximos têm a mesma disparidade ou similar. Por “espacialmente próximos”, quer dizer *pixels* de uma coordenada de imagem similar. O pressuposto de suavidade normalmente serve para todos os lugares, exceto nas fronteiras de disparidade (BLEYER, 2013).
- **Pressuposto da Ordenação:** A ordem em que os *pixels* ocorrem é preservada nas duas imagens.

Métodos de análise de correspondência podem ser classificados como: locais ou globais. Métodos locais calculam a disparidade de um determinado ponto com base nos valores de intensidade em uma janela finita. Já os métodos globais, resolvem um problema de otimização para uma linha de varredura ou uma imagem inteira, considerando uma função de custo global, sujeita a uma restrição de suavidade. A análise de correspondência é realizada linha por linha. Cada *pixel* de interesse na imagem da esquerda é comparado com cada *pixel* de interesse na linha correspondente epipolar na imagem à direita (BARROIS et al., 2010).

3.3.4 Fluxo Ótico

A análise de movimento é uma das principais tarefas na visão computacional, pois a informação obtida pelo comportamento dinâmico dos objetos observados ou pelo movimento da própria câmera é um elemento decisivo para a interpretação dos fenômenos observados (FORTUN; BOUTHEMY; KERVRANN, 2015). Para Fleet e Weiss (2005), o movimento é uma fonte rica de informações, útil em muitas tarefas visuais, incluindo: aquisição de formas em 3D, reconhecimento de padrões e compreensão da cena observada.

Segundo Sengar e Mukhopadhyay (2017) há diferentes formas de se detectar movimento, como por exemplo a subtração do plano de fundo (*background subtraction*) que considera um limiar e um modelo de plano de fundo, porém ocorrem falhas em diferentes cenários

devido à falta de modelos de plano de fundo. Uma alternativa é o fluxo ótico (*optical flow*), que calcula o movimento aparente de objetos em *frames* consecutivos. A idéia básica do fluxo ótico é exibir o deslocamento de padrões nos *frames* de vídeo como um campo vetorial, chamado de campo de fluxo ótico. A noção de fluxo ótico refere-se literalmente aos deslocamentos dos padrões de intensidade. (FORTUN; BOUTHEMY; KERVRANN, 2015). Estimar o fluxo ótico tem como objetivo calcular uma aproximação ao campo de movimento a partir da variação de intensidade da imagem no tempo (FLEET; WEISS, 2005).

A visualização do fluxo ótico pode ser de duas formas, sendo: visualização em setas ou em cor. A visualização em seta representa diretamente o vetor de movimento e oferece uma boa percepção intuitiva do movimento físico (Figura 9). A visualização em cores associa uma tonalidade de cor a uma direção e uma saturação à magnitude do vetor. Permitindo uma observação densa do campo de fluxo (FORTUN; BOUTHEMY; KERVRANN, 2015).

Figura 9 – Exemplo de Fluxo Ótico em imagem da base KITTI.



Fonte: Desenvolvido pelo autor.

3.3.4.1 Lucas-Kanade

Um método bastante conhecido e um dos mais citados para cálculo de fluxo ótico é o Lucas-Kanade (LUCAS; KANADE, 1981), disponível na biblioteca de VC, OpenCV (OPENCV, 2017). Nesse trabalho uma nova técnica de registro de imagens, que faz uso do gradiente de intensidade espacial das imagens para encontrar uma boa combinação, é apresentada. O objetivo é alinhar uma imagem de modelo $T(x)$ para uma imagem de entrada $I(x)$, onde $x = (x, y)^T$ é um vetor de coluna contendo as coordenadas dos *pixels*. Sendo aplicado como fluxo ótico, o modelo $T(x)$ é uma sub-região extraída da imagem no momento $t = 1$ e $I(x)$ é a imagem no tempo $t = 2$.

Este método resolve as equações básicas de fluxo ótico para todos os *pixels*, em uma vizinhança, pelo critério dos mínimos quadrados. É um método puramente local porque não pode fornecer informações de fluxo no interior de regiões uniformes da imagem. Assume-se

que o fluxo é constante na vizinhança local do *pixel* em consideração (PATEL; UPADHYAY, 2013).

3.3.4.2 Gunnar-Farneback

Outro método, mais recente, para o cálculo de fluxo ótico, que apresenta bons resultados, é o algoritmo de Gunnar-Farneback (FARNEBÄCK, 2003) que também está disponível na OpenCV (OPENCV, 2017). O algoritmo foi desenvolvido para produzir um método de fluxo ótico denso que funciona em uma grade de pontos. Utiliza a informação de dois *frames* consecutivos para extrair a informação de vetor de deslocamento (FARNEBÄCK, 2003).

O primeiro passo é aproximar cada vizinhança de cada *pixel* em ambos *frames* por meio de polinômios quadráticos, o que pode ser feito com uma transformação de expansão polinomial. Resultando em um modelo de sinal local, expresso em um sistema de coordenadas,

$$f(x) \sim x^T A x + b^T x + c, \quad (3.1)$$

onde A é uma matriz simétrica, b um vetor e c um escalar. Os coeficientes são estimados a partir dos mínimos quadrados ponderados ajustados aos valores do sinal na vizinhança. A ponderação tem dois componentes chamados de: certeza e aplicabilidade. A certeza é ligada aos valores do sinal na vizinhança. A aplicabilidade determina o peso relativo dos pontos na vizinhança com base na sua posição, onde normalmente o ponto central tem maior peso, que reduz radialmente (FARNEBÄCK, 2003).

Depois disso, um novo sinal é construído por um deslocamento inclusivo de todos os *pixels* na imagem. Como o resultado da expansão polinomial é que cada vizinho é aproximado por um polinômio, então é analisado o que acontece se um polinômio é submetido a uma interpretação ideal (FARNEBÄCK, 2003).

Em seguida, um método é derivado para estimar os campos de deslocamento dos coeficientes de expansão polinomial. Assim, ao equacionar os coeficientes do polinômio, o vetor de deslocamento pode ser obtido em cada ponto da imagem assumindo que existe uma sobreposição entre a região de interesse ou seja, a vizinhança da imagem em *frames* adjacentes. Por fim, uma série de refinamentos leva a um algoritmo robusto. (FARNEBÄCK, 2003).

3.3.5 Redes Neurais Convolucionais

As Redes Neurais Artificiais (*Artificial Neural Networks* - ANN) têm sido cada vez mais usadas para aplicações no campo da percepção visual para navegação automotiva. As ANNs são compostas por uma coleção de unidades conectadas chamadas Neurônios Artificiais que modelam neurônios do cérebro de um animal. Em uma ANN, os neurônios são organizados em camadas, que são interconectadas. A ANN mais amplamente utilizada é a *Error-Backpropagation Feedforward Network* (RUMELHART; HINTON; WILLIAMS, 1986).

As Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs) representam uma categoria recentemente desenvolvida de ANNs que se mostraram muito eficazes no reconhecimento e classificação de imagens. As CNNs derivam seu nome do uso de operadores de convolução de processamento de imagem, como Laplacianos, Gaussianos, etc., que são posicionados entre as camadas para transformar o sinal transmitido a partir de conjuntos de conexões de saída de uma camada em conexões de entrada individuais da próxima camada. As CNNs foram originalmente introduzidas por (LECUN et al., 1998) mas tornaram-se amplamente utilizados apenas nos últimos anos. Os Operadores de Convolução podem ser representados por uma ampla gama de operações matemáticas.

De acordo com Haykin (2009), uma CNN é uma ANN projetada para identificar formas bidimensionais com alto grau de invariância à translação, inclinação, redimensionamento e outras distorções. A estrutura das redes convolucionais pode ser dividida em três objetivos principais: Extração de características, mapeamento de características e subamostragem (HAYKIN, 2009). Com esse propósito, as CNNs possuem recursos adicionais que as diferenciam das ANNs tradicionais:

- **Volumes 3D de neurônios:** As camadas nas CNNs são organizadas em 3 dimensões e os neurônios dentro de uma camada são conectados a apenas uma pequena região da camada anterior a ela, chamada campo receptivo.
- **Conectividade local:** As CNNs exploram a localidade espacial, impondo um padrão de conectividade local entre neurônios de camadas adjacentes.
- **Pesos compartilhados:** Cada filtro é replicado em todo o campo visual. Essas unidades compartilham a mesma parametrização e formam um mapa de características, o que significa que todos os neurônios em uma determinada camada convolucional respondem a mesma característica em seu campo de resposta específico, permitindo que as características sejam detectadas independentemente de sua posição no campo visual.

Uma vantagem da CNN é exigir o mínimo de pré-processamento possível e poder receber uma grande quantidade de imagens brutas e extrair características por si só. As redes neurais convolucionais são inspiradas na organização do córtex visual animal, que é composto por milhões de aglomerados. Essas regiões, chamadas de campos receptivos, são formadas por subconjuntos selecionados do vetor de características (representação numérica do objeto) a serem analisados. Os campos receptivos de diferentes neurônios se sobrepõem parcialmente para cobrir todo o campo de visão.

As CNNs podem ser utilizadas tanto para a detecção de obstáculo, como para a detecção de caminho. Na detecção de obstáculo podem ser aplicados modelos de detecção de objetos como: *You only Look Once* (YOLO), *RetinaNet*, *Single Shot Detector* (SSD) e *Mask R-CNN*, que detectam o objeto e a área onde está o objeto, com o uso de *bounding box* em cada objeto identificado.

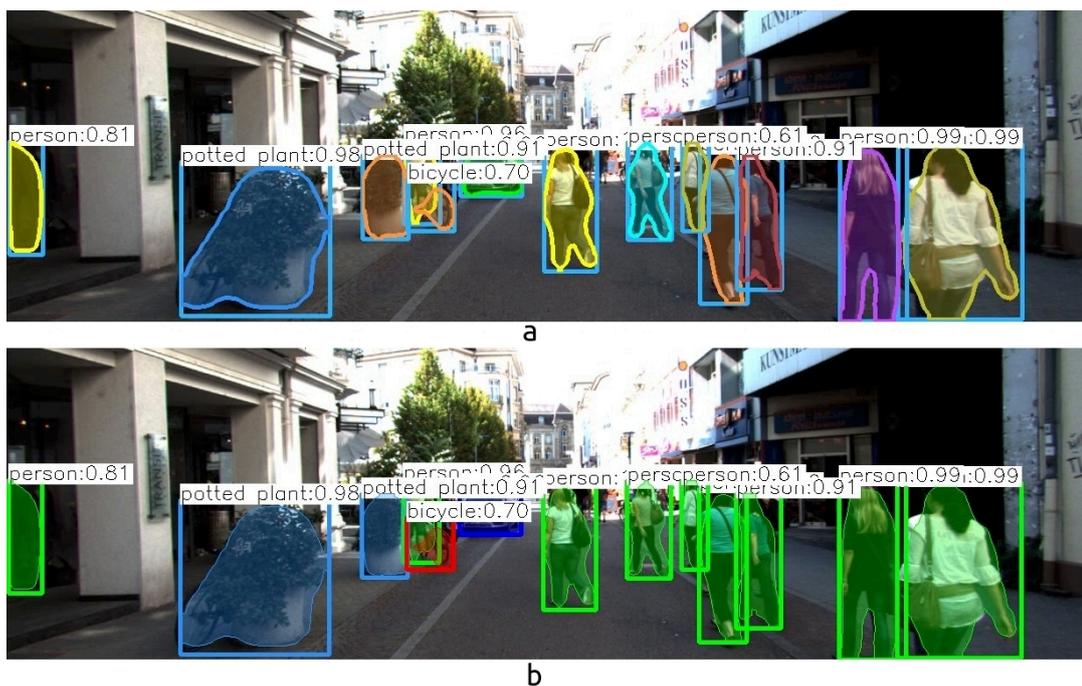
A YOLO (REDMON et al., 2016) consiste em um problema de regressão único que obtém uma imagem de entrada e processa a imagem inteira de uma única vez aprendendo as probabilidades de uma classe e as coordenadas do *bounding box*. A imagem de entrada é dividida em grades ou quadrantes e cada quadrante prevê N *bounding box* com o nível de precisão para esse *bounding box*, checando se há realmente um objeto, independente de classe. Como a grande maioria desses *bounding box* tem baixa precisão, acabam sendo descartados.

O conceito da RetinaNet é baseado no modelo *Feature Pyramid Network* (FPN) (LIN et al., 2017b) com uma nova função de perda chamada de *Focal Loss* (Perda focal) (LIN et al., 2017c). A RetinaNet também utiliza o conceito de redes residuais, ResNet (HE et al., 2016), que é quando algumas camadas são puladas, permitindo treinar redes mais profundas e também que características relevantes das primeiras camadas não sejam perdidas.

A SSD (LIU et al., 2016) executa na imagem de entrada apenas uma vez e calcula um mapa de características. Posteriormente, é executado um pequeno núcleo convolucional de tamanho 3x3 neste mapa de características para prever os *bounding box* e a probabilidade de classificação em uma classe. O SSD prevê *bounding box* após várias camadas convolucionais. Como cada camada convolucional opera em uma escala diferente, é capaz de detectar objetos de várias escalas.

Já a Mask R-CNN (HE et al., 2016) além de detectar os objetos e classifica-los com a utilização de *bounding box*, também faz a segmentação por instâncias desses objetos detectados. A segmentação por instâncias segmenta os objetos de forma individual (ex.: Figura 10 a), diferindo da segmentação semântica onde os objetos são segmentados em classes apenas (ex.: Figura 10 b). A Mask R-CNN é extensão da estrutura Faster R-CNN (REN et al., 2015).

Figura 10 – a) Segmentação por instâncias. b) Segmentação semântica.



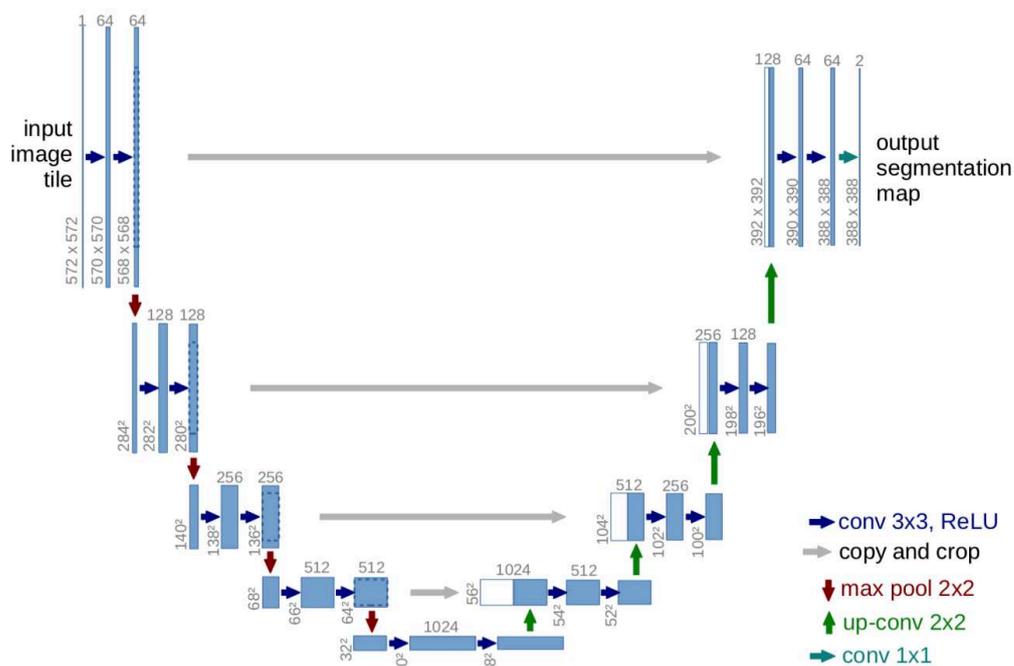
Fonte: Desenvolvido pelo autor.

A Mask R-CNN divide-se em duas etapas. Primeiro gerando propostas sobre as regiões onde pode haver um objeto. Em seguida, prevê a classe do objeto, refinando o *bounding box* e gerando também uma máscara de segmentação do objeto com base na primeira etapa. As etapas estão conectadas à estrutura do *backbone*, que consiste no modelo (FPN). Pode ser utilizada com diferentes variações, como: ResNet, ou com as diferentes variações da arquitetura Inception (SZEGEDY et al., 2016), que utiliza variados filtros (ex.: 1x1, 3x3, 5x5), buscando garantir a extração de características em diferentes escalas.

Na detecção de caminho pode-se focar em modelos específicos de segmentação, como: SegNet e UNet. A SegNet (BADRINARAYANAN; KENDALL; CIPOLLA, 2017) possui uma rede de codificadores (*encoder*) e outra de decodificadores (*decoder*) correspondente, com uma camada final de classificação em nível pixel, ou seja, a segmentação. No *encoder* ocorrem 13 camadas de convoluções e *max pooling*, processo de discretização baseado em amostra que tem por objetivo reduzir uma amostra de entrada. No *decoder* são executados convoluções e a expansão, e ao final é utilizado a função *softmax* para classificar cada *pixel*. Durante a etapa de expansão, são recuperados os índices de *max pooling* na camada de *encoder* correspondente.

Já a UNet (RONNEBERGER; FISCHER; BROX, 2015), apesar de também ter duas partes, *encoder* e *decoder*, difere da SegNet pois ao invés de utilizar índices de *max pooling*, todos os mapas de características são transferidos do codificador para o decodificador e, em seguida, com concatenação para realizar a convolução. No *encoder* da UNet é feita a redução das amostras de entrada, e simetricamente no *decoder* é feita a expansão até o tamanho da amostra de entrada original, o que deixa a arquitetura da rede em formato de “U” (Figura 11).

Figura 11 – Arquitetura UNet



Fonte: (RONNEBERGER; FISCHER; BROX, 2015).

4 REVISÃO DA LITERATURA

Este capítulo apresenta o levantamento do estado da arte obtido por meio das revisões sistemáticas da literatura (RSL) sobre Detecção de Caminho (seção 4.1) e Detecção de Obstáculos (seção 4.2). Apresentando as definições, execuções e análises dos trabalhos encontrados. Ambas as revisões sistemáticas da literatura foram conduzidas com base nos procedimentos descritos em Kitchenham (2004). Ao final deste capítulo também apresentamos alguns trabalhos mais recentes, ou fora do escopo das RSLs 4.3.

Cada RSL é dividida em três etapas: **1)** Definição, onde os objetivos da pesquisa são identificados e um protocolo é definido, especificando os procedimentos, bancos de dados e critérios de inclusão e exclusão. **2)** Execução, etapa que inclui a busca e seleção dos trabalhos relevantes de acordo com o protocolo estabelecido na etapa de definição. **3)** Análise, etapa final, que consiste na análise de cada trabalho selecionado na etapa de execução, dentro dos objetivos definidos para a RSL.

A escolha das fontes de dados levou em consideração sua pertinência nas áreas de robótica móvel, reconhecimento de padrões e processamento digital de imagens. As bases de dados escolhidas contêm publicações em periódicos e congressos importantes e especializados nas áreas mencionadas. Limitou-se as pesquisas a bancos de dados de fontes revisadas por pares: ACM¹ *Digital Library* (da *Association for Computing Machinery*), IEEE² *Xplore digital library* (do *Institute of Electrical and Electronics Engineers*), Springer Link³ (da *Springer International Publishing part of Springer Nature*) e ScienceDirect⁴ (da *Elsevier*).

Durante as RSL foram encontradas outros 5 levantamentos do estado da arte relacionados à detecção de caminho e detecção de obstáculos. O primeiro e mais antigo, focado apenas nas marcações das estradas (detecção de faixas) (MCCALL; TRIVEDI, 2006). Os autores cobriram artigos publicados entre 1992 e 2004, totalizando dezessete trabalhos, incluindo um novo método de detecção de faixa para Sistemas Avançados de Assistência ao Motorista (ADAS), apresentado pelos autores juntamente com a revisão. Essa revisão discute como os modelos de estrada são representados e apresentam métodos para extração de características (por exemplo, intensidades de imagem, magnitudes e orientações de arestas, modelos comparativos) e discutem se algum tipo de pós-processamento é empregado, por exemplo: transformada de Hough, análise de componentes relacionados, rede neural.

Apesar de ter sido publicado em 2013, Yenikaya, Yenikaya e Düven (2013) faz uma revisão de artigos publicados apenas até 2009, mas realiza uma análise mais generalizada, levando em consideração os sensores de visão ativa (LIDAR). Essa revisão também cobre as principais dificuldades na detecção de estradas, como condições climáticas e iluminação, presença de sombras, presença de outros veículos, pessoas ou objetos e diferentes geometrias das

¹ <https://dl.acm.org/>

² <https://ieeexplore.ieee.org/Xplore/home.jsp>

³ <https://link.springer.com/>

⁴ <https://www.sciencedirect.com/>

estradas. Além de apresentar as diferentes técnicas utilizadas, também menciona os ambientes de *hardware* onde essas técnicas podem ser aplicadas.

O trabalho em Hillel et al. (2014) apresenta uma revisão de artigos publicados entre 2005 e 2010 e também leva em consideração sensores de visão ativa. É uma pesquisa focada na detecção de rodovias e, principalmente, faixas. Os autores citam diferentes sensores que são comumente utilizados e também várias técnicas associadas. Essa revisão oferece uma divisão em módulos, como um sistema genérico que visa identificar estradas e faixas, com as etapas necessárias e comuns entre a maioria das tarefas, descrevendo os métodos mais comuns para cada módulo. Os autores publicaram esta revisão como uma atualização da pesquisa em (MCCALL; TRIVEDI, 2006).

A revisão de Shin, Xu e Klette (2014) também se destina a marcações nas estradas, focando em abordagens baseadas em características. Apresenta uma revisão de artigos publicados até 2013. A revisão é dividida em quatro módulos: **1)** Aplicações (tarefas), que podem ser: modelagem de estradas, detecção de calçadas ou marcações na faixa, etc. **2)** Metodologias: Transformada Hough, segmentação baseada em bordas, análise estéreo, rastreamento e visão aérea com mapeamento de perspectiva inversa (IPM). **3)** Modelos: pontos lineares, isolados, modelo parabólico, modelo hiperbólico, modelo clotoide, modelo *spline*, modelo de *snakes* e, finalmente, modelos 3D. **4)** Cenários: diferentes condições de iluminação e clima, rodovias ou estradas rurais, marcações na estrada.

Por fim, também foi identificado uma revisão (BERNINI et al., 2014) para detecção de obstáculos, com foco em técnicas de visão estéreo. Além de não estar atualizada, também não lida com outras técnicas diferentes de visão estéreo.

4.1 DETECÇÃO DE CAMINHO

Esta revisão da literatura analisa o estado da arte na área de detecção de caminho com base em imagens frontais, que sejam, ou possam vir a ser, aplicadas em sistemas de navegação autônoma. Segundo Zhou et al. (2010) a detecção de estrada pode ser classificada em três tipos: técnicas baseadas em características, técnicas baseadas em modelos e técnicas baseadas em regiões.

Essa revisão pretende contabilizar a quantidade de trabalhos em cada técnica, porém tem o foco na análise e comparação dos trabalhos baseados em regiões, pois estes podem se adaptar a diferentes tipos de terreno e não dependem da geometria do caminho que além de variar muito, pode ser um processo custoso. Os baseados em característica apesar de serem eficazes, dependem muito das marcações na pista, por esse motivo também serão apenas contabilizados, mas não avaliados. Com isso, será possível analisar os métodos que vem sendo utilizados, em quais tipos de terreno são aplicados, se são adaptativos em relação as mudanças de terreno, e se fazem a distinção de possíveis falhas e/ou alterações no caminho, como por exemplo: buracos, crateras, sombras, rachaduras e poças de água. É importante ressaltar que para um trabalho ser considerado “adaptativo” ele não deve apenas funcionar em diferentes ti-

pos de terreno, mas sim continuar detectando um caminho durante uma transição de tipos de terreno.

Questão: Qual é o estado da arte na detecção de caminho, utilizando visão passiva, com base em regiões?

População: Pesquisas sobre detecção de caminho, utilizando visão computacional, disponíveis em bibliotecas eletrônicas.

Intervenção: Análise do estado da arte na detecção de caminho.

Resultados: Comparativo das pesquisas sobre Detecção de Caminho.

Contexto: Bibliotecas digitais: *Science Direct*, *IEEEExplore*, *Springer Link* e *ACM Digital Library*.

4.1.1 Definição da Busca - Detecção de Caminho

Os detalhes de definição da busca, como: locais de pesquisas, termos, critérios de inclusão e exclusão, são apresentados na Tabela 1.

Tabela 1 – Detecção de Caminho - Definição da busca

Locais de Pesquisa	Termos de Busca
<ul style="list-style-type: none"> - <i>ACM Digital Library</i>; - <i>IEEE Xplore</i>; - <i>Science Direct</i>; - <i>Springer Link</i>. 	<ul style="list-style-type: none"> - <i>road detection</i>; - <i>road tracking</i>; - <i>road segmentation</i>.
Critérios de Inclusão	
<ul style="list-style-type: none"> - Artigos escritos na língua inglesa; - Artigos publicados entre 2006 e 2017; - Artigos que apresentam uma abordagem de detecção de caminho; - Trabalhos com imagens frontais e com visão horizontal (ou quase) ao caminho (descartando trabalhos com imagens aéreas); - Trabalhos que utilizem somente visão passiva e métodos de processamento digital de imagens e/ou visão computacional (trabalhos que utilizam outros sensores em conjunto serão aceitos caso a etapa de Visão Passiva esteja bem separada e apresente um resultado de detecção de caminho). 	
Critérios de Exclusão	
<ul style="list-style-type: none"> - Trabalhos curtos, como resumos ou resumos expandidos; - Trabalhos com detecção de caminho com base em modelo ou em características. 	

Fonte: Adaptado de (RATEKE et al., 2019).

4.1.2 Execução da Busca - Detecção de Caminho

Inicialmente a seleção resultou em 1129 artigos e uma análise por títulos, resumos, palavras-chave e imagens foi realizada. As consultas trouxeram trabalhos que não se encaixavam no tema da detecção de caminho, ou que eram sobre detecção de redes de caminho, com imagens aéreas e neste caso, sendo descartados, também foram descartados os trabalhos que não utilizam visão passiva para a detecção de caminho, ou seja, câmeras e com a utilização de métodos de visão computacional e processamento digital de imagens. Isso ocorre pois muitos trabalhos utilizam sensores de visão ativa, como por exemplo, lasers, mais especificamente LIDAR que são úteis para detecção de elevações no caminho, bordas laterais, meio-fio e possíveis obstáculos no caminho. A execução da pesquisa é apresentada pelas tabelas: Tabela 2, Tabela 3, Tabela 4 e Tabela 5.

Tabela 2 – Detecção de Caminho - Execução ACM

ACM Digital Library			
String de Busca	<i>acmdlTitle:("road detection" OR "road segmentation" OR "road tracking") OR recordAbstract:("road detection" OR "road segmentation" OR "road tracking") OR keywords.author.keyword:("road detection" OR "road segmentation" OR "road tracking")</i>		
Refinando a Pesquisa	- Data: <i>Published since</i> - 2006; - Formato: <i>Content Formats</i> - PDF;		
Quantidade de Resultados	111	Selecionados	5

Fonte: Adaptado de (RATEKE et al., 2019).

Tabela 3 – Detecção de Caminho - Execução IEEE

IEEE Xplore			
String de Busca	<i>(((((("Document Title": "road detection") OR "Abstract": "road detection") OR "Author Keywords": "road detection") OR "Document Title": "road tracking") OR "Abstract": "road tracking") OR "Author Keywords": "road tracking") OR "Document Title": "road segmentation") OR "Abstract": "road segmentation") OR "Author Keywords": "road segmentation")</i>		
Refinando a Pesquisa	- Data: 2006-2017; - Tipo de Conteúdo: <i>Journals & Magazines e Conference Publications.</i>		
Quantidade de Resultados	344	Selecionados	143

Fonte: Adaptado de (RATEKE et al., 2019).

Tabela 4 – Detecção de Caminho - Execução Science Direct

Science Direct			
String de Busca	<i>TITLE-ABSTR-KEY(road detection) or TITLE-ABSTR-KEY(road tracking) or TITLE-ABSTR-KEY(road segmentation)</i>		
Refinando a Pesquisa	- Áreas: <i>Computer Science</i> ; - Data: <i>pub-date > 2005</i> ; - Tipo de conteúdo: <i>Journals</i> .		
Quantidade de Resultados	370	Selecionados	16

Fonte: Adaptado de (RATEKE et al., 2019).

Tabela 5 – Detecção de Caminho - Execução Springer

Springer Link			
String de Busca	<i>(“road detection” OR “road tracking” OR “road segmentation”)</i>		
Refinando a Pesquisa	- Data: <i>Date Published between 2006-2017</i> ; - Área: <i>Discipline - Computer Science</i> ; - Idioma: <i>English</i> .		
Quantidade de Resultados	304	Selecionados	38

Fonte: Adaptado de (RATEKE et al., 2019).

Após a primeira análise, restou um total de 202 trabalhos. Então uma leitura mais detalhada e análise de resultados foi realizada para filtrar os trabalhos com detecção de caminho baseados em região, mesmo assim, para fins estatísticos, os demais trabalhos (baseados em características e baseados em modelos) foram contabilizados (Tabela 6).

Tabela 6 – Seleção Final

Tipos de Detecção	- Baseados em Características: 53; - Baseados em Modelos: 6; - Baseado em Regiões: 134.
	Após os critérios de exclusão
Selecionados por base	- ACM Digital Library: 2; - IEEE Xplore: 103; - Science Direct: 6; - Springer Link: 23.

Fonte: Adaptado de (RATEKE et al., 2019).

4.1.3 Análise dos Trabalhos Correlatos - Detecção de Caminho

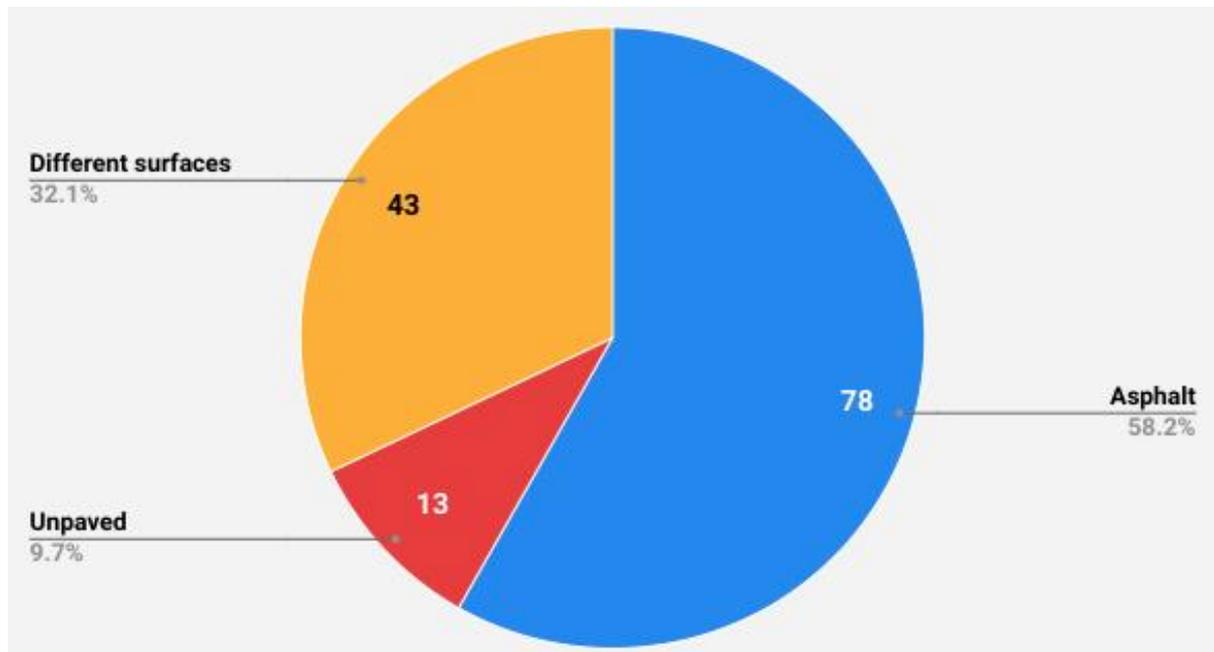
Nesta seção são apresentados alguns aspectos e levantamentos interessantes sobre a RSL da detecção do caminho. Uma análise individual e mais detalhada sobre cada trabalho encontrado pode ser vista no relatório técnico (RATEKE; JUSTEN; WANGENHEIM, 2018).

A análise geral sobre os resultados da RSL, com destaque para os métodos utilizados e as análises das características dos resultados de forma agrupada, como um mapeamento do estado da arte, é apresentado em (RATEKE et al., 2019).

Durante a análise dos trabalhos correlatos foram mapeados alguns pontos de interesse principais que são: qual o cenário de avaliação, se são adaptativos, se tratam de sombras no caminho, se identificam poças de água, se identificam buracos, quais os métodos de VC utilizados e por fim, se tem alguma característica interessante não mapeada anteriormente.

Para o cenário é considerado o tipo de terreno em que o trabalho fez seus experimentos, podendo ser: asfalto, estrada de terra, ou qualquer tipo de terreno (Figura 12). A classificação dos trabalhos com base nos tipos de superfície de terreno em que funcionam estão apresentadas em: Tabela 7, Tabela 8, Tabela 9.

Figura 12 – Cenários - Tipos de Terreno. Asfalto(*Asphalt*) (78). Sem pavimento (*Unpaved*) (13). Qualquer tipo de terreno (*Different surfaces*) (43).



Fonte: (RATEKE et al., 2019).

Nota-se, porém, que o fato do trabalho ser avaliado em diferentes tipos de terreno não garante que ele funcione em momentos de transição entre tipos de terreno. Isso ocorre pois muitos trabalhos fazem etapas de treinamento antes dos experimentos, ou mesmo segmentações por *seed points* podem se adaptar a uma mudança de cor no padrão do terreno, mas somente após algum tempo para o novo padrão ser coletado.

Deste modo, para ser considerado adaptativo o trabalho deve mostrar algum exemplo de resultado em transição de terreno ou mesmo algum *link* para resultados externos do trabalho que mostrem o funcionamento. Os trabalhos classificados como adaptativos são: (GUO; MITA; MCALLESTER, 2011), (GUO; MITA; MCALLESTER, 2012), (OSOSINSKI; LABROSSE, 2012) e (CRISTÓFORIS et al., 2016).

Tabela 7 – Tipos de Superfície - Asfalto

Tipo	Trabalhos
Asfalto	(TSAI et al., 2006), (GUO; GERASIMOV; POULTON, 2006), (GAO; LUO; MOLLI, 2007), (YUN; GUO-YING; YONG, 2007), (SON; MITA; TAKEUCHI, 2008), (SHA; YU; ZHANG, 2008), (ALVAREZ; LOPEZ; BALDRICH, 2008), (MICHALKE et al., 2008), (WANG; CHEN; SHI, 2008), (ROTARU; GRAF; ZHANG, 2008), (AHMED et al., 2008), (BERGER et al., 2008), (GUO; MITA, 2009a), (GUO; MITA, 2009b), (WEDEL et al., 2009), (ZHANG et al., 2009), (TAREL; BIGORGNE, 2009), (CHEN; LIU, 2010), (HE et al., 2017), (ONIGA; NEDEVSKI, 2010), (SHA; ZHANG, 2010), (URDZIK et al., 2010), (DORNAIKA et al., 2011), (YING et al., 2016), (ÁLVAREZ; LÓPEZ, 2011), (KIM; SON; SOHN, 2011), (MALIK; AHMED; KUNWAR, 2011), (LIN et al., 2017a), (RAVISHANKAR; MANIC, 2011), (ARDIYANTO; ADJI, 2017), (KÜHNEL; KUMMERT; FRITSCH, 2011), (HSU et al., 2011), (YANG; WANG; LIU, 2011), (KANG et al., 2011), (XIA et al., 2016), (OH; KIM; SOHN, 2012), (SHINZATO et al., 2012), (OH; SON; SOHN, 2012), (HSU et al., 2012), (WANG et al., 2017), (ALVAREZ et al., 2012), (ALVAREZ et al., 2012), (YANG et al., 2016), (GAO; SONG; YANG, 2012), (SIOGKAS; DERMATAS, 2013), (HUNG et al., 2013), (YAO; LU; YAN, 2013), (PAN; SI; OGAI, 2017), (WANG; FRÉMONT, 2013), (VITOR et al., 2013), (ZHANG et al., 2016), (ALVAREZ; SALZMANN; BARNES, 2013), (AMIT; AOKI, 2015), (FRITSCH; KÜHNEL; KUMMERT, 2014), (YUAN et al., 2014), (WANG et al., 2014), (CHANDRAN et al., 2014), (XIAO; HU, 2014), (JIANG; WANG; YUAN, 2014), (LIU et al., 2014), (LI et al., 2014), (WANG; FRÉMONT; RODRÍGUEZ, 2014), (HUSSAIN et al., 2014), (HAUTIERE et al., 2014), (JIA; CHEN; ZHANG, 2017b), (BADRINARAYANAN; BUDVYTIS; CIPOLLA, 2014), (GUO et al., 2015), (CHEN; QIAO, 2015), (XIA et al., 2015), (LU, 2015), (PAN; OGAI; WU, 2015), (WANG; FANG; YUAN, 2015), (LIU; CHENG; YI, 2016), (CHACRA; ZELEK, 2016), (OLIVEIRA; BURGARD; BROX, 2016), (JIA; CHEN; ZHANG, 2017a), (KIM; TAI; YOON, 2017), (GAO; WANG; YUAN, 2017).

Fonte: Adaptado de (RATEKE et al., 2019).

Tabela 8 – Tipos de Superfície - Sem pavimento

Tipo	Trabalhos
Sem pavimento	(BROGGI; CATTANI, 2006), (ZHANG; ZHOU; LIU, 2007), (LOOKINGBILL et al., 2007), (SONG et al., 2007), (RASMUSSEN, 2008), (SHNEIER et al., 2008), (BERNUY et al., 2011), (OZUTEMIZ et al., 2013), (XIE et al., 2014), (LU et al., 2014), (LIN et al., 2014b), (WANG; SUN; ZHAO, 2015), (XIAO et al., 2015).

Fonte: Adaptado de (RATEKE et al., 2019).

Tabela 9 – Tipos de Superfície - Qualquer tipo

Tipo	Trabalhos
Qualquer tipo	(NETO; RITTNER, 2006), (CARAFFI; CATTANI; GRISLERI, 2007), (SOQUET; AUBERT; HAUTIERE, 2007), (HUANG et al., 2007), (ÁLVAREZ; LÓPEZ; BALDRICH, 2007), (MISTRY; MAKWANA, 2016), (GUO; MITA; MCALLESTER, 2009), (WANG; JI; SU, 2009), (KONG; AUDIBERT; PONCE, 2009), (ZHANG; WU, 2009), (KONG; AUDIBERT; PONCE, 2010), (ZHOU et al., 2010), (ZHOU et al., 2010), (GUO; MITA; MCALLESTER, 2010), (ZHOU; IAGNEMMA, 2010), (RASHEED et al., 2010), (CHEN; TAI, 2010), (GUO; MITA; MCALLESTER, 2011), (GUO; MITA; MCALLESTER, 2012), (WANG; WANG; WEN, 2012), (OSOSINSKI; LABROSSE, 2012), (HEYVAERT; VEELAERT, 2012), (KONG; SARMA; TANG, 2013), (BUI; SAITOH; NOBUYAMA, 2013), (FUKUKAWA et al., 2013), (NETO et al., 2013), (RATEKE et al., 2014), (WU; LAM; SRIKANTHAN, 2015), (LU; JIANG; ZELL, 2015), (LU et al., 2015), (ZU et al., 2015), (LU; XIA; XIA, 2015), (JOHN; ANUSHA; KUTTY, 2015), (YUAN; JIANG; WANG, 2015), (SÖVÉNY; KOVÁCS; KARDKOVÁCS, 2015), (SHI; WANG; FU, 2016), (SHI et al., 2016), (NGUYEN; PHUNG; BOUZERDOUM, 2017), (AMINI; KARASFI, 2016), (LI et al., 2016), (CRISTÓFORIS et al., 2016), (WANG; REN; YANG, 2016), (VALENTE; STANCIULESCU, 2017).

Fonte: Adaptado de (RATEKE et al., 2019).

Sobre as sombras, foram considerados os trabalhos que identificam as regiões com sombra na estrada como parte do caminho, nem todos trabalhos fazem isso, e não ter esse cuidado gera resultados onde um caminho perfeitamente navegável não é reconhecido, isso ocorre em grande parte dos trabalhos que utilizam somente as características de cor da estrada. Muitos dos trabalhos levantados (60 ao todo) consideraram as sombras como parte do caminho. Alguns desses trabalhos utilizam outros espaço de cores para lidar com os problemas de iluminação, como: CIE-lab (XIAO et al., 2015; WANG; REN; YANG, 2016). outros utilizaram o espaço de cor HSI (ROTARU; GRAF; ZHANG, 2008; GAO; SONG; YANG, 2012; XIA et al., 2016). O espaço HSV também foi utilizado em alguns dos trabalhos (GAO; LUO; MOLI, 2007; HUANG et al., 2007; ZHOU; IAGNEMMA, 2010; YANG; WANG; LIU, 2011; FUKUKAWA et al., 2013; LU; JIANG; ZELL, 2015).

Outros 28 trabalhos foram classificados como “parcialmente” lidando com situações de sombras, por diferentes motivos, como: alguns citam nos trabalhos que fazem, mas não apresentaram nenhum resultado que confirmem (CARAFFI; CATTANI; GRISLERI, 2007; WANG et al., 2014; CHANDRAN et al., 2014). Alguns detectaram as sombras como caminho, mas as quebras de intensidade entre sombra e região iluminada ficaram destacadas como se não fossem parte do caminho (exemplo: Figura 13), como se houvesse uma rachadura na estrada (YUN; GUO-YING; YONG, 2007; SHA; YU; ZHANG, 2008; GUO; MITA; MCALLESTER, 2009; SHA; ZHANG, 2010; SHINZATO et al., 2012; HUNG et al., 2013). E em alguns foram

apresentadas situações com sombras fracas e pouca variação na cor entre a região de sombra e o restante do caminho (GUO; GERASIMOV; POULTON, 2006; SON; MITA; TAKEUCHI, 2008; ZHOU et al., 2010; CHEN; TAI, 2010; AMIT; AOKI, 2015).

Figura 13 – Exemplo de falhas na detecção do caminho em pequenas variações de iluminação usando imagens do conjunto de dados KITTI (GEIGER et al., 2013).



Fonte: (RATEKE et al., 2019).

Também foi verificado se os trabalhos faziam identificação de poças de água no caminho ou buracos, sendo que nesse caso, diferente de regiões com sombras, buracos e poças não devem ser considerados como parte do caminho, ou pelo menos é esperado alguma marcação diferente que identifique essas regiões. Alguns trabalhos citaram e até mostram cenários com poças de água, porém, estas, foram consideradas como parte do caminho (GUO; GERASIMOV; POULTON, 2006; WANG; BAI; FAIRHURST, 2008; ZHANG et al., 2009; KühNL; KUMMERT; FRITSCH, 2011; OSOSINSKI; LABROSSE, 2012; LIN et al., 2014b; ZU et al., 2015; XIAO et al., 2015; SHI et al., 2016). O trabalho de Sövény, Kovács e Kardkovács (2015), que é um trabalho voltado para detectar caminhos como guia para cegos, diz que lida com poças de água e buracos, porém não mostra nenhum resultado que confirme essa afirmação. Nenhum outro trabalho fala sobre detecção de buracos.

Além disso, foram levantados os métodos utilizados em cada trabalho para a realização da detecção do caminho, por exemplo: **Segmentação** com base em cores (NETO; RITTNER, 2006; CARAFFI; CATTANI; GRISLERI, 2007; SHA; YU; ZHANG, 2008; HEYVAERT; VELLAERT, 2012; LI et al., 2016; ZHANG et al., 2016; YING et al., 2016). **Redes neurais** foram utilizadas em alguns trabalhos, como os trabalhos de Chen e Qiao (2015) e Oliveira, Burgard e Brox (2016). Técnicas de **visão estéreo** para identificar espaço livre navegável (GUO et al., 2015; WU; LAM; SRIKANTHAN, 2015; YANG et al., 2016). E **detecção de ponto de fuga** (*vanishing point*) (RASMUSSEN, 2008; KONG; AUDIBERT; PONCE, 2010; KONG; SARMA; TANG, 2013; JOHN; ANUSHA; KUTTY, 2015).

Por fim, outras características interessantes dos trabalhos levantados, mas que não foram o foco principal de estudo desta revisão, também foram mapeadas, como por exemplo os trabalhos de Oh, Son e Sohn (2012) e Wang, Ren e Yang (2016) que apresentaram alguns resultados a noite e também dentro de túnel. Outros trabalhos também apresentaram alguns resultados a noite (GUO; MITA; MCALLESTER, 2009; GUO; MITA, 2009b; SHI; WANG; FU, 2016; SHI et al., 2016). Resultados dentro de túnel também são apresentados em Oh, Kim e Sohn (2012) e Chandran et al. (2014). Ainda mais desafiador, resultados a noite e em ambiente chuvoso podem ser vistos em outros trabalhos (GUO; MITA; MCALLESTER, 2010; KÜHNEL; KUMMERT; FRITSCH, 2011; GUO; MITA; MCALLESTER, 2012; SIOGKAS; DERMATAS, 2013). O trabalho de Rasmussen (2008) tratou de situações com grande claridade solar em direção à câmera, sendo o único trabalho a ter lidado com isso, que é um problema especialmente em finais de tarde, conhecida como lusco-fusco. Em todos esses trabalhos, os resultados não apresentam uma acurácia tão boa como em cenários durante o dia com pouca variação de luminosidade.

4.2 DETECÇÃO DE OBSTÁCULOS

Esta revisão da literatura pretende analisar o estado da arte na área de detecção de obstáculos, com base em imagens frontais em cenários de navegação veicular. Pretende-se, assim, checar se os trabalhos publicados estão lidando com os problemas causados pelas sombras, afinal a sombra de um objeto não deve ser considerada como obstáculo. E também se algum dos trabalhos considera buracos ou poças de água como obstáculos.

Questão: Qual é o estado da arte na detecção de obstáculos, utilizando visão passiva?

População: Pesquisas sobre detecção de obstáculos, utilizando visão computacional, disponíveis em bibliotecas eletrônicas.

Intervenção: Análise do estado da arte na detecção de obstáculos.

Resultados: Comparativo das pesquisas sobre detecção de obstáculos.

Contexto: Bibliotecas digitais: *Science Direct*, *IEEEExplore*, *Springer Link* e *ACM Digital Library*.

4.2.1 Definição da Busca - Detecção de Obstáculos

Os detalhes de definição da busca para os trabalhos relacionados na tarefa de detecção de obstáculo, como: locais de pesquisas, termos utilizados na pesquisa, critérios de inclusão e critérios de exclusão, são apresentados na Tabela 10.

Tabela 10 – Detecção de Obstáculos - Definição da busca

Locais de Pesquisa	Termos de Busca
<ul style="list-style-type: none"> - <i>ACM Digital Library</i>; - <i>IEEE Xplore</i>; - <i>Science Direct</i>; - <i>Springer Link</i>. 	<ul style="list-style-type: none"> - <i>road obstacle detection</i>; - <i>road obstacle tracking</i>; - <i>obstacle detection</i>.
Critérios de Inclusão	
<ul style="list-style-type: none"> - Artigos escritos na língua inglesa; - Artigos publicados entre 2007 e 2019; - Artigos que apresentam uma abordagem de detecção de obstáculos; - Trabalhos com imagens em visão horizontal (ou quase) em cenários de estrada (caminhos); - Trabalhos que utilizem somente visão passiva e métodos de processamento digital de imagens e/ou visão computacional. 	
Critérios de Exclusão	
<ul style="list-style-type: none"> - Trabalhos curtos, como resumos ou resumos expandidos; - Detecção de obstáculos voltados para ambientes internos (guias para cegos, máquinas de limpeza, máquinas em fábricas). 	

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

4.2.2 Execução da Busca - Detecção de Obstáculos

Inicialmente a seleção resultou em 2303 artigos e uma análise por títulos, resumos, palavras-chave e imagens foi realizada resultando em 136 trabalhos. A execução da pesquisa é apresentada pelas tabelas: Tabela 11, Tabela 12, Tabela 13 e Tabela 14.

Tabela 11 – Detecção de Obstáculos - Execução ACM

ACM Digital Library	
String de Busca	<i>acmdlTitle:(“road obstacle detection” OR “road obstacle tracking” OR “obstacle detection”) OR recordAbstract:(“road obstacle detection” OR “road obstacle tracking” OR “obstacle detection”) OR keywords.author.keyword:(“road obstacle detection” OR “road obstacle tracking” OR “obstacle detection”)</i>
Refinando a Pesquisa	<ul style="list-style-type: none"> - Data: <i>Published since</i> - 2007; - Formato: <i>Content Formats</i> - PDF.
Quantidade de Resultados	61 Selecionados 6

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

Tabela 12 – Detecção de Obstáculos - Execução IEEE

IEEE Xplore			
String de Busca	((((((((“Document Title”: “road obstacle detection”) OR “Abstract”: “road obstacle detection”) OR “Author Keywords”: “road obstacle detection”) OR “Document Title”: “road obstacle tracking”) OR “Abstract”: “road obstacle tracking”) OR “Author Keywords”: “road obstacle tracking”) OR “Document Title”: “obstacle detection”) OR “Abstract”: “obstacle detection”) OR “Author Keywords”: “obstacle detection”)		
Refinando a Pesquisa	- Data: 2007-2019; - Tipo de Conteúdo: <i>Journals and Conferences Publications</i> .		
Quantidade de Resultados	1,222	Selecionados	90

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

Tabela 13 – Detecção de Obstáculos - Execução Science Direct

Science Direct			
String de Busca	<i>Title, abstract, keywords: “road obstacle detection” or “road obstacle tracking” or “obstacle detection”</i>		
Refinando a Pesquisa	- Data: 2007-2019; - Tipo de conteúdo: <i>Research articles</i> .		
Quantidade de Resultados	135	Selecionados	11

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

Tabela 14 – Detecção de Obstáculos - Execução Springer

Springer Link			
String de Busca	(“road obstacle detection” OR “road obstacle tracking” OR “obstacle detection”)		
Refinando a Pesquisa	- Data: <i>Date Published between 2007-2019</i> ; - Área: <i>Discipline - Computer Science</i> ; - Idioma: <i>English</i> .		
Quantidade de Resultados	885	Selecionados	29

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

Os trabalhos de Hwang, Ji e Kim (2012), Costa et al. (2012), Herghelegiu, Burlacu e Caraiman (2017) apresentaram uma abordagem para auxílio a deficientes visuais. Apesar de não estarem no contexto de navegação veicular, ambos se encaixam nos critérios da busca, identificam obstáculos em ambientes externos (internos também), com imagens horizontais (ou próximas da horizontal) assim como em veículos. E, por isso, ambos foram mantidos na seleção dos trabalhos. Da mesma forma, os trabalhos de Ma et al. (2009a), Yankun, Hong e Weyrich (2011), Kim et al. (2015), Yoo et al. (2016) foram mantidos na pesquisa, apesar de serem

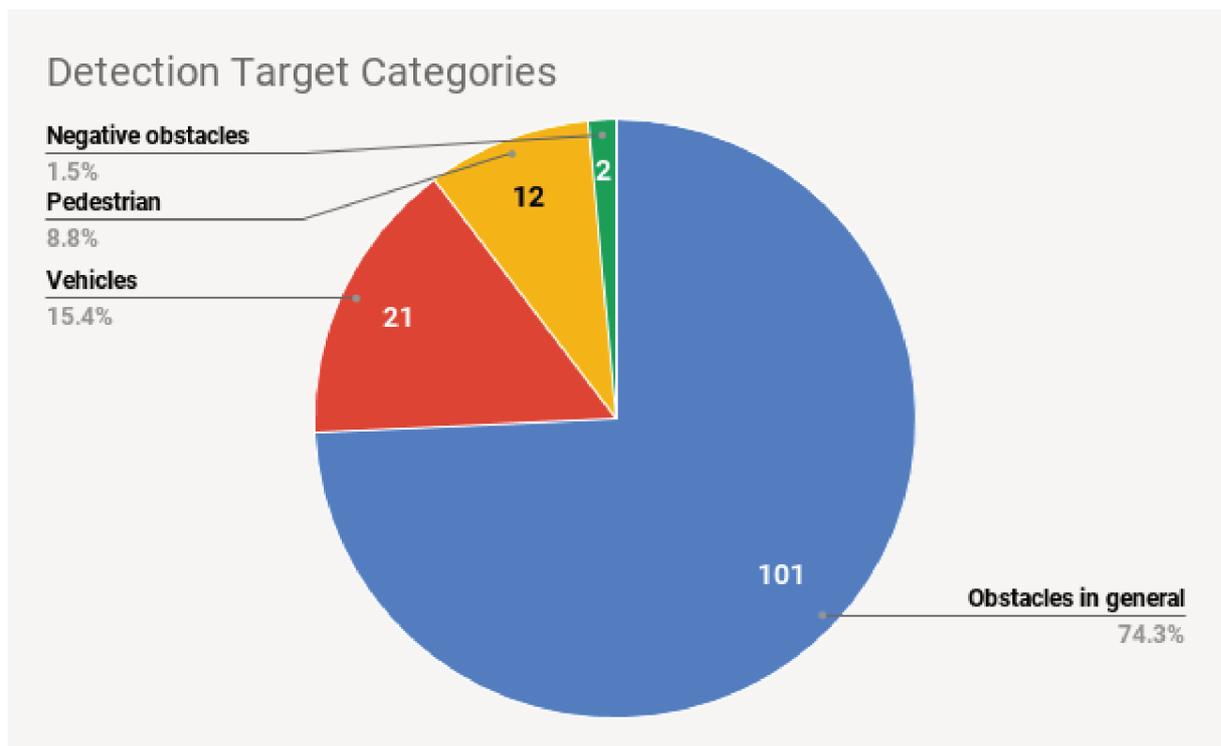
voltados para aplicações em câmeras traseiras nos veículos.

4.2.3 Análise dos Trabalhos Correlatos - Detecção de Obstáculos

Nesta seção são apresentados alguns aspectos e levantamentos interessantes sobre a RSL da detecção de Obstáculos. Uma análise individual e mais detalhada sobre cada trabalho encontrado pode ser vista no relatório técnico (RATEKE; WANGENHEIM, 2018). Um mapeamento global do estado da arte sobre os resultados da RSL, com destaque para os métodos utilizados e as análises das características dos resultados de forma agrupada, é apresentado em (RATEKE; WANGENHEIM, 2020).

À priori, os trabalhos foram categorizados em três tipos de detecções de obstáculos: “Veículos”, “Pedestres” ou “Obstáculos em Geral”. Sendo as duas primeiras para quando o foco do trabalho foi somente em uma dessas duas detecções e a última para quando o trabalho tratou qualquer obstáculo no caminho. Entretanto, durante a análise uma nova classe foi criada (apesar de conter apenas dois trabalhos), pois se diferenciava de todas as demais. Por se tratar de grandes buracos ou valas, ela foi denominada pelos autores de “Obstáculos Negativos” (Figura 14). Os trabalhos também foram analisados, assim como na detecção de caminho, verificando se tratam situações com sombras, se identificam poças de água e/ou buracos. Também foram checados os principais métodos utilizados em cada trabalho.

Figura 14 – Tipos de Detecção de Obstáculos. Obstáculos em geral (78). Veículos (18). Pedestres (12). Obstáculos Negativos (2).



Fonte: (RATEKE; WANGENHEIM, 2020).

A categoria “Obstáculos em Geral” pode ser dividida em duas subcategorias:

- trabalhos que identificam os obstáculos sem diferenciar ou classificar os obstáculos, objetivando apenas encontrar um espaço livre de obstáculos para navegação (SIMOND; PARENT, 2007), (FRANKE et al., 2008), (KANG; CHUNG, 2011), (HWANG; JI; KIM, 2012), (ZHU et al., 2012), (WANG; FRÉMONT; RODRÍGUEZ, 2014), (CAO; XIANG; LIU, 2015), (GUO et al., 2015), (PODDAR; AHMED; PUHAN, 2015), (DEGHACHE; BOUCHAFA, 2015) e (LIMA; VICTORINO; NETO, 2017);
- trabalhos que, apesar de detectarem tipos muito diferentes de obstáculos, ainda identificam e classificam os obstáculos detectados, como: veículos ou pedestres. Para esta classificação, alguns trabalhos empregaram Máquinas de Vetor de Suporte (*Support Vector Machines*- SVM) (HOTA; JONNA; KRISHNA, 2010), (WALK; SCHINDLER; SCHIELE, 2010), (WOO; LIM; LEE, 2011), (BAIG et al., 2011), (SONG et al., 2011), (CHEN; TSAI; LIN, 2012), (TEOH; BRÄUNL, 2012), (CHANAWANGSA; CHEN, 2013), (ILOIE; GIOSAN; NEDEVSKI, 2014) e (PRABHAKAR et al., 2017).

Lógica *Fuzzy* também foi utilizada para classificação em alguns artigos (LI et al., 2014), (LIU; CUI; LI, 2012). A proporção de área e a altura são integradas a visão estéreo e aos modelos de contorno ativo para classificar os tipos de objetos no trabalho de (HUANG; LIU, 2016). Em Wieszok et al. (2017) uma segmentação semântica é feita usando as informações do *Stixel World*, permitindo a classificação de obstáculos.

Na maioria dos trabalhos foram utilizadas técnicas de Visão Estéreo (VE) para a detecção dos obstáculos, sendo 92 ao todo. O Mapa de Disparidade (MD) possibilita a análise de profundidade na cena, permitindo identificar obstáculos e sua distância, e em boa parte desses trabalhos se fez uso de técnicas baseadas no MD que permitem extrair informações do plano da estrada e de forma separada dos obstáculos, isso é chamado de *v-disparity* e *u-disparity*. Isso é possível pelo cálculo de histogramas de disparidade em linhas horizontais (disparidade V) e verticais (disparidade U). Cada plano no sistema de coordenadas do mundo será mostrado como uma linha no mapa de disparidade U-V, simplificando a detecção de obstáculos em uma detecção de linhas (WANG et al., 2014; BENACER; HAMISSI; KHOUAS, 2015; BURLACU et al., 2016; GAO et al., 2011; MHIRI et al., 2015; NA; HAN; JEONG, 2011).

A classificação dos trabalhos por tipos de detecção de obstáculo é apresentada em: Tabela 15, Tabela 16, Tabela 18, Tabela 17.

Poucos trabalhos abordaram as situações de sombras, como o de Jia, Liu e Zhu (2015) que faz detecção de ponto de fuga e linha de horizonte para separar uma região de interesse, a parte inferior da imagem, e utiliza extração de pontos de característica com o método SIFT. Os trabalhos de Zhang et al. (2012) e Zhang et al. (2014) também mostraram bons resultados em situações com sombras, utilizando Mapas de Disparidade e operações morfológicas (erosão e dilatação) nas imagens.

Tabela 15 – Tipos de Obstáculos - Veículos

Tipo	Trabalhos
Veículos	(NAITO; ITO; KANEDA, 2007), (XU et al., 2009), (CHIU et al., 2009), (VENTROUX et al., 2009), (HOTA; JONNA; KRISHNA, 2010), (NA; HAN; JEONG, 2011), (LIM et al., 2011), (MIYAMA; MATSUDA, 2011), (BAIG et al., 2011), (CHONG et al., 2012), (LIANG; MORIE, 2014), (NIETO; LABORDA; SALGADO, 2011), (LEFEBVRE; AMBELLOUIS, 2012), (TEOH; BRÄUNL, 2012), (TRIF; ONIGA; NEDEVSKI, 2013), (ONIGA; TRIF; NEDEVSKI, 2013), (CHANAWANGSA; CHEN, 2013), (KHALID; MOHAMED; ABDENBI, 2013), (PĆeSZOR et al., 2018), (MA et al., 2019), (ZEBBARA et al., 2019).

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

Tabela 16 – Tipos de Obstáculos - Pedestres

Tipo	Trabalhos
Pedestres	(MA et al., 2007), (GAVRILA; MUNDER, 2007), (MA et al., 2009b), (ESS et al., 2009), (KELLER; LLORCA; GAVRILA, 2009), (WALK; SCHINDLER; SCHIELE, 2010), (SONG et al., 2011), (MITZEL et al., 2011), (BENENSON et al., 2012), (LEE; KIM, 2016), (ILOIE; GIOSAN; NEDEVSKI, 2014), (KANG; LIM, 2015).

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

Tabela 17 – Tipos de Obstáculos - Obstáculos Negativos

Tipo	Trabalhos
Obstáculos Negativos	(HERGHELEGIU; BURLACU; CARAIMAN, 2017), (KARUNASEKERA et al., 2017).

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

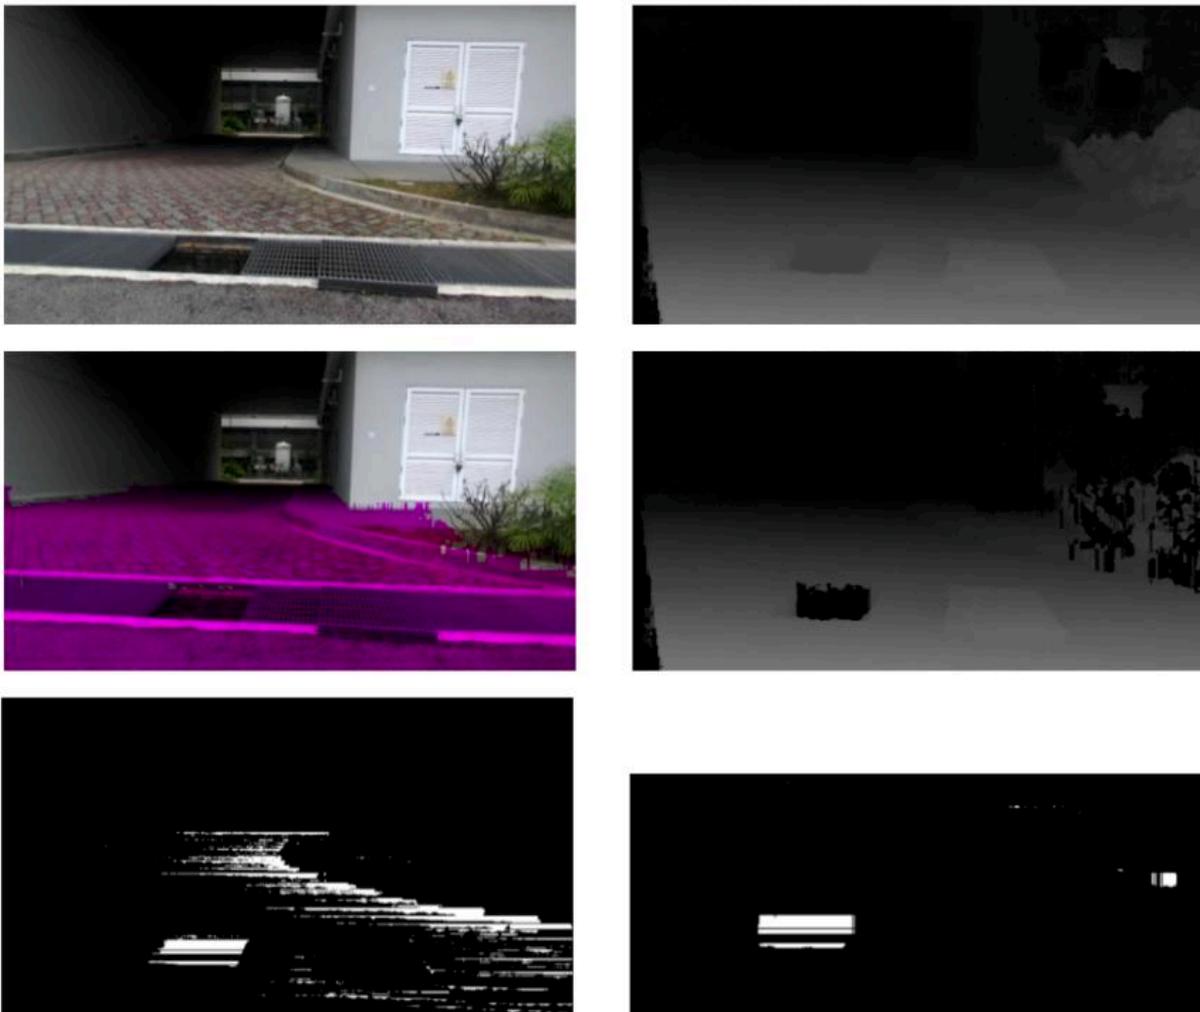
Alguns trabalhos não discutiram especificamente situações de sombra, mas suas abordagens mostraram bons resultados em imagens em que os obstáculos tinham sombras, e as sombras não são consideradas parte do obstáculo ((CABANI; TOULMINET; BENSRAHAI, 2008), (SUGANUMA; SHIMOYAMA; FUJIWARA, 2008), (KOHARA; SUGANUMA, 2009), (BROGGI et al., 2011), (SUGANUMA; KUBO, 2011), (HERMANN; BÖRNER; KLETTE, 2012) e (BURLACU et al., 2016)). Nenhum trabalho apresentou problemas em relação a poças de água. E em relação aos buracos, dois trabalhos apresentaram resultados, sendo focados exclusivamente na detecção de obstáculos negativos (ex.: buracos), não encaixando desta forma nas outras classificações de tipos de obstáculos.

O trabalho de Herghelegiu, Burlacu e Caraiman (2017) apresenta uma abordagem de auxílio a deficientes visuais. Este trabalho detecta regiões de desnível e buracos, em relação ao plano da superfície. Técnicas de visão estéreo são usadas. Um Mapa de Disparidade é construído com o algoritmo ELAS. Os buracos são detectados em regiões escuras e causam falha no cálculo do mapa de disparidade. Apresentam resultados com buracos grandes e próximos da

câmera.

No trabalho de Karunasekera et al. (2017) também apresenta uma abordagem para detecção de obstáculos negativos. Apresentam apenas um resultado de buraco, também com uma grande área preta (Figura 15). Utilizaram técnicas de Visão Estéreo. Extraí o perfil da estrada por meio da disparidade U e remove os pontos de obstáculos óbvios, identificando os picos no mapa de disparidade U . Então, utiliza esse mapa de disparidade modificado e gera a disparidade V , que será utilizada para calcular o plano do solo, sendo que os obstáculos negativos devem estar nesse plano. Use duas regiões de interesse, na imagem original e outra no mapa de disparidades que corresponde à estrada. Com a ajuda de uma segmentação super-pixel e através de funções de energia, possíveis regiões de obstáculos negativos são localizadas. A Região de Interesse no Mapa de Disparidades é digitalizada para encontrar valores de disparidade inferiores ao valor de disparidade correspondente da estrada.

Figura 15 – Exemplo da detecção de obstáculo negativo (KARUNASEKERA et al., 2017)



Fonte: (KARUNASEKERA et al., 2017)

Tabela 18 – Tipos de Obstáculos - Obstáculos em Geral

Tipo	Trabalhos
Obstáculos em Geral	<p>(KUBOTA; NAKANO; OKAMOTO, 2007), (SIMOND; PARENT, 2007), (SHEN; DU; LIU, 2007), (MILED; PESQUET; PARENT, 2007), (WEDEL et al., 2007), (CABANI; TOULMINET; BENSRAHAIR, 2008), (SUGANUMA; SHIMOYAMA; FUJIWARA, 2008), (HÄNE et al., 2017), (YONGQUAN et al., 2008), (DUMORTIER; HERLIN; DUCROT, 2008), (FRANKE et al., 2008), (MA et al., 2009a), (KOHARA; SUGANUMA, 2009), (KLAPPSTEIN et al., 2009), (ONIGA; NEDEVSCHI, 2010), (FAKHFAKH et al., 2010), (PANTILIE; NEDEVSCHI, 2010), (NISHIGAKI; ALOIMONOS, 2010), (PRABHAKAR et al., 2017), (PERROLLAZ; SPALANZANI; AUBERT, 2010), (XU; ZHANG, 2010), (GAO et al., 2011), (KANG; CHUNG, 2011), (BROGGI et al., 2011), (YANKUN; HONG; WEYRICH, 2011), (DANESCU, 2011), (BOUCHAFA; ZAVIDOVIQUE, 2011), (SUGANUMA; KUBO, 2011), (WOO; LIM; LEE, 2011), (HWANG; JI; KIM, 2012), (KIM et al., 2015), (CHEN; TSAI; LIN, 2012), (IWATA; SANEYOSHI, 2012), (KRAMM; BENSRAHAIR, 2012), (ZHANG et al., 2012), (BOROUJENI; ETEMAD; WHITEHEAD, 2012), (LIU; CUI; LI, 2012), (COSTA et al., 2012), (ZHU et al., 2012), (KYUTOKU et al., 2012), (PFEIFFER; ERBS; FRANKE, 2012), (LIMA; VICTORINO; NETO, 2017), (HERMANN; BÖRNER; KLETTE, 2012), (LIU; YU; ZHENG, 2013), (IWATA; SANEYOSHI, 2013), (ISMAIL et al., 2013), (LI et al., 2014), (LIU et al., 2014), (WANG et al., 2014), (ZHANG et al., 2014), (GIOSAN; NEDEVSCHI, 2014), (PETROVAI et al., 2014), (WANG; FRÉMONT; RODRÍGUEZ, 2014), (CAO; XIANG; LIU, 2015), (GUO et al., 2015), (MHIRI et al., 2015), (WIESZOK et al., 2017), (ONIGA; SARKOZI; NEDEVSCHI, 2015), (GE; LOBATON, 2017), (RIDEL; SHINZATO; WOLF, 2015), (PODDAR; AHMED; PUHAN, 2015), (BENACER; HAMISSI; KHOUAS, 2015), (BICHSEL; BORGES, 2015), (PETROVAI; DANESCU; NEDEVSCHI, 2015), (RAMOS et al., 2017), (PINGGERA; FRANKE; MESTER, 2015), (JIA; LIU; ZHU, 2015), (DEGHDACHE; BOUCHAFA, 2015), (WU; ZHOU; SRIKANTHAN, 2016), (CARRILLO; SUTHERLAND, 2016), (HUANG; LIU, 2016), (NADAV; KATZ, 2016), (BURLACU et al., 2016), (YOO et al., 2016), (CAMPOS; SOSSA; PAJARES, 2016), (GUPTA et al., 2017), (PARK et al., 2017), (NGUYEN; PHUNG; BOUZERDOUM, 2017), (RAMZI; LARBI; LYAMINE, 2019), (JING; ZHENG; XU, 2019), (PRAKASH; AKHBARI; KARAM, 2019), (DAIRI et al., 2018a), (KULATHUNGA; BUYVAL; KLIMCHIK, 2019), (WANG et al., 2019), (SANDHU et al., 2019), (SUN et al., 2018), (FAN et al., 2019), (ABDI; MEDDEB, 2018), (SHETTY et al., 2019), (HU et al., 2018), (HUANG; LIN, 2019), (LI et al., 2018), (DAMIAN et al., 2019), (HSIEH et al., 2019), (LIAN et al., 2019), (SALAVATI; MOHAMMADI, 2018), (DAIRI et al., 2018b), (DING et al., 2018), (XU; WANG; SONG, 2018), (TSAI et al., 2018), (HSU et al., 2018).</p>

Fonte: Adaptado de (RATEKE; WANGENHEIM, 2020).

Alguns trabalhos apresentaram algumas características diferentes dentro do escopo de detecção de obstáculo, como por exemplo o trabalho de Chanawangsa e Chen (2013), onde o foco é detectar veículos em situações de ultrapassagens. Para isso, primeiramente as marcações de faixas da estrada são detectadas, em seguida a detecção dos veículos, e por fim a geração de Hipóteses. Os trabalhos de (GUPTA et al., 2017) e (RAMOS et al., 2017) têm foco em obstáculos pequenos que possam aparecer na estrada. Os trabalhos de (SUGANUMA; SHIMOYAMA; FUJIWARA, 2008), (BAIG et al., 2011) e (NIETO; LABORDA; SALGADO, 2011) apresentam exemplos de detecção de veículos dentro de túneis.

E por fim, alguns resultados interessantes como em Ma et al. (2007) que os autores apresentaram a detecção de obstáculos e diferentes condições climáticas (ex.: em neblina ou com chuva). Em Prabhakar et al. (2017) também apresentam alguns resultados em dias chuvosos. A detecção de obstáculos em dias chuvosos também é vista em (KUBOTA; NAKANO; OKAMOTO, 2007) e (CHIU et al., 2009), além de também apresentarem a detecção de obstáculos à noite.

4.3 OUTROS TRABALHOS

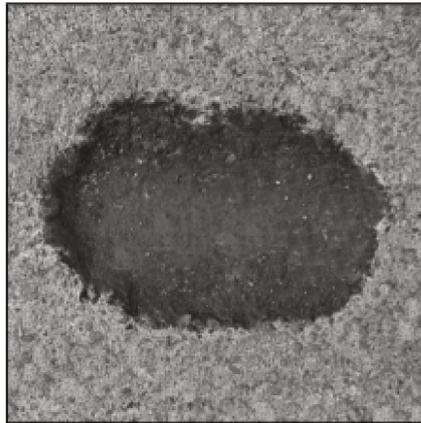
Fora do escopo de ambas revisões sistemáticas foram encontrados alguns trabalhos interessantes. Por exemplo, foi realizada uma nova busca por trabalhos utilizando apenas o termo de busca “*pothole detection*” nas mesmas quatro bases utilizadas nas RSLs (IEEE Explore, ACM Digital Library, Springer Link e Science Direct), considerando o período entre 2015 até o período recente (abril de 2020).

Nesta busca, a grande maioria dos trabalhos encontrados relacionados a detecção de buracos são baseados em imagens muito próximas dos buracos e com uma vista aérea, vertical (Ex.: Figura 16) (ERIKSSON et al., 2008), (HUIDROM; DAS; SUD, 2013), (TEDESCHI; BENEDETTO, 2017), (KOCH; BRILAKIS, 2011), (BANHARNSAKUN, 2017), (AZHAR et al., 2016), (YOUSAF et al., 2018), (OUMA; HAHN, 2017), (SAWALAKHE; PRAKASH, 2018), (UKHWAH; YUNIARNO; SUPRAPTO, 2019), (FAN et al., 2020), (AKAGIC; BUZA; OMANOVIC, 2017), (PEREIRA et al., 2018), (CHUNG; KHAN, 2019)). Desta forma, dificulta a emissão de um alerta com distância suficiente para que um veículo possa realizar uma manobra para desviar, servindo mais como um mapeamento do que como uma previsão. Esses trabalhos não entraram nas RSLs pois não encaixaram em um dos critérios de inclusão: **Trabalhos com imagens em visão horizontal (ou quase) em cenários de estrada (caminhos)**.

Ainda assim, foram selecionados oito trabalhos que respeitaram os critérios das RSLs, com visão frontal, quase que horizontal e com uso de visão passiva (DHIMAN; KLETTE, 2019), (SCHIOPU et al., 2016), (MIKHAILIUK; DAHNOUN, 2016), (ANAND et al., 2018), (JANG; PARK, 2016), (BUZA et al., 2017), (CHEN; YAO; GU, 2020), (KOH et al., 2019).

Em Dhiman e Klette (2019) o autores apresentam e comparam quatro diferentes experimentos para a detecção de buracos, dois com utilização de VE e outros dois com a utilização de CNN (Mask R-CNN e YOLO). No trabalho de Schioppa et al. (2016) primeiro é definida

Figura 16 – Exemplo de imagem em detecção de buraco com imagem aérea e muito próxima do buraco.



Fonte: (BANHARNSAKUN, 2017).

uma ROI, que é definido com a utilização de uma detecção de ponto de fuga. Em seguida, um algoritmo de limiarização é utilizado para filtrar possíveis falhas de detecção do ROI. Também é feita a distinção entre sombras e buracos.

Mapa de disparidade em conjunto com método de componente conexos é utilizado para a identificação de buracos em Mikhailiuk e Dahnoun (2016). Em Anand et al. (2018) os autores apresentam uma abordagem CNN para a detecção de buracos e rachaduras na estrada. Em Koh et al. (2019) o autores também apresentam uma abordagem com uma arquitetura CNN (R-FCN) para a detecção de buracos. O trabalho de Jang e Park (2016) utiliza informação de um mapa de saliência espaço-temporal, que leva em consideração informação de intensidade e textura dos *pixels* e também a movimentação em relação à fonte de captura.

A definição prévia de uma ROI também é aplicado no trabalho de (BUZA et al., 2017), com base em segmentação de imagem, separando desta forma a região do asfalto, que em seguida é separada em três diferentes agrupamentos onde são aplicados regressões lineares para eliminar região que não são de asfalto. Na etapa final é utilizado o método de Otsu. O trabalho de Chen, Yao e Gu (2020) utiliza CNN para a detecção de buracos. A arquitetura utilizada é separada em duas sub-redes, uma responsável por encontrar as possíveis regiões onde pode haver um buraco, e a outra responsável pela classificação destes candidatos.

Foram analisados também outros dois trabalhos encontrados fora das 4 bases utilizadas. Em Buchinger e Silva (2014) os autores apresentam um sistema de detecção de anomalias (buracos e rachaduras) em estradas de asfalto. A abordagem proposta foi testada em 186 imagens resultando em uma acurácia de 84%. Nesta abordagem a região da estrada é segmentada como um pré-processamento, ficando como Região de Interesse para a detecção de anomalias, possível após operações morfológicas nas imagens.

O trabalho recente de Maeda et al. (2018) emprega redes neurais convolucionais para detecção e classificação de danos em estradas de asfalto. A detecção é feita com a utilização de *bounding box* nos danos encontrados que são então classificados em tipos de danos. Porém, não lida com variações de tipos de superfície ou danos em outros tipos de superfícies, não faz,

por exemplo, a detecção do caminho em si.

Também foi realizada uma busca, utilizando as mesmas bases das RSLs, por trabalhos com o termo de pesquisa sendo: “*water puddle detection*”, considerando o período entre 2015 e atualmente (abril de 2020). Foram selecionados dois trabalhos (HAN et al., 2018), (LI; NGUYEN; YOU, 2019). Em Han et al. (2018) os autores apresentam uma abordagem que utiliza CNNs e leva em consideração o reflexo da água, chamada de *Reflection Attention Units* (Unidades de atenção à reflexão). Já em Li, Nguyen e You (2019), que é uma evolução do trabalho anterior, os autores utilizam informação temporal em uma arquitetura CNN 3D, que segundo os autores melhora o nível de acurácia na detecção de poças de água em relação à arquitetura anterior.

Outros dois trabalhos, mais antigos, ((RANKIN; MATTHIES, 2008) e (RANKIN; IVANOV; BRENNAN, 2010)) lidaram com detecção de grandes poças de água em cenários sem pavimento (*off-road*) com propósito de navegação veicular. Ambos utilizando Visão Estéreo. Além de focarem apenas em estradas sem pavimento, eles não lidam com outras características da estrada, nem mesmo a própria detecção de estrada.

Esses trabalhos também não contam com a detecção do restante da estrada, concentrando-se exclusivamente na detecção de buracos ou somente na detecção de poças. Ou seja, não há identificação de falhas ou alterações na superfície da estrada integradas ao cenário de navegação de veículos, mantendo o restante da detecção de estrada em operação enquanto são analisadas as mudanças no pavimento que podem representar uma ameaça.

4.4 CONCLUSÕES SOBRE O ESTADO DA ARTE

Com base no levantamento do estado da arte realizado percebe-se que há muitos trabalhos que utilizaram técnicas de visão computacional clássicas, principalmente visão estereo para a detecção de obstáculos e métodos de segmentação para a detecção de caminho, e até mesmo combinações entre diferentes técnicas para qualquer das duas tarefas (caminho e obstáculo). Ainda assim, as arquiteturas CNNs têm sido cada vez mais aplicadas, com sucesso, para ambas as tarefas.

Também é notável que a grande maioria dos trabalhos encontrados utilizam imagens com estradas em boa qualidade, com pouca variação no tipo de superfície, sendo em maioria estradas de asfalto, e uma quantidade menor ainda de trabalhos lidando com danos na superfície da estrada, principalmente buracos e poças de água.

Além disso, os trabalhos encontrados que lidaram com alguma detecção de danos na superfície, seja buracos ou poças, focam apenas nesta tarefa em específico, não detectando o restante do caminho ou outros padrões relacionados a navegação veicular. Vale ressaltar também que esses trabalhos fizeram experimentos em um único tipo de terreno, a grande maioria em asfalto, não considerando a identificação dos danos em diferentes tipos de terreno. Também não foram encontrados trabalhos que identificam a variação nos tipos de terreno.

5 DESENVOLVIMENTO

Neste capítulo são apresentadas as abordagens utilizadas neste trabalho, além da nova base de casos criada e utilizada em duas das abordagens. O capítulo está dividido em quatro seções. Na seção 5.1 é apresentada uma abordagem de extração de características de obstáculos, identificando o obstáculo, sua distância em relação à fonte de captura e sua movimentação na cena. A seção 5.2 apresenta a base de casos criada para experimentos em estradas de baixa qualidade e utilizadas nas duas abordagens seguintes. A seção 5.3 apresenta uma classificação de tipos de superfície e de qualidade da superfície. Por fim, a seção 5.4 apresenta a principal abordagem desta tese, uma segmentação semântica da superfície da estrada.

5.1 EXTRAÇÃO DE CARACTERÍSTICAS DE OBSTÁCULOS

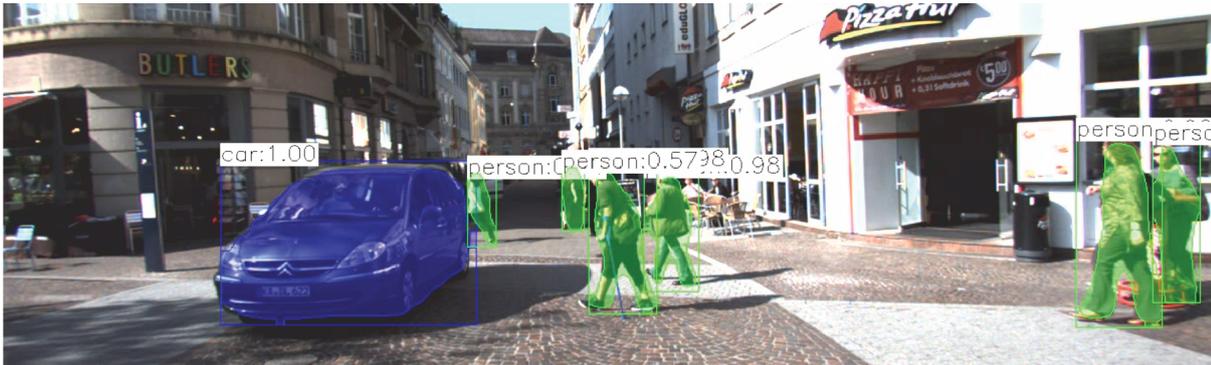
Na detecção de obstáculos em um ambiente dinâmico, é importante não só identificar o tipo de obstáculo como também o movimento desse obstáculo, permitindo assim gerar um alerta de colisão e/ou ação de mudança de rota do veículo. Deste modo é importante extrair informações como a distância dos obstáculos, a velocidade desses obstáculos e também a direção.

Nesta abordagem foi aplicado um conjunto de técnicas bem documentadas em um fluxo para, com base no obstáculo identificado, extrair as características de distância e movimento do obstáculo detectado. Nos experimentos foram utilizadas imagens de duas bases de casos, sendo: KITTI (GEIGER et al., 2013), que contém diferentes sequências de *frames*, algumas com bastante movimento de veículos e até mesmo pedestres. Além da CaRINA (SHINZATO et al., 2016), que também contém sequências de *frames* com obstáculos em movimento, apesar de em menor quantidade do que na KITTI. Ambas as bases fornecem as sequências de *frames* estéreo, onde cada cena é filmada por duas câmeras paralelas simultaneamente, permitindo o uso de técnicas de visão estéreo e conseqüentemente a extração de profundidade da cena. O fato de serem *frames* sequenciais também permite o uso de análise de Fluxo Ótico para extrair as informações de movimento da cena.

Para a detecção e identificação dos obstáculos na cena foi utilizado estrutura CNN conhecida como Mask R-CNN (HE et al., 2017), uma extensão de outra conhecida estrutura, a Faster R-CNN (REN et al., 2015). Essa estrutura além de realizar a detecção de classificação dos objetos, constrói a máscara de segmentação para cada objeto. A Mask R-CNN gera máscaras de segmentação por instâncias, onde os objetos mesmo pertencendo a uma mesma classe são identificados individualmente. Entretanto, neste experimento essas máscaras foram utilizadas como uma segmentação semântica, importando apenas a classe a qual pertence, por exemplo: pessoa, veículo, etc (Figura 17).

A estrutura foi utilizada com modelos pré-treinados na arquitetura Inception (SZE-GEDY et al., 2016), que possui boa precisão de classificação e é mais rápido do que muitas outras arquiteturas. Além disso, nossos experimentos são executados em um modelo treinado

Figura 17 – Exemplo da Mask R-CNN no dataset KITTI.



Fonte: Desenvolvido pelo autor.

com o conjunto de dados MSCOCO (LIN et al., 2014a), que é um conjunto de dados específico para detecção e segmentação de objetos.

Com base nos dados estéreo fornecidos pelos datasets também são gerados os Mapas de Disparidade da cena (mapa de profundidade) para cada par de imagens estéreo. Utilizando as máscaras de segmentação dos obstáculos identificados pela Mask R-CNN é possível aplicar o valor de profundidade para cada máscara específica, extraindo uma média de profundidade de cada obstáculo segmentado. Também com base na detecção dos obstáculos é possível calcular a média de fluxo ótico para cada obstáculo, tanto para direção como para a intensidade de movimento de cada obstáculo. O método de fluxo ótico adotado foi o de Gunnar-Farneback.

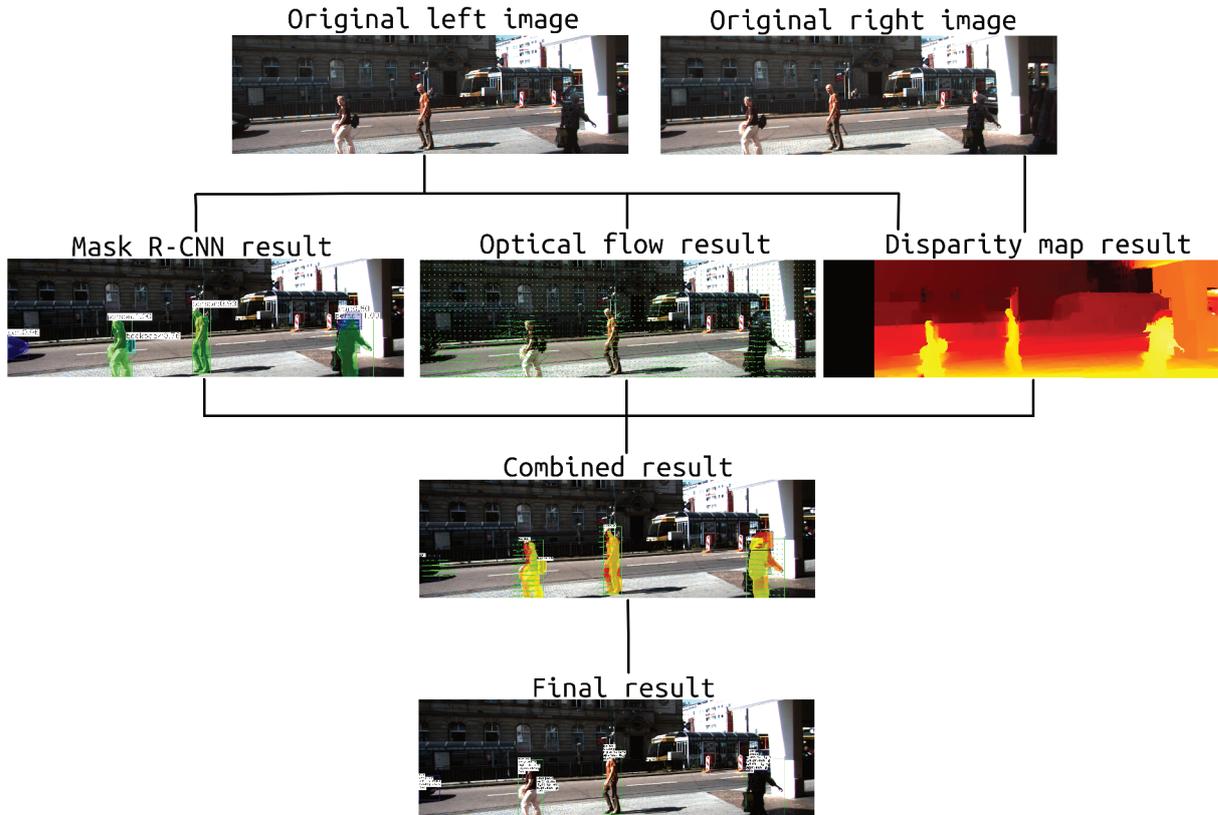
Os passos da abordagem estão representados na Figura 18. Para a detecção de obstáculos e cálculo do fluxo ótico foram utilizadas apenas as imagens esquerda de cada sequência de *frames*. Para o cálculo do Mapa de Disparidade foram utilizadas ambas imagens do par estéreo de cada sequência de *frames*. Os experimentos dessa abordagem foram executados em uma máquina com uma GPU NVIDIA GeForce GTX 1060 em um Ubuntu 18.04 com 16GB de RAM.

Utilizando os valores médios de disparidade de cada obstáculo, foram definidos limiares, com base em observação e estimativa visual, para classificação de profundidade dos obstáculos. Os rótulos de profundidade utilizados foram definidos de muito perto para muito distante, como: *very close*, *close*, *far* e *very far*.

Para as classificações de movimento foram definidos limiares com base nas médias do fluxo ótico. Para os rótulos de direção foram utilizados os valores do eixo-*x* do fluxo ótico, e com limiares definidos indicando se o objeto está indo para algum lado ou se está parado, da seguinte forma: *stable direction*, *left to right* e *right to left*. Já os valores do eixo-*y* foram utilizados para classificar se os objetos estão mantendo uma distância estável, se aproximando, ou se afastando, definidos com os seguintes rótulos: *stable distance*, *approaching* e *moving away*.

A intensidade do movimento dos obstáculos também pode ser obtida com base nos valores de fluxo ótico, pois quanto maior o deslocamento de um *pixel* entre dois *frames*, maior

Figura 18 – Os passos da abordagem.



Fonte: Desenvolvido pelo autor.

será o vetor que representa esse deslocamento. O valor de deslocamento é obtido através da multiplicação da média dos valores no eixo- x e da média dos valores do eixo- y de cada obstáculo:

$$xM = \frac{1}{n} \sum_{i=1}^n x_i \quad (5.1)$$

$$yM = \frac{1}{n} \sum_{i=1}^n y_i \quad (5.2)$$

$$VL = xM * yM \quad (5.3)$$

onde xM é a média dos valores no eixo- x em um objeto, yM é a média dos valores no eixo- y do mesmo objeto, e VL é o vetor de intensidade deste objeto. Os rótulos para intensidade de movimento, também definidos com limiares, são: *stopped*, *slow*, *average speed*, *fast* e *very fast*.

5.2 BASE DE CASOS COM ESTRADAS DE BAIXA QUALIDADE

Como o principal objetivo desta tese é o de detectar estradas de baixa qualidade, foi criado um novo conjunto de dados, chamado de *Road Traversing Knowledge* (RTK), com *frames*

sequências e com amostras de diferentes tipos de superfície de estrada: asfalto com diferentes variações (ex.: asfalto antigo e mais claro, asfalto novo e mais escuro, asfalto com remendos), estradas de terra e outros tipos de pavimento (ex.: lajota e paralelepípedo). Além de exemplos de estradas com danos, como buracos e poças de água. Algumas amostras do dataset são apresentadas na Figura 19.

Figura 19 – Amostras do dataset RTK.



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Em geral, os *frames* foram coletados durante o dia e em boas condições climáticas. Porém há bastante variações de iluminação, contendo variadas sombras no caminho. Muitos dos *frames* apresentam transições entre tipos de superfície (ex.: asfalto para terra, terra para

lajota, etc). Uma pequena introdução a este conjunto de dados foi apresentada no Capítulo 2, Seção 2.2, desta tese. Mais detalhes sobre essa base de casos podem ser conferidos na publicação (RATEKE; JUSTEN; WANGENHEIM, 2019).

O dataset RTK contém 77547 *frames* separados em quatro sequências de coleta. Parte do dataset foi utilizado como um padrão ouro (*Ground Truth* - GT) de classificação de tipos de superfície e qualidade de superfície, contendo rótulos de tipo de superfície para 62662 *frames*, como:

- GT *frames* para asfalto (***asphalt***): 43263
- GT *frames* para outros pavimentos (***paved***): 13697
- GT *frames* para estradas de terra (***unpaved***): 5702

Também contém um total de 6297 *frames* classificados em qualidade como GT, sendo:

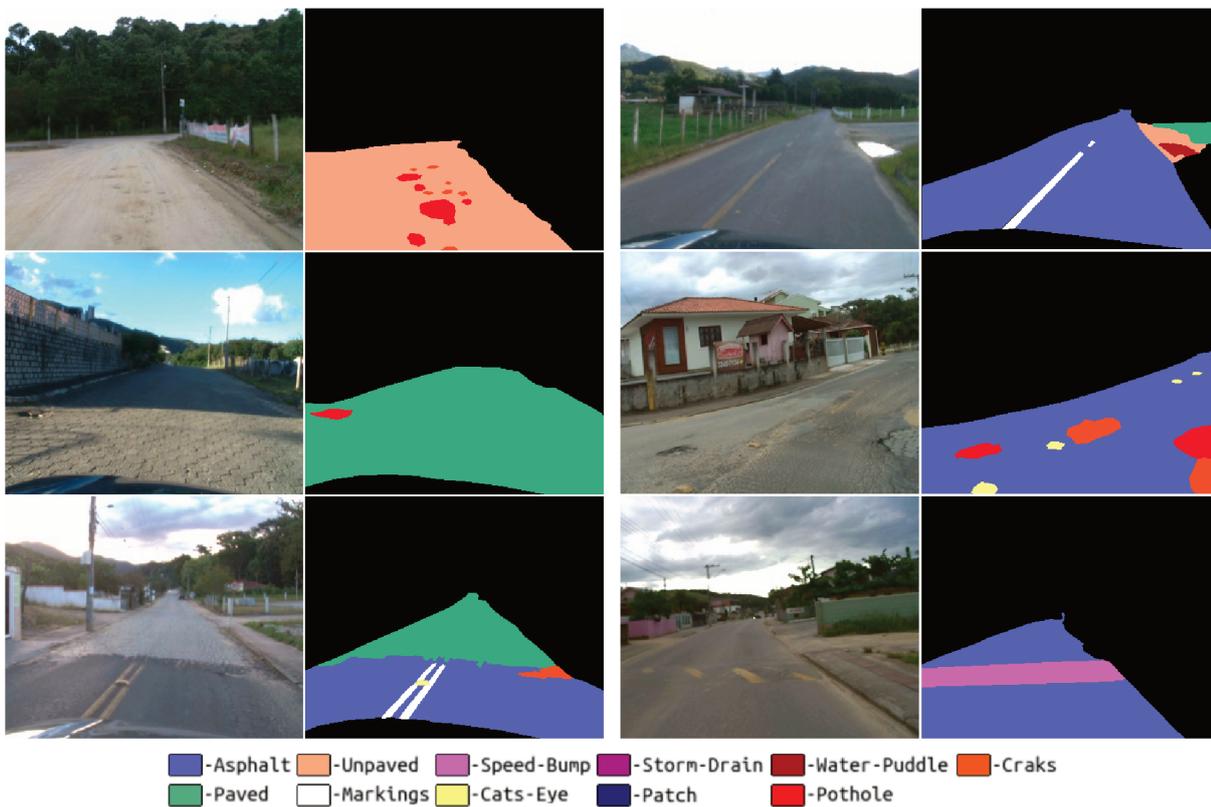
- GT *frames* para asfalto bons (***asphalt good***): 1978
- GT *frames* para asfalto regulares (***asphalt regular***): 839
- GT *frames* para asfalto ruins (***asphalt bad***): 464
- GT *frames* para outros pavimentos bons (***paved good***): 1179
- GT *frames* para outros pavimentos regulares (***paved regular***): 324
- GT *frames* para outros pavimentos ruins (***paved bad***): 124
- GT *frames* para estradas de terra regulares (***unpaved regular***): 796
- GT *frames* para estradas de terra ruins (***unpaved bad***): 593

Além do GT de classificação, também foi criado um GT de segmentação semântica da superfície da estrada e das variações na superfície. O GT com as imagens segmentadas contém 701 imagens. Exemplos do GT podem ser conferidos na Figura 20. As classes utilizadas para anotação das regiões estão listadas a seguir:

- ***Background***, tudo que não é relacionado com a superfície da estrada;
- ***Asphalt***, estradas com superfície do tipo asfalto;
- ***Paved***, diferentes tipos de pavimento (ex.: lajotas e paralelepípedos);
- ***Unpaved***, estradas sem pavimento, estradas de terra;
- ***Markings***, para as marcações na estrada;
- ***Speed-Bump***, para lombadas;

- **Cats-Eye**, olhos de gato encontrados na estrada, tanto na parte central como nos limites laterais da estrada;
- **Storm-Drain**, bueiros e valas normalmente nos limites laterais das estradas;
- **Patch**, para variados remendos encontrados em estrada de asfalto;
- **Water-Puddle**, poça de água e também para regiões lamacentas;
- **Pothole**, para diferentes tipos e tamanhos de buracos, não importando em qual tipo de superfície ocorre;
- **Cracks**, utilizado em variados danos na estrada como: rachaduras e craquelados.

Figura 20 – Amostras do GT segmentado.



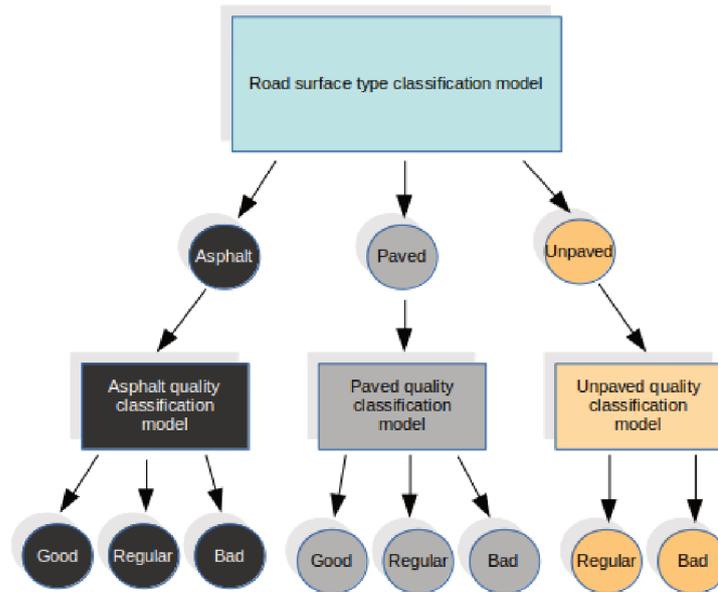
Fonte: Desenvolvido pelo autor.

5.3 CLASSIFICAÇÃO DE SUPERFÍCIE E QUALIDADE DE ESTRADA

Como primeiro passo na análise da superfície da estrada, considerando as variações na superfície e também a qualidade dessa estrada, foi desenvolvido um classificador de tipos de estrada e de qualidades de estrada. Esse classificador também pode ser conferido em detalhes na publicação (RATEKE; JUSTEN; WANGENHEIM, 2019).

Foi utilizada uma estrutura CNN simples, com base em (SACHAN, 2017), para criar quatro modelos diferentes. Essa ideia é ilustrada pela Figura 21, onde um modelo é responsável pela classificação do tipo de superfície, podendo ser asfalto (*asphalt*), terra (*unpaved*) ou outros pavimentos (*paved*). E outros três modelos seguintes específicos para a classificação de qualidade para cada tipo de superfície.

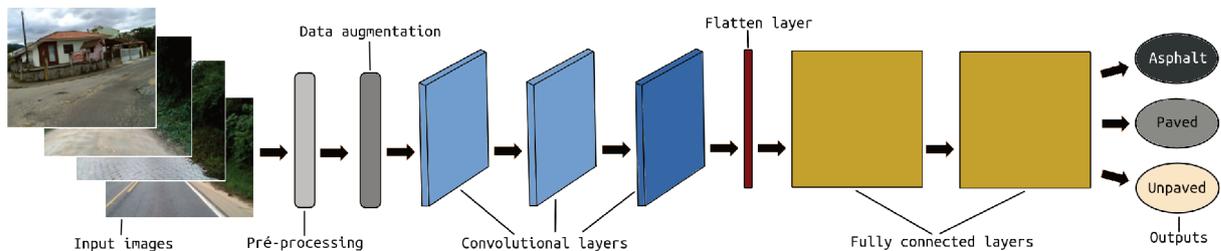
Figura 21 – Os modelos e a sequência de utilização.



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Esse classificador consiste no treinamento de uma CNN. Os treinos e experimentos dessa abordagem foram executados em uma máquina com uma GPU NVIDIA GeForce GTX 1060 em um Ubuntu 18.04 com 16GB de RAM. As etapas desta abordagem são apresentadas na Figura 22. Além do GT da base de casos RTK, também foram separados frames das bases KITTI e CaRINA para treino, validação e testes.

Figura 22 – Os passos e a estrutura CNN utilizados.



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

O pré-processamento consiste na definição de uma região de interesse (*Region of Interest - ROI*), onde há a maior parte da imagem que contém a estrada, cortando assim a parte superior da imagem e um pouco da parte inferior onde pode ocorrer de aparecer parte do veí-

culo que está sendo utilizado para filmar as imagens (Figura 23). Esse ROI é proporcional as dimensões das imagens para funcionar com os três conjuntos de dados utilizados que contêm imagens em diferentes resoluções. São cortados 50% da parte superior e 12% da parte inferior das imagens.

Figura 23 – Regiões de Interesse. Primeira linha: RTK dataset. Segunda linha: KITTI dataset. Terceira linha: CaRINA dataset.



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Em seguida, são criadas cópias das imagens de entrada com variações de iluminação, etapa conhecida como *data augmentation*. Objetiva simular diferentes condições de brilho e iluminação que podem ocorrer na superfície da estrada em diferentes momentos do dia e diferentes climas. São feitas cópias de cada imagem de entrada, colocando mais brilho nas imagens. A imagem para esta etapa é transformada para o sistema de cor HSV, onde o brilho, representado pelo *value* é acrescido em 150 quando o valor original da imagem for menor que 105 ou trocado para 255 quando o valor de brilho original for maior que 105. Desta forma, o treinamento da CNN tem além dos ROIs originais, os ROIS com *data augmentation*.

Após a etapa de *data augmentation* as imagens são passadas para a CNN, iniciando por duas camadas de convolução com 32 filtros de tamanho 3x3, seguido por uma camada de convolução final com 64 filtros de tamanho 3x3. Após as camadas de convolução, uma camada de achatamento (*flatten layer*) é utilizada para transformar o tensor multidimensional em um tensor de uma dimensão. Duas camadas totalmente conectadas são adicionadas no final. Uma ativação ReLU é aplicada na primeira camada totalmente conectada. A segunda camada

totalmente conectada tem as possíveis saídas, ou seja, a classificação da imagem entre as classes desejadas.

5.4 SEGMENTAÇÃO SEMÂNTICA DE SUPERFÍCIE DE ESTRADAS

Essa abordagem é uma evolução da abordagem apresentada anteriormente. Com base no GT segmentado do conjunto de imagens RTK. Treinando uma arquitetura CNN capaz de realizar a segmentação semântica da superfície da estrada. Os experimentos para essa abordagem foram executados no Google *Colaboratory* (Google Colab), um serviço de nuvem baseado em notebooks Jupyter, que é um ambiente web interativo para criação de documentos. Nos experimentos foram utilizadas GPUs disponibilizadas pelo Google Colab, sendo: Tesla K80 com 12GB de memória e Tesla P100-PCIE com 16GB de memória. Também foi utilizado uma biblioteca de código aberto para aplicações de *deep learning* baseada no PyTorch, conhecida como fast.ai (HOWARD et al., 2018).

A arquitetura CNN utilizada foi a U-NET (RONNEBERGER; FISCHER; BROX, 2015), que é uma arquitetura CNN projetada para realizar a tarefa de segmentação semântica em imagens médicas, mas aplicada com sucesso a muitas outras abordagens. Essa arquitetura possui duas partes principais, uma sendo o codificador (*encoder*), utilizada para extrair características da imagem. Na U-NET o *encoder* inicia com a imagem no tamanho original (ou um tamanho definido para início) e vai reduzindo até que fique pequeno e suficiente para ainda extrair padrões. A outra parte da U-NET é simétrica ao *encoder*, é conhecida como *decoder* e faz o processo inverso, aumentando o tamanho até ao valor original de entrada.

Foram utilizados modelos de pré-treinamento com resnet34 e resnet50, ambos disponíveis na biblioteca fast.ai. ResNet são modelos CNN residuais, que permitem que camadas da rede passem informações para camadas seguintes que não são diretamente ligadas sem passar por algumas camadas intermediárias, ou seja, pulando camadas. Desta forma mantendo características relevantes das camadas iniciais (HE et al., 2016).

Na etapa de *data augmentation* foram utilizadas opções padrões da biblioteca fast.ai, sendo aplicadas rotações horizontais e distorção de perspectiva. Com a fast.ai é possível cuidar para fazer as mesmas variações feitas no *data augmentation* das imagens originais, para as imagens de máscara, o GT, utilizadas para treinamento, evitando assim que uma rotação seja feita na imagem original apresentando uma curva para a direita, e que a imagem do GT fique com uma curva para a esquerda o que atrapalharia o treinamento da rede e geraria um modelo ruim.

Uma informação relevante é que as classes do GT são bastante desbalanceadas, tendo muito mais *pixels* de *background* ou dos tipos de superfície de estrada (*asphalt*, *paved* e *unpaved*) de que das demais classes do GT. Nessa situação não basta, por exemplo, apenas repetir uma imagem com buraco ou com poça de água, como é comum em situações de desbalanceamento em classificações de imagens. Pois também estará aumentando a quantidade de *pixels* de *background* ou de superfície de estrada, aumentando ainda mais a diferença entre as classes.

Após analisar todas as 701 imagens disponíveis no GT, verificando a quantidade de *pixels* em cada classe, obteve-se a proporção de cada classe no GT listada a seguir:

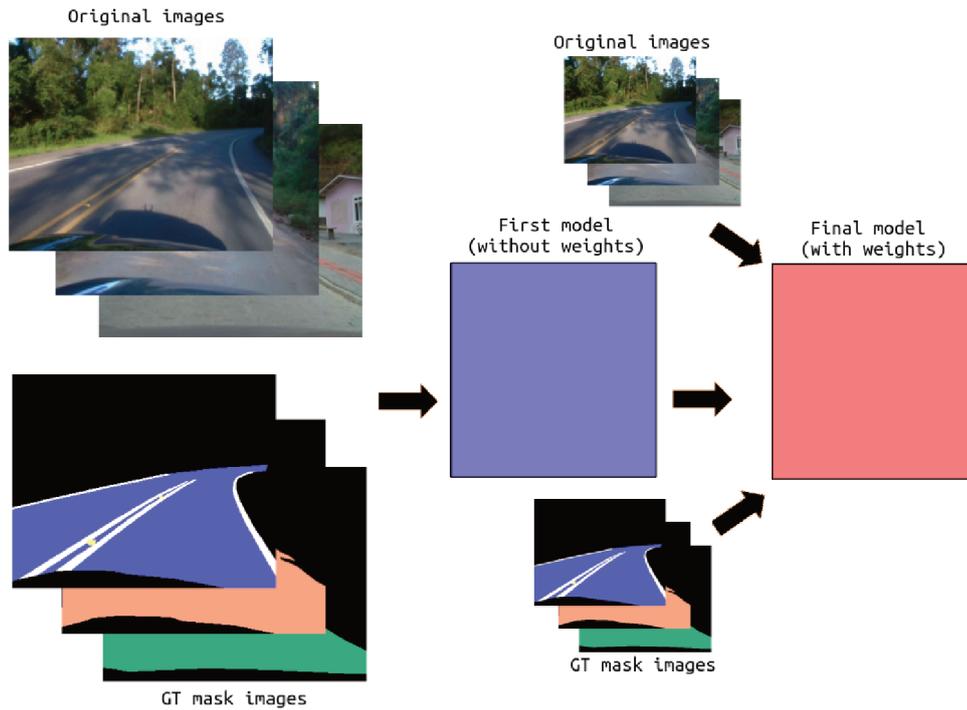
- **Background** = 65,86%;
- **Asphalt** = 12,90%;
- **Paved** = 10,50%;
- **Unpaved** = 9,22%;
- **Marking** = 0,78%;
- **Speed-Bump** = 0,06%;
- **Cats-Eye** = 0,02%;
- **Storm-Drain** = 0,02%;
- **Patches** = 0,22%;
- **Water-Puddle** = 0,03%;
- **Pothole** = 0,06%;
- **Cracks** = 0,33%.

A solução encontrada foi adicionar pesos para cada classe na etapa de treinamento da rede. Os pesos foram adicionados de forma a tentar compensar a diferença de *pixels* das classes, tentando simular que as classes tenham uma quantidade similar de amostras. Com base em diferentes experimentos percebeu-se que apenas aplicar os pesos não é o suficiente, pois ao melhorar a acurácia das classes com menor representatividade teve uma grande piora na acurácia das três classes de superfície de estrada (*asphalt*, *paved* e *unpaved*).

Diferentes experimentos foram realizados, com diferentes configurações da arquitetura utilizada, como: gerar modelo de treinamento sem pesos e sem nenhuma variação, apenas utilizando a U-NET com resnet34 ou resnet50. Ou gerar modelos de treinamento com variações de tamanho das imagens de entrada, de forma crescente, onde cada etapa utiliza o modelo anterior como base. Com as configurações anteriores mas aplicando pesos nas classes. E também treinando modelos sem pesos e utilizando esses modelos como base para um treinamento com pesos.

Os melhores valores de acurácia foram obtidos com a seguinte configuração: primeiro treinar um modelo sem utilizar os pesos, gerando um modelo com boa acurácia para os tipos de superfície (96% para asfalto, 82% para outros pavimentos e 73% para estradas de terra), porém ruim para as classes menores. Em seguida, utilizar esse modelo treinado previamente como base, como pré-treinamento, para o modelo seguinte que utiliza os pesos proporcionais para as classes, gerando assim bons valores para todas as classes, como será apresentado na Seção 6.3. A ideia é ilustrada pela Figura 24.

Figura 24 – Passos da bordagem de segmentação.



Fonte: Desenvolvido pelo autor.

É importante ressaltar que a arquitetura utilizada, assim como as imagens e as máscaras (GT) são as mesmas em ambos os modelos, em ambas as etapas. A variação está justamente na aplicação dos pesos diferentes para cada classe no treinamento do segundo modelo, ou seja na segunda etapa de treinamento.

6 RESULTADOS

Neste capítulo são apresentados os resultados relacionados as abordagens do capítulo 5 respectivamente, sendo: A seção 6.1 apresenta os resultados da abordagem de detecção e extração de características de profundidade e movimento dos obstáculos. Na seção 6.2 são apresentados os resultados da classificação de tipos e qualidade de superfície. A segmentação semântica das características de superfície são apresentadas na seção 6.3. Com base na pesquisa feita e nos resultados obtidos são verificados a questão de pesquisa e os objetivos na seção 6.4. Finalmente na seção 6.5 são listadas as publicações relacionadas a pesquisa e aos resultados desta tese.

6.1 RESULTADOS DA EXTRAÇÃO DE CARACTERÍSTICAS DE OBSTÁCULOS

Para avaliar os resultados foram feitas anotações manuais (GT) em um total de 100 *frames*, divididos em 20 sequências de 5 *frames* cada, visando identificar os padrões de movimento em uma cena. Ao todo foram 415 objetos anotados, incluindo carros, pessoas, caminhões, bicicletas e outros elementos comuns em um cenário de navegação veicular. Na Tabela 19 é apresentada a acurácia geral para cada tarefa prevista nessa etapa de análise de movimentos e distância de obstáculos. Uma análise individual para cada tarefa é apresentada pelas matrizes de confusão (Tabela 20, Tabela 21, Tabela 22 e Tabela 23).

Com base nos resultados apresentados pelas matrizes de confusão, algumas considerações podem ser feitas. Por exemplo, na Tabela 20, que apresenta os valores para as classificações de profundidade, percebe-se que os valores mais baixos ficaram com as classes “*very-close*” e “*far*”.

Tabela 19 – Acurácia da extração de características dos obstáculos.

Tarefa	Acurácia
Profundidade	81,75%
Direção do eixo x	89,51%
Direção do eixo y	83,57%
Intensidade de Movimento	80,96%

Fonte: Desenvolvido pelo autor.

Tabela 20 – Matriz de confusão da profundidade

	very close	close	far	very far
very close	72.82%	17.48%	9.71%	0.00%
close	1.00%	86.00%	6.00%	7.00%
far	0.00%	0.00%	67.00%	33.00%
very far	0.00%	0.00%	0.00%	100.00%

Fonte: Desenvolvido pelo autor.

Tabela 21 – Matriz de confusão do eixo-x

	left to right	right to left	stable direction
left to right	86.90%	8.28%	4.83%
right to left	5.11%	92.05%	2.84%
stable direction	11.24%	0.00%	88.76%

Fonte: Desenvolvido pelo autor.

Tabela 22 – Matriz de confusão do eixo-y

	approaching	moving away	stable distance
approaching	78.40%	8.45%	13.15%
moving away	0.00%	89.13%	10.87%
stable distance	5.16%	5.81%	89.03%

Fonte: Desenvolvido pelo autor.

Tabela 23 – Matriz de confusão da intensidade de movimento

	stopped	slow	average speed	fast	very fast
stopped	90.41%	5.48%	4.11%	0.00%	0.00%
slow	13.79%	58.62%	24.14%	0.00%	0.00%
average speed	0.00%	1.49%	77.61%	20.90%	0.00%
fast	0.51%	1.53%	10.71%	84.69%	2.55%
very fast	0.00%	0.00%	4.00%	26.00%	70.00%

Fonte: Desenvolvido pelo autor.

Porém, também nota-se que o maior índice de erros para ambas as classes ocorreram em classes vizinhas, não sendo tão discrepantes do resultado esperado. Ainda assim, a classe “*very-close*” apresentou uma quantidade razoável de erros como sendo da classe “*far*”, uma classe não vizinha. Isso pode ocorrer em situações onde há objetos que, apesar de terem diferentes profundidades, estão próximos entre si no eixo x do plano 2D da imagem, podendo dificultar o cálculo da média de profundidade na região dos objetos.

A mesma situação é possível com os vetores e valores do fluxo ótico, como por exemplo na Tabela 22, onde objetos que deveriam estar na classe “*approaching*” apresentaram um índice de 8,45% como sendo da classe “*moving-away*”. Por fim, na Tabela 23 o pior resultado foi apresentado pela classe “*slow*”, ainda assim, em todas as classes os erros ocorreram em classes vizinhas.

Os resultados da abordagem de extração de características dos obstáculos, combinando a Mask R-CNN, Mapa de Disparidade e Fluxo Ótico são apresentados na Figura 25 com resultados nas imagens de base KITTI, e também na Figura 26 com resultados na base CaRINA. Na coluna esquerda são os resultados dos métodos combinados e na coluna direita é a análise com

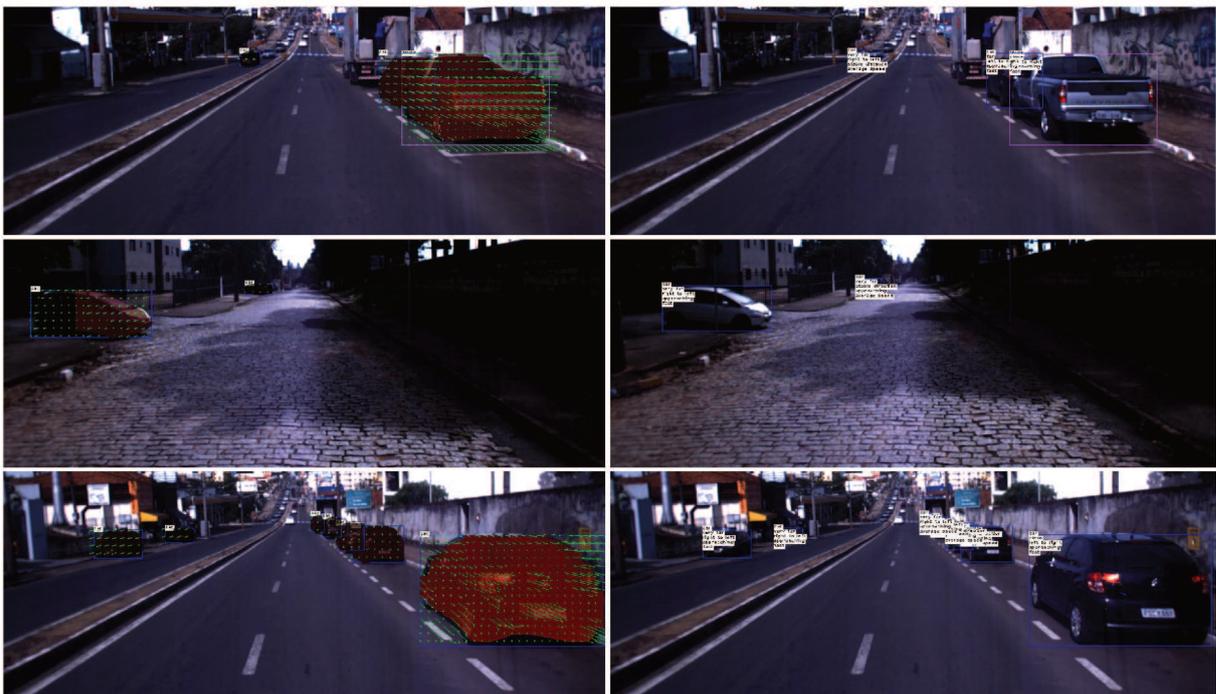
as classificações de distância, movimento e velocidade de cada obstáculo.

Figura 25 – Resultados da detecção e extração de movimento e distância de obstáculos na base KITTI.



Fonte: Desenvolvido pelo autor.

Figura 26 – Resultados da detecção e extração de movimento e distância de obstáculos na base CaRINA.

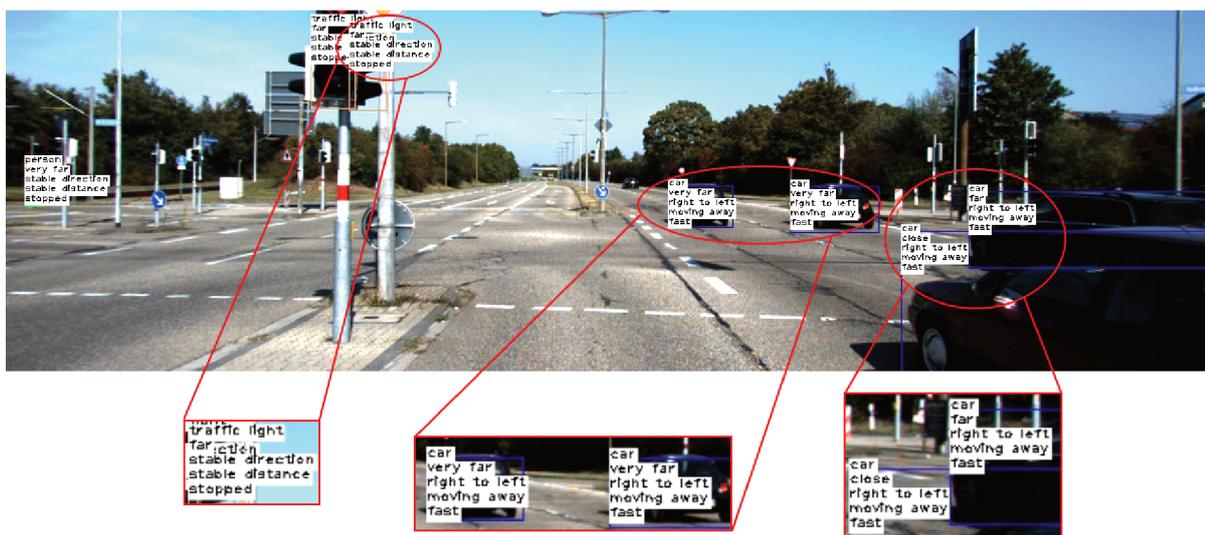


Fonte: Desenvolvido pelo autor.

Os resultados na base CaRINA (Figura 26) mostram menos participantes na cena e enquanto o veículo de captura está se movimentando os obstáculos estão parados. Mesmo assim é possível ter noção de distância de aproximação e velocidade considerando o veículo de captura se aproximando desses obstáculos estáticos.

Na primeira linha da Figura 25, na base KITTI, o veículo com a câmera para captura das imagens está parado e quatro carros estão passando pela faixa da direita. Nota-se com o resultado obtido que os veículos estão se afastando. Uma sinalização também é detectada e o resultado mostra que além de estar parada também mantém uma distância estável do veículo de filmagem, como é realçado na Figura 27. Os veículos que estão passando pela faixa da direita, apesar de estarem em linha reta tem como resultado de direção o rótulo *right to left*, isso ocorre devido à perspectiva da imagem, considerando a variação no eixo-x da imagem, algo semelhante para encontrar o ponto de fuga.

Figura 27 – Destaque na análises de movimento, velocidade e distância.

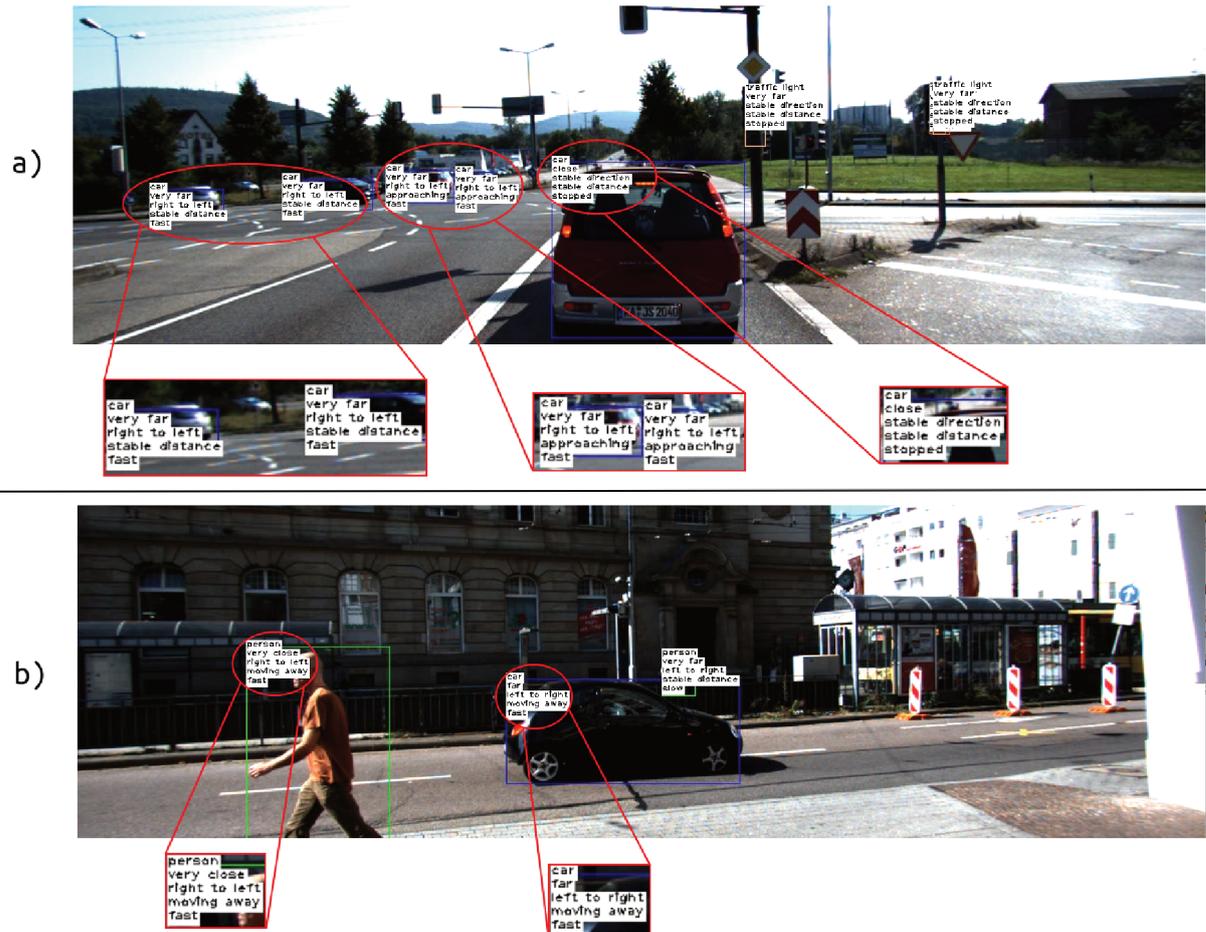


Fonte: Desenvolvido pelo autor.

A linha dois da Figura 25 mostra um veículo parado e com uma distância estável e outros veículos distantes cruzando a frente, da direita para a esquerda (Figura 28 a). Um pedestre e um veículo passando em frente a captura, em direções opostas, é apresentado na linha três da Figura 25, e com destaque para os rótulos na Figura 28 b. Por fim a última linha mostra diversos pedestres atravessando a frente do veículo da direita para a esquerda e bem próximos da captura.

Para esses resultados, inicialmente apenas uma avaliação visual foi realizada, entretanto essa avaliação foi feita nos resultados apresentados, mostrando respostas condizentes com a realidade dos obstáculos na cena. Posteriormente com as anotações realizadas e a verificação de acurácia em cada rótulo foi possível analisar e identificar onde e porque acontecem os principais erros.

Figura 28 – Destaque na análises de movimento, velocidade e distância.



Fonte: Desenvolvido pelo autor.

6.2 RESULTADOS DA CLASSIFICAÇÃO DE SUPERFÍCIE E QUALIDADE DE ESTRADA

Para a abordagem de classificação de imagens em tipo e qualidade de superfície de estrada, foram feitos experimentos primeiramente apenas para a classificação de tipos de superfície e em seguida adicionadas a classificação de sua qualidade. Dentro dos experimentos de tipos de estrada foram feitos testes com um modelo treinado apenas com imagens da base RTK (Tabela 24) e outro modelo treinado com adição das imagens das bases KITTI e CaRINA (Tabela 25).

No treinamento foram utilizadas 6264 imagens da RTK, 509 imagens da KITTI e 156 imagens da CaRINA. Já os testes foram em 62662 imagens da RTK, 5093 da KITTI e 1401 da CaRINA. Comparando os valores das tabelas 24 e 25 percebe-se que com a adição de imagens de outras bases, além de melhorar os resultados para essas bases, não teve um impacto negativo nos resultados da RTK.

Nota-se também um desbalanceamento entre as classes, com mais exemplos de asfalto que outras classes. Deste modo foi realizado um balanceamento, replicando imagens das classes menores na etapa de treinamento, possibilitando uma melhora, apresentada na Tabela 26.

Tabela 24 – Resultados da classificação de tipos de superfície. Apenas RTK

Treinado apenas com imagens da RTK

	Asphalt	Paved	Unpaved	Acurácia Geral
RTK	98.58%	85.75%	93.84%	95.73%
KITTI	54.70%	23.40%	-	53.07%
CaRINA	58.82%	6.61%	100.00%	45.30%

Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Tabela 25 – Resultados da classificação de tipos de superfície. RTK, KITTI e CaRINA

Treinado com RTK, KITTI e CaRINA

	Asphalt	Paved	Unpaved	Acurácia Geral
RTK	98.45%	86.24%	93.67%	95.72%
KITTI	94.22%	73.21%	-	93.13%
CaRINA	97.66%	100.00%	100.00%	98.36%

Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Tabela 26 – Resultados da classificação de tipos de superfície. RTK, KITTI, CaRINA e com balanceamento

Treinado com RTK, KITTI, CaRINA e com balanceamento

	Asphalt	Paved	Unpaved	Acurácia Geral
RTK	96.81%	86.05%	94.41%	94.57%
KITTI	94.49%	76.23%	-	93.54%
CaRINA	99.90%	100.00%	99.00%	99.86%

Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

As matrizes de confusão mostram onde ocorreram a maior quantidade de erros (Tabela 27, Tabela 28 e Tabela 29). Com os valores apresentados nas tabelas, é notável que a identificação de asfalto e estradas de terra tiveram bons valores de acurácia e, com exceção da CaRINA, os valores de pavimento foram os que obtiveram os piores resultados. Com as matrizes de confusão é possível identificar onde foram os erros e desta forma fazer uma análise, nota-se por exemplo que a maior parte dos erros das estradas de pavimento foi classificá-las como estrada de asfalto.

Tabela 27 – Matriz de confusão do dataset RTK

	Asphalt	Paved	Unpaved
Asphalt	96.81%	2.68%	0.51%
Paved	10.24%	86.05%	3.71%
Unpaved	4.12%	1.47%	94.41%

Fonte: Adaptado de (RATEKE; JUSTEN; WANGENHEIM, 2019).

Tabela 28 – Matriz de confusão do dataset KITTI

	Asphalt	Paved	Unpaved
Asphalt	94.49%	5.12%	0.39
Paved	22.64%	76.23%	1.13
Unpaved	-	-	-

Fonte: Adaptado de (RATEKE; JUSTEN; WANGENHEIM, 2019).

Tabela 29 – Matriz de confusão do dataset CaRINA

	Asphalt	Paved	Unpaved
Asphalt	99.90%	0.10%	0.00%
Paved	0.00%	100.00%	0.00%
Unpaved	1.00%	0.00%	99.00%

Fonte: Adaptado de (RATEKE; JUSTEN; WANGENHEIM, 2019).

Na Figura 29 são apresentados alguns resultados na base RTK, incluindo na última linha exemplos de falhas na classificação. Na Figura 30 são apresentados alguns resultados na base CaRINA e na Figura 31 são apresentados os resultados na base KITTI.

O modelo treinado previamente, para classificação de tipo de superfície, foi utilizado também para a classificação de qualidade da superfície. Pois com base nesse primeiro modelo é decidido qual modelo de qualidade será utilizado. Por exemplo, caso o caminho tenha sido classificado como asfalto, será utilizado o modelo de qualidade específico de asfalto. Observa-se que desta forma, caso ocorra um erro na primeira classificação, compromete todo o restante da abordagem.

Figura 29 – Classificação de tipos de superfície na base RTK



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Os testes com a classificação de qualidade foram executados em 6327 imagens da RTK, 606 imagens da KITTI e 721 imagens da CaRINA. Os resultados são apresentados na Tabela 30, e as matrizes de confusão para verificar onde ocorreram as falhas são apresentadas em: Tabela 31, Tabela 32 e Tabela 33. Também são apresentadas algumas imagens de amostras dos resultados de classificação de qualidade em: Figura 32, com a última linha apresentando exemplos de falhas na classificação, Figura 33 e Figura 34.

Figura 30 – Classificação de tipos de superfície na base CaRINA



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Figura 31 – Classificação de tipos de superfície na base KITTI



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Tabela 30 – Resultados da classificação de qualidade

	Asphalt(Good)	Asphalt(Regular)	Asphalt(Bad)	Paved(Good)	Paved(Regular)	Paved(Bad)	Unpaved(Regular)	Unpaved(Bad)
RTK	98.23%	94.04%	96.77%	73.71%	45.37%	9.68%	74.37%	19.73%
KITTI	97.85%	-	-	83.67%	-	-	-	-
CaRINA	98.35%	97.50%	94.12%	90%	-	0%	-	100%

Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Tabela 31 – Matriz de confusão da classificação de qualidade na RTK

	Asphalt(Good)	Asphalt(Regular)	Asphalt(Bad)	Paved(Good)	Paved(Regular)	Paved(Bad)	Unpaved(Regular)	Unpaved(Bad)
Asphalt(Good)	98.23%	0.35%	0.15%	0.40%	0.05%	0%	0.81%	0%
Asphalt(Regular)	1.79%	94.04	0.83%	0%	3.10%	0%	0%	0.24%
Asphalt(Bad)	0.22%	2.16%	96.77%	0%	0%	0%	0%	0%
Paved(Good)	3.56%	2.63%	0.59%	73.71%	4.33%	13.57%	1.19%	0%
Paved(Regular)	7.41%	2.78%	1.85%	33.95%	45.37%	7.72%	0.31%	0.62%
Paved(Bad)	9.68%	1.61%	1.61%	29.84%	43.55%	9.68%	4.03%	0%
Unpaved(Regular)	1.51%	0.38%	0%	0%	0%	0%	74.37%	14.45%
Unpaved(Bad)	4.72%	1.35%	0.67%	1.85%	0%	0.84%	50.59%	19.73%

Fonte: Adaptado de (RATEKE; JUSTEN; WANGENHEIM, 2019).

Tabela 32 – Matriz de confusão da classificação de qualidade na KITTI

	Asphalt(Good)	Asphalt(Regular)	Asphalt(Bad)	Paved(Good)	Paved(Regular)	Paved(Bad)	Unpaved(Regular)	Unpaved(Bad)
Asphalt(Good)	97.85%	0%	0%	1.97%	0%	0%	0.18%	0%
Asphalt(Regular)	-	-	-	-	-	-	-	-
Asphalt(Bad)	-	-	-	-	-	-	-	-
Paved(Good)	8.16%	0%	0%	83.67%	6.12%	2.04%	0%	0%
Paved(Regular)	-	-	-	-	-	-	-	-
Paved(Bad)	-	-	-	-	-	-	-	-
Unpaved(Regular)	-	-	-	-	-	-	-	-
Unpaved(Bad)	-	-	-	-	-	-	-	-

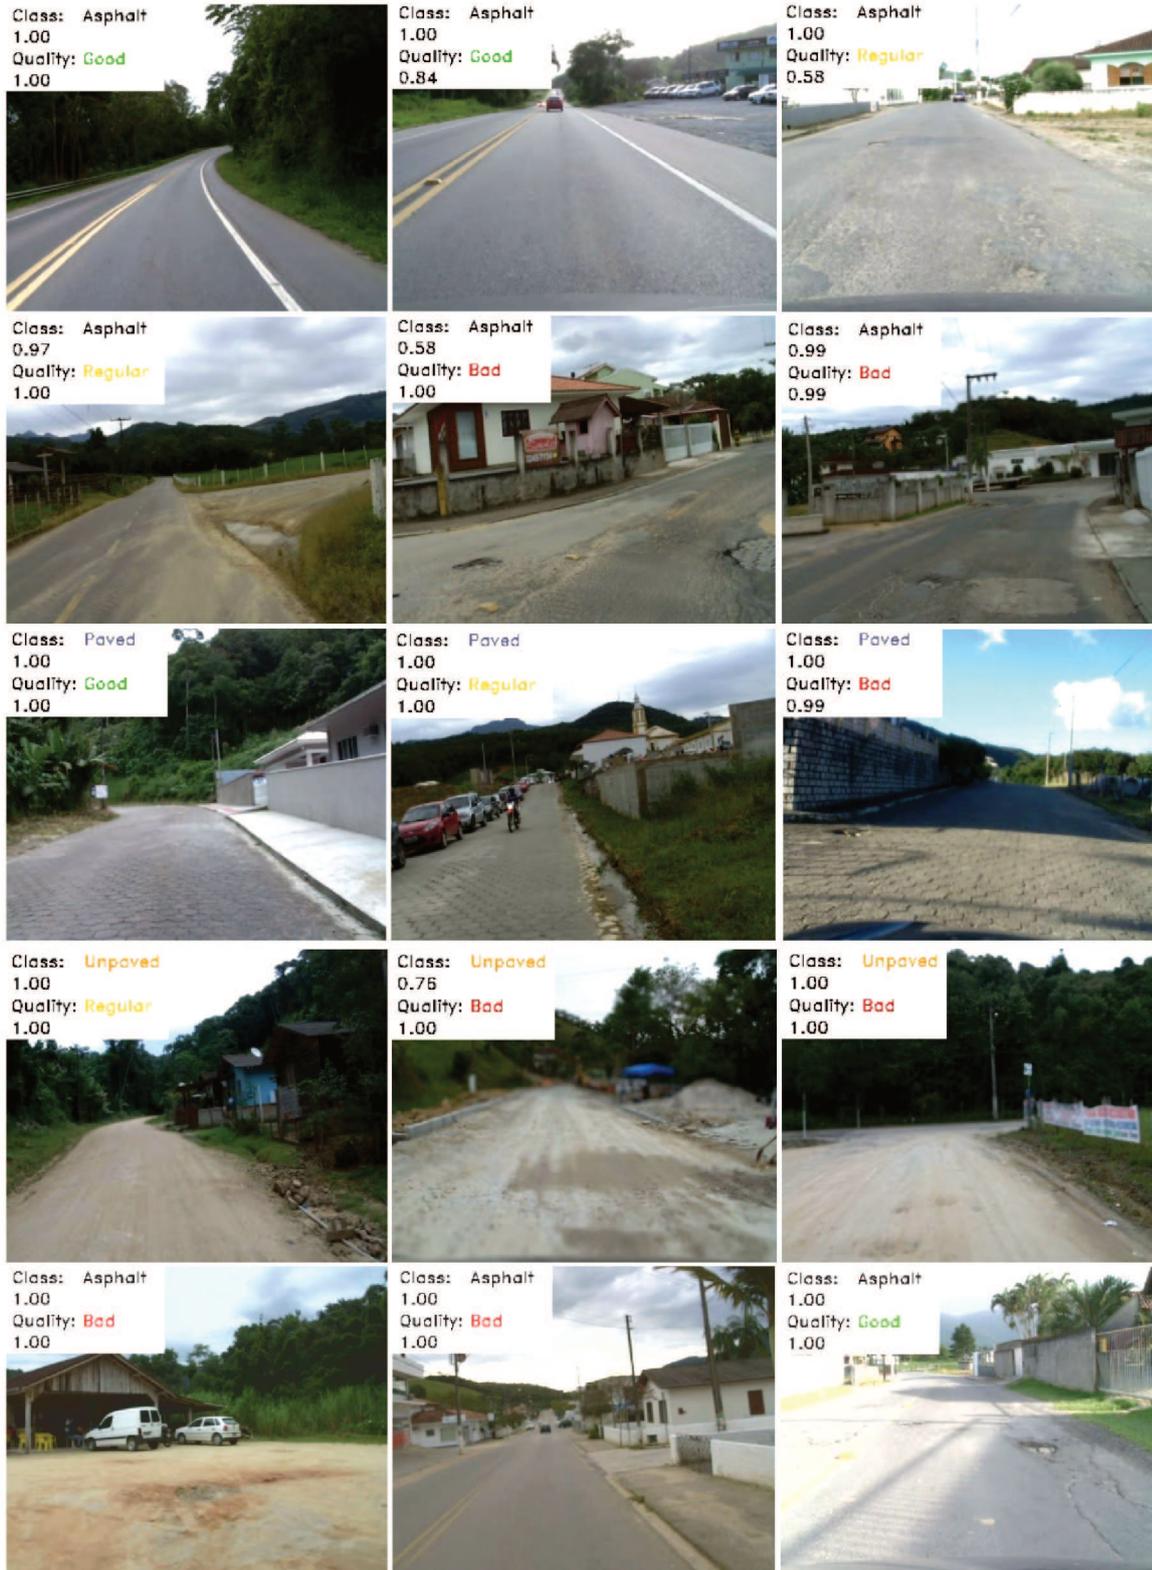
Fonte: Adaptado de (RATEKE; JUSTEN; WANGENHEIM, 2019).

Tabela 33 – Matriz de confusão da classificação de qualidade na CaRINA

	Asphalt(Good)	Asphalt(Regular)	Asphalt(Bad)	Paved(Good)	Paved(Regular)	Paved(Bad)	Unpaved(Regular)	Unpaved(Bad)
Asphalt(Good)	98.35%	0%	0.21%	1.44%	0%	0%	0%	0%
Asphalt(Regular)	0%	97.50%	0%	0%	2.50%	0%	0%	0%
Asphalt(Bad)	0%	5.88%	94.12%	0%	0%	0%	0%	0%
Paved(Good)	0%	0%	0%	90%	0%	10%	0%	0%
Paved(Regular)	-	-	-	-	-	-	-	-
Paved(Bad)	0%	0%	0%	100%	0%	0%	0%	0%
Unpaved(Regular)	-	-	-	-	-	-	-	-
Unpaved(Bad)	0%	0%	0%	0%	0%	0%	0%	100%

Fonte: Adaptado de (RATEKE; JUSTEN; WANGENHEIM, 2019).

Figura 32 – Resultados da classificação de qualidade na RTK



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Figura 33 – Resultados da classificação de qualidade na CaRINA



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

Figura 34 – Resultados da classificação de qualidade na KITTI



Fonte: (RATEKE; JUSTEN; WANGENHEIM, 2019).

6.3 RESULTADOS SEGMENTAÇÃO SEMÂNTICA DE SUPERFÍCIE DE ESTRADAS

Os experimentos para a segmentação semântica da superfície da estrada foram feitos em diferentes configurações, dessa forma possibilitando encontrar a melhor maneira de treinar o modelo ideal. Para cada modelo treinado foram utilizadas 25 épocas, ou seja em configurações onde foram treinados mais de um modelo, cada modelo dessa configuração passou por 25 épocas de treinamento. As configurações definidas foram:

- **r34-S**: com resnet34, com apenas um modelo sem pesos nas classes;
- **r34-SW**: com resnet34, com apenas um modelo, com pesos nas classes;
- **r34-I**: com resnet34, três modelos com aumento do tamanho das imagens em cada modelo e cada novo modelo utilizando o anterior como base, no primeiro modelo com tamanho das imagens divididas por 4, no segundo com divisão por 2 e no terceiro com o tamanho original, sem pesos nas classes;
- **r34-IW**: com resnet34, três modelos com aumento do tamanho das imagens em cada modelo e cada novo modelo utilizando o anterior como base, no primeiro modelo com tamanho das imagens divididas por 4, no segundo com divisão por 2 e no terceiro com o tamanho original, com pesos nas classes;
- **r34-DW**: com resnet34, com dois modelos, primeiro modelo sem pesos e o segundo modelo utilizando o primeiro como base e adicionando pesos;
- **r50-S**: com resnet50, com apenas um modelo sem pesos nas classes;
- **r50-SW**: com resnet50, com apenas um modelo, com pesos nas classes;
- **r50-I**: com resnet50, três modelos com aumento do tamanho das imagens em cada modelo e cada novo modelo utilizando o anterior como base, no primeiro modelo com tamanho das imagens divididas por 4, no segundo com divisão por 2 e no terceiro com o tamanho original, sem pesos nas classes;
- **r50-IW**: com resnet50, três modelos com aumento do tamanho das imagens em cada modelo e cada novo modelo utilizando o anterior como base, no primeiro modelo com tamanho das imagens divididas por 4, no segundo com divisão por 2 e no terceiro com o tamanho original, com pesos nas classes;
- **r50-DW**: com resnet50, com dois modelos, primeiro modelo sem pesos e o segundo modelo utilizando o primeiro como base e adicionando pesos.

A acurácia, tanto geral como de cada classe foi calculada levando em consideração a quantidade correta de *pixels* classificados sobre a quantidade total de *pixels*. Os valores de acurácia em cada configuração são apresentados na Tabela 34, onde é possível notar que as configuração onde os pesos não são aplicados apresentam os piores resultados para as classes menores. Com as configuração que utilizam pesos houve uma considerável melhora na acurácia das classes menores, ainda que com perda na acurácia das classes de tipos de superfície. Os resultados de acurácia mais equilibrados, considerando os valores para as classes menores e para as classes de tipo de superfície, foram obtidos pela configuração com 2 modelos treinados, sendo o primeiro sem pesos utilizado como base para o segundo com os pesos (**r34-DW** e **r50-DW**).

Tabela 34 – Resultados de acurácia em diferentes configurações

	Background	Asphalt	Paved	Unpaved	Markings	Speed-Bump	Cats-Eye	Storm-Drain	Patches	Water-Puddle	Pothole	Cracks	Acurácia Geral
r34-S	98,00%	93,00%	88,00%	74,00%	43,00%	0,00%	0,00%	0,00%	0,01%	0,00%	0,00%	0,07%	94,00%
r34-SW	88,00%	71,00%	76,00%	61,00%	71,00%	11,00%	94,00%	98,00%	69,00%	71,00%	66,00%	45,00%	89,00%
r34-I	98,00%	89,00%	86,00%	74,00%	50,00%	0,00%	0,00%	0,00%	11,00%	0,00%	0,00%	0,47%	95,00%
r34-IW	84,00%	57,00%	67,00%	62,00%	68,00%	75,00%	79,00%	95,00%	62,00%	60,00%	72,00%	38,00%	83,00%
r34-DW	92,00%	85,00%	87,00%	79,00%	73,00%	58,00%	86,00%	86,00%	78,00%	89,00%	66,00%	51,00%	92,00%
r50-S	97,00%	88,00%	73,00%	72,00%	19,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	87,00%
r50-SW	91,00%	78,00%	83,00%	70,00%	71,00%	58,00%	85,00%	95,00%	74,00%	95,00%	59,00%	45,00%	90,00%
r50-I	98,00%	94,00%	89,00%	76,00%	67,00%	14,00%	18,00%	20,00%	38,00%	5,03%	20,00%	13,00%	96,00%
r50-IW	87,00%	73,00%	72,00%	67,00%	79,00%	85,00%	82,00%	88,00%	70,00%	73,00%	69,00%	49,00%	87,00%
r50-DW	90,00%	80,00%	79,00%	76,00%	72,00%	93,00%	93,00%	94,00%	75,00%	97,00%	81,00%	48,00%	93,00%

Fonte: Desenvolvido pelo autor.

Então, com base nos valores obtidos pela Tabela 34, foi escolhido a configuração **r34-DW** para experimentos com mais épocas nos modelos treinados. Por ser com a ResNet34 exige menos da GPU e permite treinar com um *batch_size* maior, acelerando o experimento para uma quantidade maior de épocas. Nesse experimento, tanto o primeiro modelo sem os pesos como o segundo com os pesos tiveram 100 épocas. Os resultados obtidos são apresentados na Tabela 35.

Tabela 35 – Resultado de acurácia final com a configuração **r34-DW** durante 100 épocas

Classe	Acurácia
Background	97%
Asphalt	92%
Paved	94%
Unpaved	90%
Marking	93%
Speed-Bump	69%
Cats-Eye	94%
Storm-Drain	97%
Patches	97%
Water-Puddle	90%
Pothole	97%
Cracks	72%
Geral	97%

Fonte: Desenvolvido pelo autor.

Na Figura 35 é apresentado a matriz de confusão do experimento final, com a configuração **r34-DW** durante 100 épocas em cada modelo. A matriz de confusão ajuda a analisar onde ocorrem as principais falhas de cada classe. Por exemplo, a classe *Speed-Bump*, que foi a com menor valor de acurácia, apresentou falhas como sendo *Asphalt*, uma quantidade menor com *Cracks* e também *Marking*. A classe *Cracks*, a segunda com pior acurácia, teve falhas como sendo algumas das classes de tipos de superfície e também como *Patches*, *Storm-Drain* e *Pothole*.

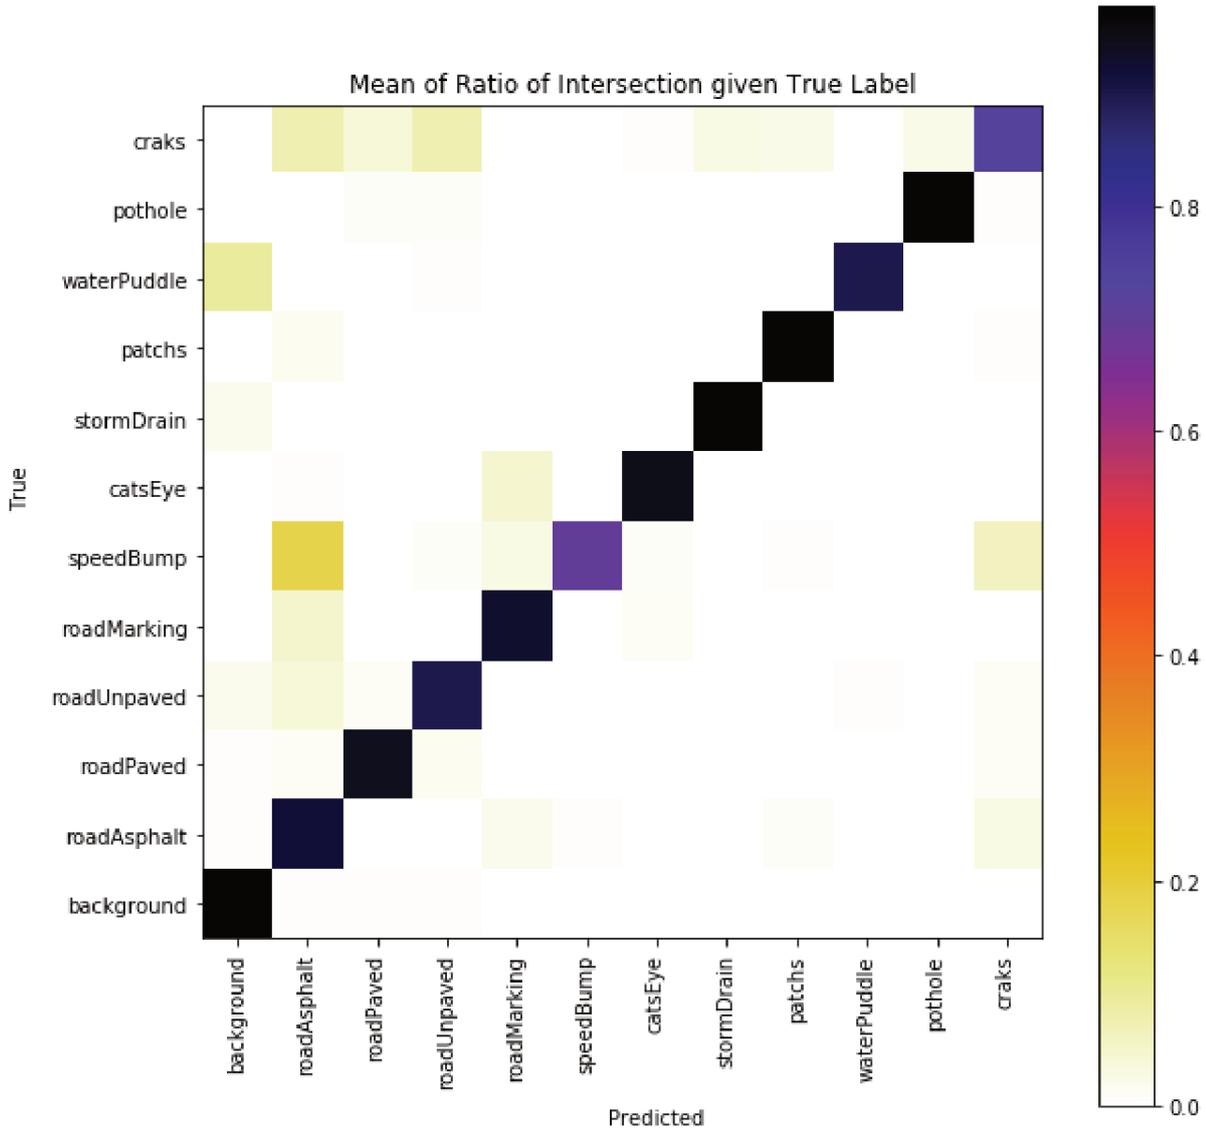
Foram selecionados alguns trabalhos para comparação com a segmentação semântica da superfície apresentada nesta tese. Trabalhos que representam um conjunto de características de resultados, foram selecionados os mais recentes em cada grupo. Destes, foram selecionados quatro trabalhos que fizeram a detecção de caminho adaptativa, ou seja, mesmo com a mudança no tipo de terreno, continuam detectando o caminho, lembrando que estes trabalhos não diferenciam os tipos de superfície. Outros dois que detectam diferentes tipos de caminho, mas não de forma adaptativa. Também foram selecionados dois trabalhos que realizaram a detecção de caminho em estradas sem pavimento, e outros cinco que fizeram a detecção em estradas de asfalto. Por fim, os trabalhos com foco nos danos da superfície, sendo dois de poças de água e cinco que apresentaram detecção de buracos. Essa comparação está apresentada na Tabela 36.

Tabela 36 – Comparativo de detecções da tese com outros trabalhos

Trabalhos	Detecções						
	Asfalto	Outros Pavimentos	Sem Pavimento	Adaptativo	Buracos	Poças de água	Outros Danos
(GUO; MITA; MCALLESTER, 2011)	Sim	Sim	Não	Sim	Não	Não	Não
(OSOSINSKI; LABROSSE, 2012)	Sim	Sim	Não	Sim	Não	Não	Não
(GUO; MITA; MCALLESTER, 2012)	Sim	Sim	Não	Sim	Não	Não	Não
(CRISTÓFORIS et al., 2016)	Sim	Sim	Não	Sim	Não	Não	Não
(VALENTE; STANCIULESCU, 2017)	Sim	Sim	Sim	Não	Não	Não	Não
(NGUYEN; PHUNG; BOUZERDOUM, 2017)	Sim	Sim	Sim	Não	Não	Não	Não
(NGUYEN; PHUNG; BOUZERDOUM, 2017)	Não	Não	Sim	Não	Não	Não	Não
(NGUYEN; PHUNG; BOUZERDOUM, 2017)	Não	Não	Sim	Não	Não	Não	Não
(GAO; WANG; YUAN, 2017)	Sim	Não	Não	Não	Não	Não	Não
(KIM; TAI; YOON, 2017)	Sim	Não	Não	Não	Não	Não	Não
(KIM; TAI; YOON, 2017)	Sim	Não	Não	Não	Não	Não	Não
(JIA; CHEN; ZHANG, 2017a)	Sim	Não	Não	Não	Não	Não	Não
(PAN; SI; OGAI, 2017)	Sim	Não	Não	Não	Não	Não	Não
(HAN et al., 2018)	Não	Não	Não	Não	Não	Sim	Não
(LI; NGUYEN; YOU, 2019)	Não	Não	Não	Não	Não	Sim	Não
(KOH et al., 2019)	Não	Não	Não	Não	Sim	Não	Não
(CHEN; YAO; GU, 2020)	Não	Não	Não	Não	Sim	Não	Não
(ANAND et al., 2018)	Não	Não	Não	Não	Sim	Não	Sim
(DHIMAN; KLETTE, 2019)	Não	Não	Não	Não	Sim	Não	Não
(MAEDA et al., 2018)	Não	Não	Não	Não	Sim	Não	Sim
Esta Tese	Sim	Sim	Sim	Sim	Sim	Sim	Sim

Fonte: Desenvolvido pelo autor.

Figura 35 – Matriz de confusão para r34-DW

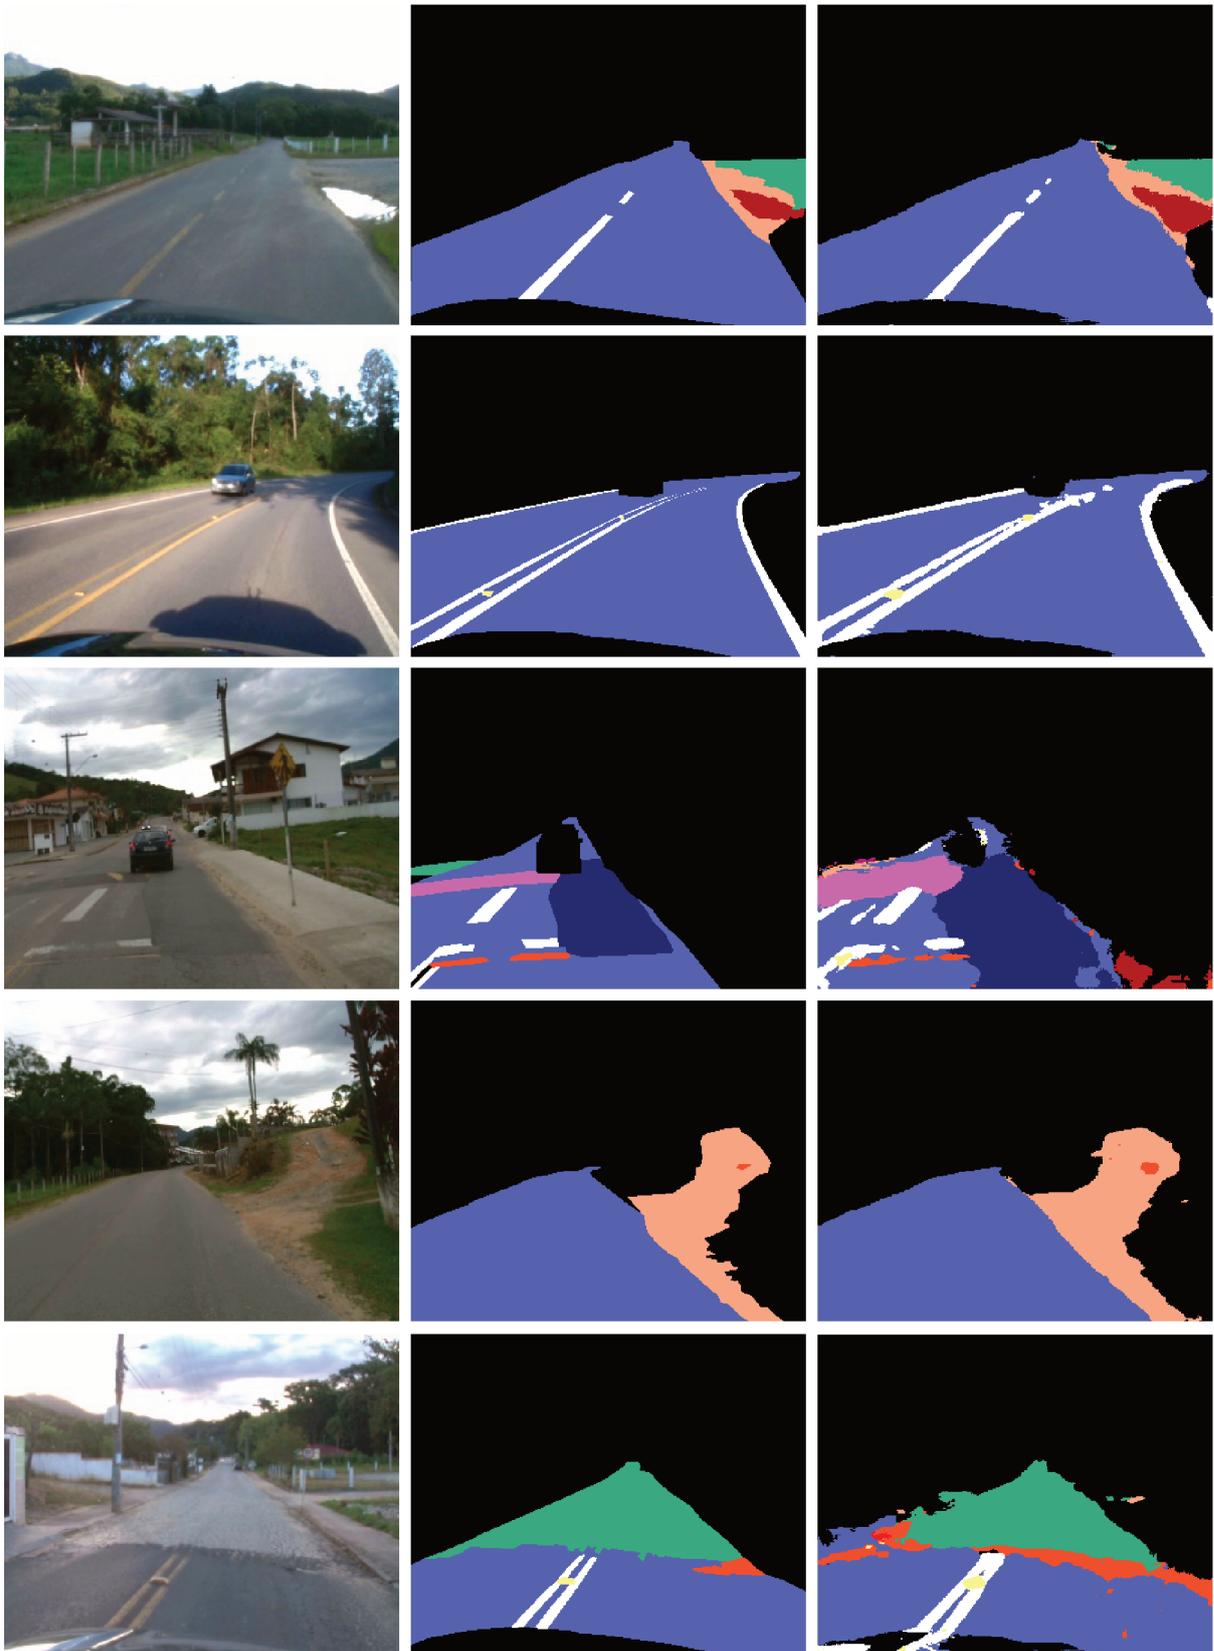


Fonte: Desenvolvido pelo autor.

Alguns resultados de predição são apresentados na Figura 36, Figura 37 e na Figura 38, onde na coluna da esquerda estão as imagens originais do conjunto de dados RTK, na coluna do meio estão as máscaras, o GT, e na coluna da direita estão os resultados obtidos. As imagens apresentadas nessas três figuras são do dataset de validação, ou seja, não foram utilizadas no treinamento dos modelos.

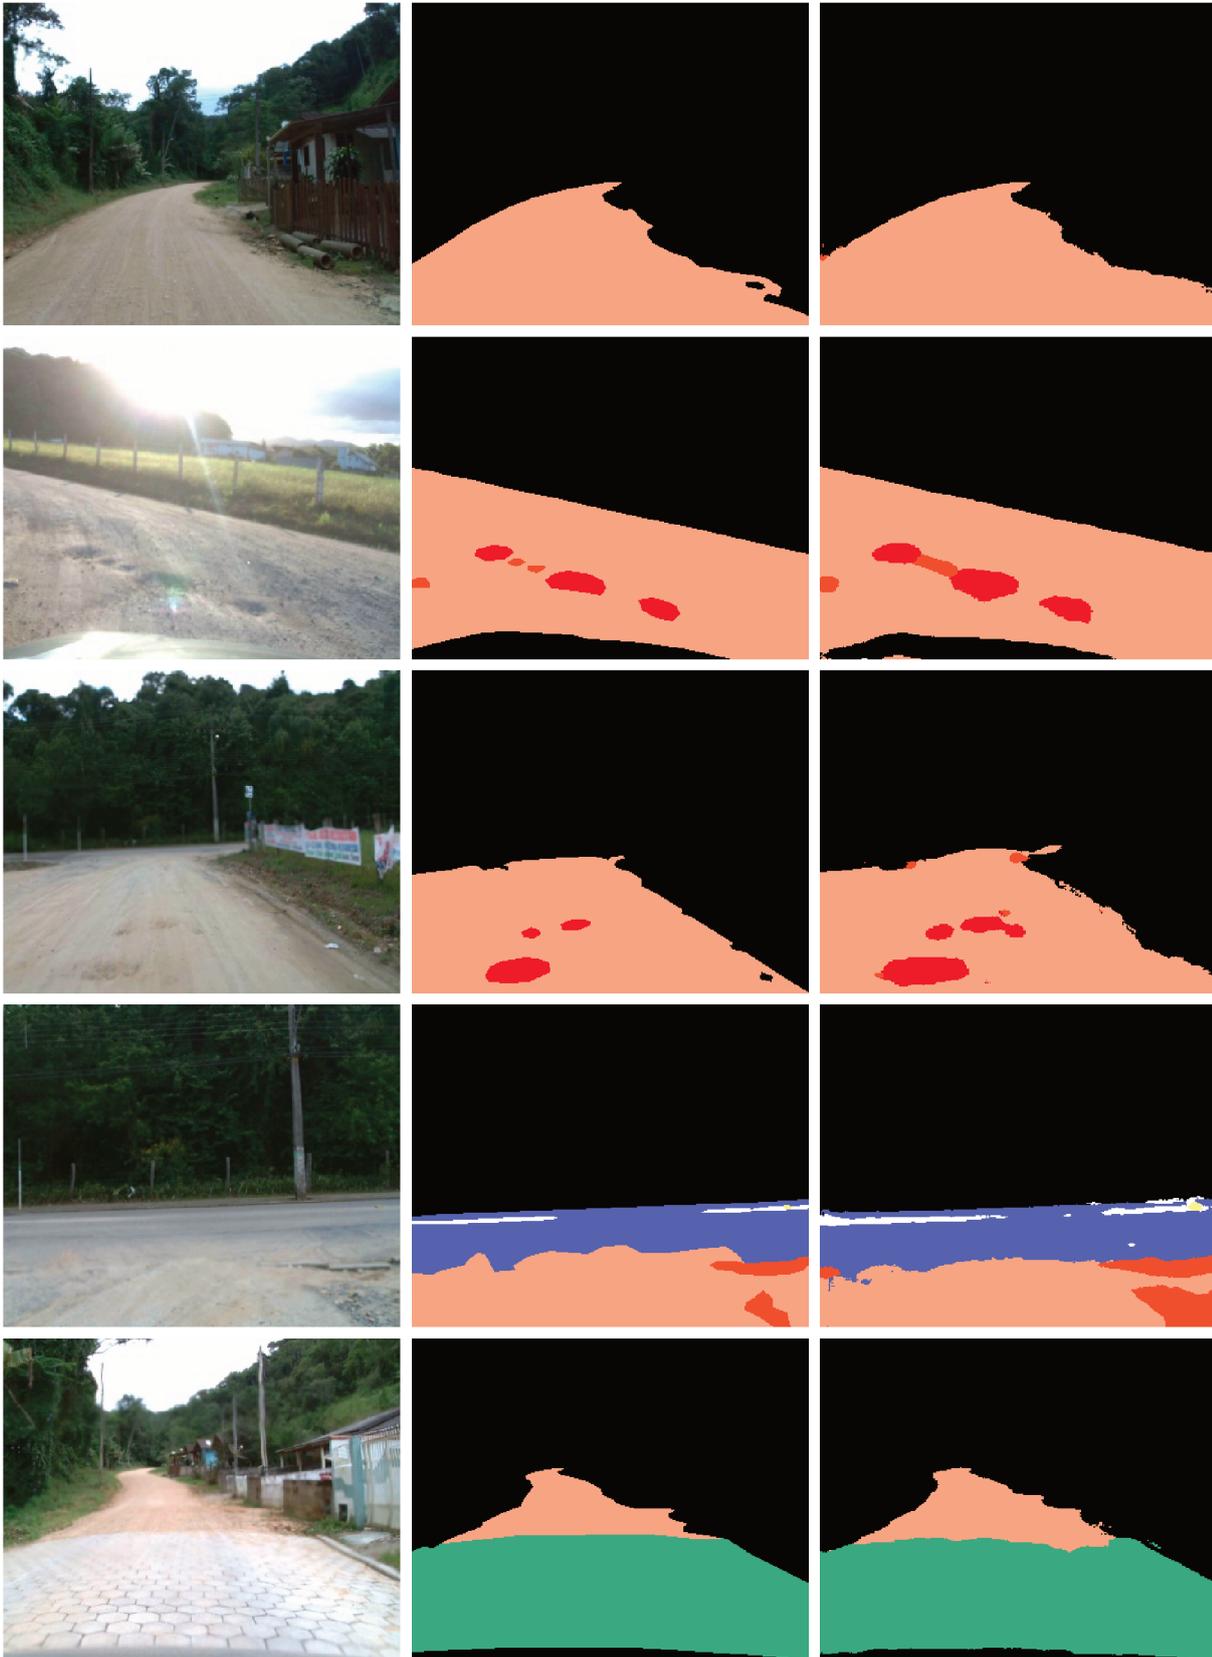
A grande maioria dos resultados mostram valores similares ao GT, com pequenas variações. A exceção está na última linha da Figura 38, onde os resultados apresentaram uma grande deformação comparado ao GT, ainda assim é possível extrair das informações que há uma lombada em frente além de variações na superfície da estrada.

Figura 36 – Resultados no dataset de validação. Estradas de asfalto com variações na superfície, e transições asfalto-terra e asfalto-lajota. Esquerda: original, centro: GT, direita: resultados



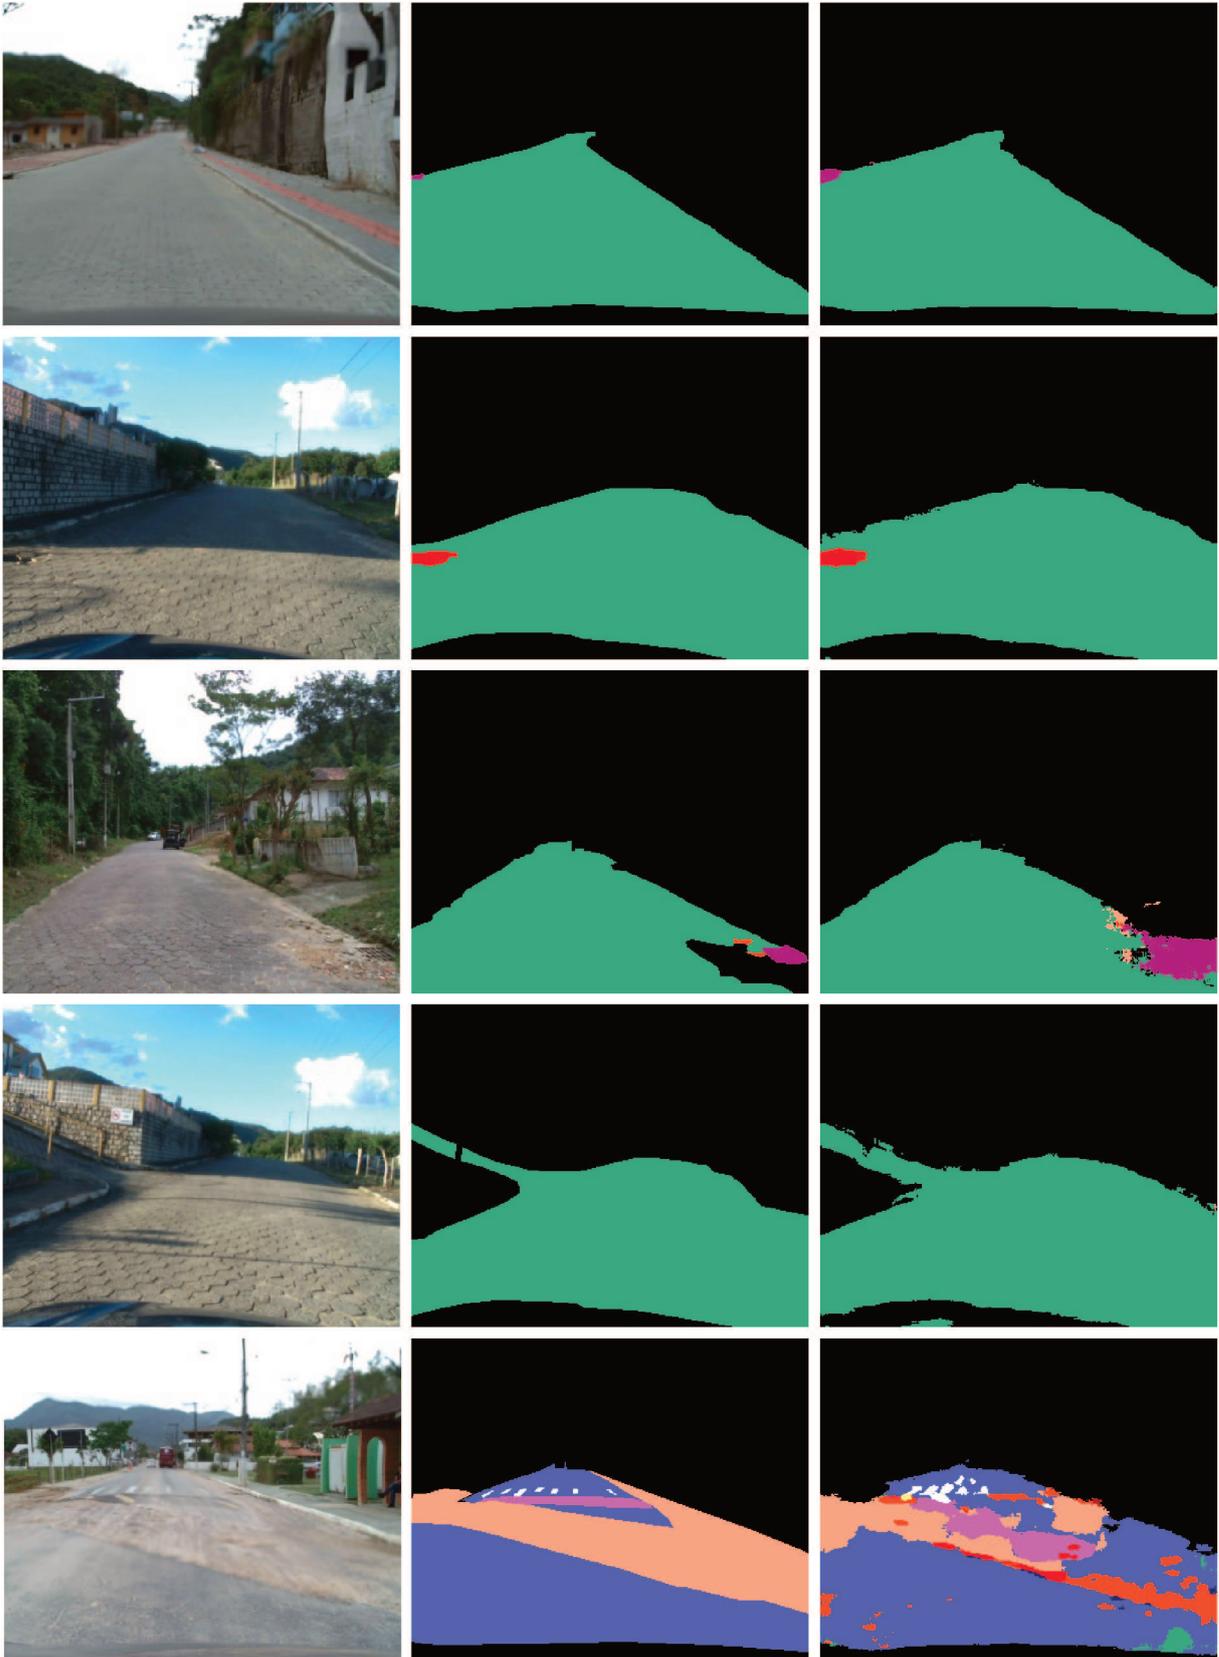
Fonte: Desenvolvido pelo autor.

Figura 37 – Resultados no dataset de validação. Estradas de terra com variações na superfície, e transições terra-asfalto e lajota-terra. Esquerda: original, centro: GT, direita: resultados



Fonte: Desenvolvido pelo autor.

Figura 38 – Resultados no dataset de validação. Estradas de lajota com variações na superfície, e exemplo em asfalto com falha na detecção de lombada. Esquerda: original, centro: GT, direita: resultados



Fonte: Desenvolvido pelo autor.

6.4 RESPOSTA A QUESTÃO DE PESQUISA

A questão de pesquisa abordada nesta tese é: “Como identificar um caminho navegável em estradas de baixa qualidade utilizando apenas visão passiva?”. Então, para responder a essa pergunta foi definido o objetivo geral de: “detectar um caminho navegável em estradas de baixa qualidade, utilizando para isso captura com base em VP e métodos de VC, PDI e DL”. O objetivo geral foi então dividido em seis objetivos específicos.

O primeiro objetivo específico, “Identificar o estado da arte em detecção de caminho” e o segundo objetivo específico, “Identificar o estado da arte em detecção de obstáculos” foram alcançados por RSL para cada um dos objetivos. Para o primeiro objetivo a RSL com foco em detecção de caminho, apresentado no capítulo 4, seção 4.1, onde nota-se que não há trabalhos com foco em estradas de baixa qualidade. A RSL com foco na detecção de obstáculos, apresentada no capítulo 4, seção 4.2 resultou em poucos trabalhos que lidam apenas com grandes buracos.

Para os objetivos específicos três e quatro: “Detectar o caminho independente de mudanças no terreno” e “Detectar obstáculos no caminho” foram desenvolvidas e experimentadas três abordagens utilizando VC e DL, apresentadas no capítulo 5, seção 5.1 com a utilização de técnicas de DL, VE e OF para detectar obstáculos, e checar distância e movimento desses obstáculos, na seção 5.3 com um classificador de tipos e qualidade de caminho é apresentado uma primeira forma de lidar diretamente com estradas de baixa qualidade, e por fim, na seção 5.4 a segmentação da estrada considerando diferentes características e variações na superfície da estrada.

Para o quinto objetivo específico, “Avaliar e validar em diferentes bases”, foram utilizadas bases conhecidas e documentadas como KITTI e CaRINA, além da criação de uma nova base, a RTK, que conseqüentemente responde ao objetivo específico número seis: “Criar uma nova base de casos com mais exemplos de transições de tipos de terrenos, buracos e poças de água”.

Deste modo, com base nos resultados alcançados para cada objetivo, é possível responder a questão de pesquisa com a utilização de técnicas de Aprendizado de Máquina, mais especificamente com Redes Neurais Convolucionais, com auxílio de técnicas de Visão Computacional e Processamento Digital de Imagens.

6.5 PUBLICAÇÕES

Durante o desenvolvimento desta tese dois relatórios técnicos foram gerados, além de dois trabalhos relacionados aos objetivos que foram publicados, um foi aceito desde que correções sejam feitas, o que está em andamento, e outros dois foram recentemente submetidos, a Tabela 37 lista os trabalhos, mostra qual o status e qualis, e ligação com os objetivos específicos (OE) de cada trabalho.

Tabela 37 – Lista dos trabalhos gerados, publicados, submetidos e em correção.

Autores	Título	Ano	Local	Relação	Qualis
Publicados					
Rateke, T.; Justen, K. A.; Chiarella, V. F.; Sobieranski, A. C.; Comunello, E.; von Wangenheim, A.	Passive Vision Region-Based Road Detection: A Literature Review	2019	ACM Computing Surveys	OE1	A1
Rateke, T.; Justen, K. A.; von Wangenheim, A.	Road Surface Classification with Images Captured From Low-cost Cameras – Road Traversing Knowledge (RTK) Dataset	2019	Revista de Informática Teórica e Aplicada (RITA)	OE3, OE5 e OE6	B3
Rateke, T.; von Wangenheim, A.	Passive Vision Road Obstacle Detection: A Literature Mapping	2020	International Journal of Computer and Applications	OE2	B2
Relatórios Técnicos					
Rateke, T.; Justen, K. A.; von Wangenheim, A.	Systematic Literature Review for Region-Based Road Detection	2018	INCoD	OE1	-
Rateke, T.; von Wangenheim, A.	Systematic Literature Review for Passive Vision Road Obstacle Detection	2018	INCoD	OE2	-
Submetidos - Em Revisão					
Rateke, T.; von Wangenheim, A.	Road obstacles positional and dynamic features extraction combining object detection, stereo disparity maps and optical flow data	-	Machine Vision and Applications	OE4 e OE5	B2
Rateke, T.; von Wangenheim, A.	Road surface detection and differentiation considering surface damages	-	Autonomous Robots	OE3 e OE4	A1

Fonte: Desenvolvido pelo autor.

7 CONCLUSÕES E DISCUSSÕES

Essa tese deu continuidade aos trabalhos desenvolvidos em (RATEKE, 2015; RATEKE et al., 2014; JUSTEN et al., 2016), no contexto do projeto de navegação veicular autônoma¹ do Laboratório de Processamento Digital de Imagens e Computação Gráfica (LAPiX)² associado ao Instituto Nacional para Convergência Digital (INCoD)³, que contam com outros trabalhos, complementares, no mesmo contexto.

O objetivo desta tese foi provar que é possível realizar a detecção de estradas de baixa qualidade somente com a utilização de Visão Passiva. Para isso foram realizadas duas revisões sistemáticas da literatura, uma sobre detecção de caminho e outra sobre detecção de obstáculos, visando encontrar trabalhos que lidam com os problemas na superfície da estrada, como buracos, poças de água ou outros danos. Em ambas as RSL percebeu-se a falta de trabalhos que lidam com cenários de estradas de baixa qualidade, apenas alguns poucos e com situações bem específicas, sendo dois trabalhos realizando a detecção de buracos grandes, um que detecta danos em asfalto e um trabalho que classifica danos em estradas de asfalto, e outros 8 trabalhos mais recentes que detectam buracos em estradas de asfalto apenas, ainda assim, sem lidar com os demais padrões da estrada. Relacionados a poças de água há ainda menos trabalhos, que também focam apenas nessa detecção em específico. Também não houve trabalhos que tratassem da variação na superfície da estrada, que é de extrema importância para o modo como um veículo deve ser controlado. Com as RSLs também é possível perceber o recente aumento na utilização de CNNs para a detecção de caminho e obstáculos.

Uma nova base de casos também foi criada como resultado desta tese, para possibilitar os experimentos em estradas com variações na superfície do caminho, como asfalto, terra e lajota, contando com diferentes transições, além de lombadas, buracos, e outros padrões comuns na superfície do caminho. Essa base foi criada com câmeras de baixo custo, com imagens de baixa resolução, e mesmo assim foi útil para os experimentos. Dois experimentos foram realizados com utilização dessa nova base. Está disponível publicamente na página do projeto⁴.

E por fim, três abordagens foram desenvolvidas, a primeira buscou garantir a detecção de obstáculos não relacionados a superfície da estrada, como pessoas e outros veículos, além de fazer uma análise de profundidade e de movimentação dos participantes da cena. Essa análise é importante tanto para gerar um alerta para um motorista humano como para o controle de um veículo autônomo, permitindo evitar colisões. Para isso foram combinados métodos de CNN para a detecção dos obstáculos, VE para análise da profundidade e OF para a análise do movimento.

As outras duas abordagens tiveram o foco na superfície do caminho, a primeira como uma classificação de tipos de superfície e qualidade, e a segunda como uma segmentação se-

¹ <http://www.lapix.ufsc.br/pesquisas/projeto-veiculo-autonomo/>

² <http://www.lapix.ufsc.br/>

³ <http://www.incod.ufsc.br/>

⁴ <http://www.lapix.ufsc.br/pesquisas/projeto-veiculo-autonomo/datasets/>

mântica de diferentes padrões da estrada. Na abordagem de classificação foi utilizado uma estrutura CNN simples com etapa de pré-processamento composta por corte de região de interesse, enviando para a rede apenas a região da imagem que contém a estrada. Também foi realizada como um fluxo onde primeiro tem-se a resposta do tipo de caminho e em seguida, com o modelo de qualidade específico de cada tipo de superfície, tem-se a classificação de qualidade da superfície. Essa abordagem foi realizada com a utilização de 2 bases de casos em adição a nova base de casos criada. Esse trabalho pode ser útil inclusive para departamentos de manutenção de rodovias, possibilitando automatizar parte do processo de análise das estradas.

Com a segmentação semântica é possível detectar de forma mais precisa as variações nos tipos de caminho, quando ocorrem as transições entre os pavimentos. E claro, outros padrões de extrema importância e que foram a grande questão desta tese, as estradas de baixa qualidade. Com a abordagem de segmentação, utilizando arquitetura CNN com ajuste de pesos para as classes nas imagens do dataset criado, foi possível detectar buracos, poças de água, lombadas, marcações na estrada, olhos de gato, bueiros, remendos e outros danos da estrada com um alto grau de acerto, respondendo, enfim, a questão de pesquisa desta tese.

7.1 TRABALHOS FUTUROS

A percepção visual para navegação veicular, quer seja como uma assistência ao motorista, como localização e mapeamento ou mesmo um veículo autônomo tem apresentado promissores resultados recentes, mas observa-se que ainda há desafios a serem trabalhados. Alguns destes, relacionados aos trabalhos feitos nesta tese, como por exemplo, dando continuidade a abordagem que combina CNN, VE e fluxo ótico, a possibilidade de tentar prever as ações dos demais participantes no cenário com base nos dados de tipos de objetos, movimento e distância.

Relacionado ao dataset criado, é interessante incluir novos desafios, como imagens noturnas, dias chuvosos ou em ambientes com neblina. Isso possibilitaria experimentos com uma classificação das condições climáticas com base em imagens, que também pode ser importante para a forma como conduzir um veículo. Ou caso a VP não se mostre capaz em condições mais extremas, que com base na classificação do clima, sejam acionados sensores auxiliares e talvez em caso de necessidade, sensores de visão ativa.

Além disso, o GT de classificação criado, pode ser modificado, com mais especificações, classificando diferentes tipos de asfalto (novo, antigo), classificando os diferentes tipos de pavimento (lajota, paralelepípedo) e inclusive variações nas estradas de terra (avermelhadas, amareladas). Talvez mais classes relacionadas a classificação de qualidade também, se possível com o auxílio de especialistas no assunto para a definição de cada classe.

Para o GT de segmentação, pode ser interessante dividir algumas classes em classes mais específicas, como por exemplo a classe *Cracks*, utilizada para diferentes danos independente do tipo de estrada. Dessa forma tendo variações da *Cracks* para cada tipo de terreno, pois os terrenos diferentes tem tipos de danos diferentes. Também dividir essa classe em diferentes danos, como: fissuras, “couro de jacaré”, etc.

REFERÊNCIAS

ABDI, L.; MEDDEB, A. Driver information system: a combination of augmented reality, deep learning and vehicular ad-hoc networks. **Multimedia Tools and Applications**, v. 77, n. 12, p. 14673–14703, Jun 2018. ISSN 1573-7721. Disponível em: <https://doi.org/10.1007/s11042-017-5054-6>.

AHMED, K. et al. Towards autonomous robot operation: Path map generation of an unknown area by a new trapezoidal approximation method using a self guided vehicle and shortest path calculation by a proposed srs algorithm. In: _____. **PRICAI 2008: Trends in Artificial Intelligence: 10th Pacific Rim International Conference on Artificial Intelligence, Hanoi, Vietnam, December 15-19, 2008. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 593–602. ISBN 978-3-540-89197-0. Disponível em: https://doi.org/10.1007/978-3-540-89197-0_54.

AKAGIC, A.; BUZA, E.; OMANOVIC, S. Pothole detection: An efficient vision based method using rgb color space image segmentation. In: **2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)**. [S.l.: s.n.], 2017. p. 1104–1109.

ALVAREZ, J. M. et al. Road scene segmentation from a single image. In: _____. **Computer Vision – ECCV 2012: 12th European Conference on Computer Vision, Florence, Italy, October 7-13, 2012, Proceedings, Part VII**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 376–389. ISBN 978-3-642-33786-4. Disponível em: https://doi.org/10.1007/978-3-642-33786-4_28.

ÁLVAREZ, J. M.; GEVERS, T.; LÓPEZ, A. M. Vision-based road detection using road models. In: **Proceedings of the 16th IEEE international conference on Image processing**. Piscataway, NJ, USA: IEEE Press, 2009. (ICIP'09), p. 2049–2052. ISBN 978-1-4244-5653-6. Disponível em: <http://dl.acm.org/citation.cfm?id=1819298.1819309>.

ALVAREZ, J. M. et al. Semantic road segmentation via multi-scale ensembles of learned features. In: _____. **Computer Vision – ECCV 2012. Workshops and Demonstrations: Florence, Italy, October 7-13, 2012, Proceedings, Part II**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 586–595. ISBN 978-3-642-33868-7. Disponível em: https://doi.org/10.1007/978-3-642-33868-7_58.

ALVAREZ, J. M.; LOPEZ, A.; BALDRICH, R. Illuminant-invariant model-based road segmentation. In: **2008 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2008. p. 1175–1180. ISSN 1931-0587.

ÁLVAREZ, J. M.; LÓPEZ, A. M. Road detection based on illuminant invariance. **Trans. Intell. Transport. Sys.**, IEEE Press, Piscataway, NJ, USA, v. 12, n. 1, p. 184–193, mar 2011. ISSN 1524-9050. Disponível em: <http://dx.doi.org/10.1109/TITS.2010.2076349>.

ÁLVAREZ, J. M.; LÓPEZ, A. M.; BALDRICH, R. Shadow resistant road segmentation from a mobile monocular system. In: _____. **Pattern Recognition and Image Analysis: Third Iberian Conference, IbPRIA 2007, Girona, Spain, June 6-8, 2007, Proceedings, Part II**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 9–16. ISBN 978-3-540-72849-8. Disponível em: https://doi.org/10.1007/978-3-540-72849-8_2.

ALVAREZ, J. M.; SALZMANN, M.; BARNES, N. Learning appearance models for road detection. In: **2013 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2013. p. 423–429. ISSN 1931-0587.

AMINI, H.; KARASFI, B. New approach to road detection in challenging outdoor environment for autonomous vehicle. In: **2016 Artificial Intelligence and Robotics (IRANOPEN)**. [S.l.: s.n.], 2016. p. 7–11.

AMIT, S. N. K. B.; AOKI, Y. High precision road segmentation for cover level of forward view estimation via stereo camera. In: **2015 10th Asian Control Conference (ASCC)**. [S.l.: s.n.], 2015. p. 1–6.

ANAND, S. et al. Crack-pot: Autonomous road crack and pothole detection. In: **2018 Digital Image Computing: Techniques and Applications (DICTA)**. [S.l.: s.n.], 2018. p. 1–6.

ARDIYANTO, I.; ADJI, T. B. Deep residual coalesced convolutional network for efficient semantic road segmentation. **IPSJ Transactions on Computer Vision and Applications**, v. 9, n. 1, p. 6, Mar 2017. ISSN 1882-6695. Disponível em: <https://doi.org/10.1186/s41074-017-0020-9>.

AYDIN, T.; AKGUL, Y. S. Stereo depth estimation using synchronous optimization with segment based regularization. **Pattern Recognition Letters**, v. 31, n. 15, p. 2389 – 2396, 2010. ISSN 0167-8655. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167865510002357>.

AZHAR, K. et al. Computer vision based detection and localization of potholes in asphalt pavement images. In: **2016 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)**. [S.l.: s.n.], 2016. p. 1–5. ISSN null.

BADRINARAYANAN, V.; BUDVYTIS, I.; CIPOLLA, R. Mixture of trees probabilistic graphical model for video segmentation. **International Journal of Computer Vision**, v. 110, n. 1, p. 14–29, Oct 2014. ISSN 1573-1405. Disponível em: <https://doi.org/10.1007/s11263-013-0673-5>.

BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 39, n. 12, p. 2481–2495, 2017.

BAIG, M. W. et al. New single camera vehicle detection based on gabor features for real time operation. In: LEE, G.; HOWARD, D.; ŚLeZAK, D. (Ed.). **Convergence and Hybrid Information Technology**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 567–574. ISBN 978-3-642-24082-9.

BANHARNSAKUN, A. Hybrid abc-ann for pavement surface distress detection and classification. **International Journal of Machine Learning and Cybernetics**, v. 8, n. 2, p. 699–710, Apr 2017. ISSN 1868-808X. Disponível em: <https://doi.org/10.1007/s13042-015-0471-1>.

BARROIS, B. et al. Resolving stereo matching errors due to repetitive structures using model information. **Pattern Recognition Letters**, v. 31, n. 12, p. 1683 – 1692, 2010. ISSN 0167-8655. Pattern Recognition of Non-Speech Audio. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167865510001698>.

BENACER, I.; HAMISSI, A.; KHOUAS, A. A novel stereovision algorithm for obstacles detection based on u-v-disparity approach. In: **2015 IEEE International Symposium on Circuits and Systems (ISCAS)**. [S.l.: s.n.], 2015. p. 369–372. ISSN 0271-4302.

BENENSON, R. et al. Fast stixel computation for fast pedestrian detection. In: FUSIELLO, A.; MURINO, V.; CUCCHIARA, R. (Ed.). **Computer Vision – ECCV 2012. Workshops and Demonstrations**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 11–20. ISBN 978-3-642-33885-4.

BERGER, K. et al. The area processing unit of caroline - finding the way through darpa's urban challenge. In: _____. **Robot Vision: Second International Workshop, RobVis 2008, Auckland, New Zealand, February 18-20, 2008. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 260–274. ISBN 978-3-540-78157-8. Disponível em: https://doi.org/10.1007/978-3-540-78157-8_20.

BERNINI, N. et al. Real-time obstacle detection using stereo vision for autonomous ground vehicles: A survey. In: **17th International IEEE Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2014. p. 873–878. ISSN 2153-0009.

BERNUY, F. et al. Adaptive and real-time unpaved road segmentation using color histograms and ransac. In: **2011 9th IEEE International Conference on Control and Automation (ICCA)**. [S.l.: s.n.], 2011. p. 136–141. ISSN 1948-3449.

BICHSEL, R.; BORGES, P. V. K. Discrete-continuous clustering for obstacle detection using stereo vision. In: **2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)**. [S.l.: s.n.], 2015. p. 538–545.

BLEYER, M. **VU Stereo Vision**. Karlsplatz, Vienna, Austria, 2013.

BOROUJENI, N. S.; ETEMAD, S. A.; WHITEHEAD, A. Fast obstacle detection using targeted optical flow. In: **2012 19th IEEE International Conference on Image Processing**. [S.l.: s.n.], 2012. p. 65–68. ISSN 1522-4880.

BOUCHAFA, S.; ZAVIDOVIQUE, B. Obstacle detection "for free"; in the c-velocity space. In: **2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2011. p. 308–313. ISSN 2153-0009.

BOYKOV, Y.; FUNKA-LEA, G. Graph cuts and efficient n-d image segmentation. **International Journal of Computer Vision**, v. 70, n. 2, p. 109–131, Nov 2006. ISSN 1573-1405. Disponível em: <https://doi.org/10.1007/s11263-006-7934-5>.

BROGGI, A.; BERTÈ, S. Vision-based road detection in automotive systems: A real-time expectation-driven approach. **Journal of Artificial Intelligence Research**, v. 3, 1995. Disponível em: <https://www.jair.org/index.php/jair/article/view/10148>.

BROGGI, A. et al. Stereo obstacle detection in challenging environments: The viac experience. In: **2011 IEEE/RSJ International Conference on Intelligent Robots and Systems**. [S.l.: s.n.], 2011. p. 1599–1604. ISSN 2153-0858.

BROGGI, A.; CATTANI, S. An agent based evolutionary approach to path detection for off-road vehicle guidance. **Pattern Recogn. Lett.**, Elsevier Science Inc., New York, NY, USA, v. 27, n. 11, p. 1164–1173, aug 2006. ISSN 0167-8655. Disponível em: <http://dx.doi.org/10.1016/j.patrec.2005.07.014>.

- BROSTOW, G. J.; FAUQUEUR, J.; CIPOLLA, R. Semantic object classes in video: A high-definition ground truth database. **Pattern Recognition Letters**, v. 30, n. 2, p. 88 – 97, 2009. ISSN 0167-8655. Video-based Object and Event Analysis. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167865508001220>.
- BUCHINGER, D.; SILVA, A. Anomalies detection in asphalt pavements: a morphological image processing approach. **Revista Brasileira de Computação Aplicada**, v. 6, n. 1, p. 121–129, abr. 2014. Disponível em: <http://seer.upf.br/index.php/rbca/article/view/3661>.
- BUI, T. H.; SAITOH, T.; NOBUYAMA, E. Road area detection based on texture orientations estimation and vanishing point detection. In: **The SICE Annual Conference 2013**. [S.l.: s.n.], 2013. p. 1138–1143.
- BURLACU, A. et al. Obstacle detection in stereo sequences using multiple representations of the disparity map. In: **2016 20th International Conference on System Theory, Control and Computing (ICSTCC)**. [S.l.: s.n.], 2016. p. 854–859.
- BUZA, E. et al. Unsupervised method for detection of high severity distresses on asphalt pavements. In: **2017 IEEE 14th International Scientific Conference on Informatics**. [S.l.: s.n.], 2017. p. 45–50.
- CABANI, I.; TOULMINET, G.; BENSRAHAI, A. Contrast-invariant obstacle detection system using color stereo vision. In: **2008 11th International IEEE Conference on Intelligent Transportation Systems**. [S.l.: s.n.], 2008. p. 1032–1037. ISSN 2153-0009.
- CABRAL, F. S. et al. An automatic survey system for paved and unpaved road classification and road anomaly detection using smartphone sensor. In: **2018 IEEE International Conference on Service Operations and Logistics, and Informatics (SOLI)**. [S.l.: s.n.], 2018. p. 65–70. ISBN 978-1-5386-4522-2. Doi: <https://doi.org/10.1109/SOLI.2018.8476788>.
- CAMPOS, Y.; SOSSA, H.; PAJARES, G. Spatio-temporal analysis for obstacle detection in agricultural videos. **Applied Soft Computing**, v. 45, p. 86 – 97, 2016. ISSN 1568-4946. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1568494616301259>.
- CAO, T.; XIANG, Z. Y.; LIU, J. L. Perception in disparity: An efficient navigation framework for autonomous vehicles with stereo cameras. **IEEE Transactions on Intelligent Transportation Systems**, v. 16, n. 5, p. 2935–2948, Oct 2015. ISSN 1524-9050.
- CARAFFI, C.; CATTANI, S.; GRISLERI, P. Off-road path and obstacle detection using decision networks and stereo vision. **Trans. Intell. Transport. Sys.**, IEEE Press, Piscataway, NJ, USA, v. 8, n. 4, p. 607–618, dec 2007. ISSN 1524-9050. Disponível em: <http://dx.doi.org/10.1109/TITS.2007.908583>.
- CARRILLO, D. A. P.; SUTHERLAND, A. Fast obstacle detection using sparse edge-based disparity maps. In: **2016 Fourth International Conference on 3D Vision (3DV)**. [S.l.: s.n.], 2016. p. 66–72.
- CHACRA, D. A.; ZELEK, J. Road segmentation in street view images using texture information. In: **2016 13th Conference on Computer and Robot Vision (CRV)**. [S.l.: s.n.], 2016. p. 424–431.
- CHANAWANGSA, P.; CHEN, C. W. A novel video analysis approach for overtaking vehicle detection. In: **2013 International Conference on Connected Vehicles and Expo (ICCVE)**. [S.l.: s.n.], 2013. p. 802–807. ISSN 2378-1289.

- CHANDRAN, P. et al. Road tracking using particle filters for advanced driver assistance systems. In: **17th International IEEE Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2014. p. 1408–1414. ISSN 2153-0009.
- CHEN, C.; LIU, J. A reinforced road detection method in complicated environment. In: **2010 Second WRI Global Congress on Intelligent Systems**. [S.l.: s.n.], 2010. v. 1, p. 65–69. ISSN 2155-6083.
- CHEN, C.-L.; TAI, C.-L. Adaptive fuzzy color segmentation with neural network for road detections. **Eng. Appl. Artif. Intell.**, Pergamon Press, Inc., Tarrytown, NY, USA, v. 23, n. 3, p. 400–410, apr 2010. ISSN 0952-1976. Disponível em: <http://dx.doi.org/10.1016/j.engappai.2009.12.004>.
- CHEN, H.; YAO, M.; GU, Q. Pothole detection using location-aware convolutional neural networks. **International Journal of Machine Learning and Cybernetics**, p. 899–911, 2020.
- CHEN, X.; QIAO, Y. Road segmentation via iterative deep analysis. In: **2015 IEEE International Conference on Robotics and Biomimetics (ROBIO)**. [S.l.: s.n.], 2015. p. 2640–2645.
- CHEN, Y.-S.; TSAI, A.-C.; LIN, T.-T. Road environment recognition method in complex traffic situations based on stereo vision. In: **2012 12th International Conference on ITS Telecommunications**. [S.l.: s.n.], 2012. p. 180–184.
- CHIU, C.-C. et al. Asynchronous stereo vision system for front-vehicle detection. In: **2009 IEEE International Conference on Acoustics, Speech and Signal Processing**. [S.l.: s.n.], 2009. p. 965–968. ISSN 1520-6149.
- CHONG, Y. et al. Integrated real-time vision-based preceding vehicle detection in urban roads. In: HUANG, D.-S. et al. (Ed.). **Advanced Intelligent Computing**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 270–275. ISBN 978-3-642-24728-6.
- CHUNG, T. D.; KHAN, M. K. A. A. Watershed-based real-time image processing for multi-potholes detection on asphalt road. In: **2019 IEEE 9th International Conference on System Engineering and Technology (ICSET)**. [S.l.: s.n.], 2019. p. 268–272.
- CNT. **Pesquisa CNT de Rodovias 2018. Relatório Gerencial**. [S.l.], 2018. v. 20. Url: <https://pesquisarodovias.cnt.org.br/Home>.
- COMMISSION, I. E. **SAFETY OF LASER PRODUCTS. Part 1: Equipment classification, requirements and user's guide**. [S.l.], 2001.
- CORDTS, M. et al. The cityscapes dataset for semantic urban scene understanding. In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2016. p. 3213–3223. ISSN 1063-6919. Doi: <https://doi.org/10.1109/CVPR.2016.350>.
- CORDTS, M. et al. **The Cityscapes Dataset**. 2015.
- COSTA, P. et al. Obstacle detection using stereo imaging to assist the navigation of visually impaired people. **Procedia Computer Science**, v. 14, n. Supplement C, p. 83 – 93, 2012. ISSN 1877-0509. Proceedings of the 4th International Conference on Software Development for Enhancing Accessibility and Fighting Info-exclusion (DSAI 2012). Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877050912007727>.

CRISTÓFORIS, P. D. et al. Real-time monocular image-based path detection. **Journal of Real-Time Image Processing**, v. 11, n. 2, p. 335–348, 2016. ISSN 1861-8219. Disponível em: <http://dx.doi.org/10.1007/s11554-013-0356-z>.

DAIRI, A. et al. Unsupervised obstacle detection in driving environments using deep-learning-based stereovision. **Robotics and Autonomous Systems**, v. 100, p. 287 – 301, 2018. ISSN 0921-8890. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0921889017304736>.

DAIRI, A. et al. Obstacle detection for intelligent transportation systems using deep stacked autoencoder and k -nearest neighbor scheme. **IEEE Sensors Journal**, v. 18, n. 12, p. 5122–5132, June 2018. ISSN 2379-9153.

DAMIAN, C. et al. Using mono and stereo camera system for static and moving objects detection. In: **2019 International Conference on Electromechanical and Energy Systems (SIELMEN)**. [S.l.: s.n.], 2019. p. 1–5. ISSN null.

DANESCU, R. et al. Particle grid tracking system stereovision based obstacle perception in driving environments. **Intelligent Transportation Systems Magazine, IEEE**, v. 4, n. 1, p. 6–20, Spring 2012. ISSN 1939-1390.

DANESCU, R. G. Obstacle detection using dynamic particle-based occupancy grids. In: **2011 International Conference on Digital Image Computing: Techniques and Applications**. [S.l.: s.n.], 2011. p. 585–590.

DEGHACHE, H. E.; BOUCHAFA, S. Driving space detection by combining v -disparity and c -velocity. In: **2015 IEEE International Conference on Vehicular Electronics and Safety (ICVES)**. [S.l.: s.n.], 2015. p. 219–224.

DHIMAN, A.; KLETTE, R. Pothole detection using computer vision and learning. **IEEE Transactions on Intelligent Transportation Systems**, p. 1–15, 2019.

DING, H. et al. Stereovision based generic obstacle detection and motion estimation using v -stxial algorithm. In: **2018 IEEE 4th Information Technology and Mechatronics Engineering Conference (ITOEC)**. [S.l.: s.n.], 2018. p. 903–908. ISSN null.

DORNAIKA, F. et al. A new framework for stereo sensor pose through road segmentation and registration. **Intelligent Transportation Systems, IEEE Transactions on**, v. 12, n. 4, p. 954–966, 2011. ISSN 1524-9050.

DUMORTIER, Y.; HERLIN, I.; DUCROT, A. 4-d tensor voting motion segmentation for obstacle detection in autonomous guided vehicle. In: **2008 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2008. p. 379–384. ISSN 1931-0587.

ERIKSSON, J. et al. The pothole patrol: Using a mobile sensor network for road surface monitoring. In: **Proceedings of the 6th International Conference on Mobile Systems, Applications, and Services**. New York, NY, USA: ACM, 2008. (MobiSys '08), p. 29–39. ISBN 978-1-60558-139-2. Disponível em: 10.1145/1378600.1378605.

ESS, A. et al. Moving obstacle detection in highly dynamic scenes. In: **2009 IEEE International Conference on Robotics and Automation**. [S.l.: s.n.], 2009. p. 56–63. ISSN 1050-4729.

- FAKHFAKH, N. et al. Background subtraction and 3d localization of moving and stationary obstacles at level crossings. In: **2010 2nd International Conference on Image Processing Theory, Tools and Applications**. [S.l.: s.n.], 2010. p. 72–78. ISSN 2154-5111.
- FAN, R. et al. Pothole detection based on disparity transformation and road surface modeling. **IEEE Transactions on Image Processing**, v. 29, p. 897–908, 2020.
- FAN, Y. et al. Multiple obstacle detection for assistance driver system using deep neural networks. In: SUN, X.; PAN, Z.; BERTINO, E. (Ed.). **Artificial Intelligence and Security**. Cham: Springer International Publishing, 2019. p. 501–513. ISBN 978-3-030-24271-8.
- FARNEBÄCK, G. Two-frame motion estimation based on polynomial expansion. In: _____. **Image Analysis: 13th Scandinavian Conference, SCIA 2003 Halmstad, Sweden, June 29 – July 2, 2003 Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003. p. 363–370. ISBN 978-3-540-45103-7. Disponível em: https://doi.org/10.1007/3-540-45103-X_50.
- FERNANDES, L. C. et al. Carina intelligent robotic car: Architectural design and applications. **Journal of Systems Architecture**, v. 60, n. 4, p. 372 – 392, 2014. ISSN 1383-7621. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1383762113002841>.
- FLEET, D. J.; WEISS, Y. **Optical Flow Estimation**. 2005.
- FORTUN, D.; BOUTHEMY, P.; KERVRANN, C. Optical flow modeling and computation: A survey. **Computer Vision and Image Understanding**, v. 134, n. Supplement C, p. 1 – 21, 2015. ISSN 1077-3142. Image Understanding for Real-world Distributed Video Networks. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1077314215000429>.
- FRANKE, U. et al. Towards optimal stereo analysis of image sequences. In: _____. **Robot Vision: Second International Workshop, RobVis 2008, Auckland, New Zealand, February 18-20, 2008. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p. 43–58. ISBN 978-3-540-78157-8. Disponível em: https://doi.org/10.1007/978-3-540-78157-8_4.
- FRISONI, R. et al. **EU Road Surfaces: Economic and Safety Impact of the Lack of Regular Road Maintenance**. [S.l.], 2014. Disponível em: [http://www.europarl.europa.eu/thinktank/en/document.html?reference=IPOL_STU\(2014\)529059](http://www.europarl.europa.eu/thinktank/en/document.html?reference=IPOL_STU(2014)529059).
- FRITSCH, J.; KÜHNEL, T.; GEIGER, A. A new performance measure and evaluation benchmark for road detection algorithms. In: **16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)**. [S.l.: s.n.], 2013. p. 1693–1700. ISSN 2153-0009.
- FRITSCH, J.; KÜHNEL, T.; KUMMERT, F. Monocular road terrain detection by combining visual and spatial information. **IEEE Transactions on Intelligent Transportation Systems**, v. 15, n. 4, p. 1586–1596, Aug 2014. ISSN 1524-9050.
- FUKUKAWA, T. et al. Road detection method corresponded to multi road types with flood fill and vehicle control. In: **2013 Second International Conference on Robot, Vision and Signal Processing**. [S.l.: s.n.], 2013. p. 274–277. ISSN 2376-9793.
- GAO, J.; WANG, Q.; YUAN, Y. Embedding structured contour and location prior in siamesed fully convolutional networks for road detection. In: **2017 IEEE International Conference on Robotics and Automation (ICRA)**. [S.l.: s.n.], 2017. p. 219–224.

GAO, Q.; LUO, Q.; MOLI, S. Rough set based unstructured road detection through feature learning. In: **2007 IEEE International Conference on Automation and Logistics**. [S.l.: s.n.], 2007. p. 101–106. ISSN 2161-8151.

GAO, Y. et al. U-v-disparity based obstacle detection with 3d camera and steerable filter. In: **2011 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2011. p. 957–962. ISSN 1931-0587.

GAO, Y.; SONG, Y.; YANG, Z. A real-time drivable road detection algorithm in urban traffic environment. In: _____. **Computer Vision and Graphics: International Conference, ICCVG 2012, Warsaw, Poland, September 24-26, 2012. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 387–396. ISBN 978-3-642-33564-8. Disponível em: https://doi.org/10.1007/978-3-642-33564-8_47.

GAVRILA, D. M.; MUNDER, S. Multi-cue pedestrian detection and tracking from a moving vehicle. **International Journal of Computer Vision**, v. 73, n. 1, p. 41–59, Jun 2007. ISSN 1573-1405. Disponível em: <https://doi.org/10.1007/s11263-006-9038-7>.

GE, Q.; LOBATON, E. Obstacle detection in outdoor scenes based on multi-valued stereo disparity maps. In: **2017 IEEE Symposium Series on Computational Intelligence (SSCI)**. [S.l.: s.n.], 2017. p. 1–8.

GEIGER, A. et al. Vision meets robotics: The kitti dataset. **Int. J. Rob. Res.**, Sage Publications, Inc., Thousand Oaks, CA, USA, v. 32, n. 11, p. 1231–1237, sep 2013. ISSN 0278-3649. Disponível em: <http://dx.doi.org/10.1177/0278364913491297>.

GEIGER, A.; LENZ, P.; URTASUN, R. Are we ready for autonomous driving? the kitti vision benchmark suite. In: **Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on**. [S.l.: s.n.], 2012. p. 3354–3361. ISSN 1063-6919.

GIOSAN, I.; NEDEVSKI, S. Superpixel-based obstacle segmentation from dense stereo urban traffic scenarios using intensity, depth and optical flow information. In: **17th International IEEE Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2014. p. 1662–1668. ISSN 2153-0009.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 2nd. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 2001. ISBN 0201180758.

GU, Z. et al. Local stereo matching with adaptive support-weight, rank transform and disparity calibration. **Pattern Recognition Letters**, v. 29, n. 9, p. 1230 – 1235, 2008. ISSN 0167-8655. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167865508000366>.

GUO, C. et al. A multimodal adas system for unmarked urban scenarios based on road context understanding. **IEEE Transactions on Intelligent Transportation Systems**, v. 16, n. 4, p. 1690–1704, Aug 2015. ISSN 1524-9050.

GUO, C.; MITA, S. Drivable road region detection based on homography estimation with road appearance and driving state models. In: **Autonomous Robots and Agents, 2009. ICARA 2009. 4th International Conference on**. [S.l.: s.n.], 2009. p. 204–209.

GUO, C.; MITA, S. Stereovision-based road boundary detection for intelligent vehicles in challenging scenarios. In: **Proceedings of the 2009 IEEE/RSJ international conference on Intelligent robots and systems**. Piscataway, NJ, USA: IEEE

Press, 2009. (IROS'09), p. 1723–1728. ISBN 978-1-4244-3803-7. Disponível em: <http://dl.acm.org/citation.cfm?id=1733023.1733028>.

GUO, C.; MITA, S.; MCALLESTER, D. Drivable road region detection using homography estimation and efficient belief propagation with coordinate descent optimization. In: **2009 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2009. p. 317–323. ISSN 1931-0587.

GUO, C.; MITA, S.; MCALLESTER, D. Mrf-based road detection with unsupervised learning for autonomous driving in changing environments. In: **2010 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2010. p. 361–368. ISSN 1931-0587.

GUO, C.; MITA, S.; MCALLESTER, D. Adaptive non-planar road detection and tracking in challenging environments using segmentation-based markov random field. In: **2011 IEEE International Conference on Robotics and Automation**. [S.l.: s.n.], 2011. p. 1172–1179. ISSN 1050-4729.

GUO, C.; MITA, S.; MCALLESTER, D. Robust road detection and tracking in challenging scenarios based on markov random fields with unsupervised learning. **Intelligent Transportation Systems, IEEE Transactions on**, v. 13, n. 3, p. 1338–1354, 2012. ISSN 1524-9050.

GUO, C.-Z.; YAMABE, T.; MITA, S. Drivable road boundary detection for intelligent vehicles based on stereovision with plane-induced homography. **Acta Automatica Sinica**, v. 39, n. 4, p. 371 – 380, 2013. ISSN 1874-1029. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1874102913600361>.

GUO, Y.; GERASIMOV, V.; POULTON, G. Vision-based drivable surface detection in autonomous ground vehicles. In: **2006 IEEE/RSJ International Conference on Intelligent Robots and Systems**. [S.l.: s.n.], 2006. p. 3273–3278. ISSN 2153-0858.

GUPTA, K. et al. Small obstacle detection using stereo vision for autonomous ground vehicle. In: **Proceedings of the Advances in Robotics**. New York, NY, USA: ACM, 2017. (AIR '17), p. 25:1–25:6. ISBN 978-1-4503-5294-9. Disponível em: <http://doi.acm.org/10.1145/3132446.3134889>.

HAN, X. et al. Single image water hazard detection using fcn with reflection attention units. In: FERRARI, V. et al. (Ed.). **Computer Vision – ECCV 2018**. Cham: Springer International Publishing, 2018. p. 105–121. ISBN 978-3-030-01231-1.

HAUTIÈRE, N. et al. Enhanced fog detection and free-space segmentation for car navigation. **Machine Vision and Applications**, v. 25, n. 3, p. 667–679, 2014. ISSN 1432-1769. Disponível em: <http://dx.doi.org/10.1007/s00138-011-0383-3>.

HAYKIN, S. S. **Neural networks and learning machines**. Third. Upper Saddle River, NJ: Pearson Education, 2009.

HE, K. et al. Deep residual learning for image recognition. In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2016. p. 770–778.

HE, W. et al. Feature++: Cross dimension feature fusion for road detection. In: **2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. [S.l.: s.n.], 2017. p. 1662–1666.

HERGHELEGIU, P.; BURLACU, A.; CARAIMAN, S. Negative obstacle detection for wearable assistive devices for visually impaired. In: **2017 21st International Conference on System Theory, Control and Computing (ICSTCC)**. [S.l.: s.n.], 2017. p. 564–570.

HERMANN, S.; BÖRNER, A.; KLETTE, R. Mid-level segmentation and segment tracking for long-range stereo analysis. In: _____. **Advances in Image and Video Technology: 5th Pacific Rim Symposium, PSIVT 2011, Gwangju, South Korea, November 20-23, 2011, Proceedings, Part I**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 224–235. ISBN 978-3-642-25367-6. Disponível em: https://doi.org/10.1007/978-3-642-25367-6_20.

HEYVAERT, M.; VEELAERT, P. Fast planarity estimation and region growing on gpu. In: _____. **Applications of Discrete Geometry and Mathematical Morphology: First International Workshop, WADGMM 2010, Istanbul, Turkey, August 22, 2010, Revised Selected Papers**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 125–139. ISBN 978-3-642-32313-3. Disponível em: https://doi.org/10.1007/978-3-642-32313-3_9.

HILLEL, A. B. et al. Recent progress in road and lane detection: a survey. **Machine Vision and Applications**, v. 25, n. 3, p. 727–745, 2014. ISSN 1432-1769. Disponível em: <http://dx.doi.org/10.1007/s00138-011-0404-2>.

HOTA, R. N.; JONNA, K.; KRISHNA, P. R. On-road vehicle detection by cascaded classifiers. In: **Proceedings of the Third Annual ACM Bangalore Conference**. New York, NY, USA: ACM, 2010. (COMPUTE '10), p. 27:1–27:5. ISBN 978-1-4503-0001-8. Disponível em: <http://doi.acm.org/10.1145/1754288.1754315>.

HOWARD, J. et al. **fastai**. [S.l.]: GitHub, 2018. <https://github.com/fastai/fastai>.

HSIEH, Y. et al. Deep learning-based obstacle detection and depth estimation. In: **2019 IEEE International Conference on Image Processing (ICIP)**. [S.l.: s.n.], 2019. p. 1635–1639. ISSN 1522-4880.

HSU, C. M. et al. Road detection based on region similarity analysis. In: **International Conference on Automatic Control and Artificial Intelligence (ACAI 2012)**. [S.l.: s.n.], 2012. p. 1775–1778.

HSU, C. M. et al. Road detection based on bread-first search in urban traffic scenes. In: **2011 8th Asian Control Conference (ASCC)**. [S.l.: s.n.], 2011. p. 1393–1397.

HSU, Y. et al. Developing an on-road obstacle detection system using monovision. In: **2018 International Conference on Image and Vision Computing New Zealand (IVCNZ)**. [S.l.: s.n.], 2018. p. 1–9. ISSN 2151-2191.

HU, F. et al. A combined clustering and image mapping based point cloud segmentation for 3d object detection. In: **2018 Chinese Control And Decision Conference (CCDC)**. [S.l.: s.n.], 2018. p. 1664–1669. ISSN 1948-9447.

HUANG, J. et al. A new method of unstructured road detection based on hsv color space and road features. In: **2007 International Conference on Information Acquisition**. [S.l.: s.n.], 2007. p. 596–601.

HUANG, P.; LIN, H. Rear obstacle warning for reverse driving using stereo vision techniques. In: **2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)**. [S.l.: s.n.], 2019. p. 921–926. ISSN 1062-922X.

HUANG, Y.; LIU, S. Multi-class obstacle detection and classification using stereovision and improved active contour models. **IET Intelligent Transport Systems**, v. 10, n. 3, p. 197–205, 2016. ISSN 1751-956X.

HUIDROM, L.; DAS, L. K.; SUD, S. Method for automated assessment of potholes, cracks and patches from road surface video clips. **Procedia - Social and Behavioral Sciences**, v. 104, p. 312 – 321, 2013. ISSN 1877-0428. 2nd Conference of Transportation Research Group of India (2nd CTRG). Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877042813045151>.

HUNG, C. W. et al. Road area detection based on image segmentation and contour feature. In: **2013 International Conference on System Science and Engineering (ICSSE)**. [S.l.: s.n.], 2013. p. 147–151. ISSN 2325-0909.

HUSSAIN, S. et al. Driving space detection for structured outdoor environment using monocular vision. In: **2014 International Conference on Robotics and Emerging Allied Technologies in Engineering (iCREATE)**. [S.l.: s.n.], 2014. p. 64–67.

HWANG, J.; JI, Y.; KIM, E. Y. Monocular vision-based collision avoidance system. In: **Proceedings of the 14th International Conference on Human-computer Interaction with Mobile Devices and Services Companion**. New York, NY, USA: ACM, 2012. (MobileHCI '12), p. 125–130. ISBN 978-1-4503-1443-5. Disponível em: <http://doi.acm.org/10.1145/2371664.2371688>.

HÄNE, C. et al. 3d visual perception for self-driving cars using a multi-camera system: Calibration, mapping, localization, and obstacle detection. **Image and Vision Computing**, v. 68, p. 14 – 27, 2017. ISSN 0262-8856. Automotive Vision: Challenges, Trends, Technologies and Systems for Vision-Based Intelligent Vehicles. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0262885617301117>.

ILOIE, A.; GIOSAN, I.; NEDEVSCHI, S. Uv disparity based obstacle detection and pedestrian classification in urban traffic scenarios. In: **2014 IEEE 10th International Conference on Intelligent Computer Communication and Processing (ICCP)**. [S.l.: s.n.], 2014. p. 119–125.

ISMAIL, L. et al. Monocular vision-based collision avoidance system using shadow detection. In: **2013 7th IEEE GCC Conference and Exhibition (GCC)**. [S.l.: s.n.], 2013. p. 589–594.

IWATA, H.; SANEYOSHI, K. Forward obstacle detection system by stereo vision. In: **2012 IEEE International Conference on Robotics and Biomimetics (ROBIO)**. [S.l.: s.n.], 2012. p. 1842–1847.

IWATA, H.; SANEYOSHI, K. Forward obstacle detection in a lane by stereo vision. In: **IECON 2013 - 39th Annual Conference of the IEEE Industrial Electronics Society**. [S.l.: s.n.], 2013. p. 2420–2425. ISSN 1553-572X.

JANG, D.; PARK, R. Pothole detection using spatio-temporal saliency. **IET Intelligent Transport Systems**, v. 10, n. 9, p. 605–612, 2016.

JIA, B.; CHEN, J.; ZHANG, K. Drivable road reconstruction for intelligent vehicles based on two-view geometry. **IEEE Transactions on Industrial Electronics**, v. 64, n. 5, p. 3696–3706, May 2017. ISSN 0278-0046.

JIA, B.; CHEN, J.; ZHANG, K. Recursive drivable road detection with shadows based on two-camera systems. **Machine Vision and Applications**, v. 28, n. 5, p. 509–523, Aug 2017. ISSN 1432-1769. Disponível em: <https://doi.org/10.1007/s00138-017-0858-y>.

JIA, B.; LIU, R.; ZHU, M. Real-time obstacle detection with motion features using monocular vision. **The Visual Computer**, v. 31, n. 3, p. 281–293, Mar 2015. ISSN 1432-2315. Disponível em: <https://doi.org/10.1007/s00371-014-0918-5>.

JIANG, Z.; WANG, Q.; YUAN, Y. Adaptive road detection towards multiscale-multilevel probabilistic analysis. In: **2014 IEEE China Summit International Conference on Signal and Information Processing (ChinaSIP)**. [S.l.: s.n.], 2014. p. 698–702.

JING, P.; ZHENG, W.; XU, Q. Vision-based mobile robot's environment outdoor perception. In: **Proceedings of the 3rd International Conference on Computer Science and Application Engineering**. New York, NY, USA: ACM, 2019. (CSAE 2019), p. 120:1–120:5. ISBN 978-1-4503-6294-8. Disponível em: <http://doi.acm.org/10.1145/3331453.3361655>.

JOCHEM, T.; POMERLEAU, D.; THORPE, C. Vision-based neural network road and intersection detection and traversal. In: **Intelligent Robots and Systems 95. 'Human Robot Interaction and Cooperative Robots', Proceedings. 1995 IEEE/RSJ International Conference on**. [S.l.: s.n.], 1995. v. 3, p. 344–349 vol.3.

JOHN, N.; ANUSHA, B.; KUTTY, K. A reliable method for detecting road regions from a single image based on color distribution and vanishing point location. **Procedia Computer Science**, v. 58, p. 2 – 9, 2015. ISSN 1877-0509. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877050915021134>.

JUSTEN, K. A. et al. Controle de veículo a partir da visão computacional. In: **Computer on the Beach 2016**. Florianópolis, Santa Catarina, Brasil: Universidade do Vale do Itajaí, 2016. p. 222–231. ISSN 2358-0852. Disponível em: <https://siaiap32.univali.br/seer/index.php/acotb/article/view/10732/6061>.

KANG, J.; CHUNG, M. J. Stereo-vision based free space and obstacle detection with structural and traversability analysis using probabilistic volume polar grid map. In: **2011 IEEE 5th International Conference on Robotics, Automation and Mechatronics (RAM)**. [S.l.: s.n.], 2011. p. 245–251. ISSN 2158-2181.

KANG, M.-S.; LIM, Y.-C. Fast stereo-based pedestrian detection using hypotheses. In: **Proceedings of the 2015 Conference on Research in Adaptive and Convergent Systems**. New York, NY, USA: ACM, 2015. (RACS), p. 131–135. ISBN 978-1-4503-3738-0. Disponível em: <http://doi.acm.org/10.1145/2811411.2811486>.

KANG, Y. et al. Road image segmentation and recognition using hierarchical bag-of-textons method. In: _____. **Advances in Image and Video Technology: 5th Pacific Rim Symposium, PSIVT 2011, Gwangju, South Korea, November 20-23, 2011, Proceedings, Part I**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 248–256. ISBN 978-3-642-25367-6. Disponível em: https://doi.org/10.1007/978-3-642-25367-6_22.

KARUNASEKERA, H. et al. Stereo vision based negative obstacle detection. In: **2017 13th IEEE International Conference on Control Automation (ICCA)**. [S.l.: s.n.], 2017. p. 834–838.

- KELLER, C. G.; LLORCA, D. F.; GAVRILA, D. M. Dense stereo-based roi generation for pedestrian detection. In: DENZLER, J.; NOTNI, G.; SÜSSE, H. (Ed.). **Pattern Recognition**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009. p. 81–90. ISBN 978-3-642-03798-6.
- KHALID, Z.; MOHAMED, E. A.; ABDENBI, M. Stereo vision-based road obstacles detection. In: **2013 8th International Conference on Intelligent Systems: Theories and Applications (SITA)**. [S.l.: s.n.], 2013. p. 1–6.
- KIM, B.; SON, J.; SOHN, K. Illumination invariant road detection based on learning method. In: **Intelligent Transportation Systems (ITSC), 2011 14th International IEEE Conference on**. [S.l.: s.n.], 2011. p. 1009–1014. ISSN 2153-0009.
- KIM, D. et al. Rear obstacle detection system with fisheye stereo camera using hct. **Expert Systems with Applications**, v. 42, n. 17, p. 6295 – 6305, 2015. ISSN 0957-4174. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0957417415002717>.
- KIM, T.; TAI, Y. W.; YOON, S. E. Pca based computation of illumination-invariant space for road detection. In: **2017 IEEE Winter Conference on Applications of Computer Vision (WACV)**. [S.l.: s.n.], 2017. p. 632–640.
- KITCHENHAM, B. **Procedures for Performing Systematic Reviews**. [S.l.], 2004.
- KLAPPSTEIN, J. et al. Moving object segmentation using optical flow and depth information. In: _____. **Advances in Image and Video Technology: Third Pacific Rim Symposium, PSIVT 2009, Tokyo, Japan, January 13-16, 2009. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009. p. 611–623. ISBN 978-3-540-92957-4. Disponível em: https://doi.org/10.1007/978-3-540-92957-4_53.
- KOCH, C.; BRILAKIS, I. Pothole detection in asphalt pavement images. **Advanced Engineering Informatics**, v. 25, n. 3, p. 507 – 515, 2011. ISSN 1474-0346. Special Section: Engineering informatics in port operations and logistics. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1474034611000036>.
- KOH, J. J. et al. Autonomous road potholes detection on video. In: ALFRED, R. et al. (Ed.). **Computational Science and Technology**. Singapore: Springer Singapore, 2019. p. 137–143. ISBN 978-981-13-2622-6.
- KOHARA, K.; SUGANUMA, N. Obstacle detection based on occupancy grid maps from virtual disparity image. In: **2009 ICCAS-SICE**. [S.l.: s.n.], 2009. p. 4617–4622.
- KONG, H.; AUDIBERT, J. Y.; PONCE, J. Vanishing point detection for road detection. In: **2009 IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2009. p. 96–103. ISSN 1063-6919.
- KONG, H.; AUDIBERT, J.-Y.; PONCE, J. General road detection from a single image. **Trans. Img. Proc.**, IEEE Press, Piscataway, NJ, USA, v. 19, n. 8, p. 2211–2220, aug 2010. ISSN 1057-7149. Disponível em: <http://dx.doi.org/10.1109/TIP.2010.2045715>.
- KONG, H.; SARMA, S. E.; TANG, F. Generalizing laplacian of gaussian filters for vanishing-point detection. **IEEE Transactions on Intelligent Transportation Systems**, v. 14, n. 1, p. 408–418, March 2013. ISSN 1524-9050.

- KRAMM, S.; BENSRAHAI, A. Obstacle detection using sparse stereovision and clustering techniques. In: **2012 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2012. p. 760–765. ISSN 1931-0587.
- KUBOTA, S.; NAKANO, T.; OKAMOTO, Y. A global optimization algorithm for real-time on-board stereo obstacle detection systems. In: **2007 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2007. p. 7–12. ISSN 1931-0587.
- KULATHUNGA, G.; BUYVAL, A.; KLIMCHIK, A. Multi-camera fusion in apollo software distribution. **IFAC-PapersOnLine**, v. 52, n. 8, p. 49 – 54, 2019. ISSN 2405-8963. 10th IFAC Symposium on Intelligent Autonomous Vehicles IAV 2019. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2405896319303672>.
- KYUTOKU, H. et al. Subtraction-based forward obstacle detection using illumination insensitive feature for driving-support. In: FUSIELLO, A.; MURINO, V.; CUCCHIARA, R. (Ed.). **Computer Vision – ECCV 2012. Workshops and Demonstrations**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 515–525. ISBN 978-3-642-33868-7.
- KÜHNEL, T.; KUMMERT, F.; FRITSCH, J. Monocular road segmentation using slow feature analysis. In: **2011 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2011. p. 800–806. ISSN 1931-0587.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, November 1998.
- LEE, C. H.; KIM, D. Dense disparity map-based pedestrian detection for intelligent vehicle. In: **2016 IEEE International Conference on Intelligent Transportation Engineering (ICITE)**. [S.l.: s.n.], 2016. p. 108–111.
- LEFEBVRE, S.; AMBELLOUIS, S. Vehicle detection and tracking using mean shift segmentation on semi-dense disparity maps. In: **2012 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2012. p. 855–860. ISSN 1931-0587.
- LEZAMA, J.; RANDALL, G.; GIOI, R. Grompone von. Vanishing Point Detection in Urban Scenes Using Point Alignments. **Image Processing On Line**, v. 7, p. 131–164, 2017.
- LI, J. et al. Robust urban road image segmentation. In: **Proceeding of the 11th World Congress on Intelligent Control and Automation**. [S.l.: s.n.], 2014. p. 2923–2928.
- LI, J.; NGUYEN, C.; YOU, S. Temporal 3d fully connected network for water-hazard detection. In: **2019 Digital Image Computing: Techniques and Applications (DICTA)**. [S.l.: s.n.], 2019. p. 1–5.
- LI, P. et al. Detection and discrimination of obstacles to vehicle environment under convolutional neural networks. In: **2018 Chinese Control And Decision Conference (CCDC)**. [S.l.: s.n.], 2018. p. 337–341. ISSN 1948-9447.
- LI, Q. et al. Intersection detection and recognition for autonomous urban driving using a virtual cylindrical scanner. **IET Intelligent Transport Systems**, v. 8, n. 3, p. 244–254, May 2014. ISSN 1751-956X.
- LI, Y. et al. Road detection algorithm for autonomous navigation systems based on dark channel prior and vanishing point in complex road scenes. **Robotics and Autonomous Systems**, v. 85, p. 1 – 11, 2016. ISSN 0921-8890. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0921889015301925>.

- LIAN, J. et al. Study on obstacle detection and recognition method based on stereo vision and convolutional neural network. In: **2019 Chinese Control Conference (CCC)**. [S.l.: s.n.], 2019. p. 8766–8771. ISSN 1934-1768.
- LIANG, H.; MORIE, T. A motion detection model inspired by hippocampal function and its applications to obstacle detection. **Neurocomputing**, v. 129, p. 59 – 66, 2014. ISSN 0925-2312. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0925231213009818>.
- LIDAR. **LIDAR**. UK, 2015. Disponível em: <http://www.lidar-uk.com/>. Acesso em: 18 fev. 2015.
- LIM, Y. C. et al. Event-driven track management method for robust multi-vehicle tracking. In: **2011 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2011. p. 189–194. ISSN 1931-0587.
- LIMA, D. A. de; VICTORINO, A. C.; NETO, A. de M. A 2d/3d environment perception approach applied to sensor-based navigation of automated driving systems. In: **2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)**. [S.l.: s.n.], 2017. p. 1–6.
- LIN, J. et al. Learning based semantic segmentation for robot navigation in outdoor environment. In: **2017 Joint 17th World Congress of International Fuzzy Systems Association and 9th International Conference on Soft Computing and Intelligent Systems (IFSA-SCIS)**. [S.l.: s.n.], 2017. p. 1–5.
- LIN, T. et al. Feature pyramid networks for object detection. In: **2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2017. p. 936–944.
- LIN, T. et al. Focal loss for dense object detection. In: **2017 IEEE International Conference on Computer Vision (ICCV)**. [S.l.: s.n.], 2017. p. 2999–3007. ISSN 2380-7504.
- LIN, T.-Y. et al. Microsoft coco: Common objects in context. In: FLEET, D. et al. (Ed.). **Computer Vision – ECCV 2014**. Cham: Springer International Publishing, 2014. p. 740–755. ISBN 978-3-319-10602-1.
- LIN, Y. et al. Multi-scale ill-structured road detection. In: **2014 International Conference on Computational Intelligence and Communication Networks**. [S.l.: s.n.], 2014. p. 1153–1157.
- LIU, L.; CUI, J.; LI, J. Obstacle detection and classification in dynamical background. **AASRI Procedia**, v. 1, n. Supplement C, p. 435 – 440, 2012. ISSN 2212-6716. AASRI Conference on Computational Intelligence and Bioinformatics. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2212671612000698>.
- LIU, W. et al. Ssd: Single shot multibox detector. In: LEIBE, B. et al. (Ed.). **Computer Vision – ECCV 2016"**. Cham: Springer International Publishing, 2016. p. 21–37. ISBN 978-3-319-46448-0.
- LIU, X.; CHENG, Z. M.; YI, F. Y. A road detection technology based on reverse perspective transformation. In: **2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)**. [S.l.: s.n.], 2016. v. 01, p. 126–129.

LIU, X. et al. Unstructured road detection based on fuzzy clustering arithmetic. In: **2014 11th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)**. [S.l.: s.n.], 2014. p. 114–118.

LIU, Z.; YU, C.; ZHENG, B. Any type of obstacle detection in complex environments based on monocular vision. In: **Proceedings of the 32nd Chinese Control Conference**. [S.l.: s.n.], 2013. p. 7692–7697.

LOOKINGBILL, A. et al. Reverse optical flow for self-supervised adaptive autonomous robot navigation. **International Journal of Computer Vision**, v. 74, n. 3, p. 287–302, 2007. ISSN 1573-1405. Disponível em: <http://dx.doi.org/10.1007/s11263-006-0024-x>.

LU, H.; JIANG, L.; ZELL, A. Long range traversable region detection based on superpixels clustering for mobile robots. In: **2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)**. [S.l.: s.n.], 2015. p. 546–552.

LU, K. et al. A hierarchical approach for road detection. In: **2014 IEEE International Conference on Robotics and Automation (ICRA)**. [S.l.: s.n.], 2014. p. 517–522. ISSN 1050-4729.

LU, K. et al. Unstructured road detection from a single image. In: **2015 10th Asian Control Conference (ASCC)**. [S.l.: s.n.], 2015. p. 1–6.

LU, K.; XIA, S.; XIA, C. Clustering based road detection method. In: **2015 34th Chinese Control Conference (CCC)**. [S.l.: s.n.], 2015. p. 3874–3879.

LU, X. Self-supervised road detection from a single image. In: **2015 IEEE International Conference on Image Processing (ICIP)**. [S.l.: s.n.], 2015. p. 2989–2993.

LUCAS, B. D.; KANADE, T. An iterative image registration technique with an application to stereo vision. In: **Proceedings of the 7th International Joint Conference on Artificial Intelligence - Volume 2**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1981. (IJCAI'81), p. 674–679. Disponível em: <http://dl.acm.org/citation.cfm?id=1623264.1623280>.

MA, G. et al. A real-time rear view camera based obstacle detection. In: **2009 12th International IEEE Conference on Intelligent Transportation Systems**. [S.l.: s.n.], 2009. p. 1–6. ISSN 2153-0009.

MA, G. et al. Pedestrian detection using a single monochrome camera. **IET Intelligent Transport Systems**, v. 3, n. 1, p. 42–56, March 2009. ISSN 1751-956X.

MA, G. et al. Vision-based pedestrian detection -reliable pedestrian candidate detection by combining ipm and a 1d profile. In: **2007 IEEE Intelligent Transportation Systems Conference**. [S.l.: s.n.], 2007. p. 137–142. ISSN 2153-0009.

MA, X. et al. Single-binocular vision conversion strategy for obstacle detection at non-signalized intersections. In: ESPOSITO, C.; HONG, J.; CHOO, K.-K. R. (Ed.). **Pervasive Systems, Algorithms and Networks**. Cham: Springer International Publishing, 2019. p. 371–380. ISBN 978-3-030-30143-9.

MAEDA, H. et al. Road damage detection and classification using deep neural networks with smartphone images. **Computer-Aided Civil and Infrastructure Engineering**, v. 33, n. 12, p. 1127–1141, 2018. Doi: <https://doi.org/10.1111/mice.12387>.

- MALIK, U. A.; AHMED, S. U.; KUNWAR, F. A self-organizing neural scheme for road detection in varied environments. In: **The 2011 International Joint Conference on Neural Networks**. [S.l.: s.n.], 2011. p. 3049–3054. ISSN 2161-4393.
- MCCALL, J. C.; TRIVEDI, M. M. Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation. **IEEE Transactions on Intelligent Transportation Systems**, v. 7, n. 1, p. 20–37, March 2006. ISSN 1524-9050.
- MENZE, M.; GEIGER, A. Object scene flow for autonomous vehicles. In: **Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2015.
- MHIRI, R. et al. Obstacle detection using unsynchronized multi-camera network. In: **2015 12th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)**. [S.l.: s.n.], 2015. p. 7–12.
- MICHALKE, T. et al. A generic temporal integration approach for enhancing feature-based road-detection systems. In: **2008 11th International IEEE Conference on Intelligent Transportation Systems**. [S.l.: s.n.], 2008. p. 657–663. ISSN 2153-0009.
- MIKHAILIUK, A.; DAHNOUN, N. Real-time pothole detection on tms320c6678 dsp. In: **2016 IEEE International Conference on Imaging Systems and Techniques (IST)**. [S.l.: s.n.], 2016. p. 123–128.
- MILED, W.; PESQUET, J. C.; PARENT, M. Robust obstacle detection based on dense disparity maps. In: DÍAZ, R. M.; PICHLER, F.; ARENCIBIA, A. Q. (Ed.). **Computer Aided Systems Theory – EUROCAST 2007**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 1142–1150. ISBN 978-3-540-75867-9.
- MISTRY, V. H.; MAKWANA, R. M. Computationally efficient vanishing point detection algorithm based road segmentation in road images. In: **2016 IEEE International Conference on Advances in Electronics, Communication and Computer Technology (ICAECCT)**. [S.l.: s.n.], 2016. p. 103–110.
- MITZEL, D. et al. Real time vision based multi-person tracking for mobile robotics and intelligent vehicles. In: JESCHKE, S.; LIU, H.; SCHILBERG, D. (Ed.). **Intelligent Robotics and Applications**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 105–115. ISBN 978-3-642-25489-5.
- MIYAMA, M.; MATSUDA, Y. Vehicle detection and tracking with affine motion segmentation in stereo video. In: **2011 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)**. [S.l.: s.n.], 2011. p. 271–276.
- NA, I.; HAN, S. H.; JEONG, H. Stereo-based road obstacle detection and tracking. In: **13th International Conference on Advanced Communication Technology (ICACT2011)**. [S.l.: s.n.], 2011. p. 1181–1184. ISSN 1738-9445.
- NADAV, I.; KATZ, E. Off-road path and obstacle detection using monocular camera. In: **2016 IEEE International Conference on the Science of Electrical Engineering (ICSEE)**. [S.l.: s.n.], 2016. p. 1–5.
- NAITO, T.; ITO, T.; KANEDA, Y. The obstacle detection method using optical flow estimation at the edge image. In: **2007 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2007. p. 817–822. ISSN 1931-0587.

- NETO, A. M.; RITTNER, L. A simple and efficient road detection algorithm for real time autonomous navigation based on monocular vision. In: **2006 IEEE 3rd Latin American Robotics Symposium**. [S.l.: s.n.], 2006. p. 92–99.
- NETO, A. M. et al. Real-time estimation of drivable image area based on monocular vision. In: **2013 IEEE Intelligent Vehicles Symposium Workshops (IV Workshops)**. [S.l.: s.n.], 2013. p. 63–68.
- NEVES, S.; PELAES, E. **Estudo e implementação de técnicas de segmentação de imagens**. Campus Universitário do Guamá, Belém, Pará, 2001. v. 1, n. 2, 1-11 p.
- NGUYEN, L.; PHUNG, S. L.; BOUZERDOUM, A. Enhanced pixel-wise voting for image vanishing point detection in road scenes. In: **2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. [S.l.: s.n.], 2017. p. 1852–1856.
- NIETO, M.; LABORDA, J. A.; SALGADO, L. Road environment modeling using robust perspective analysis and recursive bayesian segmentation. **Machine Vision and Applications**, v. 22, n. 6, p. 927–945, 2011. ISSN 1432-1769. Disponível em: <http://dx.doi.org/10.1007/s00138-010-0287-7>.
- NISHIGAKI, M.; ALOIMONOS, Y. Moving obstacle detection using cameras for driver assistance system. In: **2010 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2010. p. 805–812. ISSN 1931-0587.
- OH, C.; KIM, B.; SOHN, K. Automatic illumination invariant road detection with stereo vision. In: **2012 7th IEEE Conference on Industrial Electronics and Applications (ICIEA)**. [S.l.: s.n.], 2012. p. 889–893. ISSN 2156-2318.
- OH, C.; SON, J.; SOHN, K. Illumination robust road detection using geometric information. In: **2012 15th International IEEE Conference on Intelligent Transportation Systems**. [S.l.: s.n.], 2012. p. 1566–1571. ISSN 2153-0009.
- OLIVEIRA, G. L.; BURGARD, W.; BROX, T. Efficient deep models for monocular road segmentation. In: **2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)**. [S.l.: s.n.], 2016. p. 4885–4891.
- ONIGA, F.; NEDEVSCHI, S. Processing dense stereo data using elevation maps: Road surface, traffic isle, and obstacle detection. **Vehicular Technology, IEEE Transactions on**, v. 59, n. 3, p. 1172–1182, 2010. ISSN 0018-9545.
- ONIGA, F.; SARKOZI, E.; NEDEVSCHI, S. Fast obstacle detection using u-disparity maps with stereo vision. In: **2015 IEEE International Conference on Intelligent Computer Communication and Processing (ICCP)**. [S.l.: s.n.], 2015. p. 203–207.
- ONIGA, F.; TRIF, A.; NEDEVSCHI, S. Stereovision for obstacle detection on smart mobile devices: First results. In: **16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)**. [S.l.: s.n.], 2013. p. 342–347. ISSN 2153-0009.
- OPENCV. **Open Source Computer Vision Library**. 2017. Acesso em: 11 out. 2017.
- OSOSINSKI, M.; LABROSSE, F. Real-time autonomous colour-based following of ill-defined roads. In: _____. **Advances in Autonomous Robotics: Joint Proceedings of the 13th Annual TAROS Conference and the 15th Annual FIRA RoboWorld Congress, Bristol, UK, August 20-23, 2012**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 366–376. ISBN 978-3-642-32527-4. Disponível em: https://doi.org/10.1007/978-3-642-32527-4_33.

OSOSINSKI, M.; LABROSSE, F. Automatic driving on ill-defined roads: An adaptive, shape-constrained, color-based method. **Journal of Field Robotics**, p. n/a–n/a, 2013. ISSN 1556-4967. Disponível em: <http://dx.doi.org/10.1002/rob.21494>.

OUMA, Y. O.; HAHN, M. Pothole detection on asphalt pavements from 2d-colour pothole images using fuzzy c-means clustering and morphological reconstruction. **Automation in Construction**, v. 83, p. 196 – 211, 2017. ISSN 0926-5805. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0926580516302837>.

OZGUNALP, U.; KAYMAK, S. Lane detection by estimating and using restricted search space in hough domain. **Procedia Computer Science**, v. 120, p. 148 – 155, 2017. ISSN 1877-0509. 9th International Conference on Theory and Application of Soft Computing, Computing with Words and Perception, ICSCCW 2017, 22-23 August 2017, Budapest, Hungary. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877050917324341>.

OZUTEMIZ, K. B. et al. Adaptive unstructured road detection using close range stereo vision. In: **2013 9th Asian Control Conference (ASCC)**. [S.l.: s.n.], 2013. p. 1–6.

PAN, X.; OGAI, H.; WU, N. Multi-frames based real-time road detection method for autonomous vehicle. In: **2015 54th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)**. [S.l.: s.n.], 2015. p. 1429–1434.

PAN, X.; SI, W.; OGAI, H. Fast road detection based on a dual-stage structure. In: **Proceedings of the 9th International Conference on Computer and Automation Engineering**. New York, NY, USA: ACM, 2017. (ICCAE '17), p. 155–162. ISBN 978-1-4503-4809-6. Disponível em: <http://doi.acm.org/10.1145/3057039.3057101>.

PANTILIE, C. D.; NEDEVSCHI, S. Real-time obstacle detection in complex scenarios using dense stereo vision and optical flow. In: **13th International IEEE Conference on Intelligent Transportation Systems**. [S.l.: s.n.], 2010. p. 439–444. ISSN 2153-0009.

PARK, J. Y. et al. Accurate vertical road profile estimation using v-disparity map and dynamic programming. In: **2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2017. p. 1–6.

PATEL, D.; UPADHYAY, S. Article: Optical flow measurement using lucas kanade method. **International Journal of Computer Applications**, v. 61, n. 10, p. 6–10, January 2013. Full text available.

PĆeSZOR, D. et al. Optical flow for collision avoidance in autonomous cars. In: NGUYEN, N. T. et al. (Ed.). **Intelligent Information and Database Systems**. Cham: Springer International Publishing, 2018. p. 482–491. ISBN 978-3-319-75420-8.

PEDRINI, H.; SCHWARTZ, W. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. São Paulo, Brazil: Ed. Thomson Learning, 2007. 528 p. ISBN 978-85-221-0595-3.

PENSAMENTO, L. **O método hipotético-dedutivo**. 2013. Disponível em: <https://livrepensamento.com/2013/10/01/o-metodo-hipotetico-dedutivo/>. Acesso em: 15 out. 2016.

PEREIRA, V. et al. A deep learning-based approach for road pothole detection in timor leste. In: **2018 IEEE International Conference on Service Operations and Logistics, and Informatics (SOLI)**. [S.l.: s.n.], 2018. p. 279–284.

PERROLLAZ, M.; SPALANZANI, A.; AUBERT, D. Probabilistic representation of the uncertainty of stereo-vision and application to obstacle detection. In: **2010 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2010. p. 313–318. ISSN 1931-0587.

PETROVAI, A. et al. Obstacle detection using stereovision for android-based mobile devices. In: **2014 IEEE 10th International Conference on Intelligent Computer Communication and Processing (ICCP)**. [S.l.: s.n.], 2014. p. 141–147.

PETROVAI, A.; DANESCU, R.; NEDEVSCI, S. A stereovision based approach for detecting and tracking lane and forward obstacles on mobile devices. In: **2015 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2015. p. 634–641. ISSN 1931-0587.

PFEIFFER, D.; ERBS, F.; FRANKE, U. Pixels, stixels, and objects. In: FUSIELLO, A.; MURINO, V.; CUCCHIARA, R. (Ed.). **Computer Vision – ECCV 2012. Workshops and Demonstrations**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 1–10. ISBN 978-3-642-33885-4.

PINGGERA, P.; FRANKE, U.; MESTER, R. High-performance long range obstacle detection using stereo vision. In: **2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)**. [S.l.: s.n.], 2015. p. 1308–1313.

PODDAR, A.; AHMED, S. T.; PUHAN, N. B. Adaptive saliency-weighted obstacle detection for the visually challenged. In: **2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN)**. [S.l.: s.n.], 2015. p. 477–482.

POMERLEAU, D. A. **Neural Network Perception for Mobile Robot Guidance**. Norwell, MA, USA: Kluwer Academic Publishers, 1993. ISBN 0792393732.

POPPER, K. R. **The Logic of Scientific Discovery**. [S.l.]: Routledge, 2002. 1st English Edition:1959. ISBN 0-415-27844-9.

PPGCC. **Linhas de Pesquisa**. [S.l.], 2017. Disponível em: <http://ppgcc.posgrad.ufsc.br/linhas-de-pesquisa-2/>. Acesso em: 20 set. 2017.

PRABHAKAR, G. et al. Obstacle detection and classification using deep learning for tracking in high-speed autonomous driving. In: **2017 IEEE Region 10 Symposium (TENSYP)**. [S.l.: s.n.], 2017. p. 1–6.

PRAKASH, C. D.; AKHBARI, F.; KARAM, L. J. Robust obstacle detection for advanced driver assistance systems using distortions of inverse perspective mapping of a monocular camera. **Robotics and Autonomous Systems**, v. 114, p. 172 – 186, 2019. ISSN 0921-8890. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0921889018301787>.

RAMOS, S. et al. Detecting unexpected obstacles for self-driving cars: Fusing deep learning and geometric modeling. In: **2017 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2017. p. 1025–1032.

RAMZI, M.; LARBI, G.; LYAMINE, G. Road obstacle detection. In: **Proceedings of the 3rd International Conference on Future Networks and Distributed Systems**. New York, NY, USA: ACM, 2019. (ICFNDS '19), p. 9:1–9:5. ISBN 978-1-4503-7163-6. Disponível em: <http://doi.acm.org/10.1145/3341325.3341999>.

RANKIN, A.; IVANOV, T.; BRENNAN, S. Evaluating the performance of unmanned ground vehicle water detection. In: **Proceedings of the 10th Performance Metrics for Intelligent Systems Workshop**. New York, NY, USA: ACM, 2010. (PerMIS '10), p. 305–311. ISBN 978-1-4503-0290-6. Disponível em: <http://doi.acm.org/10.1145/2377576.2377632>.

RANKIN, A. L.; MATTHIES, L. H. Daytime mud detection for unmanned ground vehicle autonomous navigation. In: . [S.l.: s.n.], 2008.

RASHEED, U. et al. Generic vision based algorithm for driving space detection in diverse indoor and outdoor environments. In: **2010 IEEE International Conference on Mechatronics and Automation**. [S.l.: s.n.], 2010. p. 1609–1614. ISSN 2152-7431.

RASMUSSEN, C. Roadcompass: Following rural roads with vision + lidar using vanishing point tracking. **Auton. Robots**, Kluwer Academic Publishers, Hingham, MA, USA, v. 25, n. 3, p. 205–229, oct 2008. ISSN 0929-5593. Disponível em: <http://dx.doi.org/10.1007/s10514-008-9091-x>.

RATEKE, T. **Detecção de Caminho em Tempo Real para Veículos Autônomos Utilizando Visão Passiva**. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Florianópolis, Santa Catarina, Brasil, 2015.

RATEKE, T. et al. A fast pavement location approach for autonomous car navigation. In: _____. **Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 19th Iberoamerican Congress, CIARP 2014, Puerto Vallarta, Mexico, November 2-5, 2014. Proceedings**. Cham: Springer International Publishing, 2014. p. 844–851. ISBN 978-3-319-12568-8. Disponível em: http://dx.doi.org/10.1007/978-3-319-12568-8_102.

RATEKE, T. et al. Passive vision region-based road detection: A literature review. **ACM Comput. Surv.**, ACM, New York, NY, USA, v. 52, n. 2, p. 31:1–31:34, mar. 2019. ISSN 0360-0300. Doi: <http://doi.acm.org/10.1145/3311951>.

RATEKE, T.; JUSTEN, K. A.; WANGENHEIM, A. von. **Systematic Literature Review for Region-Based Road Detection**. [S.l.], 2018.

RATEKE, T.; JUSTEN, K. A.; WANGENHEIM, A. von. Road surface classification with images captured from low-cost cameras – road traversing knowledge (rtk) dataset. **Revista de Informática Teórica e Aplicada (RITA)**, v. 26, n. 3, p. 50–64, 2019. ISSN 2175-2745.

RATEKE, T.; WANGENHEIM, A. von. **Systematic Literature Review for Passive Vision Road Obstacle Detection**. [S.l.], 2018.

RATEKE, T.; WANGENHEIM, A. von. Passive vision road obstacle detection: a literature mapping. **International Journal of Computers and Applications**, Taylor & Francis, v. 0, n. 0, p. 1–20, 2020. Disponível em: <https://doi.org/10.1080/1206212X.2020.1758877>.

RAVISHANKAR, U.; MANIC, M. A hardware suitable integrated neural system for autonomous vehicles - road structuring and path tracking. In: **The 2011 International Joint Conference on Neural Networks**. [S.l.: s.n.], 2011. p. 2024–2030. ISSN 2161-4393.

REDMON, J. et al. You only look once: Unified, real-time object detection. In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2016. p. 779–788. ISSN 1063-6919.

- REN; MALIK. Learning a classification model for segmentation. In: **Proceedings Ninth IEEE International Conference on Computer Vision**. [S.l.: s.n.], 2003. p. 10–17 vol.1. ISSN null.
- REN, S. et al. Faster r-cnn: Towards real-time object detection with region proposal networks. In: **Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 1**. Cambridge, MA, USA: MIT Press, 2015. (NIPS'15), p. 91–99. Disponível em: <http://dl.acm.org/citation.cfm?id=2969239.2969250>.
- RIDEL, D. A.; SHINZATO, P. Y.; WOLF, D. F. A clustering-based obstacle segmentation approach for urban environments. In: **2015 12th Latin American Robotics Symposium and 2015 3rd Brazilian Symposium on Robotics (LARS-SBR)**. [S.l.: s.n.], 2015. p. 265–270.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: NAVAB, N. et al. (Ed.). **Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015**. Cham: Springer International Publishing, 2015. p. 234–241. ISBN 978-3-319-24574-4.
- ROSENBLUM, M. Neurons that know how to drive. In: **Proceedings of the IEEE Intelligent Vehicles Symposium, Dearborn, MI**. [S.l.: s.n.], 2000. p. 556–562.
- ROTARU, C.; GRAF, T.; ZHANG, J. Color image segmentation in hsi space for automotive applications. **Journal of Real-Time Image Processing**, v. 3, n. 4, p. 311–322, 2008. ISSN 1861-8219. Disponível em: <http://dx.doi.org/10.1007/s11554-008-0078-9>.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, Nature Publishing Group SN -, v. 323, p. 533 EP –, Oct 1986. Disponível em: <http://dx.doi.org/10.1038/323533a0>.
- SACHAN, A. **Tensorflow Tutorial 2: image classifier using convolutional neural network**. 2017. Url: <https://cv-tricks.com/tensorflow-tutorial/training-convolutional-neural-network-for-image-classification/>.
- SALAVATI, P.; MOHAMMADI, H. M. Obstacle detection using googlenet. In: **2018 8th International Conference on Computer and Knowledge Engineering (ICCKE)**. [S.l.: s.n.], 2018. p. 326–332. ISSN 2375-1304.
- SANDHU, M. et al. Motion segmentation using spectral clustering on indian road scenes. In: LEAL-TAIXÉ, L.; ROTH, S. (Ed.). **Computer Vision – ECCV 2018 Workshops**. Cham: Springer International Publishing, 2019. p. 676–687. ISBN 978-3-030-11021-5.
- SAWALAKHE, H.; PRAKASH, R. Development of roads pothole detection system using image processing. In: THALMANN, D. et al. (Ed.). **Intelligent Embedded Systems**. Singapore: Springer Singapore, 2018. p. 187–195. ISBN 978-981-10-8575-8.
- SCHIOPU, I. et al. Pothole detection and tracking in car video sequence. In: **2016 39th International Conference on Telecommunications and Signal Processing (TSP)**. [S.l.: s.n.], 2016. p. 701–706.
- SENGAR, S. S.; MUKHOPADHYAY, S. Motion detection using block based bi-directional optical flow method. **Journal of Visual Communication and Image Representation**, v. 49, n. Supplement C, p. 89 – 103, 2017. ISSN 1047-3203. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1047320317301700>.

SHA, Y.; YU, X.; ZHANG, G. A feature selection algorithm based on boosting for road detection. In: **2008 Fifth International Conference on Fuzzy Systems and Knowledge Discovery**. [S.l.: s.n.], 2008. v. 2, p. 257–261.

SHA, Y.; ZHANG, G. y. An adaptive weighted boosting algorithm for road detection. In: **2010 International Conference on Networking, Sensing and Control (ICNSC)**. [S.l.: s.n.], 2010. p. 582–586.

SHANG, E. et al. Offroadscene: An open database for unstructured road detection algorithms. In: **2013 International Conference on Computer Sciences and Applications**. [S.l.: s.n.], 2013. p. 779–783.

SHEN, Y.; DU, X.; LIU, J. Monocular vision based obstacle detection for robot navigation in unstructured environment. In: LIU, D. et al. (Ed.). **Advances in Neural Networks – ISNN 2007**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 714–722. ISBN 978-3-540-72383-7.

SHETTY, A. A. et al. Disparity maps based path planning algorithm for autonomous robot navigation. In: **2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)**. [S.l.: s.n.], 2019. p. 669–675. ISSN null.

SHI, J. et al. A novel path segmentation method for autonomous road following. In: **2016 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)**. [S.l.: s.n.], 2016. p. 1–6.

SHI, J.; WANG, J.; FU, F. Fast and robust vanishing point detection for unstructured road following. **IEEE Transactions on Intelligent Transportation Systems**, v. 17, n. 4, p. 970–979, April 2016. ISSN 1524-9050.

SHIN, B.-S.; XU, Z.; KLETTE, R. Visual lane analysis and higher-order tasks: a concise review. **Machine Vision and Applications**, v. 25, n. 6, p. 1519–1547, 2014. ISSN 1432-1769. Disponível em: <http://dx.doi.org/10.1007/s00138-014-0611-8>.

SHINZATO, P. Y. et al. Fast visual road recognition and horizon detection using multiple artificial neural networks. In: **2012 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2012. p. 1090–1095. ISSN 1931-0587.

SHINZATO, P. Y. et al. Carina dataset: An emerging-country urban scenario benchmark for road detection systems. In: **2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2016. p. 41–46. Doi: <http://dx.doi.org/10.1109/ITSC.2016.7795529>.

SHNEIER, M. et al. Learning traversability models for autonomous mobile vehicles. **Autonomous Robots**, v. 24, n. 1, p. 69–86, 2008. ISSN 1573-7527. Disponível em: <http://dx.doi.org/10.1007/s10514-007-9063-6>.

SIMOND, N.; PARENT, M. Obstacle detection from ipm and super-homography. In: **2007 IEEE/RSJ International Conference on Intelligent Robots and Systems**. [S.l.: s.n.], 2007. p. 4283–4288. ISSN 2153-0858.

SIOGKAS, G. K.; DERMATAS, E. S. Random-walker monocular road detection in adverse conditions using automated spatiotemporal seed selection. **IEEE Transactions on Intelligent Transportation Systems**, v. 14, n. 2, p. 527–538, June 2013. ISSN 1524-9050.

SON, T.; MITA, S.; TAKEUCHI, A. Road detection using segmentation by weighted aggregation based on visual information and a posteriori probability of road regions. In: **Systems, Man and Cybernetics, 2008. SMC 2008. IEEE International Conference on**. [S.l.: s.n.], 2008. p. 3018–3025. ISSN 1062-922X.

SONG, D. et al. Vision-based motion planning for an autonomous motorcycle on ill-structured roads. **Autonomous Robots**, v. 23, n. 3, p. 197–212, 2007. ISSN 1573-7527. Disponível em: <http://dx.doi.org/10.1007/s10514-007-9042-y>.

SONG, W. et al. Depth calculation and object detection using stereo vision with subpixel disparity and hog feature. In: TAN, H.; ZHOU, M. (Ed.). **Advances in Information Technology and Education**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 489–494. ISBN 978-3-642-22418-8.

SOQUET, N.; AUBERT, D.; HAUTIERE, N. Road segmentation supervised by an extended v-disparity algorithm for autonomous navigation. In: **2007 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2007. p. 160–165. ISSN 1931-0587.

SÖVÉNY, B.; KOVÁCS, G.; KARDKOVÁCS, Z. T. Blind guide. **Journal on Multimodal User Interfaces**, v. 9, n. 4, p. 287–297, 2015. ISSN 1783-8738. Disponível em: <http://dx.doi.org/10.1007/s12193-015-0191-6>.

STANDARD, A. N. **American National Standard for Safe use of Lasers Outdoors**. Orlando, FL, 2005.

SUGANUMA, N.; KUBO, T. Fast dynamic object extraction using stereovision based on occupancy grid maps and optical flow. In: **2011 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)**. [S.l.: s.n.], 2011. p. 978–983. ISSN 2159-6247.

SUGANUMA, N.; SHIMOYAMA, M.; FUJIWARA, N. Obstacle detection using virtual disparity image for non-flat road. In: **2008 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2008. p. 596–601. ISSN 1931-0587.

SUN, Y. et al. An obstacle detection method based on binocular stereovision. In: ZENG, B. et al. (Ed.). **Advances in Multimedia Information Processing – PCM 2017**. Cham: Springer International Publishing, 2018. p. 571–580. ISBN 978-3-319-77383-4.

SZEGEDY, C. et al. Rethinking the inception architecture for computer vision. In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2016. p. 2818–2826. ISSN 1063-6919.

TAREL, J. P.; BIGORGNE, E. Long-range road detection for off-line scene analysis. In: **2009 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2009. p. 15–20. ISSN 1931-0587.

TEDESCHI, A.; BENEDETTO, F. A real-time automatic pavement crack and pothole recognition system for mobile android-based devices. **Advanced Engineering Informatics**, v. 32, p. 11 – 25, 2017. ISSN 1474-0346. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1474034616301197>.

TEOH, S. S.; BRÄUNL, T. Symmetry-based monocular vehicle detection system. **Machine Vision and Applications**, v. 23, n. 5, p. 831–842, Sep 2012. ISSN 1432-1769. Disponível em: <https://doi.org/10.1007/s00138-011-0355-7>.

TRIF, A.; ONIGA, F.; NEDEVSKI, S. Stereovision on mobile devices for obstacle detection in low speed traffic scenarios. In: **2013 IEEE 9th International Conference on Intelligent Computer Communication and Processing (ICCP)**. [S.l.: s.n.], 2013. p. 169–174.

TSAI, J.-F. et al. Road detection and classification in urban environments using conditional random field models. In: **2006 IEEE Intelligent Transportation Systems Conference**. [S.l.: s.n.], 2006. p. 963–967. ISSN 2153-0009.

TSAI, Y. et al. Accurate and fast obstacle detection method for automotive applications based on stereo vision. In: **2018 International Symposium on VLSI Design, Automation and Test (VLSI-DAT)**. [S.l.: s.n.], 2018. p. 1–4. ISSN 2472-9124.

UKHWAH, E. N.; YUNIARNO, E. M.; SUPRAPTO, Y. K. Asphalt pavement pothole detection using deep learning method based on yolo neural network. In: **2019 International Seminar on Intelligent Technology and Its Applications (ISITIA)**. [S.l.: s.n.], 2019. p. 35–40.

URDZIŃ, D. et al. Detection of driving space using vanishing point estimation. In: **2010 IEEE 8th International Symposium on Applied Machine Intelligence and Informatics (SAMII)**. [S.l.: s.n.], 2010. p. 323–328.

URMSON, C. **Just press go: designing a self-driving vehicle**. 2014. Disponível em: <https://www.blog.google/inside-google/alphabet/just-press-go-designing-self-driving/>. Acesso em: 26 nov. 2014.

URMSON, C. **The latest chapter for the self-driving car: mastering city street driving**. 2014. Disponível em: <https://www.blog.google/inside-google/alphabet/the-latest-chapter-for-self-driving-car/>. Acesso em: 26 nov. 2014.

URMSON, C. et al. Autonomous driving in urban environments: Boss and the urban challenge. **Journal of Field Robotics Special Issue on the 2007 DARPA Urban Challenge, Part I**, Wiley InterScience, v. 25, n. 8, p. 425–466, June 2008.

VALENTE, M.; STANCIULESCU, B. Real-time method for general road segmentation. In: **2017 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2017. p. 443–447.

VENTROUX, N. et al. Stereovision-based 3d obstacle detection for automotive safety driving assistance. In: **2009 12th International IEEE Conference on Intelligent Transportation Systems**. [S.l.: s.n.], 2009. p. 1–6. ISSN 2153-0009.

VITOR, G. B. et al. A 2d/3d vision based approach applied to road detection in urban environments. In: **2013 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2013. p. 952–957. ISSN 1931-0587.

WALK, S.; SCHINDLER, K.; SCHIELE, B. Disparity statistics for pedestrian detection: Combining appearance, motion and stereo. In: DANIILIDIS, K.; MARAGOS, P.; PARAGIOS, N. (Ed.). **Computer Vision – ECCV 2010**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p. 182–195. ISBN 978-3-642-15567-3.

WANG, B.; FRÉMONT, V. Fast road detection from color images. In: **2013 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2013. p. 1209–1214. ISSN 1931-0587.

WANG, B.; FRÉMONT, V.; RODRÍGUEZ, S. A. Color-based road detection and its evaluation on the kitti road benchmark. In: **2014 IEEE Intelligent Vehicles Symposium Proceedings**. [S.l.: s.n.], 2014. p. 31–36. ISSN 1931-0587.

WANG, H. et al. Road detection via superpixels and interactive image segmentation. In: **The 4th Annual IEEE International Conference on Cyber Technology in Automation, Control and Intelligent**. [S.l.: s.n.], 2014. p. 152–155.

WANG, H.; REN, M.; YANG, J. Capitalizing on the boundary ratio prior for road detection. **Multimedia Tools and Applications**, v. 75, n. 19, p. 11999–12019, Oct 2016. ISSN 1573-7721. Disponível em: <https://doi.org/10.1007/s11042-016-3280-y>.

WANG, J.; JI, Z.; SU, Y.-T. Unstructured road detection using hybrid features. In: **2009 International Conference on Machine Learning and Cybernetics**. [S.l.: s.n.], 2009. v. 1, p. 482–486. ISSN 2160-133X.

WANG, J.; SUN, S.; ZHAO, X. Unstructured road detection and path tracking for tracked mobile robot. In: **2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)**. [S.l.: s.n.], 2015. p. 535–539.

WANG, Q.; FANG, J.; YUAN, Y. Adaptive road detection via context-aware label transfer. **Neurocomputing**, v. 158, p. 174 – 183, 2015. ISSN 0925-2312. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0925231215001010>.

WANG, Q. et al. Design and implementation of stereo vision system based on fpga. In: JIA, M.; GUO, Q.; MENG, W. (Ed.). **Wireless and Satellite Systems**. Cham: Springer International Publishing, 2019. p. 766–774. ISBN 978-3-030-19153-5.

WANG, W. et al. Self-paced cross-modality transfer learning for efficient road segmentation. In: **2017 IEEE International Conference on Robotics and Automation (ICRA)**. [S.l.: s.n.], 2017. p. 1394–1401.

WANG, Y.; BAI, L.; FAIRHURST, M. Robust road modeling and tracking using condensation. **Intelligent Transportation Systems, IEEE Transactions on**, v. 9, n. 4, p. 570–579, 2008. ISSN 1524-9050.

WANG, Y.; CHEN, D.; SHI, C. Vision-based road detection by adaptive region segmentation and edge constraint. In: **2008 Second International Symposium on Intelligent Information Technology Application**. [S.l.: s.n.], 2008. v. 1, p. 342–346.

WANG, Y. et al. Robust obstacle detection based on a novel disparity calculation method and g-disparity. **Computer Vision and Image Understanding**, v. 123, n. Supplement C, p. 23 – 40, 2014. ISSN 1077-3142. Disponível em: <http://www.sciencedirect.com/science/article/pii/S107731421400040X>.

WANG, Y.; WANG, X.; WEN, C. Fast vanishing point detection for unstructured road using haar texture. In: **2012 IEEE International Conference on Signal Processing, Communication and Computing (ICSPCC 2012)**. [S.l.: s.n.], 2012. p. 167–170.

WEDEL, A. et al. B-spline modeling of road surfaces with an application to free-space estimation. **Intelligent Transportation Systems, IEEE Transactions on**, v. 10, n. 4, p. 572–583, 2009. ISSN 1524-9050.

WEDEL, A. et al. Warpcut – fast obstacle segmentation in monocular video. In: HAMPRECHT, F. A.; SCHNÖRR, C.; JÄHNE, B. (Ed.). **Pattern Recognition**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 264–273. ISBN 978-3-540-74936-3.

WIESZOK, Z. et al. Stixel based scene understanding for autonomous vehicles. In: **2017 IEEE 14th International Conference on Networking, Sensing and Control (ICNSC)**. [S.l.: s.n.], 2017. p. 43–48.

WON, K.; JUNG, S. Billboard sweep stereo for obstacle detection in road scenes. **Electronics Letters**, v. 48, n. 24, p. 1528–1530, 2012. ISSN 0013-5194.

WOO, J.-W.; LIM, Y.-C.; LEE, M. Dynamic obstacle identification based on global and local features for a driver assistance system. **Neural Computing and Applications**, v. 20, n. 7, p. 925–933, Oct 2011. ISSN 1433-3058. Disponível em: <https://doi.org/10.1007/s00521-010-0401-9>.

WU, M.; LAM, S. K.; SRIKANTHAN, T. Nonparametric technique based high-speed road surface detection. **IEEE Transactions on Intelligent Transportation Systems**, v. 16, n. 2, p. 874–884, April 2015. ISSN 1524-9050.

WU, M.; ZHOU, C.; SRIKANTHAN, T. Robust and low complexity obstacle detection and tracking. In: **2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2016. p. 1249–1254.

XIA, S. et al. Road detection via unsupervised feature learning. In: **2015 International Conference on Image and Vision Computing New Zealand (IVCNZ)**. [S.l.: s.n.], 2015. p. 1–6.

XIA, X. et al. Segmentation based on the unstructured road with shadow. In: **2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)**. [S.l.: s.n.], 2016. v. 01, p. 501–504.

XIAO, D.; HU, X. Road detection based on superpixels and anisotropic heat diffusion. In: **2014 Fourth International Conference on Digital Information and Communication Technology and its Applications (DICTAP)**. [S.l.: s.n.], 2014. p. 425–429.

XIAO, L. et al. Fast unstructured road detection and tracking from monocular video. In: **The 27th Chinese Control and Decision Conference (2015 CCDC)**. [S.l.: s.n.], 2015. p. 3974–3980. ISSN 1948-9439.

XIE, Q. et al. Road detection based on off-line and on-line learning. In: **2014 IEEE International Conference on Computer and Information Technology**. [S.l.: s.n.], 2014. p. 193–197.

XU, B.; WANG, X.; SONG, M. Extending the dynamic stixel world with b-spline based road estimation for obstacle detection. In: **2018 Chinese Automation Congress (CAC)**. [S.l.: s.n.], 2018. p. 2973–2978. ISSN null.

XU, Y. et al. A method of stereo obstacle detection based on image symmetrical move. In: **2009 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2009. p. 36–41. ISSN 1931-0587.

XU, Z.-y.; ZHANG, J. Parallel computation for stereovision obstacle detection of autonomous vehicles using gpu. In: LI, K. et al. (Ed.). **Life System Modeling and Intelligent Computing**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p. 176–184. ISBN 978-3-642-15621-2.

YANG, B.; WANG, Y.; LIU, J. Lane detection in critical shadow conditions based on double a/d convertors camera. In: _____. **Artificial Intelligence and Computational Intelligence: Third International Conference, AICI 2011, Taiyuan, China, September 24-25, 2011, Proceedings, Part III**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 54–62. ISBN 978-3-642-23896-3. Disponível em: https://doi.org/10.1007/978-3-642-23896-3_7.

YANG, Q. et al. Road detection by ransac on randomly sampled patches with slanted plane prior. In: **2016 IEEE 13th International Conference on Signal Processing (ICSP)**. [S.l.: s.n.], 2016. p. 929–933. ISSN 2164-5221.

YANKUN, Z.; HONG, C.; WEYRICH, N. A single camera based rear obstacle detection system. In: **2011 IEEE Intelligent Vehicles Symposium (IV)**. [S.l.: s.n.], 2011. p. 485–490. ISSN 1931-0587.

YAO, J.; LU, S.; YAN, G. Self-adaptive road detection method based on vision and cluster analysis. In: **2013 2nd International Symposium on Instrumentation and Measurement, Sensor Network and Automation (IMSNA)**. [S.l.: s.n.], 2013. p. 471–476.

YENIKAYA, S.; YENIKAYA, G.; DÜVEN, E. Keeping the vehicle on the road: A survey on on-road lane detection systems. **ACM Comput. Surv.**, ACM, New York, NY, USA, v. 46, n. 1, p. 2:1–2:43, jul 2013. ISSN 0360-0300. Disponível em: <http://doi.acm.org/10.1145/2522968.2522970>.

YING, Z. et al. A novel shadow-free feature extractor for real-time road detection. In: **Proceedings of the 2016 ACM on Multimedia Conference**. New York, NY, USA: ACM, 2016. (MM '16), p. 611–615. ISBN 978-1-4503-3603-1. Disponível em: <http://doi.acm.org/10.1145/2964284.2967294>.

YONGQUAN, X. et al. A stereo matching approach to detect obstacle in alv system. In: **2008 International Conference on Computer Science and Software Engineering**. [S.l.: s.n.], 2008. v. 1, p. 1103–1106.

YOO, H. et al. Real-time rear obstacle detection using reliable disparity for driver assistance. **Expert Systems with Applications**, v. 56, n. Supplement C, p. 186 – 196, 2016. ISSN 0957-4174. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0957417416300884>.

YOUSAF, M. H. et al. Visual analysis of asphalt pavement for detection and localization of potholes. **Advanced Engineering Informatics**, v. 38, p. 527 – 537, 2018. ISSN 1474-0346. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1474034618301435>.

YUAN, J. et al. A robust road segmentation method based on graph cut with learnable neighboring link weights. In: **17th International IEEE Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2014. p. 1644–1649. ISSN 2153-0009.

YUAN, Y.; JIANG, Z.; WANG, Q. Video-based road detection via online structural learning. **Neurocomputing**, v. 168, p. 336 – 347, 2015. ISSN 0925-2312. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0925231215007900>.

YUN, S.; GUO-YING, Z.; YONG, Y. A road detection algorithm by boosting using feature combination. In: **2007 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2007. p. 364–368. ISSN 1931-0587.

ZANIN, M. et al. **diplodoc road stereo sequence**. 2004.

- ZEBBARA, K. et al. A fast road obstacle detection using association and symmetry recognition. In: **2019 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS)**. [S.l.: s.n.], 2019. p. 1–5. ISSN null.
- ZHANG, G. et al. An efficient road detection method in noisy urban environment. In: **2009 IEEE Intelligent Vehicles Symposium**. [S.l.: s.n.], 2009. p. 556–561. ISSN 1931-0587.
- ZHANG, J. et al. Robust road detection from a single image. In: **2016 23rd International Conference on Pattern Recognition (ICPR)**. [S.l.: s.n.], 2016. p. 859–864.
- ZHANG, L.; WU, E. y. A road segmentation and road type identification approach based on new-type histogram calculation. In: **2009 2nd International Congress on Image and Signal Processing**. [S.l.: s.n.], 2009. p. 1–5.
- ZHANG, L.; ZHOU, W.-H.; LIU, J.-L. A robust road segmentation method. In: **2007 International Conference on Wavelet Analysis and Pattern Recognition**. [S.l.: s.n.], 2007. v. 2, p. 912–917. ISSN 2158-5695.
- ZHANG, Y. et al. A simple algorithm of superpixel segmentation with boundary constraint. **IEEE Transactions on Circuits and Systems for Video Technology**, v. 27, n. 7, p. 1502–1514, July 2017. ISSN 1558-2205.
- ZHANG, Y. et al. Two-stage obstacle detection based on stereo vision in unstructured environment. In: **2014 Sixth International Conference on Intelligent Human-Machine Systems and Cybernetics**. [S.l.: s.n.], 2014. v. 1, p. 168–172.
- ZHANG, Z. et al. Real-time obstacle detection based on stereo vision for automotive applications. In: **2012 5th European DSP Education and Research Conference (EDERC)**. [S.l.: s.n.], 2012. p. 281–285.
- ZHOU, S. et al. Road detection using support vector machine based on online learning and evaluation. In: **Intelligent Vehicles Symposium (IV), 2010 IEEE**. [S.l.: s.n.], 2010. p. 256–261. ISSN 1931-0587.
- ZHOU, S.; IAGNEMMA, K. Self-supervised learning method for unstructured road detection using fuzzy support vector machines. In: **2010 IEEE/RSJ International Conference on Intelligent Robots and Systems**. [S.l.: s.n.], 2010. p. 1183–1189. ISSN 2153-0858.
- ZHOU, W. et al. Combining dark channel prior and color cues for road following in outdoor environments. In: **2010 IEEE International Conference on Image Processing**. [S.l.: s.n.], 2010. p. 2197–2200. ISSN 1522-4880.
- ZHOU, Z.; FARHAT, F.; WANG, J. Z. Detecting dominant vanishing points in natural scenes with application to composition-sensitive image retrieval. **IEEE Transactions on Multimedia**, v. 19, n. 12, p. 2651–2665, Dec 2017. ISSN 1941-0077.
- ZHU, M. et al. Monocular visual odometry and dense 3d reconstruction for on-road vehicles. In: FUSIELLO, A.; MURINO, V.; CUCCHIARA, R. (Ed.). **Computer Vision – ECCV 2012. Workshops and Demonstrations**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 596–606. ISBN 978-3-642-33868-7.
- ZU, Z. et al. Real-time road detection with image texture analysis-based vanishing point estimation. In: **2015 IEEE International Conference on Progress in Informatics and Computing (PIC)**. [S.l.: s.n.], 2015. p. 454–457.

ZUO, W.-h.; YAO, T.-z. Road model prediction based unstructured road detection. **Journal of Zhejiang University SCIENCE C**, v. 14, n. 11, p. 822–834, Nov 2013. ISSN 1869-196X.
Disponível em: <https://doi.org/10.1631/jzus.C1300090>.

ZUREIKI, A.; DEVY, M.; CHATILA, R. Stereo matching using reduced-graph cuts. In: **Image Processing, 2007. ICIP 2007. IEEE International Conference on**. [S.l.: s.n.], 2007. v. 1, p. I – 237–I – 240. ISSN 1522-4880.