



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TRANSPORTES

GABRIEL TAVARES DE MELO FREITAS

***SOFTWARE PARA IDENTIFICAÇÃO DE DEFEITOS NA SUPERFÍCIE DE
PAVIMENTOS RODOVIÁRIOS UTILIZANDO DEEP LEARNING***

FORTALEZA

2022

GABRIEL TAVARES DE MELO FREITAS

*SOFTWARE PARA IDENTIFICAÇÃO DE DEFEITOS NA SUPERFÍCIE DE PAVIMENTOS
RODOVIÁRIOS UTILIZANDO DEEP LEARNING*

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Transportes. Área de concentração: Infraestrutura de Transportes.

Orientador: Prof. Dr. Ernesto Ferreira Nobre Júnior

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

F936s Freitas, Gabriel Tavares de Melo.
Software para identificação de defeitos na superfície de pavimentos rodoviários utilizando deep learning / Gabriel Tavares de Melo Freitas. – 2022.
109 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2022.
Orientação: Prof. Dr. Ernesto Ferreira Nobre Júnior.

1. Redes Neurais Convolucionais. 2. Defeitos no pavimento. 3. Detecção de buracos e remendos. 4. Software. 5. Gerência de Pavimentos. I. Título.

CDD 388

GABRIEL TAVARES DE MELO FREITAS

*SOFTWARE PARA IDENTIFICAÇÃO DE DEFEITOS NA SUPERFÍCIE DE PAVIMENTOS
RODOVIÁRIOS UTILIZANDO DEEP LEARNING*

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Transportes. Área de concentração: Infraestrutura de Transportes.

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Ernesto Ferreira Nobre Júnior (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Elias Teodoro da Silva Júnior
Instituto Federal do Ceará (IFCE)

Prof. Dr. Auzuir Ripado de Alexandria
Instituto Federal do Ceará (IFCE)

A Deus.

Aos meus pais, familiares e amigos que prestaram apoio.

AGRADECIMENTOS

À Universidade Federal do Ceará, pelo ensino de qualidade.

Ao professor Dr. Ernesto Ferreira Nobre Júnior, pelo papel de orientação.

Aos professores participantes da banca examinadora Dr. Auzuir Ripado de Alexandria e Dr. Elias Teodoro da Silva Júnior pelo apoio.

Aos professores e aos colegas da turma de mestrado, pelas reflexões, críticas e sugestões recebidas.

Ao Doutorando em Engenharia Elétrica, Ednardo Moreira Rodrigues, e seu assistente, Alan Batista de Oliveira, aluno de graduação em Engenharia Elétrica, pela adequação do *template* utilizado neste trabalho para que o mesmo ficasse de acordo com as normas da biblioteca da Universidade Federal do Ceará (UFC).

“A única coisa que você não pode fazer é desistir.”

(Tiago Brunet)

RESUMO

O modal rodoviário é o principal sistema de transporte brasileiro. No entanto, problemas no pavimento causam um impacto direto na economia do nosso país, gerando custos relacionados a acidentes, atraso no transporte de cargas, indenização para as vítimas, aumento do preço dos produtos, entre outros fatores. Neste trabalho criou-se um *software* que identifique, quantifique, georreferencie e apresente os defeitos presentes em pavimentos rodoviários de revestimento asfáltico, com o intuito de contribuir na área de gerência de pavimentos. Para a elaboração deste *software*, utilizou-se um algoritmo de *Deep Learning* para o aprendizado dos defeitos. Foi realizado um processo de coleta de dados de defeitos no pavimento em imagens e vídeos para realizar o treinamento e a validação da rede neural. Neste processo, foram estruturados seis *datasets* envolvendo *smartphones* e câmeras de ação na aquisição dos dados, onde foi realizada uma análise comparativa de cada um. Para auxiliar na validação dos resultados, desenvolveu-se um *software* de apoio ao inventário. Este *software* é executado na plataforma web com o intuito de apresentar as informações do inventário em uma interface gráfica, que pode também servir de apoio na tomada de decisão por parte dos pesquisadores, engenheiros, analistas e técnicos da área de gerência de pavimentos para levantamentos futuros. E, por fim, realizou-se a classificação com base no aprendizado do algoritmo a fim de automatizar a detecção de defeitos no pavimento. Como objeto de estudo, duas classes de defeitos foram utilizadas: buracos e remendos. Dentre os resultados gerados, o melhor *dataset* obteve uma acurácia de 99,89% para buracos e 95,91% para remendos. Todos os resultados foram disponibilizados no *software* de apoio ao inventário. Portanto, neste trabalho é apresentado um *software* que detecta de buracos e remendos em rodovias pavimentadas através de imagens capturadas de câmeras ou *smartphones*.

Palavras-chave: *Software*. Gerência de Pavimentos. *Deep Learning*. Buracos e remendos.

ABSTRACT

The road modal is the main Brazilian transport system. However, however, problems in the country's economy, generating direct costs related to accidents, delay in cargo, impact on the economy as impact, between our transport, increase in the price of products other factors. In this case, a software that identifies, quantifies, georeferences and presents the challenges presented in asphalt routing pavements in order to contribute in the area of pavement management. For the elaboration of this software, use a Deep Learning software to learn from the exercises. A test data collection process was carried out to perform in the test on training images and videos and the neural network. In this process, studies of data sets for smartphones and data acquisition attempts were carried out, where a comparative analysis of each was performed. To assist in the validation of the results, an inventory support software was developed. This software runs on the web platform with the aim of presenting inventory information in a graphical interface, which can also serve as a support in decision making by researchers, engineers, analysts and technicians in the area of management of plans for future surveys. And, finally, the classification was carried out based on the learning to make a diagnostic detection order on the pavement. As an object of study, two classes of used objects were used: holes. Among the results generated, the best dataset obtained an accuracy of 99.89% for holes and 95.91% for patches. All results were made available in the inventory support software. Therefore, this work presents a software that detects holes and patches in paved roads through images captured from cameras or smartphones.

Keywords: Software. Pavement Management. Deep Learning. Potholes and patches.

LISTA DE FIGURAS

Figura 1 – Camadas do Pavimento Rodoviário	22
Figura 2 – Relação entre Índice de Serventia, a vida útil do pavimento e o efeito causado pelo adiamento na aplicação das atividades de manutenção	24
Figura 3 – Principais Componentes de um SGP	25
Figura 4 – Fluxograma básico de um SGP	26
Figura 5 – Principais Tipos de Defeitos: trincas transversais (a), trincas longitudinais (b), trincas em blocos (c), trincas couro de jacaré (d), bombeamento (e), escorregamento (f), exsudação (g), desgaste (h), deformação permanente nas trilhas de roda (i/j), buracos (k) e remendos (l)	29
Figura 6 – Estratégia de manutenção e reabilitação mais indicada baseada no valor do ICP	39
Figura 7 – Distúrbios longitudinais e transversais	43
Figura 8 – Desenho esquemático para a determinação do IRI utilizando um veículo	44
Figura 9 – Perfilômetro a laser acoplado no veículo	45
Figura 10 – Aplicativo SmartIRI	46
Figura 11 – Rede Neural Simples	48
Figura 12 – Rede Neural Artificial	49
Figura 13 – Rede Neural Profunda (<i>Deep Learning</i>)	50
Figura 14 – Bloco Residual da ResNet	52
Figura 15 – Representação de uma imagem digital	54
Figura 16 – (a) Classificação e (b) Detecção	55
Figura 17 – Algoritmo do YOLO	56
Figura 18 – Sistema de Detecção do YOLO	56
Figura 19 – Etapas do processo	59
Figura 20 – Arquitetura do <i>software</i>	60
Figura 21 – Processo de aquisição de dados pelo iPhone	61
Figura 22 – Imagens do <i>dataset</i> do iPhone (a) 4K e (b) <i>FullHD</i>	62
Figura 23 – Processo de aquisição de dados pelo S20 FE	63
Figura 24 – Imagens do <i>dataset</i> do S20 FE (a) 4K e (b) <i>FullHD</i>	64
Figura 25 – Processo de aquisição de dados pela GARMIN 4K	65
Figura 26 – Imagens do <i>dataset</i> da GARMIN 4K	66

Figura 27 – Processo de aquisição de dados pela GOPRO 4K	66
Figura 28 – Imagens do <i>dataset</i> da GOPRO 4K	67
Figura 29 – Rotulação de remendos no pavimento	68
Figura 30 – Região de Interesse	69
Figura 31 – Equipamento utilizado nos experimentos	71
Figura 32 – IoU: Objeto rotulado vs. Objeto detectado	75
Figura 33 – Treinamento do YOLOv3	77
Figura 34 – Detecção de Defeitos no Pavimento Rodoviário	77
Figura 35 – Gráfico da perda e do mAP pelas iterações do Treinamento do iPhone FHD .	80
Figura 36 – Gráfico da perda e do mAP pelas iterações do Treinamento do iPhone 4K . .	80
Figura 37 – Gráfico da perda e do mAP pelas iterações do Treinamento do S20 FHD . .	81
Figura 38 – Gráfico da perda e do mAP pelas iterações do Treinamento do S20 4K . . .	82
Figura 39 – Gráfico da perda e do mAP pelas iterações do Treinamento da GARMIN . .	83
Figura 40 – Gráfico da perda e do mAP pelas iterações do Treinamento da GARMIN . .	84
Figura 41 – Imagens de validação do <i>dataset</i> do iPhone FHD	85
Figura 42 – Imagens de validação do <i>dataset</i> do iPhone 4K	86
Figura 43 – Imagens de validação do <i>dataset</i> do S20 FHD	87
Figura 44 – Imagens de validação do <i>dataset</i> do S20 4K	88
Figura 45 – Imagens de validação do <i>dataset</i> da GARMIN	89
Figura 46 – Resultado de um caso de detecção do Treinamento da GARMIN	90
Figura 47 – Imagens de validação do <i>dataset</i> da GOPRO	91
Figura 48 – Tela de Autenticação (a) <i>desktop</i> (b) <i>mobile</i>	104
Figura 49 – Tela de Busca do Levantamento (a) <i>desktop</i> (b) <i>mobile</i>	105
Figura 50 – Tela de Imagens do Levantamento (a) <i>desktop</i> (b) <i>mobile</i>	106
Figura 51 – Tela de Geolocalização das Imagens (a) <i>desktop</i> (b) <i>mobile</i>	107
Figura 52 – Tela de Métricas do Treinamento (a) <i>desktop</i> (b) <i>mobile</i>	107

LISTA DE TABELAS

Tabela 1 – Custos relacionados as tarefas de manutenção	23
Tabela 2 – Níveis de serventia	34
Tabela 3 – Defeitos do método PCI	38
Tabela 4 – Índice de Condição do Pavimento	38
Tabela 5 – Degradação do Pavimento em função do IGG	40
Tabela 6 – Conceitos do ICPF	41
Tabela 7 – Classificação do IGGE	41
Tabela 8 – Pesos para cálculo	41
Tabela 9 – Índice do Estado da Superfície do Pavimento	42
Tabela 10 – Quantitativo de imagens, buracos e remendos rotulados por <i>dataset</i>	70
Tabela 11 – Valores utilizados no treinamento da rede YOLOv3	72
Tabela 12 – Variáveis utilizadas no cálculo do <i>Precision</i> e <i>Recall</i>	73
Tabela 13 – Resultado das métricas dos seis treinamento realizados	79

LISTA DE ABREVIATURAS E SIGLAS

3D	Tridimensional
AP	<i>Average Precision</i> – Precisão Média
AVG Loss	<i>Average Loss</i>
CNN	<i>Convolutional Neural Network</i> – Rede Neural Convolucional
CUDA	Compute Unified Device Architecture
cuDNN	<i>CUDA Deep Neural Network Library</i>
DNER	Departamento Nacional de Estradas de Rodagem
DNIT	Departamento Nacional de Infraestrutura de Transportes
FN	Falsos Negativos
FP	Falsos Positivos
Geipot	Empresa Brasileira de Planejamento de Transportes
GPS	<i>Global Positioning System</i> – Sistema de Posicionamento Global
GPU	<i>Graphics Processing Unit</i> – Unidade de Processamento Gráfico
IA	Inteligência Artificial
ICP	Índice de Condição do Pavimento
ICPF	Índice de Condição de Pavimentos Flexíveis
IES	Índice do Estado de Superfície do Pavimento
IGG	Índice de Gravidade Global
IGGE	Índice de Gravidade Global Expedito
IGI	Índice de Gravidade Individual
ILSVRC	<i>Imagenet Large Scale Visual Recognition Challenge</i>
IoU	<i>Intersection over union</i> – Intersecção da União
IRI	<i>International Roughness Index</i> – Índice de Irregularidade Internacional
LVC	Levantamento Visual Contínuo
mAP	<i>mean Average Precision</i> – Média das Precisões de Todas as Métricas
MTC	<i>Metropolitan Transportation Commission</i>
PCI	<i>Paviment Condition Index</i>
ReLU	<i>Rectified Linear Unit</i>
RNA	Rede Neural Artificial
SGP	Sistema de Gerência de Pavimentos
SHRP, 1993	<i>Strategic Highway Reserch Program</i>

VP	Verdadeiros Positivos
VSA	Valor de Serventia Atual
YOLO	<i>You Only Look Once</i>

LISTA DE SÍMBOLOS

\$	Dólar
%	Porcentagem
£	Libra
¥	Iene
€	Euro
§	Seção
©	Copyright
®	Marca Registrada

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Contextualização	17
1.2	Problema de pesquisa	19
1.3	Questões de pesquisa	20
1.4	Objetivo	20
1.4.1	<i>Objetivo Geral</i>	20
1.4.2	<i>Objetivos Específicos</i>	20
1.5	Estrutura do Trabalho	21
2	REVISÃO BIBLIOGRÁFICA	22
2.1	Sistema de Gerência de Pavimentos – SGP	22
2.1.1	<i>Conceitos</i>	22
2.1.2	<i>Coleta de dados</i>	27
2.1.3	<i>Tipos de defeitos</i>	28
2.1.4	<i>Levantamento de defeitos e avaliação dos pavimentos</i>	31
2.1.5	<i>Métodos para avaliação de defeitos</i>	35
2.1.6	<i>Índices do pavimento</i>	37
2.1.7	<i>Irregularidade longitudinal</i>	42
2.1.8	<i>Equipamentos de medição</i>	45
2.2	Machine Learning	47
2.3	Redes Neurais Artificiais	47
2.4	Deep Learning	50
2.5	Convolutional Neural Network (CNN)	51
2.6	Arquitetura ResNet	52
2.7	Visão Computacional	53
2.8	Técnicas de Detecção e Classificação de Objetos	54
2.9	YOLO	55
2.10	Pesquisas relacionadas a utilização de <i>Deep Learning</i> na detecção de defeitos nos pavimentos rodoviários	56
3	MATERIAIS E MÉTODOS	59
3.1	Etapas do processo metodológico	59

3.2	<i>Arquitetura do software</i>	60
3.3	<i>Aquisição dos dados</i>	61
3.3.1	<i>iPhone 12 Pro</i>	61
3.3.2	<i>Samsung Galaxy S20 FE</i>	63
3.3.3	<i>GARMIN Virb Ultra 30</i>	64
3.3.4	<i>GOPRO Hero 7</i>	66
3.4	<i>Estruturação do dataset</i>	68
3.5	<i>Algoritmo de detecção de buracos e remendos</i>	70
3.5.1	<i>Infraestrutura Computacional</i>	70
3.5.2	<i>Parâmetros do YOLO</i>	72
3.5.3	<i>Métricas do treinamento</i>	73
3.5.4	<i>Processo de treinamento</i>	76
3.5.5	<i>Processo de detecção</i>	77
4	RESULTADOS E DISCUSSÕES	79
4.1	Análise dos Treinamentos	79
4.2	Discussões	84
5	CONCLUSÕES E RECOMENDAÇÕES	93
5.1	Conclusões	93
5.2	Sugestões para trabalhos futuros	94
	REFERÊNCIAS	95
	APÊNDICES	101
	APÊNDICE A – FORMULÁRIO PARA O LEVANTAMENTO VISUAL	
	CONTÍNUO	101
	APÊNDICE B – CÁLCULO DO IGGE	102
	APÊNDICE C – QUADRO RESUMO	103
	APÊNDICE D – SOFTWARE DE APOIO AO INVENTÁRIO	104

1 INTRODUÇÃO

1.1 Contextualização

O transporte rodoviário é o principal sistema logístico brasileiro, com uma rede de 1.720.700 quilômetros de estradas e rodovias nacionais, a quarta maior rede do mundo (CNT, 2021). O transporte de cargas no Brasil é altamente dependente do modal rodoviário, representa cerca de 60% da matriz de transporte, enquanto países com dimensões similares, como os Estados Unidos, a participação das rodovias é de 26%, na Austrália, de 24%, e na China, de apenas 8% (BARTHOLOMEU *et al.*, 2006).

A falta de manutenção das rodovias, resulta em vias danificadas em aproximadamente 52,2% da extensão da malha viária brasileira (CNT, 2021). Ainda segundo a CNT (2021), que avalia toda a malha federal pavimentada e os principais trechos estaduais, 61,9% das vias apresentam algum tipo de problema sendo classificadas como regular, ruim ou péssima em metade dos trechos, tornando-se um entrave econômico.

De acordo com a CNT (2021), além da segurança das rodovias, a má qualidade do pavimento ou sua ausência afeta a própria operação do serviço de transporte. Uma via deteriorada pode aumentar as despesas de manutenção do veículo (reposição de peças, lubrificação, entre outros); os desgastes e troca de pneus e freios; maior demanda do motor e de consumo de combustíveis por quilômetro rodado; a lavagem do veículo; entre outros custos operacionais. Considerando o transporte rodoviário de carga, estima-se que um estado de pavimento rodoviário classificado como péssimo pode aumentar em até 91,5% o custo operacional do transporte (CNT, 2021). Isto não pode ser realizado de forma eficaz se as condições dos pavimentos se mantêm precárias, podendo causar acidentes, diminuir o fluxo de tráfego das vias e prejudicar a eficiência do sistema.

Além disso, tem-se uma sobrecarga na malha e pode ocasionar um aumento no número de acidentes. Somente no ano de 2020, foram constatados 51.865 acidentes com vítimas e 5.287 óbitos em rodovias federais (CNT, 2021). Vale ressaltar que os acidentes têm causas mais ligadas à fatores humanos, porém a má qualidade do revestimento contribui consideravelmente no aumento desses valores. Portanto, os índices são elevados e nos mostra que é preciso uma solução na área de infraestrutura. É preciso melhorar a qualidade da malha para que as rodovias não fiquem tão sobrecarregadas. Sob o ponto de vista ambiental, as rodovias deterioradas geram impacto ao fazerem com que os veículos consumam mais combustíveis com acelerações e

frenagens não eficientes, o que provoca uma maior emissão de poluentes (CNT, 2021).

Estudos indicam que a má conservação das rodovias não somente impacta de forma negativa a economia, como gera um processo de "anti-economia", ou seja, o montante poupado em serviços de manutenção da qualidade no momento inadequado resulta em acréscimos nos gastos futuros com obras de reconstrução e em custos adicionais para os usuários das vias. Um estudo realizado pelo Departamento Nacional de Estradas de Rodagem (DNER) e da Empresa Brasileira de Planejamento de Transportes (Geipot) apontaram que uma estrada degradada representa aumento de 58% no consumo de combustíveis, de 38% nos gastos de manutenção de veículo, de 50% no índice de acidentes e de até 100% no tempo gasto nas viagens (Revista CNT, 2001 apud BARTHOLOMEU *et al.*, 2008).

Outro ponto a considerar, é o aumento do preço nos produtos. Segundo o Prof. Dr. Edésio Lopes¹, a logística e o transporte são dois aspectos que preocupam empresários de todo o mundo, mas geram uma atenção especial no Brasil em função do tamanho do país. Ou seja, quem conseguir otimizar esse custo tende a ser mais competitivo. Os problemas das rodovias brasileiras e a dificuldade em transportar cargas no país são um custo compartilhado pelas empresas com o consumidor final em razão do repasse dessas deficiências ao preço final dos produtos ou serviços. Portanto, trata-se de um problema que afeta a população como um todo e tem um impacto importante para as empresas do país.

Além do impacto gerado em toda a cadeia, existe um alto preço a ser pago nas obras rodoviárias: R\$ 19,6 bilhões para a fase de manutenção e R\$ 62,9 bilhões para as fases de reconstrução e restauração dessas rodovias (CNT, 2021). Dentro desse escopo, engloba o processo de identificação de defeitos no pavimento, de modo que é necessário mapear os segmentos mais atingidos para, posteriormente, realizar o reparo.

Os pavimentos rodoviários são um patrimônio valioso, de modo que o processo de conservação e reabilitação no momento ideal são essenciais para a sua preservação. Um Sistema de Gerência de Pavimentos irá para auxiliar os tomadores de decisão na busca de estratégias necessárias à manutenção desse patrimônio otimizando custos substanciais na operação de veículos e nos investimentos para realização dos reparos (AASHTO, 1990).

Geralmente, os recursos financeiros para a manutenção e conservação da malha viária ficam sob autonomia de gestores da área financeira. Dessa forma, o uso de equipamentos automatizados para a avaliação dos pavimentos deve-se aumentar cada vez mais, já que o acesso a

¹ Disponível em: <<https://blog.ipog.edu.br/engenharia-e-arquitetura/infraestrutura-e-logistica-no-brasil/>>

esses equipamentos está cada vez mais fácil e se faz necessário para munir os gestores financeiros de conhecimentos técnicos, já apontava BERNNETT (1998). Portanto, é de extrema necessidade uma ferramenta que forneça dados confiáveis sobre as condições da rodovia, de modo que a manutenção tardia da malha poderá causar um envelhecimento antes do período normal e até gerar um processo de deterioração irreversível (PATERSON, 1987).

Atualmente, o intuito do processo de avaliação dos pavimentos é reestabelecer o conforto e a segurança dos usuários, onde o levantamento pode ser realizado de forma manual ou automatizada. Na avaliação manual, os avaliadores descem do veículo e identificam os defeitos conforme seu tipo, sua extensão e sua severidade. Na avaliação automatizada, câmeras são acopladas aos veículos a fim de registrar as condições do pavimento em imagens ou vídeos, permitindo que a avaliação seja realizada posteriormente no escritório.

Neste trabalho, iremos focar na avaliação automatizada para identificar buracos e remendos presentes na superfície do revestimento asfáltico em rodovias do estado do Ceará. Portanto, realizou-se o registro de fotos e vídeos de pavimentos rodoviários defeituosos a partir de quatro câmeras distintas e foram utilizadas técnicas de visão computacional e *Deep Learning* para identificar os defeitos. Além disso, foram utilizados recursos de geolocalização durante o levantamento a fim de catalogar os locais dos defeitos. Por fim, foi desenvolvido um *software* para plataforma web que exibe essas informações e possibilita o usuário acessá-las através do navegador do seu computador ou dispositivo móvel.

1.2 Problema de pesquisa

O levantamento de defeitos é uma etapa fundamental na gerência dos pavimentos para aferir o seu grau de deterioração. Para isto, é realizado a identificação, a contagem e a localização geográfica dos defeitos contidos na superfície do revestimento asfáltico. Atualmente, este processo é registrado de forma manual pelas empresas e órgãos governamentais nas rodovias brasileiras. No entanto, devido às contínuas evoluções tecnológicas, é propício reconsiderar o uso de métodos computacionais para solucionar este problema. Portanto, o problema de pesquisa pode ser resumido através da seguinte pergunta:

Como é possível encontrar uma solução que identifique, quantifique e forneça a localização geográfica dos defeitos encontrados no pavimento de forma automatizada?

1.3 Questões de pesquisa

Em virtude do que foi apresentado anteriormente, surgem as seguintes questões de pesquisa:

- a) De que forma a detecção automatizada de objetos, através da técnica *Deep Learning*, pode ser aplicada para a identificação de defeitos na avaliação de pavimentos asfálticos?
- b) Que procedimentos utilizar para a coleta de dados de defeitos na superfície do pavimento asfáltico?
- c) Como é possível informar tecnicamente os defeitos do pavimento, suas quantidades e sua localização geográfica para embasar os tomadores de decisão na escolha de estratégias de intervenção no pavimento?
- d) Qual seria a melhor forma de obtenção de dados para o algoritmo encontrar os defeitos na superfície do pavimento de modo eficiente?

1.4 Objetivo

1.4.1 *Objetivo Geral*

O objetivo geral desta dissertação é desenvolver um *software* capaz de identificar, quantificar, georreferenciar e apresentar os buracos e remendos presentes nos pavimentos rodoviários de revestimento asfáltico.

1.4.2 *Objetivos Específicos*

- a) Desenvolver um modelo computacional capaz de identificar e classificar defeitos, em imagens, podendo ser aplicado na etapa de avaliação de pavimentos asfálticos;
- b) Estruturar bancos de imagens (*datasets*) a partir de 4 câmeras distintas que apresentem defeitos de buracos e remendos em pavimentos asfálticos;
- c) Criar um *software* capaz de apresentar as informações técnicas que expressem o estado atual da rodovia, através da detecção automatizada dos buracos e remendos identificados pelo modelo; Além disso, coletar dados sobre a localização geográfica dos defeitos.
- d) Analisar os bancos de imagens (*datasets*), com o intuito de encontrar a melhor

condição para detectar e classificar os buracos e remendos existentes na superfície da via.

1.5 Estrutura do Trabalho

Além deste Capítulo 1 introdutório, este trabalho é composto por mais quatro capítulos, descritos a seguir. O Capítulo 2 apresenta uma revisão da literatura a partir de uma leitura crítica de artigos, teses, dissertações e documentos de agências reguladoras nacionais sobre Sistema de Gerência de Pavimentos, levantamento de defeitos, avaliação dos pavimentos, *Deep Learning*, redes neurais convolucionais e técnicas de detecção e classificação de objetos para elaboração da ferramenta computacional. O Capítulo 3 descreve os materiais e métodos, equipamentos utilizados, aquisição dos dados, estruturação dos *datasets*, parâmetros e métricas utilizados no modelo de detecção e a elaboração do *software* de apoio ao inventário. O Capítulo 4 apresenta a análise comparativa de resultados para os *datasets* distintos coletados a através de um iPhone 12 Pro, Samsung Galaxy S20 FE, GOPRO Hero 7 e uma GARMIN Virb Ultra 30. O Capítulo 5 apresenta a conclusão e as proposições para trabalhos futuros. Por conseguinte, constam apêndices que foram utilizados na elaboração desta Dissertação.

2 REVISÃO BIBLIOGRÁFICA

Neste tópico, serão explanados os conceitos de um Sistema de Gerência de Pavimentos onde será abordada a etapa de coleta de dados, tipos de defeitos e o processo de avaliação dos defeitos dos pavimentos. Serão mencionados os conceitos de Redes Neurais Artificiais através da utilização de *Deep Learning* e visão computacional na avaliação de pavimentos.

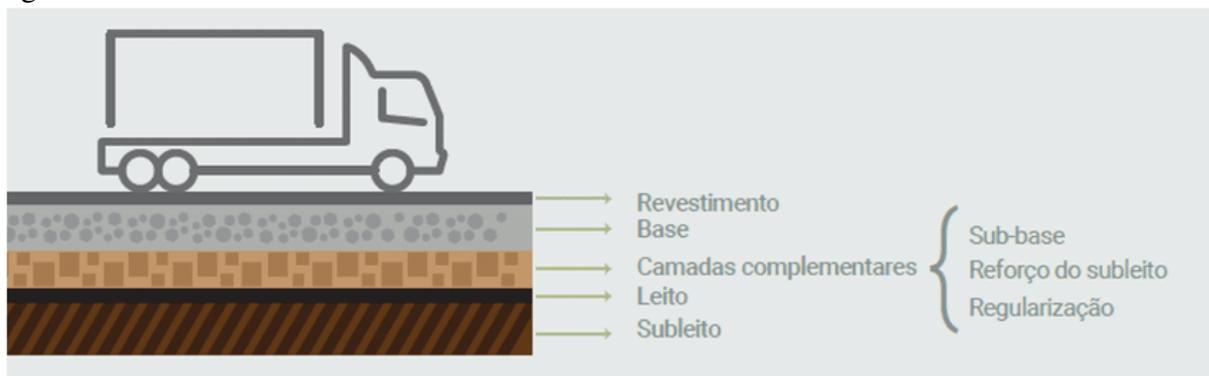
Além disso, serão apresentadas as ferramentas tecnológicas que realizam a automatização da detecção de defeitos nos pavimentos rodoviários. Logo, iremos pontuar alguns trabalhos realizados no contexto nacional e internacional sobre a utilização dessa automatização para a detecção de defeitos nos pavimentos.

2.1 Sistema de Gerência de Pavimentos – SGP

2.1.1 Conceitos

Um pavimento é composto de múltiplas camadas, sendo do tipo asfáltico pode-se mencionar as seguintes: revestimento, base, camadas complementares, leito e subleito. Essas camadas são destinadas a resistir aos esforços do tráfego e intempéries do meio ambiente (Figura 1). A partir da década de 1980, ocorreu um grande interesse no desenvolvimento e aplicação dos Sistemas de Gerência de Pavimentos (SGPs) por vários órgãos rodoviários. Isso porque os órgãos financiadores passaram a estimular o emprego de técnicas padronizadas, com o intuito de obter melhores resultados na construção e aplicação dos projetos rodoviários (DNIT-IPR 745/2011).

Figura 1 – Camadas do Pavimento Rodoviário



Fonte: CNT (2019)

Segundo a AASHTO (1990), um Sistema de Gerência de Pavimentos é um conjunto de ferramentas que serve para auxiliar os tomadores de decisão na busca de estratégias viáveis, para avaliar, prover e manter os pavimentos em boas condições durante um determinado período de tempo. Os SGPs foram criados para dar apoio aos modelos de reparo e manutenção, tendo como principal objetivo a utilização de informações confiáveis que possibilitem uma tomada de decisão para a construção, manutenção ou reabilitação dos pavimentos, alcançando o maior retorno possível para os recursos disponíveis. A manutenção pode ser definida como a preservação da condição do pavimento, da segurança e da qualidade de rolamento, a reabilitação é uma melhoria estrutural ou funcional aumentando a vida útil, de modo que irá melhorar a condição do pavimento e a qualidade do rolamento.

As tarefas de manutenção geralmente são divididas em três categorias: corretiva, preventiva e de rotina. A manutenção corretiva busca corrigir os defeitos existentes. A manutenção preventiva é realizada antes que o problema aconteça e inclui tarefas que protegem a estrutura do pavimento, impedindo sua deterioração e permitindo boas condições no rolamento (BAUSANO *et al.*, 2004). A manutenção de rotina é definida pela AASHTO (1990) como as tarefas que envolvem manutenções do dia a dia, onde são inventariadas e estão sob controle do pessoal de manutenção.

Segundo o DNER (1998), os órgãos rodoviários têm deixado de focar na construção de novas rodovias para realizar tarefas de manutenção e reabilitação nos pavimentos existentes. As tarefas de manutenção, geralmente utilizadas, são preventivas e corretivas. Sempre que possível, recomenda-se a execução de tarefas de manutenção preventiva ou de rotina, uma vez que se forem executadas de forma periódica e correta, terão um custo inferior se comparadas as manutenções corretivas, já que são realizadas na fase de deterioração do pavimento. A Tabela 1 mostra os custos associados aos serviços de manutenção (DNER, 1998).

Tabela 1 – Custos relacionados as tarefas de manutenção

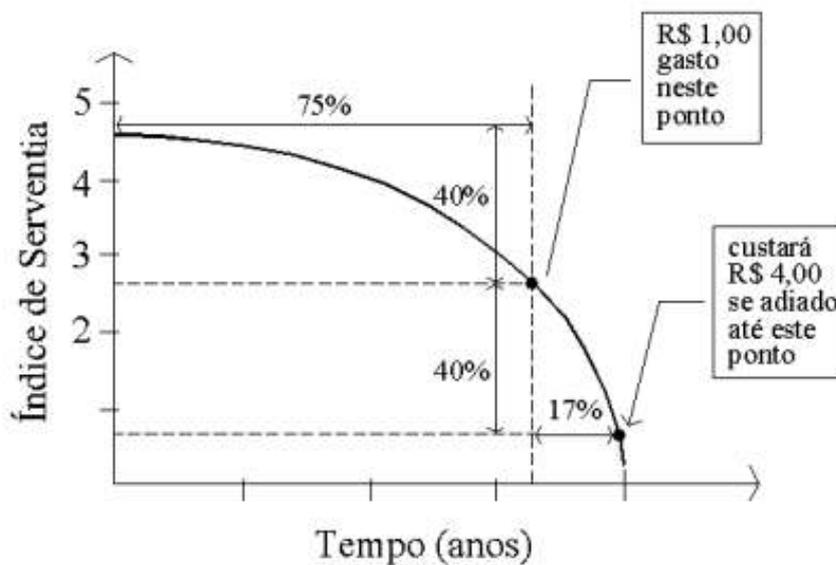
Intervenção	Intervalo de Custo (por km de rodovia)
Manutenção de Rotina	US\$ 300 a US\$ 5.000
Manutenção Periódica	US\$ 8.000 a US\$ 40.000
Reabilitação	US\$ 30.000 a US\$ 200.000
Reconstrução	US\$ 45.000 a US\$ 300.000

Fonte: Adaptado de DNER (1998)

A disponibilização de recursos de forma tardia, para executar os serviços de manutenção e restauração na malha rodoviária de países desenvolvidos, conforme os levantamentos

realizados pelo Banco Mundial, gera prejuízos bastante elevados (PATERSON, 1987). Os gastos para estes serviços passaram de 12 bilhões para 90 bilhões de dólares. Conforme demonstrado na Figura 2, deixar de aplicar R\$ 1,00 no tempo devido (com índice de serventia de aproximadamente 2,5), esse custo passa de R\$ 1,00 para R\$ 4,00 se aplicado após grande perda de serventia, o que implica em uma elevação de 300% no custo das atividades de manutenção, devido o adiamento.

Figura 2 – Relação entre Índice de Serventia, a vida útil do pavimento e o efeito causado pelo adiamento na aplicação das atividades de manutenção



Fonte: Adaptado de Haas e Hudson (1978)

Na prática, os órgãos rodoviários utilizam SGP internamente. No entanto, não existe uma padronização, de modo que um órgão ao implantá-lo faz adaptações conforme o cenário no qual ele atua, conforme as características da malha viária e os recursos disponíveis (MARCON, 1996; YSHIBA, 2003).

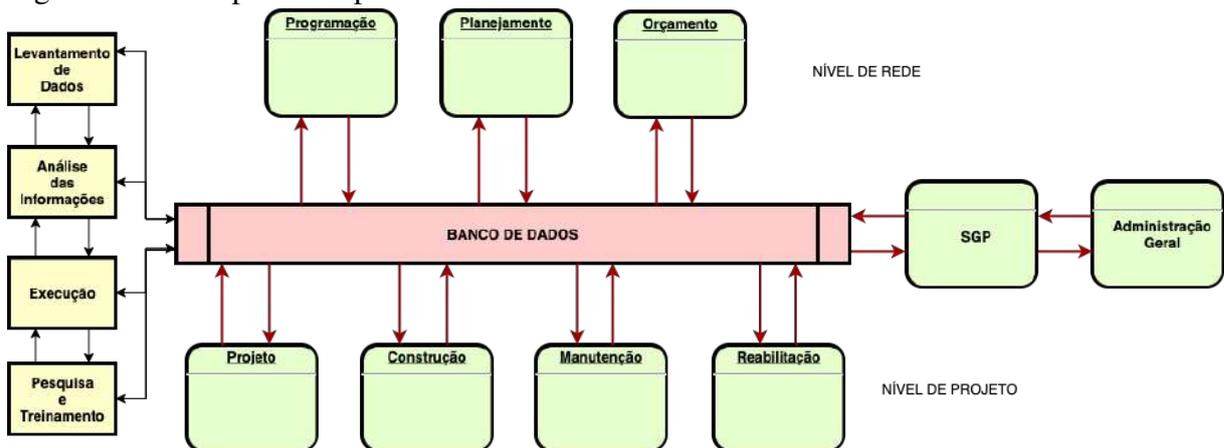
A presença de uma política eficaz é fundamental para a gerência de um sistema rodoviário, onde sua ausência provoca desperdícios de recursos financeiros, de mão de obra qualificada e de equipamentos. Além disso, a execução de tarefas de manutenção e reabilitação fora das normas técnicas, causam grandes prejuízos financeiros para os cofres públicos e para a sociedade (PATERSON, 1987).

Um Sistema de Gerência de Pavimentos deve disponibilizar a maior quantidade possível de informações, para que os gestores, engenheiros e analistas possam tomar as melhores decisões a respeito da manutenção e reabilitação, além de poder analisar e avaliar os resultados

posteriormente. Pode-se afirmar que um SGP tem como principal finalidade facilitar e fundamentar as tomadas de decisões. O SGP apresenta o estado real das condições do pavimento, proporcionando uma compreensão adequada à maioria dos usuários do sistema, além de atender à estrutura do órgão (PATERSON, 1987).

Segundo a AASHTO (1990) um SGP é projetado como uma ferramenta de planejamento estratégico para a administração superior e como uma ferramenta de engenharia para os tomadores de decisões técnicas. Para Haas *et al.* (1994), o processo de tomada de decisão em um Sistema de Gerência de Pavimentos é em nível de rede e de projeto. Em nível de rede, estão inclusas atividades como: programação, planejamento e orçamento. Em nível de projeto, destacam-se: projeto, construção, manutenção e reabilitação. Para os dois níveis é preciso ter um banco de dados contendo as informações da rede e que deve ser atualizado periodicamente. Na Figura 3 são apresentados os principais componentes de um Sistema de Gerência de Pavimentos.

Figura 3 – Principais Componentes de um SGP



Fonte: Adaptado de Haas *et al.* (1994)

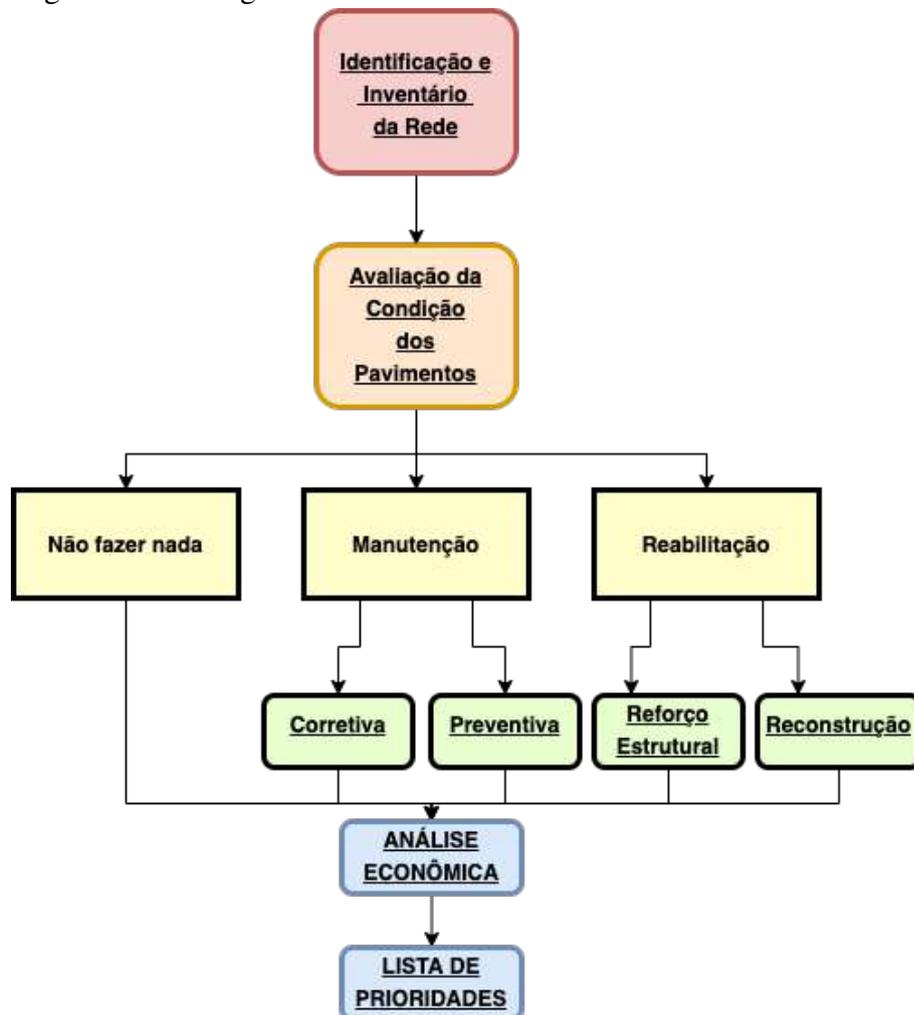
Marcon (1996) menciona que os três objetivos fundamentais de um SGP são:

- Utilização de um conjunto de informações confiáveis a fim de auxiliar a gestão superior;
- Fornecer conforto e segurança aos usuários que trafegam na via, reduzindo os custos de operações dos veículos;
- Embasar – de forma técnica, administrativa e econômica – os tomadores de decisão na escolha estratégica das intervenções em uma rede de pavimentos.

A Figura 4 mostra um fluxograma de um SGP. O primeiro passo é definir e identificar os segmentos dos pavimentos para realizar a análise. O passo seguinte corresponde em levantar

a situação do pavimento, obtendo informações sobre as características físicas, o estado de deterioração, anotando-se as extensões e os níveis de severidade dos segmentos. A análise em nível de rede permite a escolha das alternativas das estratégias de manutenção e reabilitação. Em seguida é realizada uma análise em nível de projeto, para as definições das atividades de manutenção, ou, caso seja necessário, de dimensionamento de reforços ou de reconstrução. A partir destas definições são efetuadas as análises econômicas e estabelecidas às prioridades (FERNANDES JÚNIOR *et al.*, 2003).

Figura 4 – Fluxograma básico de um SGP



Fonte: Fernandes Júnior *et al.* (2003)

Um Sistema de Gerência de Pavimentos deve ser adaptativo, isto é, não existe um começo bem elaborado para sua concepção. Ele nasce a partir de um problema ou de um conjunto de problemas, porém não se deve perder de vista a coerência global do sistema pretendido. Por exemplo, um SGP poderá começar pela avaliação da situação dos pavimentos e evoluir posteriormente até os procedimentos de manutenção e reabilitação. Vale ressaltar que

um banco de dados confiável é a condição principal a ser considerada no desenvolvimento de um sistema de gerência. A qualidade e a veracidade dos dados condicionam todo o sistema (FERNANDES JÚNIOR *et al.*, 2003).

De modo geral, os órgãos rodoviários não possuem autonomia para definir a concentração dos recursos financeiros para a manutenção e conservação da sua malha rodoviária. Geralmente gestores da área financeira é que têm esse poder de decisão, entretanto muitos não detêm de conhecimentos técnicos. Por isso, é extremamente necessário que haja uma ferramenta capaz de fornecer informações técnicas e confiáveis que expressem o estado atual e futuro da rodovia, de modo que o adiamento da manutenção da malha poderá causar um envelhecimento antes do período normal e até gerar um processo de deterioração irreversível (PATERSON, 1987).

2.1.2 Coleta de dados

A disponibilidade de dados confiáveis e precisos é uma etapa fundamental em qualquer Sistema de Gerência de Pavimentos. As atividades de obtenção de dados são de grande importância em um SGP, por servirem como base das análises e decisões a serem tomadas. As informações devem ser coletadas com objetividade, confiabilidade e atualidade (AASHTO, 1990).

Dentre as despesas de um SGP, a coleta de dados é a etapa de maior custo unitário. Em virtude disso, há uma tendência cada vez maior de se utilizar equipamentos automáticos para a coleta, permitindo um alto volume na obtenção dos dados e um processamento mais rápido com pequenas interrupções no tráfego. Os dados para os SGPs em nível de rede, devem ser colhidos de forma cautelosa e analisadas as informações que possam vir a comprometer a confiabilidade dos levantamentos. Deve-se efetuar um filtro dos dados a fim de melhorar a confiabilidade das informações coletadas (MARCON, 1996). A qualidade das informações coletadas, processadas e apresentadas determina o valor de um sistema de gerência de pavimentos (HAAS *et al.*, 1994).

Devem ser obtidos dados de inventário, condições do pavimento, custos e tráfego. No inventário é realizada uma coleta dos registros históricos disponíveis do órgão, com as informações características de cada trecho, como: tipo de pavimento, materiais das camadas, ano de construção e outras informações relevantes. Nas condições do pavimento, as informações coletadas são: irregularidade, capacidade estrutural, desgaste e segurança. A determinação dos custos envolve muitas variáveis principalmente nos gastos com os veículos e na duração

da viagem, portanto devem ser coletadas as informações sobre os custos de construção e de manutenções realizadas. No tráfego são obtidas informações de contagem e pesagem de veículos para que possa prever a demanda e o crescimento do tráfego (PATERSON, 1987).

2.1.3 Tipos de defeitos

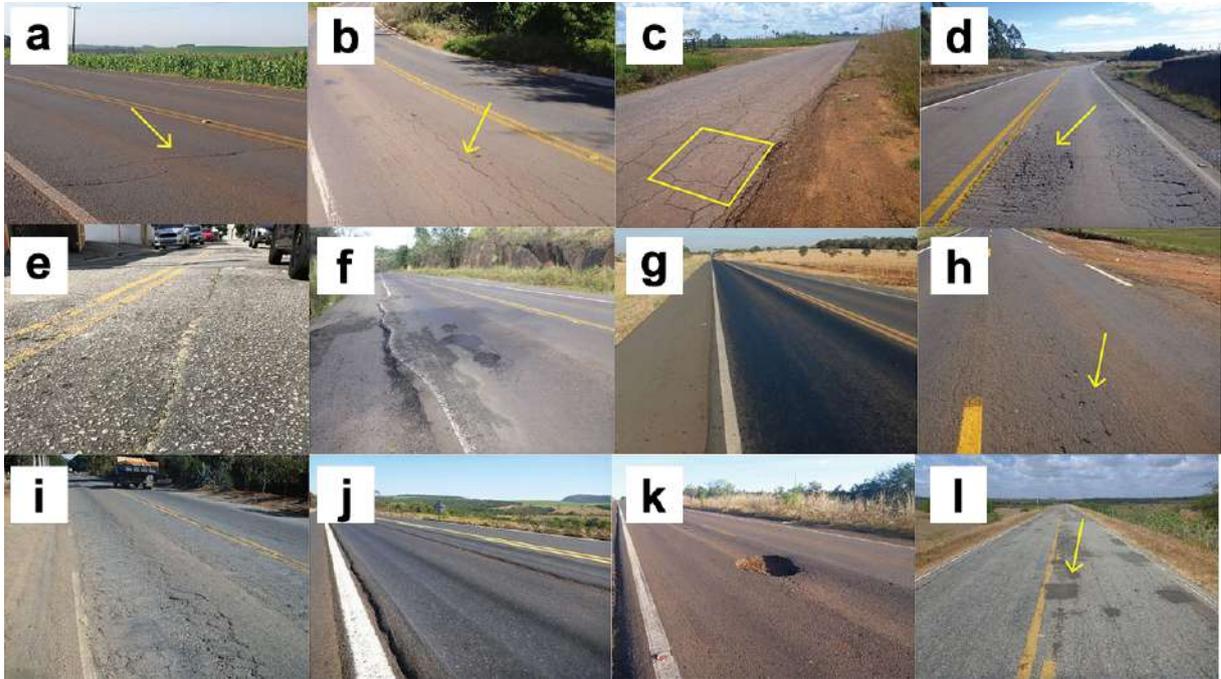
Segundo o *Strategic Highway Reserch Program* (SHRP, 1993), os pavimentos podem apresentar uma grande variedade de patologias, que neste trabalho iremos denominar por defeitos. Os defeitos nada mais são do que danos ou deteriorações causados na superfície dos pavimentos asfálticos, podendo ser causados pelo tráfego, pelo meio ambiente e por falhas nas construções. Os defeitos podem surgir na superfície da rodovia por inúmeros fatores. Logo, falhas nas etapas de projeto e execução podem culminar na criação ou na evolução de defeitos que irão afetar a serventia, as capacidades funcionais e estruturais dos pavimentos, gerando desconforto aos usuários.

Defeitos de classes funcionais se associam à qualidade e à segurança do pavimento. Como exemplo, podemos citar os afundamentos de trilhas de roda e a exsudação. Os defeitos de classes estruturais estão relacionados à perda de capacidade do pavimento em suportar as cargas que o solicitam. Um exemplo é a descontinuidade provocada pelo trincamento por fadiga de alto nível de severidade (DOMINGUES, 1993).

No território brasileiro, os defeitos em sua maioria estão relacionados às trincas, à deformação permanente nas trilhas de roda, aos buracos (ou panelas), aos remendos, ao desgaste do agregado, ao bombeamento, ao escorregamento e a exsudação (HAAS *et al.*, 1994). Assim, serão apresentados os principais defeitos encontrados nos pavimentos asfálticos.

Na Figura 5, são apresentados os principais tipos de defeitos encontrados nos pavimentos rodoviários: trincas transversais (a), trincas longitudinais (b), trincas em blocos (c), trincas couro de jacaré (d), bombeamento (e), escorregamento (f), exsudação (g), desgaste (h), deformação permanente nas trilhas de roda (i/j), buracos (k) e remendos (l).

Figura 5 – Principais Tipos de Defeitos: trincas transversais (a), trincas longitudinais (b), trincas em blocos (c), trincas couro de jacaré (d), bombeamento (e), escorregamento (f), exsudação (g), desgaste (h), deformação permanente nas trilhas de roda (i/j), buracos (k) e remendos (l)



Fonte: Adaptado de Barbosa e Moura (2018)

Conforme DNIT 007/2003a-PRO, a trinca é definida como “qualquer descontinuidade na superfície do pavimento, consistindo em aberturas de maior ou menor porte, apresentando-se sob diversas formas” e a definição da classe da trinca é de acordo com a abertura que a mesma apresenta. Os tipos de trincamentos nos pavimentos asfálticos são: por fadiga, envelhecimento, reflexão e devido à variação de temperatura. As trincas transversais, conforme mostrado na Figura 5a, formam-se em ângulos aproximadamente retos em relação à linha central da via, sendo espaçados regularmente (ADLINGE; GUPTA, 2013). As trincas longitudinais, conforme mostrado na Figura 5b, ocorrem de forma isolada e se manifestam paralelamente ao eixo da pista (CNT, 2018). Segundo DNIT (2005), as trincas em blocos são defeitos que se apresentam em formato bem definido de blocos compostos, constituindo-se por várias trincas conectadas, com lados bem definidos e com aspecto que se assemelha a um retângulo, podendo, ou não, exibir erosões acentuadas nas bordas (Figura 5c). As trincas couro de jacaré correspondem a um tipo de defeito que se surge no pavimento por meio de trincas interligadas, sem direções preestabelecidas, e como o próprio nome sugere, o formato é parecido com um couro de jacaré ou crocodilo (Figura 5d), dependendo da severidade existirá erosão nas bordas (DNIT, 2005). As rachaduras apresentadas nas trincas couro de jacaré, levam à desintegração da superfície,

ocasionando o surgimento de buracos (ADLINGE; GUPTA, 2013).

Segundo Bernuccii *et al.* (2008), o bombeamento de finos ocorre como consequência da ação do tráfego sob uma estrutura com presença de água, onde os finos sobem para a superfície por meio de trincas, juntas e outros defeitos (Figura 5e).

O defeito do tipo escorregamento é a movimentação do revestimento em consideração as camadas inferiores do pavimento, e a principal característica é o surgimento de trincas em figura de meia-lua (Figura 5f). O escorregamento é constantemente encontrado em trechos da via com grande índice de aceleração e frenagem dos veículos, como nas rampas acentuadas, curvas horizontais de raio pequeno, interseções e próximo às paradas de ônibus ou lombadas (DNIT, 2005).

A exsudação é um tipo de defeito em que a película ou filme de material betuminoso se estende na superfície da via, sendo gerada por causa do deslocamento do ligante através do revestimento (DNIT, 2005). Com isso, é possível observar a formação de manchas de diferentes dimensões (Figura 5g). Não há local determinado para a ocorrência desse defeito, porém, constantemente, a exsudação se apresenta nas trilhas de rodas.

O desgaste é um tipo de defeito que se caracteriza pelo desprendimento do agregado ou da argamassa fina do revestimento, tornando a superfície do pavimento visivelmente áspera (DNIT, 2005). Essa aspereza aparente é muito significativa, em consequência dos esforços tangenciais provocados pelo tráfego dos veículos (Figura 5h).

Conforme DNIT (2005), a deformação permanente nas trilhas de rodas, ou o afundamento de trilha de roda, pode ser dividido em dois tipos: afundamento por consolidação (Figura 5i) e afundamento plástico (Figura 5j). O afundamento por consolidação se caracteriza por ser um abatimento na trilha de roda, menos perceptível do que o afundamento plástico, pois a ocorrência não apresenta nenhuma mudança brusca nas laterais da pista. Os principais fatores para ocorrência do afundamento por consolidação são: compactação insuficiente de alguma camada do pavimento, mistura asfáltica inadequada e enfraquecimento de uma ou mais camadas por causa da infiltração de água (DNIT, 2005). O afundamento plástico, ao contrário do afundamento por consolidação, além de apresentar um buraco formado na trilha, há também a formação de uma elevação na lateral da via. É um defeito que começa com a ruptura de uma ou mais camadas do pavimento, ocasionando a elevação lateral do pavimento devido à movimentação dos materiais, na qual fica visível a ruptura por afundamento plástico (DNIT, 2005).

Os buracos ou panelas (Figura 5k) são irregularidades que se apresentam por meio de cavidades formadas inicialmente no revestimento do pavimento. Eles possuem dimensões e profundidades variadas, prejudicando estruturalmente o pavimento e ocasionando a entrada de água nas camadas subjacentes (DNIT, 2005). Dentre outros fatores, os buracos podem evoluir a partir dos trincamentos por fadiga na fase final e pela desintegração fixada na superfície do pavimento. Em outras palavras, com o passar do tempo as trincas se interligam e formam pequenas placas sem vínculo com bordas erodidas. Com isso, sem o devido tratamento formam-se grandes buracos no revestimento asfáltico que possibilitam a infiltração da água (DNIT, 2005).

O remendo é a correção de um defeito identificado na via (DNIT, 2005). A área que contém o defeito deve ser substituída por um material igual ou similar, de modo que o reparo se apresente em formato de retângulo (Figura 5l). Segundo Adlinge e Gupta (2013), o remendo é parte do pavimento que foi removido e substituído, e ele serve para fazer o reparo dos defeitos na via. A existência de um remendo na rodovia é avaliada como uma falha no pavimento, pois a execução ocasiona o mau funcionamento da estrutura original, gerando irregularidade longitudinal e conseqüentemente desconforto ao usuário.

2.1.4 Levantamento de defeitos e avaliação dos pavimentos

O levantamento de defeitos embasa o diagnóstico da situação funcional, proporcionando a definição de uma solução adequada para indicar a melhor alternativa de reparo. Além disso, é essencial coletar dados sobre a localização e a evolução de cada tipo de defeito para que possam ser estabelecidas e definidas as estratégias de intervenção e as atividades de manutenção e restauração (MARCON, 1996; YSHIBA, 2003).

Os principais objetivos do levantamento dos defeitos surgidos na superfície dos pavimentos são:

- Identificar os tipos, severidade e extensão dos defeitos aparentes;
- Determinar índices de condição ou aptidão dos pavimentos;
- Diagnosticar os problemas apresentados pelo pavimento (mecanismos de degradação);
- Determinar as necessidades atuais e futuras de manutenção (evitar uma deterioração acelerada no futuro);
- Auxiliar no dimensionamento do pavimento a ser restaurado;

- Estabelecer prioridades na programação de investimentos sob restrição orçamentária;
- Elaborar curvas de previsão de deterioração;
- Estimar a vida restante dos pavimentos.

De acordo com Haas e Hudson (1978), a etapa de avaliação dos pavimentos é fundamental, senão a principal etapa de um sistema de gerência de pavimentos. É na fase de avaliação que se pode aferir o grau de deterioração do pavimento, quais atividades de manutenção e reabilitação são convenientes, verificar se o pavimento foi bem construído e se está atendendo devidamente às especificações para que fora projetado. Esta atividade possibilita que sejam estudadas as condições funcionais, estruturais e operacionais dos pavimentos, mediante a obtenção dos dados fundamentais que alimentam periodicamente o SGP.

É com base nos dados levantados através da avaliação funcional, estrutural e de superfície dos pavimentos que se realizam os diagnósticos e estratégias de intervenção, além de permitir estimar a vida restante de um pavimento que sofreu solicitações extremas ou para as quais não foi projetado (abalos sísmicos, inundação, excesso de carga ou problemas de natureza construtiva) e determinar possíveis necessidades de reforço estrutural caso o pavimento seja submetido a solicitações de tráfego maiores que aquelas para as quais fora dimensionado (BERNUCCII *et al.*, 2008).

Inúmeros motivos contribuem para o desempenho de um pavimento e o aumento dos defeitos no decorrer de sua vida útil. Esses motivos são retratados por muitas variáveis que representam as mudanças de estado e de comportamento do pavimento. As principais variáveis a serem avaliadas são (PATERSON, 1987):

- Comportamento funcional e estrutural: irregularidade, deflexões, atrito pneu pavimento, profundidade de trilha de roda e defeitos superficiais;
- Tráfego: volume e classificação dos veículos, carga por eixo, tipo de eixo, pressão de enchimento dos pneus, tipo de suspensão e distribuição horária do fluxo;
- Clima: variações de temperatura, pluviometria e teor de umidade nas camadas;
- Manutenção e reabilitação: alteração das condições funcionais e estruturais provocadas pelos serviços de manutenção e reabilitação e registro dos parâmetros relativos às intervenções efetuadas;
- Características físicas e químicas dos materiais de construção.

A condição estrutural do pavimento indica por quanto tempo este manterá um nível

adequado de condição funcional ou serventia. A condição de um pavimento em um determinado instante da observação, representa o nível de degradação resultante do processo de deterioração (DNER, 1998).

Avaliação e monitoramento das condições do pavimento devem ser realizados de forma periódica e permite que sejam estimados quatro componentes principais: conforto de rodagem, capacidade de suportar a solicitação das cargas, segurança (aderência pneu-pavimento e resistência à derrapagem) e conforto (visual e de ruídos gerados pelo tráfego). (MEDINA, 1997).

A avaliação de danos em pavimentos nos permite que sejam realizados os reparos a fim de reestabelecer a segurança e o conforto aos usuários. Para que os reparos necessários sejam implementados da forma mais adequada e no momento certo, com a melhor aplicação dos recursos financeiros disponíveis, essa avaliação deverá ser a mais eficiente possível. É importante considerar tanto os aspectos de conforto como de segurança, para que a avaliação de uma rodovia seja classificada em boa ou má qualidade. Uma rodovia confortável e segura, conseqüentemente, será uma rodovia com tráfego mais econômico (BALBO, 2007).

Dito isto, foram criados métodos de avaliação do pavimento, podendo ser classificados em: subjetivos e objetivos (BERNUCCII *et al.*, 2008). A avaliação subjetiva possui como base a opinião dos usuários sobre a rodovia conforme o conforto identificado durante a trafegabilidade, identificando o nível de satisfação dos motoristas com o pavimento, através de atribuição de notas ou conceitos. A avaliação objetiva avalia a segurança da rodovia e a qualidade de rolamento de acordo com as irregularidades e os defeitos identificados no pavimento, dessa forma, as medições são realizadas através de vários métodos.

I - Avaliação subjetiva

No Brasil, a Norma DNIT 009/2003c-PRO define alguns procedimentos para se fazer uma avaliação subjetiva de forma adequada. Essa norma é utilizada em nível federal, estadual e municipal, quando for o caso.

O Valor de Serventia Atual (VSA), que representa as condições de conforto e segurança ao rolamento percebidas pelos usuários da rodovia. O VSA é uma atribuição numérica compreendida em uma escala de 0 (muito fraco) a 5 (muito bom), dada pela média de notas de avaliadores para o conforto ao rolamento de um veículo trafegando em um determinado trecho, em um dado momento da vida do pavimento. Esta escala compreende cinco níveis de serventia,

conforme expresso na Tabela 2, sendo também adotada no Brasil pelo Procedimento DNIT 009/2003c-PRO.

Tabela 2 – Níveis de serventia

Padrão de conforto ao rolamento	Avaliação (faixa de notas)
Péssimo	0 a 1
Ruim	1 a 2
Regular	2 a 3
Bom	3 a 4
Excelente	4 a 5

Fonte: DNIT 009/2003c-PRO

II - Avaliação objetiva

No Brasil, a Norma DNIT 006/2003-PRO e DNIT 007/2003a-PRO, define alguns procedimentos para poder identificar as ocorrências aparentes e as deformações permanentes nas trilhas de roda. Em linhas gerais são determinadas: trincas isoladas (transversais ou longitudinais) ou interligadas (em bloco ou com aparência de couro de jacaré), deformação permanente (plástico ou de consolidação), ondulação ou corrugação, escorregamento, exsudação, desgaste, panelas ou buracos.

A situação dos pavimentos de uma malha sofre variações ao longo de sua extensão. No decorrer da malha, torna-se indispensável dividi-la em segmentos, isso por causa das suas características físicas e de condições. Os métodos mais utilizados são: (1) definir segmentos com extensão fixa, por exemplo, aproximadamente 100 metros, e (2) dividir em segmentos homogêneos. A divisão em extensão fixa gera uma enorme desvantagem, uma vez que pode apresentar diferenças nas estruturas dos pavimentos. Os segmentos homogêneos de extensões variáveis devem conter a mesmo tipo de constituição de estrutura (tipo de revestimento, base, sub-base e subleito), o mesmo tipo de materiais das camadas e espessuras, mesma situação climática e a mesma incidência de tráfego (DNER, 1998).

A avaliação das condições funcionais e estruturais de um pavimento devem ser realizadas por procedimentos adequados às suas características, utilizando-se várias metodologias para levantamento de defeitos que aparecem na superfície dos pavimentos. Portanto, estas metodologias possuem como objetivo:

- Avaliar a situação da faixa de rolamento relativa ao conforto e à segurança que são oferecidos aos usuários;
- Preparar um inventário que contenha as principais ocorrências de defeitos que foram

identificados na superfície das faixas de rolamento asfálticos;

- Identificar os fatores que causaram os defeitos na superfície dos pavimentos, através de medições;
- Caracterizar e descrever cada defeito, quanto ao tipo, à severidade e à densidade.

Atualmente, a determinação do VSA tem sido substituída pelo LVC – “Levantamento Visual Contínuo da Superfície de Pavimento Flexível e Semi-rígido”, nos trechos onde ocorre este tipo de revestimento, considerando as ocorrências do pavimento descritas na norma DNIT 006/2003 PRO.

2.1.5 Métodos para avaliação de defeitos

Dentre os métodos disponíveis, a avaliação da condição de superfície dos pavimentos, geralmente, ocorre de forma visual. No entanto, na realização da medição alguns métodos fazem o uso de instrumentos adequados. A escolha de um determinado método é com base no tamanho da amostra de pavimento a ser avaliada, nos tipos de defeitos de acordo com o uso do pavimento (urbano, rodoviário ou aeroportuário), no modo de aferir o grau de condição do pavimento e em quais tipos de pavimento se aplicam (RODRIGUES, 1987).

Portanto, dado as diferentes formas de deterioração nos pavimentos, utiliza-se dois métodos para realizar as avaliações: manuais e automatizados (HAAS *et al.*, 1994).

I - Levantamento Manuais

Nos métodos de levantamento manuais, os avaliadores registram as características dos defeitos em planilhas que devem conter as informações de localização para posterior processamento dos dados. São avaliados os acostamentos e as faixas de tráfego.

Os levantamentos podem ser realizados andando a pé ou dentro de um veículo trafegando em baixa velocidade, isto é, variando de 6,4 a 16 km/h (HAAS *et al.*, 1994). Durante o levantamento, a equipe de avaliadores juntamente com o motorista desce do veículo e, através do uso de ferramentas simples como trena e régua, identificam o tipo de defeito, sua extensão e sua severidade.

Para o caso em que os avaliadores percorram o trecho a pé, indica-se:

- A área das amostras deve ser suficiente para não dar margem à erros de interpretação e, suas posições, devem ter caráter aleatório selecionados através de procedimentos

estatísticos;

- A área das amostras deve corresponder a um mínimo de 10% da área total do pavimento quando o estudo for destinado a gerência de pavimentos em nível de rede e 25% quando for para nível de projeto (HAAS *et al.*, 1994);
- Recomenda-se a adoção do procedimento “DNIT 007/2003-PRO - Levantamento para avaliação da condição de superfície de subtrecho homogêneo de rodovias de pavimentos flexíveis e semirrígidos para gerência de pavimentos e estudos e projetos – Procedimento”, para determinar o tamanho e a localização das amostras.

II - Levantamentos Automatizados

Nos levantamentos automatizados, câmeras são acopladas aos veículos para realizar a captura de vídeos ou de fotografias. A velocidade média do veículo deve variar de 30 km/h a 110 km/h. Através das câmeras, as condições do pavimento são registradas em imagens ou vídeos, permitindo que a avaliação dos defeitos seja realizada posteriormente no escritório. Através de sensores é possível identificar e classificar os defeitos quanto ao tipo, severidade, integridade e frequência. Logo, há possibilidade associar as imagens e/ou vídeos capturados à outras informações coletadas, tais como: volume médio de tráfego, materiais utilizados nas camadas, dados de sinalização, dados de clima e entre outras informações utilizadas na construção dos pavimentos (BERNETT, 1998).

Com uma câmera acoplada a um veículo e um *Global Positioning System* – Sistema de Posicionamento Global (GPS) é possível catalogar os defeitos presentes no pavimento à medida em que se desloca pela rodovia. As câmeras podem ser fixadas na parte frontal e/ou traseira dos veículos, possibilitando o Levantamento Visual Contínuo (LVC) em que os avaliadores vão dentro de um veículo em movimento. O LVC, normalizado pelo DNIT (008/2003b-PRO), consiste em um levantamento visual da superfície do pavimento, incluindo pista e acostamento, onde é definido a localização de início e de fim de cada defeito e a severidade observada. O método baseia-se na verificação do estado geral da superfície asfáltica e dos danos nela presentes, resultando em três índices que são: Índice de Condição de Pavimentos Flexíveis (ICPF), Índice de Gravidade Global Expedito (IGGE) e o Índice do Estado de Superfície do Pavimento (IES).

2.1.6 Índices do pavimento

Uma vez que o levantamento de defeitos foi finalizado, registrado de forma adequada, separado em grupos homogêneos e identificados por seções, deve-se fazer uma avaliação de modo a combinar os defeitos entre si e quantificá-los. Após isso, podem ser obtidos os índices de degradação, sendo possível estabelecer uma análise mais apurada da condição do pavimento, que de acordo com a metodologia utilizada, essa quantificação pode ser calculada a partir de informações detalhadas sobre a extensão e nível de severidade de diferentes formas de danos gerados nos pavimentos (HAAS *et al.*, 1994).

Os índices de degradação são números gerados a partir de fórmulas matemáticas, tendo como entrada os dados dos defeitos avaliados. Como exemplo, existe o Índice de Condição do Pavimento (ICP) ou *Paviment Condition Index* (PCI), e Índice de Gravidade Global (IGG). Os cálculos destes índices são bastante utilizados na análise da situação atual dos pavimentos e na definição de critérios de priorização nos serviços de manutenção e reabilitação (HAAS *et al.*, 1994).

I - Paviment Condition Index (PCI)

O PCI indica o grau de degradação do pavimento. Este índice foi considerado na metodologia PAVER e Micro Paver, onde foi publicado pelo corpo de engenheiros do exército dos Estados Unidos (SHAHIN; KHON, 2005). Inicialmente foi criado para realizar a avaliação de pavimentos aeroportuários, no entanto passou a ser aplicado em rodovias, ruas e até estacionamentos por sua ampla aplicabilidade.

O PCI foi adaptado em sistemas de gerência de pavimentos urbanos como o *Metropolitan Transportation Commission* (MTC), utilizado na região metropolitana de San Francisco - Califórnia (CATION, 1987). O método pode ser usado em toda extensão da via ou por amostragem, de modo que cada segmento avaliado deve ter aproximadamente 225 m² e deve ser inventariado em uma planilha contendo os tipos de defeitos encontrados, a frequência que ocorrem e a severidade. A caracterização dos defeitos é apresentada na Tabela 3.

Tabela 3 – Defeitos do método PCI

Defeito	Forma de medir
Couro de jacaré	área
Exsudação	área
Trincas em blocos	extensão
Elevações e recalques	área
Corrugação	área
Afundamento localizado	área
Trincas de bordo	extensão
Trincas de reflexão de juntas	extensão
Desnível pista/acostamento	extensão
Trincas longitudinais e transversais	extensão
Remendos	área
Agregado polido	área
Panelas	unidade
Cruzamento ferroviário	área
Afundamentos de trilha de rodas	área
Escorregamento de massa	área
Fissuras devido ao escorregamento de massa	área
Inchamento	área
Desgaste superficial	área

Fonte: APS *et al.* (1998)

Este método sugere que o pavimento inicie de uma condição ótima, equivalente a 100 e cada defeito representa um fator de redução da nota. Portanto, a faixa de notas varia de 0 a 100, onde o valor 100 indica a melhor condição possível do pavimento, e o valor 0 indica a pior. A Tabela 4 demonstra essa escala.

Tabela 4 – Índice de Condição do Pavimento

Conceito	PCI (faixa de notas)
Excelente	100-86
Muito Bom	85-71
Bom	70-56
Regular	55-41
Ruim	40-26
Muito Ruim	25-11
Péssimo	10-0

Fonte: APS *et al.* (1998)

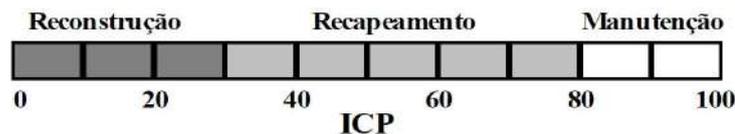
Desde seu surgimento, o PCI tem sido referência nos diferentes índices de defeitos, onde seu principal objetivo é determinar os fatores de ponderação para os defeitos do pavimento que permitam calcular o valor a deduzir de uma condição ideal (LANDERS *et al.*, 2001). O PCI obtido além de representar quantitativamente a condição do pavimento, serve para apoiar na tomada de decisão a respeito de quais intervenções são pertinentes na priorização de serviços.

II - Índice de Condição do Pavimento (ICP)

No Brasil, o PCI apareceu proposto em português por meio de uma adaptação do Instituto do Asfalto (1981), chamado Índice de Condição de Pavimento (ICP) (BERTOLLO; FERNANDES JUNIOR, 1997). Ele apresenta quinze defeitos e varia de 0 a 100, onde 100 representa uma ótima condição do pavimento.

O Instituto do Asfalto define os intervalos em função da importância de acordo com o tipo de defeito na caracterização de um índice de condição de pavimento. A proposta realizada por Bertollo e Fernandes Junior (1997), define os primeiros intervalos para uma cidade brasileira a partir de testes. O método ICP, propõe a seleção de estratégias de intervenção utilizando a escala que é mostrada na Figura 6.

Figura 6 – Estratégia de manutenção e reabilitação mais indicada baseada no valor do ICP



Fonte: Instituto do Asfalto (1981)

III - Índice de Gravidade Global (IGG)

No Brasil, um índice de avaliação de defeitos bastante utilizado é o Índice de Gravidade Global (IGG), avaliação objetiva da superfície de pavimentos flexíveis e semi-rígidos (DNIT 006/2003-PRO). O IGG é um parâmetro numérico que permite avaliação dos segmentos da rodovia segundo seu estado de degradação. Além disso, este índice reflete o estado de cada segmento considerado isoladamente, permitindo a comparação relativa entre os estados apresentados por segmentos distintos.

O IGG está baseado na caracterização de dez ocorrências de defeitos. Sendo desses, oito que apresentam tipos individuais de defeitos: trincas, afundamentos, corrugação, escorregamento, exsudação, desgaste, panelas e remendos. Os outros dois são derivados da mensuração das flechas nas trilhas de rodas. Portanto, o valor do IGG representa o efeito conjunto de uma ampla gama de deficiências estruturais atuantes no pavimento.

O cálculo do IGG considera cada defeito isoladamente correspondendo à um valor específico chamado Índice de Gravidade Individual (IGI). O IGI é estabelecido em função do peso de cada defeito, desse modo para cada ocorrência é considerado um valor de ponderação.

O IGG é calculado a partir da somatória dos IGI de cada um dos seguintes defeitos que são multiplicados por fatores de ponderação estabelecidos de acordo com cada caso. A condição do pavimento pode ser definida segundo o parâmetro do IGG, sendo apresentada na Tabela 5, referente aos específicos intervalos de valores e seus respectivos conceitos.

Tabela 5 – Degradação do Pavimento em função do IGG

Conceito	IGG (limites)
Ótimo	0 - 20
Bom	20 - 40
Regular	40 - 80
Ruim	80 - 160
Péssimo	> 160

Fonte: DNIT 006/2003 - PRO.

O método IGG, estabelecido pelo DNIT 006/2003-PRO, apresenta algumas limitações, uma vez que para o cálculo leva-se em consideração apenas o tipo de defeito dos segmentos, sem levar em conta a severidade (exceto para trincas) e considera apenas o número de ocorrências e não extensão dos defeitos. No entanto, o IGG permite que a situação do pavimento seja analisada e seja detalhado o perfil das falhas em cada segmento, uma vez que o método avalia 15% da área total do pavimento analisado.

IV - Índice de Condição dos Pavimentos Flexíveis e Semi-rígidos (ICPF)

O Índice de Condição dos Pavimentos Flexíveis e Semi-rígidos (ICPF) é um índice obtido a partir do levantamento de defeitos da superfície dos pavimentos, como panelas, trincas, entre outros defeitos. Este índice é realizado em relação aos índices contidos no Formulário do Levantamento (Apêndice A) que são avaliados por dois ou mais técnicos (DNIT, 008/2003b-PRO). O valor numérico do ICPF varia de 0 (para uma péssima condição) a 5 (para uma excelente condição), conforme mostrado na Tabela 6, onde é definido o conceito e a descrição das intervenções de acordo com o cálculo do ICPF.

Tabela 6 – Conceitos do ICPF

Conceito	Descrição	ICPF
Ótimo	NECESSITA APENAS DE CONSERVAÇÃO ROTINEIRA	5 - 4
Bom	APLICAÇÃO DE LAMA ASFÁLTICA - Desgaste superficial, trincas não muito severas em áreas não muito extensas	4 - 3
Regular	CORREÇÃO DE PONTOS LOCALIZADOS OU RECAPEAMENTO - pavimento trincado, com “panelas” e remendos pouco freqüentes e com irregularidade longitudinal ou transversal.	3 - 2
Ruim	RECAPEAMENTO COM CORREÇÕES PRÉVIAS - defeitos generalizados com correções prévias em áreas localizadas - remendos superficiais ou profundos.	2 - 1
Péssimo	RECONSTRUÇÃO - defeitos generalizados com correções prévias em toda a extensão. Degradação do revestimento e das demais camadas - infiltração de água e descompactação da base	1 - 0

Fonte: DNIT 006/2003 - PRO.

V - Índice de Gravidade Global Expedido (IGGE)

O Índice de Gravidade Global Expedido (IGGE) é realizado pela média dos dados contidos no Formulário de Levantamento (Apêndice B), sendo a média dos resultados levantados por dois ou mais avaliadores (DNIT,2003a).

A determinação do IGGE é dividida por panelas, remendos e demais defeitos conforme a Tabela 7.

Tabela 7 – Classificação do IGGE

Panelas (P) e Remendos (R)			
Frequência	Fator Fpr	Quantidade/Km	Gravidade
A – Alta		≥ 5	3
M – Média		2 – 5	2
B – Baixa		≤ 2	1
Demais defeitos (trincas, deformações)			
Frequência	Fator Ft e Foap(%)		Gravidade
A – Alta		≥ 50	3
M – Média		50 – 10	2
B – Baixa		≤ 10	1

Fonte: DNIT 006/2003 - PRO.

Na Tabela 8 é mostrada os pesos para o cálculo para cada quilômetro avaliado ou divisões de cada trecho de forma homogênea.

Tabela 8 – Pesos para cálculo

Gravidade	Pt	Poap	Ppr
3	0,65	1,00	1,00
2	0,45	0,70	0,80
1	0,30	0,60	0,70

Fonte: DNIT 006/2003 - PRO.

VI - Índice do Estado da Superfície do Pavimento (IES)

No Índice do Estado da Superfície do Pavimento (IES), os valores estão compreendidos de 0 a 10 e é analisado de acordo com dois índices: ICPF e do IGGE (Apêndice C). Os valores do IES juntamente com o Código e o Conceito atribuídos ao estado da superfície do pavimento são definidos de acordo com a Tabela 9.

Tabela 9 – Índice do Estado da Superfície do Pavimento

Descrição	IES	Código	Conceito
$IGGE \leq 20$ e $ICPF > 3,5$	0	A	Ótimo
$IGGE \leq 20$ e $ICPF < 3,5$	1	B	Bom
$20 \leq IGGE \leq 40$ e $ICPF > 3,5$	2	B	Bom
$20 \leq IGGE \leq 40$ e $ICPF \leq 3,5$	3	C	Regular
$40 \leq IGGE \leq 60$ e $ICPF > 2,5$	4	C	Regular
$40 \leq IGGE \leq 60$ e $ICPF \leq 2,5$	5	D	Ruim
$60 \leq IGGE \leq 90$ e $ICPF > 2,5$	7	D	Ruim
$60 \leq IGGE \leq 90$ e $ICPF \leq 2,5$	8	E	Péssimo
$IGGE > 90$	10	E	Péssimo

Fonte: DNIT 006/2003 - PRO.

O método LVC apresenta a vantagem de determinar não só o ICPF – Índice de Condição dos Pavimentos Flexíveis, semelhante ao VSA, como proporciona os elementos necessários para avaliação do IGGE – Índice de Gravidade Global Expedito.

Os índices de degradação mencionados possuem bastante relevância na área de gerência de pavimentos e faz-se necessário mencioná-los. No entanto, nesta pesquisa não faremos o uso deles, uma vez que requerem outros parâmetros de entrada, além da quantidade de buracos e remendos, para calcular seus valores finais, conforme demonstrado nos Apêndices A, B e C deste trabalho.

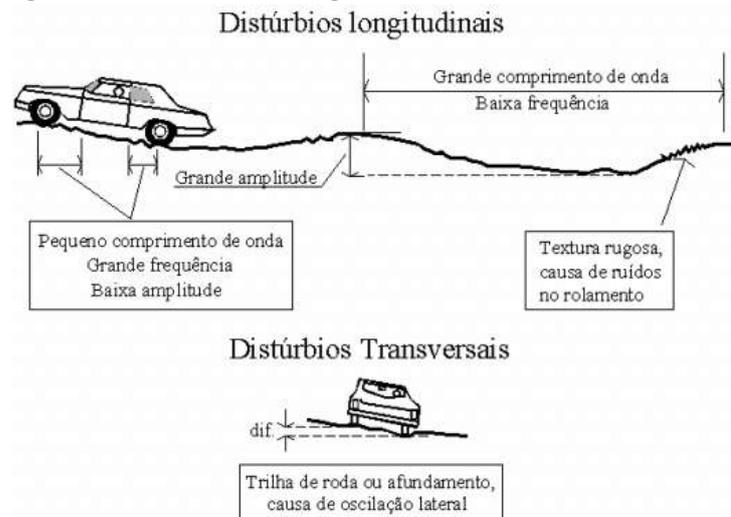
2.1.7 Irregularidade longitudinal

A irregularidade longitudinal de um pavimento é definida como o desvio da superfície da rodovia com relação a um plano de referência, que afeta a dinâmica dos veículos, a qualidade de rolamento e as cargas dinâmicas sobre a via (DNER-PRO 182/1994).

A American Society for Testing and Materials conceitua a irregularidade longitudinal como sendo o "desvio de uma superfície de pavimento em relação a uma superfície plana, cuja magnitude é capaz de afetar a dinâmica dos veículos, a qualidade do rolamento, as cargas dinâmicas sobre a via e a drenagem"(ASTM, 1982).

A irregularidade longitudinal é influenciada por vários fatores, como: problemas construtivos, manutenções realizadas, trincamento, ação do tráfego, desgaste, deformações permanentes, entre outros. Estes fatores causam distúrbios da superfície, afetando a dinâmica dos veículos em movimento que, por sua vez, influencia os custos de operação dos automóveis pelo aumento do seu desgaste, tempo de viagem e manutenção. Esses distúrbios resultam em forças que provocam deslocamento vertical e lateral do veículo. O deslocamento vertical é gerado pelos distúrbios longitudinais do perfil do pavimento, sendo o principal fator de desconforto do usuário. O deslocamento lateral é provocado pelas curvas horizontais e pelas diferenças das elevações transversais do pavimento. Estes deslocamentos também são responsáveis pelo aumento da ação das cargas dinâmicas dos veículos sobre a superfície do pavimento, que acelera a deterioração da sua estrutura (HAAS *et al.*, 1994). A Figura 7, caracteriza os distúrbios longitudinais e transversais.

Figura 7 – Distúrbios longitudinais e transversais



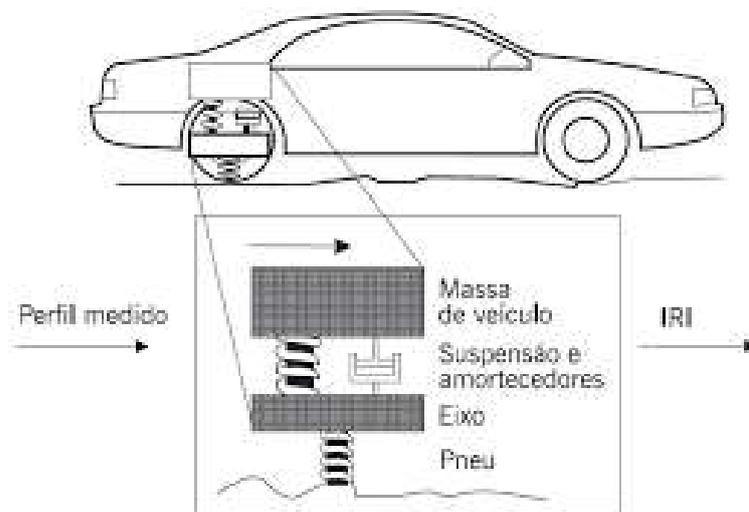
Fonte: Adaptado de Yoder e Witczak (1975)

A irregularidade longitudinal afeta a segurança dos veículos, quando a aceleração e as forças verticais produzem cargas dinâmicas que são transmitidas sobre os pneus, deformando-os totalmente, como se fosse uma mola comprimida, ou causando grandes forças diferenciais sobre o veículo, diminuindo sensivelmente o desenvolvimento das forças de atrito entre pneu e o pavimento, podendo causar o descontrole do veículo.

Existe um índice internacional para a medida da irregularidade, chamado de *International Roughness Index* – Índice de Irregularidade Internacional (IRI). O IRI é definido matematicamente a partir de um perfil obtido com nível e mira, visando simular os movimentos

verticais induzidos a uma roda (modelo quarto-de-carro) sob velocidade aproximada de 60 km/h e é expresso em m/km (Figura 8). A irregularidade de cada segmento da via pode ser caracterizada pelo valor médio do IRI para o segmento, por exemplo o valor médio do IRI calculado para as trilhas de roda direita e esquerda. Os procedimentos pertinentes ao atributo irregularidade de pavimento rígido estão especificados pelo Departamento Nacional de Infraestrutura de Transportes (DNIT) e podem ser mensurados de forma objetiva, por meio de DNIT (2004a), e quantificada de forma subjetiva por meio de DNIT (2004b).

Figura 8 – Desenho esquemático para a determinação do IRI utilizando um veículo



Fonte: Adaptado de Sayers e Karamihis (1998)

O perfil longitudinal do pavimento pode ser medido no campo e avaliado utilizando um equipamento computacional, ou pode ser processado por meio de um equipamento mecânico do tipo resposta (HAAS *et al.*, 1994). Os veículos utilizados para os levantamentos de avaliação visual da superfície dos pavimentos podem realizar concomitantemente a avaliação do perfil longitudinal. Esta associação nos levantamentos de campo facilita o sincronismo dos dados obtidos, conseqüentemente na avaliação conjunta do desempenho funcional do pavimento. Para os levantamentos em conjunto dos dados de IRI e LVC, deve-se observar o limite máximo de velocidade no deslocamento sobre o trecho avaliado, sendo 50 km/h. Como no agrupamento das ocorrências representativas do Levantamento Visual Contínuo, a avaliação do perfil longitudinal deverá representar extratos a cada 20m determinando o IRI para o segmento (DNIT-IPR 745/2011).

2.1.8 Equipamentos de medição

Existem diversos tipos de equipamentos de medidas da irregularidade longitudinal da superfície de pavimentos, tais como: régua, régua deslizante, perfilômetro a laser ou através de medidores tipo resposta – SMITR, mecânicos ou baseado em acelerômetro. Na literatura, vários autores citam os diversos equipamentos ou processos que são utilizados para a medição de parâmetros ligados às irregularidades, dentre eles, DNER (1998), Marcon (1996), Sayers e Karamihas (1998), Farias e Souza (2010), Haas *et al.* (1994).

O perfilômetro a laser foi desenvolvido na década de 60 pela General Motors - GM (HAAS *et al.*, 1994) e se tornou disponível comercialmente somente na década de 80. A grande diferença dele é que as medidas podiam ser feitas a partir de um veículo trafegando a altas velocidades. Conforme mostrado na Figura 9, o perfilômetro é acoplado a um veículo possibilitando coletar informações do pavimento através do uso de acelerômetros, módulos a laser, um hodômetro, um GPS e um sistema computacional para coleta e processamento de dados. Os dados são processados no próprio equipamento embarcado no veículo e ao final do levantamento esses dados são salvos em arquivos de texto que podem ser transferidos para manipulação em sistemas computacionais (BARELLA, 2008).

Figura 9 – Perfilômetro a laser acoplado no veículo



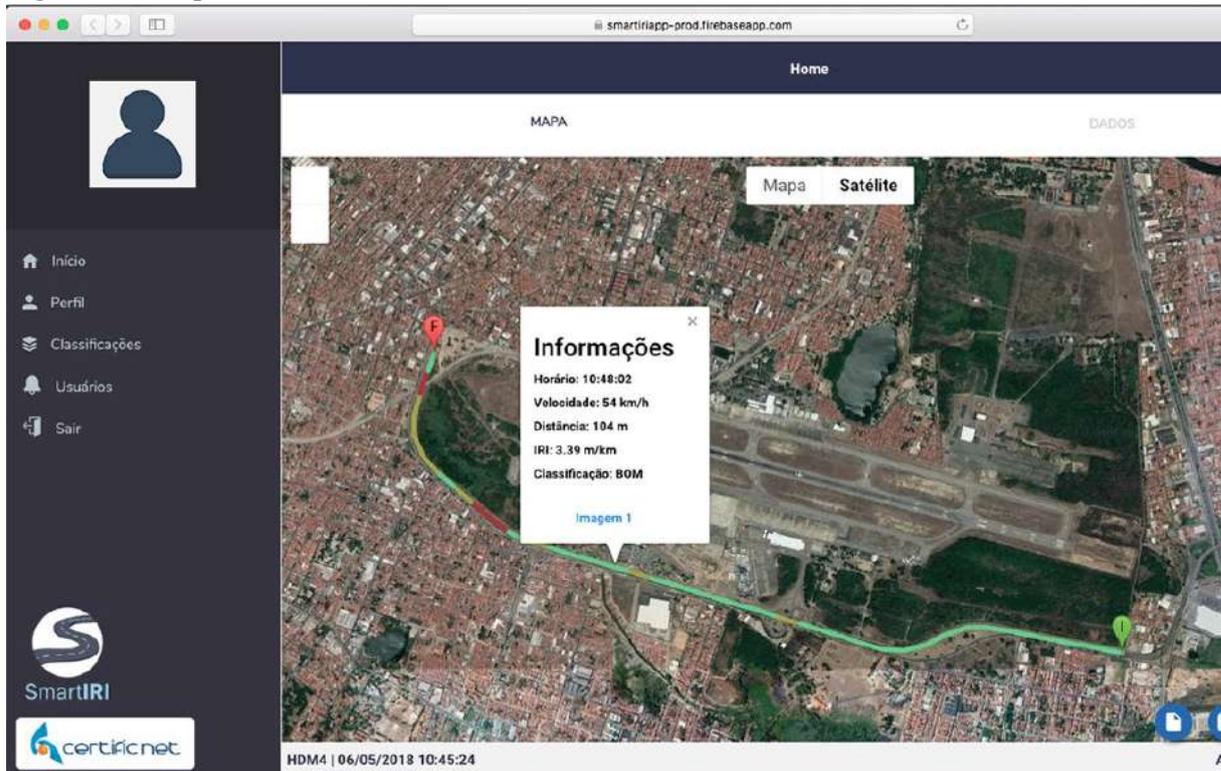
Fonte: Oliveira e Albuquerque (2017)

Com a medida do IRI é possível classificar as condições dos trechos de rodovias em bons, regulares e ruins, de modo que, cada país estabelece o seu limite de aceitabilidade para o valor do IRI. Além das condições específicas, considera-se o grau de importância atribuído pelos usuários à irregularidade quanto as avaliações dos pavimentos.

Com a popularização dos *smartphones* e a inclusão de diversos sensores, surgiram muitos estudos com a proposta de substituir o perfilômetro por um *smartphone* acoplado em

um veículo com a utilização de um aplicativo (Figura 10). Com um acelerômetro e um GPS, os mesmos recursos utilizados no perfilômetro e que estão inclusos nos celulares atuais, grupos de pesquisa e empresas desenvolveram aplicativos capazes de identificar em que nível de condição um trecho de uma rodovia se encontra para tráfego. Na Figura 10 é mostrado o aplicativo SmartIRI desenvolvido pela empresa Certific Net.

Figura 10 – Aplicativo SmartIRI



Fonte: Certific Net (2019)

O SmartIRI é acoplado em um veículo por meio de um suporte fixado no para-brisas do veículo e baseia-se na utilização de sensores presentes em *smartphones*, tais como o acelerômetro e o sensor do Sistema de Posicionamento Global (GPS - *Global Positioning System*), para a obtenção dos dados de aceleração vertical, velocidade e geolocalização. Os dados provenientes do acelerômetro e do receptor de GPS são obtidos do *smartphone* e enviados para uma nuvem computacional de modo a permitir que a obtenção do IRI georreferenciado seja informado ao usuário em tempo real (CERTIFIC NET, 2019). Segundo Almeida (2018), os testes obtidos através de medições em campo com o uso do protótipo SmartIRI em versão embarcada, mostraram que os valores calculados de IRI apresentaram correlação satisfatória com dados fornecidos por outro aplicativo de medição de irregularidade longitudinal, como: método de nível e mira, medições do perfilômetro a laser e análise subjetiva por meio do Valor

de Serventia Atual (VSA).

2.2 *Machine Learning*

O *Machine Learning* (aprendizagem de máquina) é a capacidade de fazer com que uma máquina aprenda através de tentativa e erro a realizar alguma ação com eficiência. O aprender de uma máquina pode ser definido como o reconhecimento de padrões em algum cenário específico, seja ele, uma sequência de imagens, uma sequência de números probabilísticos, alterações no clima de uma determinada região, entre outros (EL NAQA; MURPHY, 2015).

O *Machine Learning* é a prática mais básica de usar algoritmos para coletar dados, aprender com eles, e então fazer uma determinação ou previsão sobre alguma coisa no mundo. Então ao invés de implementar as rotinas de *software* manualmente, com um bloco de código específico de instruções para completar uma tarefa em particular, a máquina é treinada usando uma grande quantidade de dados e algoritmos que possibilitam a capacidade de aprender como executar a tarefa. O *Machine Learning* é uma das áreas da computação que permite tornar a inteligência artificial real (MITCHELL, 2006).

Esta área foi umas das primeiras técnicas de implementação de Inteligência Artificial (IA). Nessa abordagem utilizou-se algoritmos de árvore de aprendizado, programação lógica indutiva, agrupamento, aprendizado reforçado, redes Bayesianas, entre outros. (COPELAND, 2016).

Vale ressaltar que as técnicas de *Machine Learning* possuem seus desafios. Os dados supracitados não apresentam resultados satisfatórios, especialmente quando o objeto não se encontra perfeitamente visível. No cenário do *Machine Learning*, a visão computacional e detecção de imagens não consegue garantir a mesma eficácia na resposta como os humanos, ela é rasa e propensa a erros (COPELAND, 2016).

2.3 **Redes Neurais Artificiais**

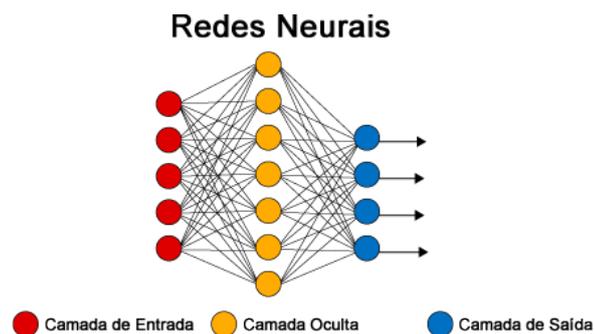
Rede neurais são inspiradas pelo entendimento da biologia do nosso cérebro — todas as interconexões entre neurônios. Mas, diferente de um cérebro biológico onde qualquer neurônio pode se conectar com qualquer outro neurônio dentro de uma certa distância física, as redes neurais artificiais têm camadas discretas, conexões e direções de propagação de dados (HAYKIN, 2001).

O cérebro é um computador (sistema de processamento de informação) altamente complexo, não linear e paralelo (HAYKIN, 2001). Partindo desse princípio, foi pensado em elaborar um algoritmo que fosse capaz de processar informações de maneira semelhante ao cérebro humano, ou seja, foi criada a Rede Neural Artificial (RNA).

As Redes Neurais Artificiais não são necessariamente novas, existem pelo menos desde a década de 1950. Mas durante muitos anos, embora a arquitetura desses modelos tivesse evoluído, ainda faltavam dois recursos que os fizessem realmente funcionar, são eles: dados e processamento. O volume de dados gerado em variedade e velocidade cada vez maior, permite criar modelos e atingir altos níveis de precisão. Para processar grandes modelos de redes neurais com grandes quantidades de dados é necessário computadores com poder de processamento suficiente (VAZ, 2018). Nos dias de hoje temos esses dois recursos a nossa disposição, o que permitiu a aplicação dos estudos nessa área no nosso dia a dia.

A unidade fundamental de uma rede neural artificial é um nó ou neurônio matemático. As conexões entre esses neurônios matemáticos foram inspiradas em cérebros biológicos, especialmente na forma como essas conexões se desenvolvem ao longo do tempo com treinamento. Segundo Haykin (2001), cada neurônio atribui um peso para os dados que entram — o quão correto ou incorreto ele é relativo à tarefa que está sendo executada. A saída final é então determinada pelo total desses pesos (Figura 11).

Figura 11 – Rede Neural Simples

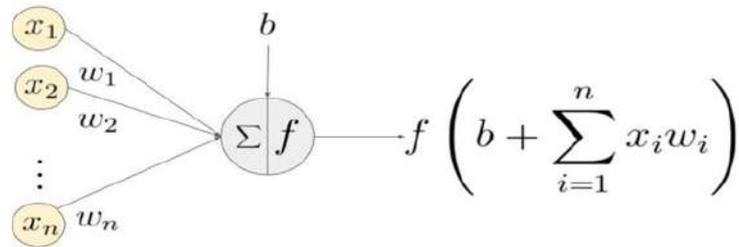


Fonte: He *et al.* (2016)

Uma rede neural artificial possui sinapses, função de soma, função de ativação e saída. A Figura 12, demonstra como o neurônio é representado no ambiente computacional, deixando de maneira explícita que sua inspiração vem dessa relação. As variáveis “ x_1, x_2, \dots, x_n ” são os valores de entrada do neurônio, em seguida, cada valor possui um peso que é definido pela sinapse específica de cada entrada, simbolizado pelas variáveis “ w_1, w_2, \dots, w_n ” na Figura 12. Após calculado os pesos, os valores passam por uma função de soma e uma outra de ativação

(variável b na Figura 12), para assim alcançar uma saída (KOVÁCS, 2002).

Figura 12 – Rede Neural Artificial



Fonte: Margapuri *et al.* (2020)

A composição da rede é realizada pelos neurônios. Geralmente, o tipo de processamento de um neurônio é a combinação linear das entradas com os pesos seguida pela passagem da combinação linear por uma função de ativação (FLECK, 2016). A função de ativação tem como objetivo restringir a amplitude do valor de saída de um neurônio (RAUBER, 2005). Segundo Haykin (2001) existem diversos tipos de funções de ativação, sendo as mais populares:

- **Linear:** é a função de ativação mais básica porque não altera a saída de um neurônio. Geralmente é utilizada nas camadas de saída em redes neurais de regressão.
- **Sigmóide:** função não linear que apresenta um balanço entre o comportamento linear e não-linear.
- **Rectified Linear Unit (ReLU):** função não linear, onde podemos facilmente copiar os erros para trás e ter várias camadas de neurônios ativados pela função ReLU. A principal vantagem de usar a função ReLU sobre outras funções de ativação é que ela não ativa todos os neurônios ao mesmo tempo. Dessa forma, apenas alguns neurônios são ativados, tornando a rede esparsa, eficiente e fácil para a computação. Portanto, se o parâmetro de entrada for positivo ou zero retorna o parâmetro, caso contrário retorna zero.
- **Softmax:** é uma função do tipo sigmóide e bastante útil quando tentamos lidar com problemas de classificação. Ela transforma as saídas para cada classe em valores entre 0 e 1. Geralmente utilizada na camada de saída do classificador, onde estamos tentando gerar as probabilidades para definir a classe de cada entrada.

Em visão computacional, os atributos de uma foto são examinados pelos neurônios, de modo que a rede gera um conjunto de probabilidades, que é um valor calculado a partir dos pesos atribuídos a imagem. No momento em que uma rede está sendo ajustada (ou treinada), ela

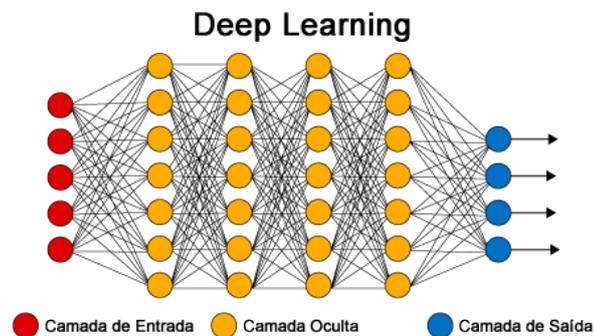
está produzindo respostas erradas — recorrentemente — e, portanto, precisa de treino. Significa dizer que a rede aprende com seus próprios erros e ela precisa ver milhares ou até milhões de imagens até que os pesos de cada informação recebida pelos neurônios estejam precisamente calibrados. Quando o resultado da calibração estiver respondendo de forma correta, a rede neural terá aprendido os padrões definidos e saberá classificar um objeto de forma precisa (HE *et al.*, 2016).

2.4 Deep Learning

O *Deep Learning* (aprendizagem profunda) é um ramo do *Machine Learning* que, por meio de algoritmos tentam modelar abstrações de alto nível de dados usando um grafo profundo com várias camadas de processamento, compostas de várias transformações lineares e não lineares (HINTON, 2007). No *Deep Learning*, o grande avanço foi de ampliar o tamanho das redes neurais utilizadas no *Machine Learning*, isto é, aumentar as camadas e os neurônios, e então alimentá-las com um nível massivo de dados para que fossem treinadas (COPELAND, 2016).

Segundo Hinton (2007), o *Deep Learning* usa camadas de neurônios matemáticos para processar dados, sinais e imagens. A informação é passada através de cada camada, com a saída da camada anterior fornecendo entrada para a próxima camada. A primeira camada da rede é a camada de entrada, enquanto a última é camada de saída. Todas as camadas entre as duas são referidas como camadas ocultas. Cada camada é tipicamente um algoritmo simples e uniforme contendo um tipo de função de ativação (Figura 13).

Figura 13 – Rede Neural Profunda (*Deep Learning*)



Fonte: He *et al.* (2016)

O *Deep Learning* em comparação ao *Machine Learning* apresenta algumas vantagens, dentre elas se propõe resolver problemas de grandes quantidades de dados de amostra, melhoria

do desempenho computacional (especialmente com o uso de Unidades de Processamento Gráficos (GPUs) que são amplamente utilizadas na computação paralela em grande escala) e inovação do modelo de algoritmo. O *Deep Learning* pode aprender com a experiência e compreender problemas complexos com base em uma hierarquia de conceitos (GOODFELLOW *et al.*, 2016) que foram definidos e aprendidos por meio de níveis crescentes de abstração (MURPHY, 2012).

As GPUs consistem em muitos núcleos de processamento que realizam cálculos de matrizes de forma rápida em paralelo. Esses dispositivos são bastante difundidos, pois seu desenvolvimento é motivado pela indústria de jogos. Além disso, as GPUs mais recentes não funcionam apenas como um mecanismo gráfico, mas também um processador computacional altamente paralelizado e com alta largura de banda de memória para algoritmos paralelos massivos. Embora as GPUs tenham sido inicialmente destinadas a jogos de alto desempenho (ROSEBROCK, 2017), novas técnicas na Compute Unified Device Architecture (CUDA) e CUDA *Deep Neural Network Library* (cuDNN) permitiram aos usuários adaptar seus algoritmos de *Deep Learning* para fins específicos, melhorando o desempenho do sistema (CHETLUR, 2014).

Hoje, o reconhecimento de imagens por máquinas treinadas através de *Deep Learning* em alguns cenários possui taxa de acerto até maior que a dos humanos (COPELAND, 2016).

2.5 Convolutional Neural Network (CNN)

Convolutional Neural Network – Rede Neural Convolutacional (CNN), representam um modelo de *Deep Learning* baseado na organização do córtex visual dos animais. A analogia é de que as células do córtex visual são sensíveis a pequenas sub-regiões do campo de visão. Essas pequenas sub-regiões são divididas em mosaicos de forma a cobrir todo o campo de visão. Essas células são adequadas para explorar as fortes correlações espaciais locais encontradas nos tipos de imagens que nosso cérebro processa, de forma a atuar como filtros locais sobre o espaço de entrada. Assim, as células mais simples são ativadas quando detectam padrões mais simples, como arestas e células mais complexas são ativadas quando detectam padrões mais específicos – geralmente baseados em diversos resultados de várias células simples (PATTERSON; GIBSON, 2017).

Redes Neurais Artificiais recebem as entradas em vetores unidirecionais que transformam os dados e os enviam para uma ou mais camadas ocultas totalmente conectadas, então os resultados são retornados pela camada de saída. O problema dessa abordagem, principalmente

tratando-se com imagens, é a dificuldade de escalar (PATTERSON; GIBSON, 2017).

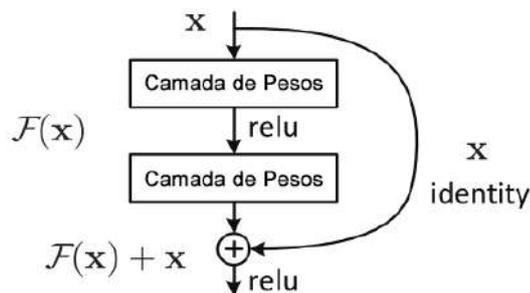
Desde 2010, anualmente, acontece uma competição chamada *Imagenet Large Scale Visual Recognition Challenge* (ILSVRC) que tem como objetivo avaliar algoritmos de detecção e classificação de imagens (RUSSAKOVSKY *et al.*, 2015). A partir de 2012, os algoritmos com melhores resultados têm sido das arquiteturas de Redes Neurais Convolucionais. Essas arquiteturas são comumente utilizadas para a resolução de diversos outros problemas.

2.6 Arquitetura ResNet

A arquitetura ResNet (HE *et al.*, 2016) é um nome abreviado de *Residual Neural Network* (Rede Neural Residual – em português). A nova terminologia que essa rede introduz é o aprendizado residual. Essa arquitetura é utilizada como base para muitas tarefas de visão computacional. Em 2015, a ResNet venceu o desafio ILSVRC. O principal avanço com a ResNet é permitir o treinamento de redes neurais muito profundas contendo mais de 150 camadas.

Antes do treinamento da ResNet, redes neurais convolucionais profundas eram difíceis de treinar devido ao problema dos gradientes de desaparecimento, após uma dada quantidade de camadas o incremento de mais camadas não conseguia aumentar a qualidade do modelo (HE *et al.*, 2016). Essa arquitetura trabalha na proposta em que as camadas continuem a receber os valores resultantes das funções de ativação ReLu (*Rectified Linear Unit*) – $F(x)$, da camada anterior, mas também recebam os parâmetros de entrada X dessas funções (Figura 14).

Figura 14 – Bloco Residual da ResNet



Fonte: He *et al.* (2016)

A ResNet possui dois componentes principais: “conexões de salto” e foco pesado em normalização de lotes. As “conexões de salto” pulam pares de grupos de camadas convolucionais, são chamadas unidades bloqueadas ou unidades recorrentes fechadas, apesar de não apresentarem uma recorrência no sentido tradicional dos modelos de redes neurais recorrentes. O foco pesado

em normalização de lotes possibilita tornar diferentes entradas de um modelo de aprendizado de máquina mais semelhantes entre si, para que o modelo possa aprender e generalizar bem novos dados (CHOLLET, 2017).

Portanto, a estratégia dos saltos em ResNets é evitar que a rede, extremamente profunda, morra por dissipação de gradientes através do empilhamento de mapeamentos de identidades que, do ponto de vista matemático estão simplesmente empilhando camadas que não fazem nada. Com isso, como mostra a Figura 14, a ResNet utiliza, em um determinado ponto, um sinal de adição que é a soma do sinal produzido pelas duas camadas convolucionais anteriores somado ao sinal transmitido diretamente do ponto anterior a estas camadas, juntando um sinal processado com um sinal de uma etapa anterior no processamento (HE *et al.*, 2016).

Em geral, em uma Rede Neural Convolucional profunda, várias camadas são empilhadas e treinadas para a tarefa em questão. Comprovou-se que a arquitetura ResNet é possibilita treinar redes neurais convolucionais muito profundas, além de resolver o problema de degradar a precisão. A arquitetura ResNet-152 obteve os melhores resultados no ILSVRC de 2015. Além da ResNet-152, também são propostas ResNets com várias profundidades, por exemplo: ResNet-18, ResNet-34, ResNet-50 e ResNet-101 (HE *et al.*, 2016).

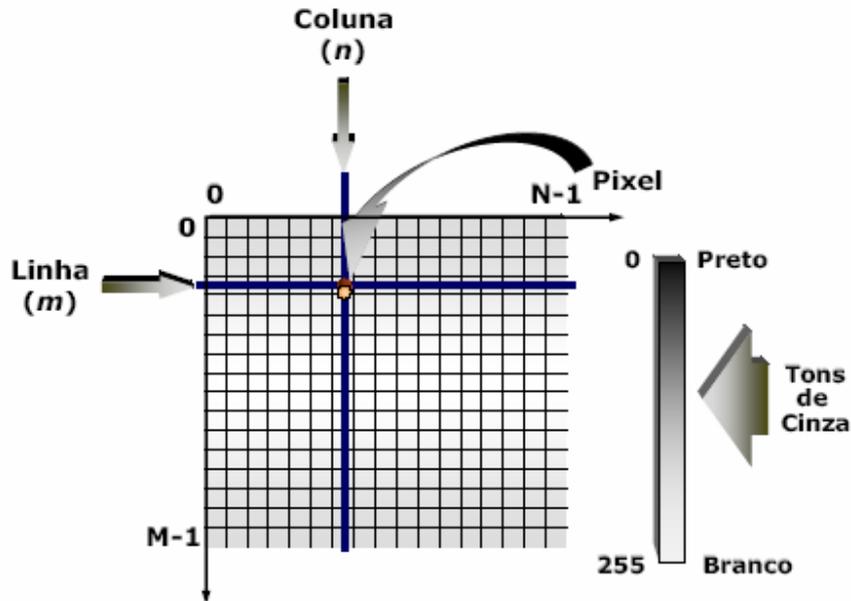
2.7 Visão Computacional

A visão computacional é a área que permite aos computadores a capacidade que os humanos têm de reconhecer padrões e extrair informações em imagens. Segundo Khan e Al-Habsi (2020), na visão computacional, as máquinas são construídas para desenvolver um entendimento de alto nível das imagens de entrada com o propósito de automatizar tarefas que os sistemas visuais dos humanos podem fazer. Em problemas de visão computacional, as entradas do modelo de *Machine Learning* são imagens digitais. Essas são usadas para realizar inferências a respeito dos rótulos de cada imagem. Para isso, utiliza-se um modelo que relacione as informações visuais e o rótulo da imagem (PRINCE, 2012).

Uma imagem pode ser definida como uma função de duas dimensões, $f(x,y)$, em que x e y são coordenadas espaciais, e a amplitude f é chamada de intensidade ou nível de cinza da imagem nesse ponto (GONZALEZ; WOODS, 2000). Esse ponto, em uma representação matricial bidimensional de uma imagem digital, é chamado de *pixel*. Uma imagem digital é composta por $M \times N$ *pixels*, e cada intensidade f de um *pixel* é representado por k *bits*. A Figura 15 mostra a representação de uma imagem digital. A intensidade f de cada um dos *pixels* de k

bits pode possuir até $2k$ valores diferentes. A quantidade de *pixels* define a resolução de uma imagem, o que pode representar a qualidade da imagem (TYAGI, 2018).

Figura 15 – Representação de uma imagem digital



Fonte: Adaptado de Jähne (2005)

Feng *et al.* (2019) relatam que os avanços na implementação de algoritmos de visão computacional não são apenas baseados em técnicas de *Deep Learning* e grandes conjuntos de dados, mas também contam com arquiteturas avançadas de computação paralela permitindo o treinamento eficiente de múltiplas camadas de redes neurais.

2.8 Técnicas de Detecção e Classificação de Objetos

A técnica de classificação de objetos busca apenas prever a classe presente na imagem. Por exemplo, quando construímos um classificador de buracos e remendos, o nosso classificador vai retornar como resultado da predição a classe (buraco ou remendo) e a confiança (grau de certeza sobre aquela predição).

Já a técnica de detecção de objetos além de prever a classe, precisa também identificar a localização do objeto nessa imagem. O retângulo que contém a localização do objeto é chamado de *bounding box* (caixa delimitadora – em português). Na Figura 16 são ilustradas essas duas técnicas: classificação e detecção.

Figura 16 – (a) Classificação e (b) Detecção



Fonte: O Autor (2022)

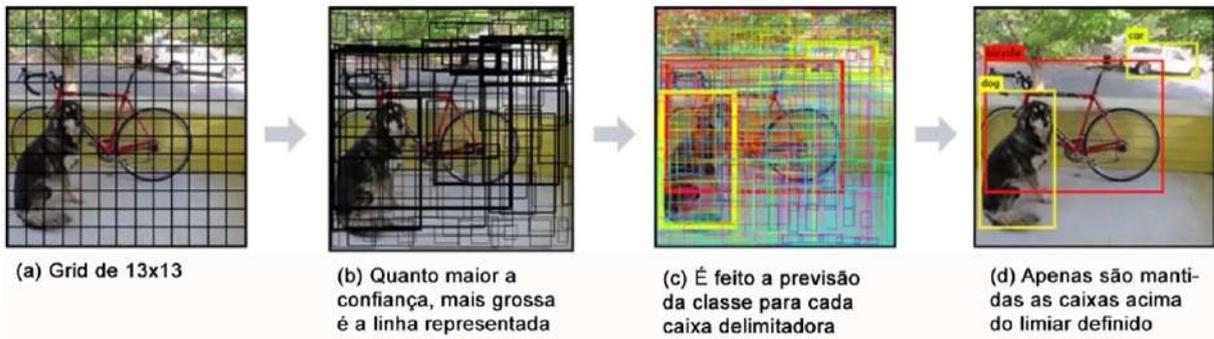
2.9 YOLO

O *You Only Look Once* (YOLO) é uma Rede Neural Convolutacional (CNN) em tempo real que visa detectar objetos de imagens. Usando uma CNN implementada na rede YOLO, os objetos podem ser rastreados, localizados e classificados (RADOVIC *et al.*, 2017). Durante a execução do modelo YOLO versão 3 as imagens são processadas em tempo real, a 45 quadros por segundo em uma GPU e utiliza a ResNet-50, uma arquitetura consideravelmente profunda. O YOLO realiza a detecção e a classificação dos objetos em tempo real e utiliza o método de detecção de objetos de passada única para encontrar padrões em imagens, onde precisa olhar pela imagem uma única vez para enviar para a rede neural (REDMON *et al.*, 2016). Por isso ele recebe esse nome (*You Only Look Once* – “Você só olha uma vez”).

Segundo Redmon *et al.* (2016), o algoritmo do YOLO trata a detecção de objetos como um simples problema de regressão. O primeiro passo é dividir a imagem em um grid de $S \times S$ células (Figura 17a). Cada uma dessas células é responsável por fazer a predição de 5 caixas delimitadoras (B), para caso haja mais de um objeto naquela célula. Também é retornado a pontuação de confiança que diz o quanto de certeza ele tem que aquela caixa delimitadora contenha um objeto (Figura 17b). Para cada caixa, a célula também faz a previsão de uma classe. É um classificador, de modo que é fornecido um valor de probabilidade para cada uma das classes possíveis. O valor de confiança para a caixa delimitadora e a predição da classe são combinados em uma pontuação final, que vai nos dizer a probabilidade dessa caixa conter um objeto específico. Na Figura 17 é utilizado um *grid* 13×13 , gerando um total de 169 células. Para cada uma dessas células são detectadas 5 caixas delimitadoras, o que resulta em 845 no total (Figura 17c). No entanto, a maioria dessas caixas terá um valor de confiança extremamente

baixo, então por isso geralmente se consideram apenas as caixas cuja pontuação final seja maior que 30%. Esse valor de 30% é o limiar, chamado de *threshold* e ele pode ser alterado dependendo do quão preciso você quer que o detector seja (Figura 17d).

Figura 17 – Algoritmo do YOLO



Fonte: Adaptado de Redmon *et al.* (2016).

O Sistema de Detecção do YOLO ocorre da seguinte forma: a imagem de entrada é redimensionada, submetida à Rede Neural Convolutacional (YOLO) e, por fim, realiza a detecção (Figura 18). Assim, depois de rotular uma grande quantidade de objetos para as fases de treinamento, validação e teste, os defeitos no pavimento podem ser rapidamente detectados e classificados.

Figura 18 – Sistema de Detecção do YOLO



Fonte: Redmon *et al.* (2016).

2.10 Pesquisas relacionadas a utilização de *Deep Learning* na detecção de defeitos nos pavimentos rodoviários

Pesquisas que envolvem *Deep Learning* na engenharia de transportes são um tanto recentes. De acordo com a revisão da literatura, existem três tipos de sistemas de detecção de buracos: métodos baseados em vibração, métodos baseados em laser e métodos baseados em imagem (KIM; RYU, 2014). O método de vibração, que é baseado em um sensor de acelerômetro, não pode prever buracos com antecedência. Isso porque o veículo deve passar pelo buraco para

realizar a detecção. Este método não pode diferenciar entre buracos e outros artefatos na estrada, como juntas de ponte e refletores sinalizadores de estrada (YU; YU, 2006).

Os sistemas de varredura a laser são classificados entre os métodos de reconstrução Tridimensional (3D). Este sistema pode detectar buracos em tempo real. No entanto, este método possui como desvantagem o alto esforço computacional para reconstrução da superfície do pavimento, a sensibilidade à vibração e a necessidade de alinhamento perfeito da câmera (CHANG *et al.*, 2005).

As abordagens baseadas em imagens, que fazem uso de câmera monocular junto com alguns algoritmos de detecção de objetos, mostraram uma melhoria na detecção de buracos em tempo real, além de melhorar as formas convencionais e garante uma maior precisão (KOCH; BRILAKIS, 2011). Devido ao desenvolvimento de técnicas avançadas de processamento de imagens, a facilidade de interpretar de imagens e a disponibilidade de dispositivos de aquisição de câmeras de baixo custo, inspiraram o desenvolvimento da detecção de buracos baseada em imagens. Portanto, a presença de novos métodos no estudo de visão computacional, especialmente relacionados à detecção de objetos, abrem-se novas oportunidades de implementá-lo na detecção de defeitos em pavimentos rodoviários.

Koch e Brilakis (2011) definem três características visuais específicas do buraco, são elas: forma oval, cor escurecida e superfície mais áspera do que o seu entorno. A partir dessas três características, a extração da forma, a segmentação da imagem e a extração de recursos são comparadas com seus arredores para determinar um valor específico que representa um buraco. Como forma de complementar e aprimorar o método anterior, Koch *et al.* (2013) propuseram uma técnica aprimorada de detecção de buracos para atualizar incrementalmente o método anterior, utilizando o vídeo como base de seu material de pesquisa. Portanto, no novo método proposto, eles utilizam rastreamento e contagem de buracos no vídeo do pavimento. Além disso, foi cortado o tempo de processamento para inspecionar buracos em cada quadro.

Huidrom *et al.* (2013) propuseram um método para classificar três tipos de problemas nos pavimentos rodoviários: buracos, trincas e remendos juntamente com a medição de sua respectiva área em *pixels*. Os métodos de detecção foram propostos em duas etapas. Primeiro, implementou-se um algoritmo para realizar a detecção do tipo de defeito. Em seguida, um outro algoritmo foi criado para atribuir o nível do defeito e a medição da área em *pixels*. Eles utilizaram a textura da imagem, um fator da forma geométrica e a dimensão como os principais atributos para definir o nível do defeito.

Além da detecção baseada em processamento de imagem, os desenvolvimentos tecnológicos em aprendizado de máquina também culminaram na detecção de buracos de forma mais adaptativa. Hoang (2018) propôs um modelo de inteligência artificial para detectar buracos na superfície do pavimento asfáltico. Ele utiliza os seguintes métodos de processamento de imagem para extrair as características de um buraco: filtro gaussiano, filtro direcionável e projeção integral. Em seguida, foi atribuído a classe buraco dois algoritmos de aprendizado de máquina: a Máquina de Vetores de Suporte de Mínimos Quadrados (LS-SVM) e a Rede Neural Artificial (RNA).

As abordagens anteriores foram benéficas no processo de detecção de buracos, no entanto possuem desvantagens onde a extração de características deve ser realizada por especialistas para produzir um melhor desempenho e precisão durante o processo de detecção (LECUN *et al.*, 2015). Por isso, faz-se necessário a utilização do *Deep Learning* no estudo de visão computacional. Dessa forma, é possível computar a extração e a classificação dos recursos simultaneamente através de uma Rede Neural Convolutiva (CNN).

Maeda *et al.* (2018) propuseram um método de detecção de defeitos com oito tipos de classes, cujo foco foi fornecer um conjunto de dados acessível ao público. As imagens da superfície do pavimento foram coletadas através de um *smartphone* de baixo custo em municípios no Japão. Ao final, foram registradas 9.053 imagens com 15.435 defeitos. Maeda *et al.* (2018) comparam o desempenho no processo de detecção do SSD MobileNet e do Inception V2. A principal contribuição dos autores foi realizar a inspeção e a análise de problemas rodoviários através de um aplicativo móvel.

Neste trabalho, nos concentramos na detecção de buracos e remendos em pavimentos utilizando *Deep Learning* nas rodovias do estado do Ceará. Também foi realizado um comparativo entre os *datasets* coletados, cujos processos de aquisição de dados foram feitos por meio de quatro câmeras distintas posicionadas na parte frontal do veículo. Além disso, foi criado um *software* que apresente os defeitos identificados pelo algoritmo de forma clara e objetiva a fim de permitir a análise e a tomada de decisão dos responsáveis pela gerência dos pavimentos.

3 MATERIAIS E MÉTODOS

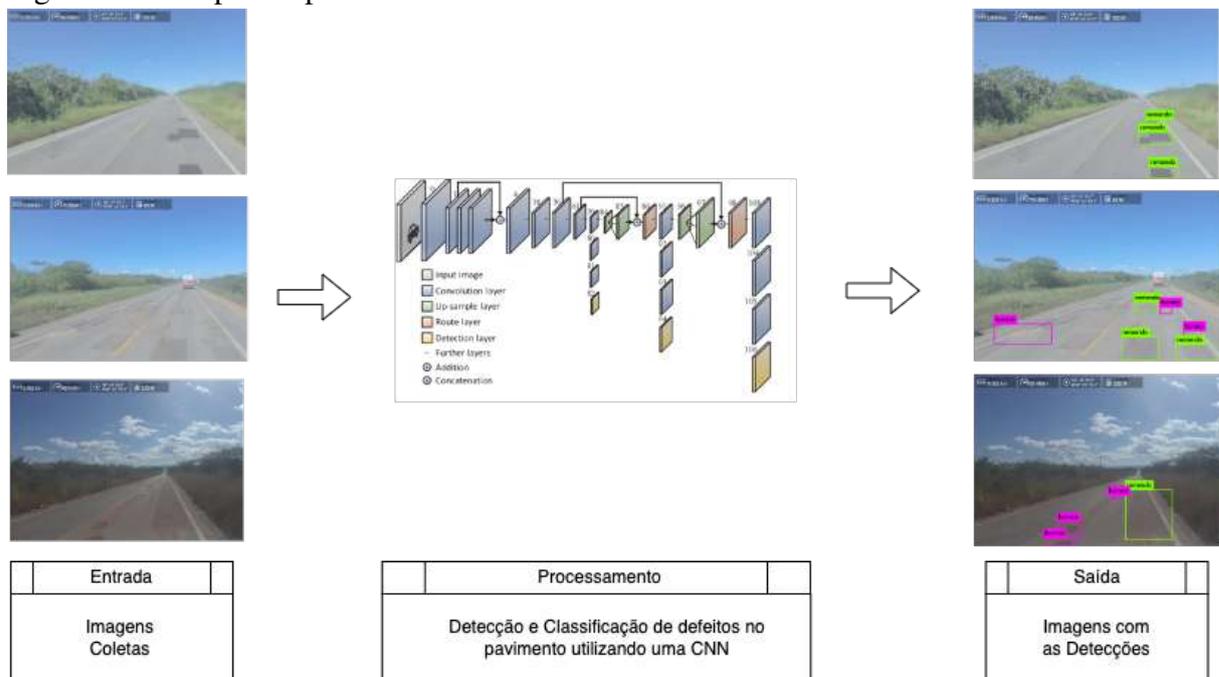
Neste capítulo, são descritos os procedimentos para a aquisição dos dados do pavimento em imagens e vídeos; estruturação e rotulação dos buracos e remendos contidos nos *datasets*; e o algoritmo de detecção utilizando *Deep Learning*. Além disso, vale ressaltar que nesta pesquisa foi criado um *software* de apoio ao inventário que apresente, quantifique e georreferencie os defeitos encontrados onde é abordado no Apêndice D.

3.1 Etapas do processo metodológico

Neste trabalho, é proposto um *software* para detecção e análise de imagens de deterioração do pavimento através da identificação de buracos e remendos. Uma etapa prévia fundamental, refere-se à criação dos *datasets* contendo as imagens dos defeitos nas rodovias.

Dito isto, o processo é dividido em 3 etapas: entrada, processamento e saída. A etapa de entrada representa as imagens coletadas da rodovia e incluídas no *dataset*. A camada de processamento é composta pela organização dos dados e a execução do algoritmo de treinamento ou detecção. E, por fim, a camada de saída exibe o resultado do treinamento ou da detecção. A estrutura geral é mostrada na Figura 19.

Figura 19 – Etapas do processo



Fonte: Adaptado de Choi (2019).

Na camada de processamento (Figura 19) é executado o algoritmo. Nesta etapa,

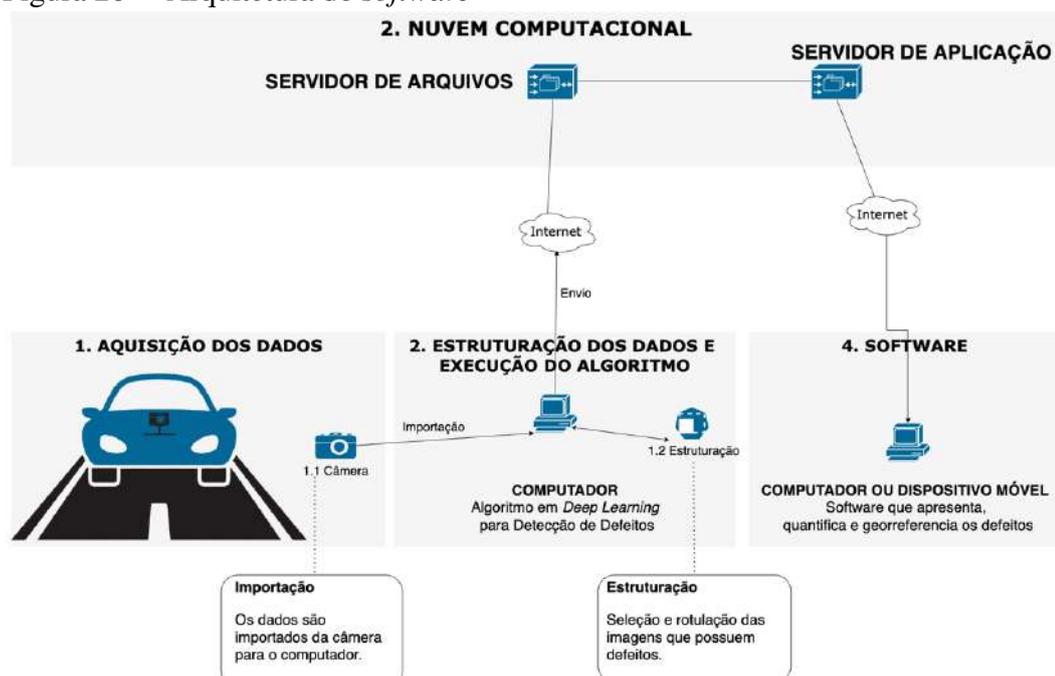
envolve a análise, separação e rotulação das classes para realizar o treinamento da rede neural. Uma vez que o treinamento foi concluído, é executada a fase de validação onde os defeitos são detectados pelo algoritmo de treinamento e comparados com os objetos rotulados. Este processo é realizado automaticamente pelo YOLOv3 e a partir disso são geradas as métricas a fim de saber o nível de assertividade da rede.

3.2 Arquitetura do *software*

Estudos recentes têm utilizado o conceito de redes neurais para automatizar os procedimentos de Levantamentos Visuais Contínuos (LVC). Neste trabalho utilizou-se o conceito de *Deep Learning* através da rede YOLOv3 para implementar o algoritmo de detecção de defeitos em pavimentos asfálticos. Portanto foi necessário treinar uma Rede Neural Convolutacional profunda com base nas classes definidas na fase de rotulação e buscar a melhor configuração possível para gerar uma precisão aceitável.

A Figura 20 mostra a arquitetura do *software* implementado neste trabalho. Os dados coletados da rodovia são enviados para o sistema de arquivos de um computador pessoal (PC ou *Notebook*), a fim de organizá-los e estruturá-los. Após esse procedimento, os dados são consumidos pelo o algoritmo de treinamento e detecção de defeitos, e ao final podem ser visualizados em um *software* desenvolvido para uma análise mais detalhada.

Figura 20 – Arquitetura do *software*



Fonte: O Autor (2022).

3.3 Aquisição dos dados

Os dados utilizados nessa pesquisa consistiram em imagens de trechos de rodovias do estado do Ceará. Esses registros são de pavimento asfáltico que apresentaram incidência de buracos e remendos.

Os equipamentos de aquisição utilizados para obtenção de mídias (imagens ou vídeos) da rodovia consistiram em dois *smartphones* e duas câmeras de ação, são eles: iPhone 12 Pro, Samsung Galaxy S20 FE, GARMIN Virb Ultra 30 e GOPRO Hero 7. Ambos fixadas em um veículo (Mitsubishi ASX 2015) trafegando a 80 km/h e ajustadas para enquadramento nos defeitos do pavimento. Além disso, os *datasets* incluem uma variedade de condições com diferentes iluminações e sombras de objetos à beira da estrada.

Os levantamentos utilizando a GARMIN Virb Ultra 30 foram realizados por uma empresa de modo que neste trabalho iremos nos referir por Empresa A. Os demais levantamentos foram realizados pelo autor dessa dissertação. Em ambos os levantamentos o enquadramento da câmera permaneceu inalterado durante a coleta. A Empresa A realizou o levantamento em diversas rodovias do estado do Ceará, gerando um banco de imagens diversificado de vários trechos. Os levantamentos do próprio autor foram realizados na BR-020 do Km 404 até o Km 209, trecho que interliga os municípios de Caucaia à Boa Viagem no estado do Ceará.

3.3.1 iPhone 12 Pro

O iPhone 12 Pro foi fixado no para-brisa de um veículo leve (parte interna do carro) e ajustada para enquadramento de imagens panorâmicas da via. A Figura 21 mostra o posicionamento do *smartphone* no carro.

Figura 21 – Processo de aquisição de dados pelo iPhone



Fonte: O Autor (2022).

Com este *smartphone* foram gerados dois *datasets*, onde o armazenamento dos dados foi registrado em vídeo à 30 quadros por segundo com *zoom 2x*, utilizando o aplicativo de câmera nativo no aparelho. Foi necessário realizar a coleta em vídeo porque o aplicativo de câmera do iPhone não possui o recurso de *timelapse* com geolocalização até o momento de aquisição desses dados. Uma possibilidade seria a implementação de um aplicativo próprio que registrasse imagens e sua respectiva localização geográfica, porém não é o foco deste trabalho.

O primeiro vídeo foi gravado em resolução *FullHD* (1920 x 1080 *pixels*) e o segundo em 4K (3840 x 2160 *pixels*). Neste trabalho, chamaremos de iPhone FHD e iPhone 4K, respectivamente, quando formos referenciar cada um deles. Ambos foram gerados pelo próprio autor e foram percorridos um total de 200 km resultando em vídeos de aproximadamente 2 horas de duração. Os vídeos foram registrados durante o dia e em boas condições climáticas. No vídeo 4K apresentou uma nitidez bem superior ao *FullHD*, de modo que os defeitos no *FullHD* pareceram borradas. No entanto, ainda assim é possível identificá-los a olho humano. As imagens dos *datasets* são mostradas na Figura 22.

Figura 22 – Imagens do *dataset* do iPhone (a) 4K e (b) *FullHD*



Fonte: O Autor (2022).

Vale ressaltar que o iPhone não permite desabilitar o foco automático, portanto, durante a coleta o aplicativo da câmera tentava focar automaticamente e isso resultou em trechos tremidos na gravação do vídeo. Ao final do levantamento, foram copiados os arquivos

do *smartphone* para o computador e com base nos arquivos de vídeo, foi necessário extrair os quadros e gerar as imagens em formato JPEG no sistema de arquivos. Como a coleta foi realizada em vídeos, não foi possível obter os dados de geolocalização em cada imagem, de modo que neste *dataset*, após a extração e a seleção das imagens válidas, resultou em aproximadamente 519 imagens com defeitos no total para o iPhone 4K e 291 para o iPhone FHD.

3.3.2 Samsung Galaxy S20 FE

De modo semelhante a aquisição realizada no iPhone, o Samsung Galaxy S20 FE foi fixado no para-brisa de um veículo (parte interna do carro) e ajustada para enquadramento de imagens panorâmicas da via. A Figura 23 mostra o posicionamento deste *smartphone* no carro.

Figura 23 – Processo de aquisição de dados pelo S20 FE



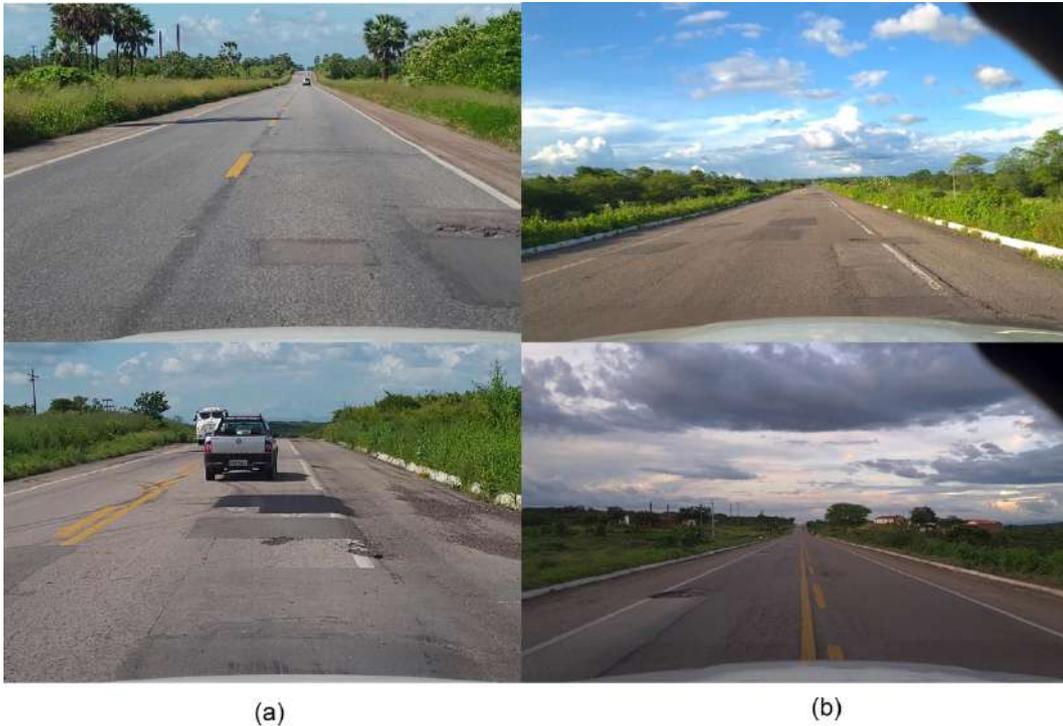
Fonte: O Autor (2022).

Foram gerados dois *datasets* com este *smartphone*, de modo que o armazenamento dos dados foi em arquivo vídeo a 30 quadros por segundo, utilizando o aplicativo de câmera nativo instalado no aparelho. Foi necessário realizar a coleta em vídeo porque o aplicativo de câmera do S20 FE não possui o recurso de *timelapse* com geolocalização até o momento de aquisição desses dados.

O primeiro vídeo foi gravado em resolução *FullHD* (1920 x 1080 *pixels*) e o segundo em 4K (3840 x 2160 *pixels*). Neste trabalho, chamaremos de S20 FHD e S20 4K, respectivamente, quando formos abordar cada um deles. Ambos foram gerados pelo próprio autor e foram percorridos um total de 200 km resultando em vídeos de aproximadamente 2 horas de duração. Os vídeos foram registrados durante o dia e em boas condições climáticas. No vídeo 4K apresentou uma nitidez bem superior ao *FullHD*, de modo que os defeitos no *FullHD* pareceram

*pixelated*¹. As imagens dos *datasets* são mostradas na Figura 24.

Figura 24 – Imagens do *dataset* do S20 FE (a) 4K e (b) *FullHD*



Fonte: O Autor (2022).

O registro dos vídeos foi realizado através do modo “Vídeo Profissional” nas opções de câmera do Samsung Galaxy S20 FE. Além disso, foi habilitada a função “estabilizar vídeo”, o foco manual foi definido em 0,7 e o zoom em panorâmica 2x. Após essas configurações foi iniciada a gravação e ao final do levantamento foram copiados os arquivos do *smartphone* para o computador. Após a cópia, foi necessário extrair os quadros e gerar as imagens em formato JPEG no sistema de arquivos, semelhante ao procedimento realizado no iPhone. Após a extração e a seleção das imagens válidas, resultou em 406 imagens com defeitos no total para o S20 4K e 330 para o S20 FHD.

3.3.3 *GARMIN Virb Ultra 30*

A GARMIN Virb Ultra 30 foi fixada no para-brisa de um veículo (parte externa do carro) e ajustada para enquadramento de imagens panorâmicas da via. A Figura 25 mostra o posicionamento da câmera no para-brisa do carro (em vermelho).

¹ <<https://en.wikipedia.org/wiki/Pixelation>>

Figura 25 – Processo de aquisição de dados pela GARMIN 4K



Fonte: Empresa A (2022).

Este *dataset* gerado pela Empresa A e foi percorrido um total de 800 km. A coleta dos dados foi realizada no formato de imagens JPEG, através da opção “Intervalo de distância entre fotos (*Travelapse*)” configurada para capturar uma foto a cada 20 metros e com GPS habilitado. Além disso, esta câmera salva os dados de geolocalização no próprio arquivo JPEG através do recurso de EXIF² (*Exchangeable Image File Format*), de modo que a latitude e longitude podem ser acessados através de uma leitura ao arquivo.

As imagens foram registradas durante o dia e em boas condições climáticas. Vale ressaltar que as imagens coletadas foram enquadradas para uma visão panorâmica da via, de modo que se teve pouca informação visual da via e bastante informação de “céu”. Além disso, as imagens apresentaram muita clareza e pouca nitidez, de modo que os defeitos não ficaram com uma boa visibilidade. Com isso, cerca de 50 imagens por quilômetro foram geradas (40 mil imagens no total). O armazenamento dos dados foi registrado em imagens 4K (3840 x 2160 *pixels*) no cartão de memória inserido na própria câmera. Após a extração e a seleção das imagens, resultou em 10.000 imagens no total contendo defeitos. As imagens do *dataset* são

² <https://pt.wikipedia.org/wiki/Exchangeable_image_file_format>

mostradas na Figura 26.

Figura 26 – Imagens do *dataset* da GARMIN 4K



Fonte: Empresa A (2022).

3.3.4 GOPRO Hero 7

A GOPRO Hero 7 foi fixada no capô de um veículo (parte externa do carro) e ajustada para enquadramento nos defeitos do pavimento. A Figura 27 demonstra o posicionamento da câmera no carro.

Figura 27 – Processo de aquisição de dados pela GOPRO 4K



Fonte: O Autor (2022).

Neste *dataset*, gerado pelo autor, e foi percorrido um total de 200 km. A coleta dos dados foi realizada no formato de imagens JPEG, através da opção “Foto com lapso de tempo (*Timelapse*)” configurada para capturar uma foto a cada 0,5 segundos à 12 *megapixels* no modo linear e com GPS habilitado. Nesta configuração uma foto é registrada a cada 0,5 segundos. O modo linear permite com que as imagens não fiquem curvas. Além disso, a GOPRO salva os dados de geolocalização no próprio arquivo JPEG através do recurso de EXIF, procedimento idêntico ao realizado pela GARMIN. As imagens foram registradas durante o dia e em boas condições climáticas. As imagens coletadas tiveram um enquadramento voltado para o pavimento e com bastante nitidez, de modo que os defeitos ficaram bem perceptivos a olho humano. Ao final do levantamento, foram registradas aproximadamente 14 mil imagens no total. O armazenamento dos dados foi registrado em imagens 4K (3840 x 2160 *pixels*) no cartão de memória inserido na câmera. Após a extração e a seleção das imagens, resultou-se em 1.389 imagens com defeitos no total. Na Figura 28 são exibidas algumas imagens do *dataset*.

Figura 28 – Imagens do *dataset* da GOPRO 4K



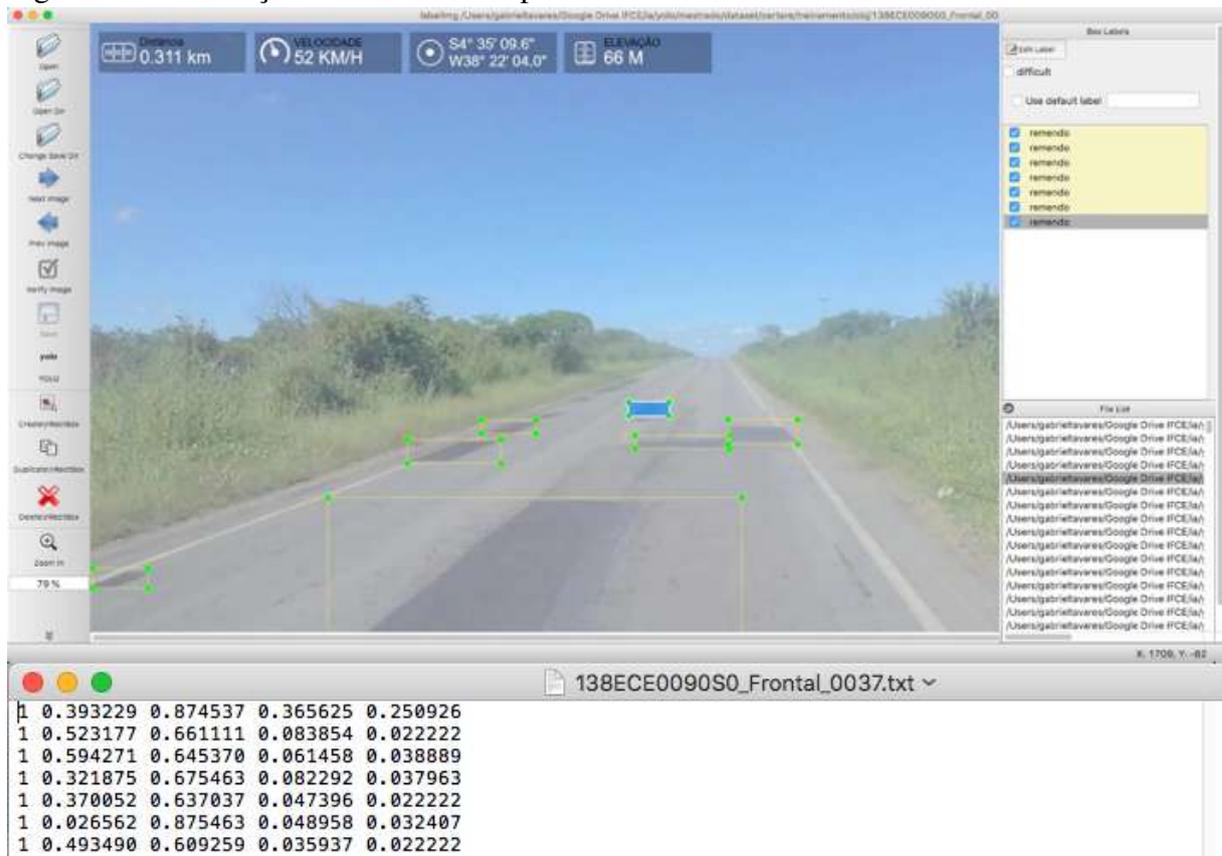
Fonte: O Autor (2022).

3.4 Estruturação do *dataset*

Após a aquisição dos dados, a etapa subsequente é a estruturação do *dataset*. É importante ressaltar que diversos segmentos do trecho apresentaram o pavimento em bom estado de conservação e esses trechos não foram considerados no estudo realizado neste trabalho. Portanto, foi necessário fazer uma seleção das imagens coletadas em duas categorias: com defeitos e sem defeitos. As imagens selecionadas que apresentaram defeitos, foram utilizadas no processo de rotulação.

A rotulação pode ser realizada através de várias ferramentas de código livre, como *LabelImg*, *Bbox*, *Yolo_mark*, entre outras. Neste trabalho foi utilizado o *LabelImg*, pois pode rotular imagens diretamente no formato YOLO. A rede YOLO adota o padrão na rotulação dos objetos anotados: *class-id*, *center_X*, *center_Y*, *width*, *height*. Na parte inferior da Figura 29, contém um exemplo dessa anotação em um arquivo de texto.

Figura 29 – Rotulação de remendos no pavimento

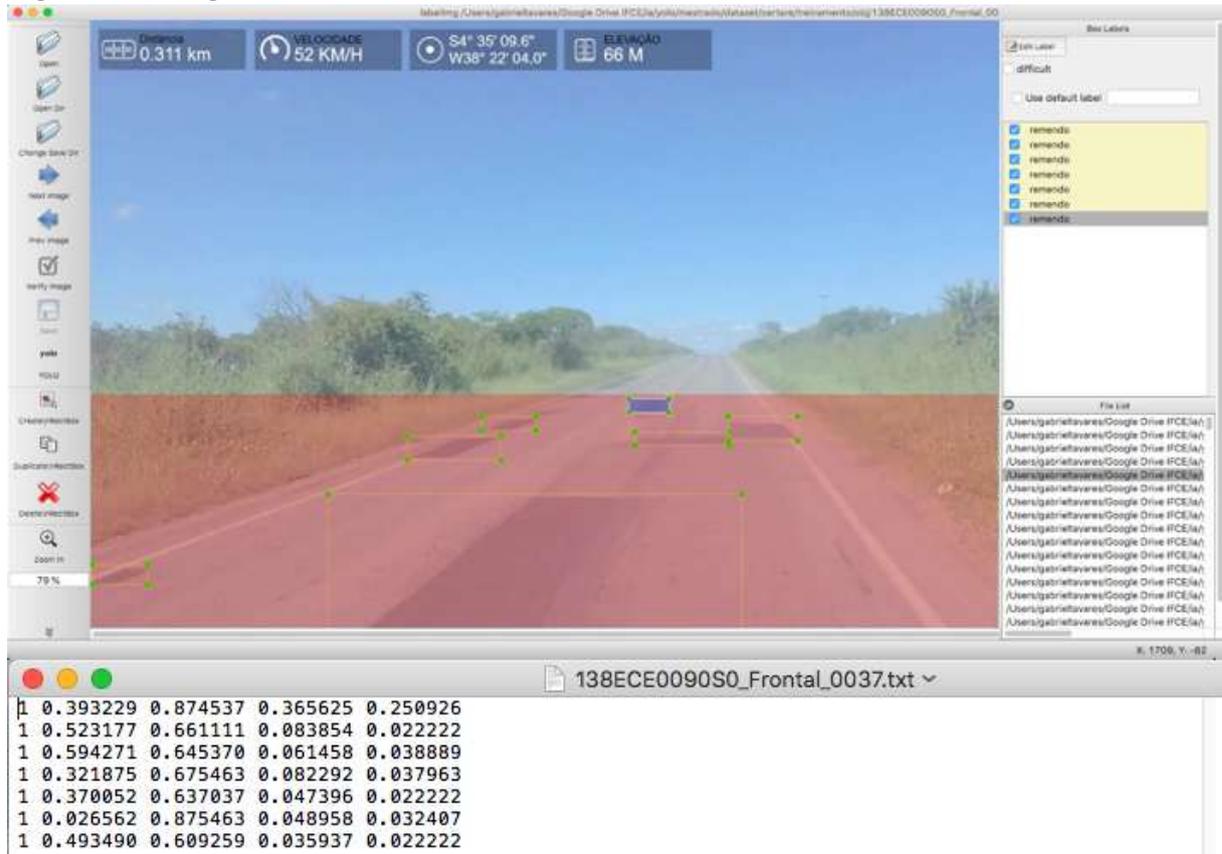


Fonte: O Autor (2022).

Nesta etapa, é realizado o processo de rotulação dos buracos e remendos em cada imagem, para isso são desenhadas formas geométricas retangulares sobre os defeitos visualizados

na imagem (Figura 29). Esta é uma etapa de extrema importância, pois essas anotações são a base de conhecimento da rede neural, de modo que, o algoritmo faz as classificações e localizações dos defeitos conforme o padrão de rotulação. Vale salientar que os rótulos foram demarcados tendo como região de interesse 80% da área total da rodovia para o que corresponde a parte de baixo, conforme mostrado em vermelho na Figura 30.

Figura 30 – Região de Interesse



Fonte: O Autor (2022).

O processo de rotulação foi realizado para todos os *datasets* utilizados neste trabalho. Após concluída esta etapa, os arquivos são utilizados no processo de treinamento e validação da rede YOLOv3. Esses dados coletados foram implementados em um modelo elaborado com objetivo de determinar se o tipo de defeito se classifica como buraco ou remendo, e qual a sua respectiva localização no campo visual da imagem em que o defeito se encontra.

No primeiro treinamento (iPhone FHD) foram utilizadas foram utilizadas 291 imagens contemplando um total de 770 rótulos (157 para buracos e 613 para remendos). No segundo, o iPhone 4K, foi utilizado um *dataset* contendo 519 imagens gerando um total de 726 rótulos de buracos e 743 de remendos (1.469 rótulos). No terceiro, o S20 FHD, foram selecionadas 330 imagens contendo 349 rótulos de buracos e 320 de remendos (669 rótulos). No quarto, o

S20 4K, foram usadas 406 imagens com 364 buracos e 741 remendos rotulados (1.105 rótulos). No *dataset* da GARMIN 4K, o quinto, composto de 10 mil imagens das quais existem 6.001 rótulos de buracos e 17.090 de remendos (23.091 rótulos). Por fim, o sexto *dataset* (GOPRO 4K), contém 1.389 imagens com 1.505 buracos rotulados e 1.192 remendos (2.697 rótulos). Em cada um dos *datasets*, foram separados dois conjuntos: treinamento e validação. O conjunto de treinamento corresponde à 90% das imagens e o conjunto de validação aos 10% restantes, ambos escolhidos aleatoriamente. A Tabela 10 informa os valores totais de imagens, buracos e remendos rotulados por *dataset* após ao final da etapa de rotulação.

Tabela 10 – Quantitativo de imagens, buracos e remendos rotulados por *dataset*

<i>Dataset</i>	Imagens	Buracos	Remendos
1 - iPhone FHD	291	157	613
2 - iPhone 4K	519	726	743
3 - S20 FHD	330	349	320
4 - S20 4K	406	364	741
5 - GARMIN 4K	10.000	6.001	17.090
6 - GOPRO 4K	1.389	1.505	1.192

Fonte: O autor (2022).

3.5 Algoritmo de detecção de buracos e remendos

Uma vez gerados os rótulos de buracos e remendos, inicia-se a fase de treinamento do modelo utilizando a técnica computacional *Deep Learning*. Portanto, na criação do classificador de defeitos, foi utilizado a rede YOLOv3 a fim de aprender e detectar os buracos e os remendos presentes nas imagens.

3.5.1 Infraestrutura Computacional

Para implementar o reconhecimento de objetos utilizando uma rede neural, é necessário realizar treinamento do modelo. A fase de treinamento consiste na implementação de um algoritmo que aprende de acordo com os padrões apresentados a ele. Esses padrões são os rótulos gerados nas imagens. Esses rótulos são enviados para o algoritmo de treinamento, de modo que o sistema passa a aprender a forma geométrica de cada defeito, juntamente com sua cor, textura, grandeza e dimensões.

No algoritmo de treinamento foi utilizado o código fonte baseado no projeto *Darknet*. O algoritmo de detecção foi codificado na linguagem de programação Python (versão 3.7).

Ambos executados no Sistema Operacional Linux (Distribuição: Ubuntu 20.04 LTS). Os experimentos foram realizados em um Notebook Acer Nitro 5 com processador Intel Core i5, 32GB de memória RAM, SSD 1TB NVMe M2 e placa gráfica GeForce GTX 1650 com 4 GB memória interna (Figura 31). Para a construção do modelo utilizou-se a rede YOLO (versão 3), de modo que o tempo gasto no treinamento dessa rede foi de aproximadamente 24 horas. É importante mencionar que tanto o processo de detecção quanto o de treinamento foram realizados pela GPU que fez o uso da placa gráfica disponível no equipamento.

Figura 31 – Equipamento utilizado nos experimentos



Fonte: O Autor (2022).

As mídias (imagens e/ou vídeos) utilizadas nesta pesquisa foram coletadas de rodovias do estado do Ceará, em câmeras acopladas nos veículos leves. Uma vez concluído o processo de aquisição de dados, as mídias contidas em dispositivos de armazenamento removíveis foram copiadas para diretórios no sistema de arquivos do Notebook. Para os *datasets* coletados no formato de vídeo, foi necessário extrair os quadros e gerar as imagens em formato JPEG. Após este procedimento, realizou-se a seleção e a rotulação dos defeitos (buracos e remendos) para as

etapas de treinamento e validação.

3.5.2 Parâmetros do YOLO

Nesta pesquisa foi realizado a identificação de duas classes de objetos em imagens: buracos e remendos. Portanto, para garantir uma boa precisão foi preciso ajustar o modelo de arquitetura nas configurações do YOLOv3. Nessas configurações foram alterados os seguintes parâmetros: *batch*, *subdivisions*, *classes*, *max_batches*, *steps* e *filters*. O parâmetro *batch* representa o número de imagens por iteração. *Subdivisions* representa a quantidade de partes em que o *batch* é dividido na memória. O parâmetro *classes* representa a quantidade de categorias que o algoritmo irá detectar. O *max_batches* representa a quantidade máxima de iterações que o treinamento irá processar. O parâmetro *steps* representa o número de iterações onde as escalas serão aplicadas e determina como a taxa de aprendizado será alterada durante o número crescente de iterações no treinamento. Essas escalas representam um coeficiente em que a taxa de aprendizado será multiplicada nestes pontos de iteração. O parâmetro *filters* representa a quantidade de *kernels* convolucionais existentes em uma camada (REDMON *et al.*, 2016).

O tamanho do *batch* foi definido para 64 e as *subdivisions* para 16. O tamanho do *batch* e da *subdivision* pode ser alterado com base nas capacidades gráficas do sistema. O tamanho do *filter* deve ser definido através da fórmula $(classes + 5) \times 3$, como temos apenas duas classes, o valor do *filter* é definido para 21. Além disso, os *max_batches* são definidos para 4.000, pois é definido através da fórmula $classes \times 2000$. O atributo *steps* deve corresponder a 80% e 90% do valor do *max_batches*. Na Tabela 11 são listadas as fórmulas utilizadas nas configurações do YOLO.

Tabela 11 – Valores utilizados no treinamento da rede YOLOv3

Atributo	Valor	Fórmula
<i>batch</i>	64	-
<i>subdivisions</i>	16	-
<i>classes</i>	2	-
<i>max_batches</i>	4000	$classes \times 2000$
<i>steps</i>	3200, 3600	$0,8 \times max_batches$ $0,9 \times max_batches$
<i>filters</i>	21	$classes + 5 \times 3$

Fonte: O Autor (2022).

As imagens dos *datasets* gerados, são em resolução 4K (3840 x 2160 *pixels*) ou *FullHD* (1920 x 1080 *pixels*). O YOLO redimensiona essas imagens através dos parâmetros *width*

(largura) e *height* (altura) nas configurações. Vale ressaltar que qualquer redimensionamento afetará o desempenho do modelo, no entanto quanto maior o tamanho da imagem passado para a rede mais memória e mais processamento serão exigidos, isso impacta no tempo. Foi realizada uma tentativa de utilizar um valor maior que 512, porém o hardware utilizado nesta pesquisa não suportou e ocasionou estouro de memória. Portanto, neste trabalho utilizamos o valor de 512 para *width* e *height*.

3.5.3 Métricas do treinamento

O uso de métricas serve para definir a qualidade do modelo em que são geradas com base no *dataset*, são elas: *Precision* (Precisão), *Recall* (Sensibilidade), F1-score, *Intersection over union* – Intersecção da União (IoU), *Average Precision* (Precisão Média - AP) e *mean Average Precision* – Média das Precisões de Todas as Métricas (mAP). Vale ressaltar que para realizar o cálculo do *Precision* e *Recall* é necessário utilizar os Verdadeiros Positivos (VP), Falsos Positivos (FP) e Falsos Negativos (FN) que são explicados na Tabela 12 (PADILLA *et al.*, 2020).

Tabela 12 – Variáveis utilizadas no cálculo do *Precision* e *Recall*

Variáveis	Definição
VP	Verdadeiros Positivos: Número previsto de positivos que estavam corretos, em redes neurais significa dizer que o objeto detectado é igual ao que foi aprendido no treinamento.
FP	Falsos Positivos: Número previsto de positivos que estavam incorretos, em redes neurais significa dizer que o objeto detectado é diferente do que foi aprendido no treinamento.
FN	Falsos Negativos: Número previsto de negativos que estavam incorretos, em redes neurais significa dizer que objeto está presente na imagem, porém classificador informa que ele não está.

Fonte: Powers (2020)

O *Precision* é a capacidade de um modelo de identificar os objetos relevantes entre os objetos recuperados (POWERS, 2020). É representado pela porcentagem de objetos detectados de forma correta (VP) entre todos os objetos detectados (VP + FP), conforme definido na Equação 3.1.

$$Precision = \frac{VP}{VP + FP} \quad (3.1)$$

O *Recall* informa a capacidade de um modelo de encontrar os casos relevantes que foram recuperados (POWERS, 2020). É representado pela porcentagem de objetos detectados de

forma correta (VP) entre todos os objetos rotulados (VP + FN), conforme definido na Equação 3.2.

$$Recall = \frac{VP}{VP + FN} \quad (3.2)$$

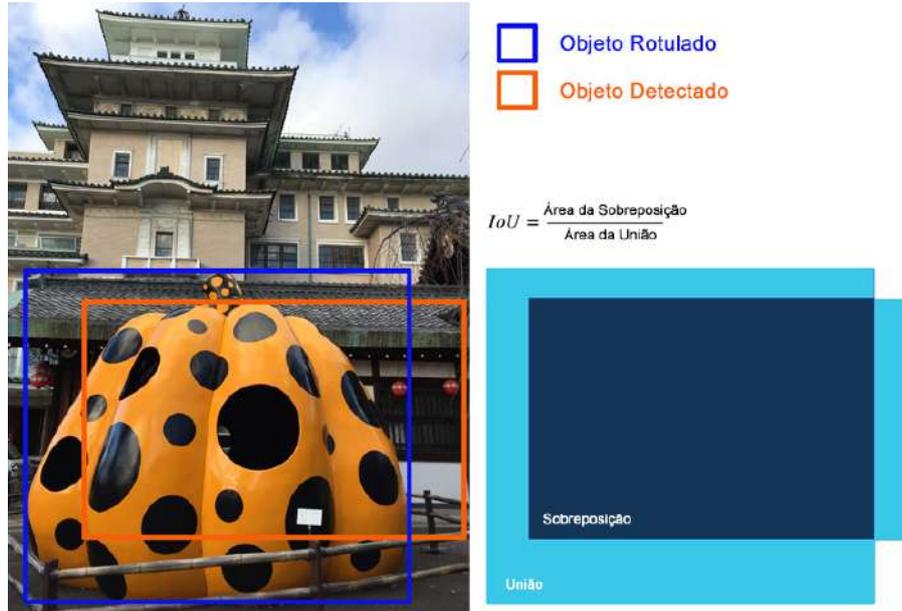
O *F1-score* é utilizado para determinar a confiança ideal que equilibra os valores de *Precision* e *Recall* para o modelo (SASAKI, 2007). Ele se encontra dentro de uma escala de valores entre 0 e 1. O F1-score leva em consideração não apenas o número de erros de previsão que seu modelo comete, mas também os tipos de erros que são cometidos. Uma métrica de avaliação de valor único pode ser derivada do conjunto de pontuações F1 que pode ser um bom indicador do desempenho geral do modelo.

$$F_1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3.3)$$

O IoU mede a sobreposição entre dois quadrantes: o objeto rotulado e o objeto detectado. Segundo Everingham *et al.* (2010), essa métrica é utilizada para medir o quanto o quadrante do objeto detectado se sobrepõe em relação ao objeto demarcado na fase de rotulação (Figura 32), conforme definido na Equação 3. Em alguns *datasets*, é estabelecido um limiar para o IoU a fim de determinar se o objeto detectado é um verdadeiro positivo (VP) ou um falso positivo (FP).

$$IoU = \frac{readaSobreposio}{readaUnio} \quad (3.4)$$

Figura 32 – IoU: Objeto rotulado vs. Objeto detectado



Fonte: Adaptada de Hui (2018). Disponível em: <https://jonathan-hui.medium.com/map-mean-average-precision-for-object-detection-45c121a31173>.

O *Average Precision* – Precisão Média (AP) ou Precisão Média é uma métrica popular na medição da precisão do YOLO, onde é calculado o valor de precisão média para o valor de *Recall* acima entre 0 e 1 (EVERINGHAM, 2010). O AP é a representação da área da curva de *precision* e *recall* em um valor escalar, conforme definido na Equação 3.5.

$$AP = \int_{r=0}^1 p(r) dr \quad (3.5)$$

O mAP (*mean Average Precision*) compara os objetos demarcados na fase de rotulação com os objetos detectados pelo modelo e retorna uma pontuação. Quanto maior a pontuação, mais preciso é o modelo em suas detecções. O mAP é calculado tomando a média de AP em todas as classes em consideração (Equação 3.6).

$$mAP = \frac{1}{k} \sum_i^k AP \quad (3.6)$$

Enquanto o mAP aumentar, o treinamento deverá continuar, caso contrário deve-se parar. Vale ressaltar que o treinamento deverá ser interrompido também quando o *Average Loss*

(AVG *Loss*) estabilizar ao longo das iterações. Segundo AlexeyAB³, desenvolvedor do projeto *Darknet*, os pesos que apresentarem maior mAP ou maior IoU são os que apresentam melhores métricas.

Apesar da Precisão Média (AP) ser a métrica mais comum, o uso das demais métricas apresentadas possuem uma importância relevante. Em um SGP, não informar a presença de um buraco onde ele existe é um sério problema, uma vez que um buraco não leva muito tempo para aumentar de tamanho. E, conseqüentemente, o aumento do tamanho e do número de buracos podem causar acidentes graves. Portanto, a geração de informações confiáveis corroboram para uma tomada de decisão eficaz por parte dos gestores, permitindo a definição de estratégias de intervenção no pavimento de forma periódica e correta.

3.5.4 Processo de treinamento

Depois de definir os parâmetros do modelo, o treinamento é inicializado e a cada 1.000 iterações um arquivo de peso é gerado. Vale salientar, que o conjunto de treinamento corresponde a 90% das imagens e o conjunto de validação aos 10% restantes do *dataset*. Ao final, tem-se o arquivo de pesos gerado no treinamento e suas métricas. O tempo de treinamento durou 24 horas.

Foi realizado o treinamento no YOLOv3 para cada um dos *datasets*: iPhone FHD, iPhone 4K, S20 FHD, S20 4K e GARMIN 4K e GOPRO 4K. Portanto, foi necessário executar o treinamento seis vezes, isto é, um para cada *dataset*. O treinamento foi realizado utilizando o código baseado no projeto *Darknet* desenvolvido por AlexeyAB.

Como entrada, foram definidos os parâmetros da rede e as imagens com seus respectivos rótulos. Como saída, foram gerados as métricas e o arquivo de pesos que representa o aprendizado da rede. Na Figura 33 é mostrado o processo de treinamento no YOLOv3.

³ <https://github.com/AlexeyAB/darknet>

Figura 33 – Treinamento do YOLOv3

```

runtrain.txt
16
17 -- EXECUÇÃO DO TREINAMENTO
18
19 conda info --envs
20 conda activate yolov4
21
22 python generate-train-txt.py
23 python generate-valid-txt.py
24
25 ./darknet detector train data/obj.data cfg/yolov3_custom.cfg darknet53.conv.74 -map -dont_show 2>&1 > backup/training_e
26
PROBLEMS OUTPUT DEBUG CONSOLE TERMINAL
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 94 Avg (IOU: 0.150098), count: 1, class_loss = 841.500513, iou_loss = 2
.080537, total_loss = 844.701050
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 100 Avg (IOU: 0.161929), count: 3, class_loss = 2983.809488, iou_loss = 1
4.215333, total_loss = 2997.322821
total bbox = 75, rewritten bbox = 0.000000 %
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 82 Avg (IOU: 0.234572), count: 1, class_loss = 207.382111, iou_loss = 1
.063071, total_loss = 209.045191
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 94 Avg (IOU: 0.412831), count: 2, class_loss = 848.731586, iou_loss = 1
.950317, total_loss = 842.631824
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 100 Avg (IOU: 0.693352), count: 1, class_loss = 2985.261963, iou_loss = 0
.131340, total_loss = 2995.303311
total bbox = 75, rewritten bbox = 0.000000 %
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 82 Avg (IOU: 0.248595), count: 1, class_loss = 207.333786, iou_loss = 1
.064639, total_loss = 208.698425
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 94 Avg (IOU: 0.274373), count: 2, class_loss = 848.807196, iou_loss = 3
.749939, total_loss = 844.557129
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 100 Avg (IOU: 0.308568), count: 3, class_loss = 2981.270568, iou_loss = 3
.713579, total_loss = 2984.906684
total bbox = 95, rewritten bbox = 0.000000 %
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 82 Avg (IOU: 0.000000), count: 1, class_loss = 208.159683, iou_loss = 0
.000000, total_loss = 208.159683
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 94 Avg (IOU: 0.000000), count: 1, class_loss = 848.176575, iou_loss = 0
.000000, total_loss = 848.176575
v3 [sse loss, Normalizer: (iou: 0.75, obj: 1.00, cls: 1.00) Region 100 Avg (IOU: 0.299590), count: 6, class_loss = 2977.146240, iou_loss = 1
3.054932, total_loss = 2990.201172
total bbox = 91, rewritten bbox = 0.000000 %

```

Fonte: O Autor (2022).

3.5.5 Processo de detecção

Uma vez concluído o treinamento, o algoritmo está pronto para realizar a detecção dos defeitos. Vale notar que o algoritmo identifica os buracos e os remendos que aparecem no campo visual da imagem. A Figura 34 mostra o resultado da detecção no *dataset* da Empresa A, as duas imagens da esquerda são as imagens originais registradas pela câmera e as duas imagens da direita foram geradas pelo algoritmo de detecção.

Figura 34 – Detecção de Defeitos no Pavimento Rodoviário



Fonte: Empresa A (2022).

Nesta fase foi implementado um código na linguagem de programação Python que

lê todas as imagens de um diretório, no sistema de arquivos, e realiza a detecção dos buracos e remendos. À medida que as detecções vão sendo realizadas, geram-se novos arquivos de imagens em formato JPEG representando a saída do algoritmo. Essas imagens, tanto as de entrada quanto as de saída, são enviadas para o servidor de arquivos da nuvem computacional (Figura 20) para possibilitar sua visualização no *software* de apoio ao inventário (Apêndice D).

4 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados e discutidos os resultados obtidos na pesquisa considerando os seis *datasets* estruturados no contexto do presente trabalho, são eles: iPhone FHD, iPhone 4K, S20 FHD, S20 4K, GARMIN 4K e GOPRO 4K. Para isso, foi realizado um comparativo entre os resultados obtidos para cada *dataset* treinado.

4.1 Análise dos Treinamentos

A Tabela 13 apresenta os resultados dos treinamentos da rede YOLOv3 realizados nesta dissertação. Observando as métricas de avaliação e levando em consideração as características do conjunto de imagens de cada treino, pode-se chegar a algumas conclusões sobre o melhor posicionamento de câmera para fazer a detecção dos defeitos estudados de forma automática.

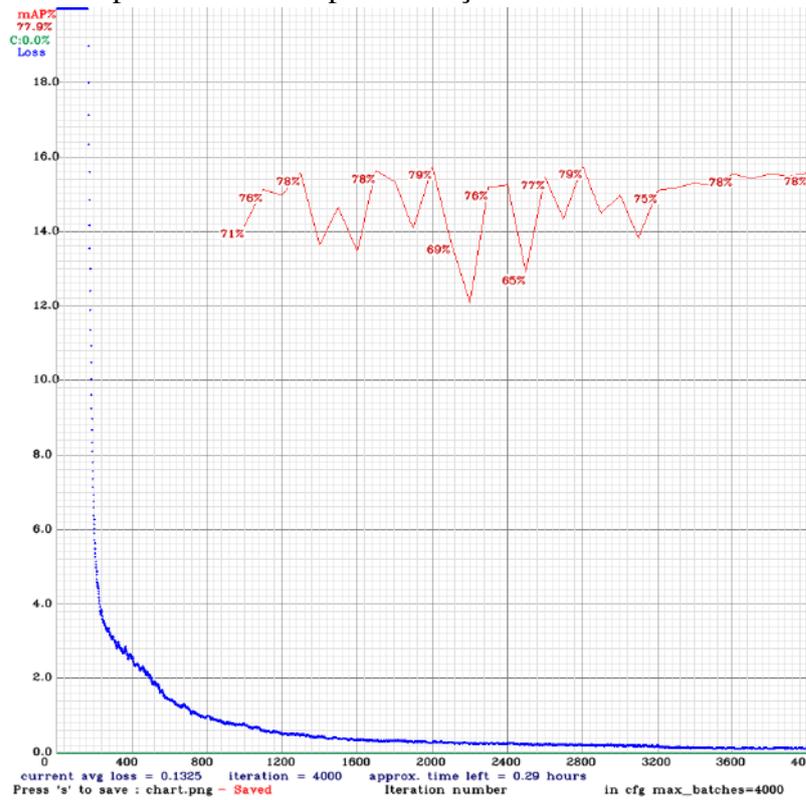
Tabela 13 – Resultado das métricas dos seis treinamento realizados

Dataset	AP (%)		Precision (%)	Recall (%)	F1-Score (%)	VP	FP	FN	AVG IoU (%)	mAP (%)
	Buraco	Remendo								
1 - iPhone FHD	71,86	83,86	86	77	81	63	10	19	65,49	78,86
2 - iPhone 4K	63,31	76,38	77	65	71	89	27	47	55,54	69,84
3 - S20 FHD	77,08	65,28	81	69	75	43	10	19	59,97	79,18
4 - S20 4K	66,80	73,30	81	71	76	66	15	27	61,86	78,05
5 - GARMIN 4K	57,82	76,42	73	68	70	1617	603	772	53,41	57,12
6 - GOPRO 4K	99,89	95,91	98	97	98	64	1	2	80,14	84,90

Fonte: O Autor (2022).

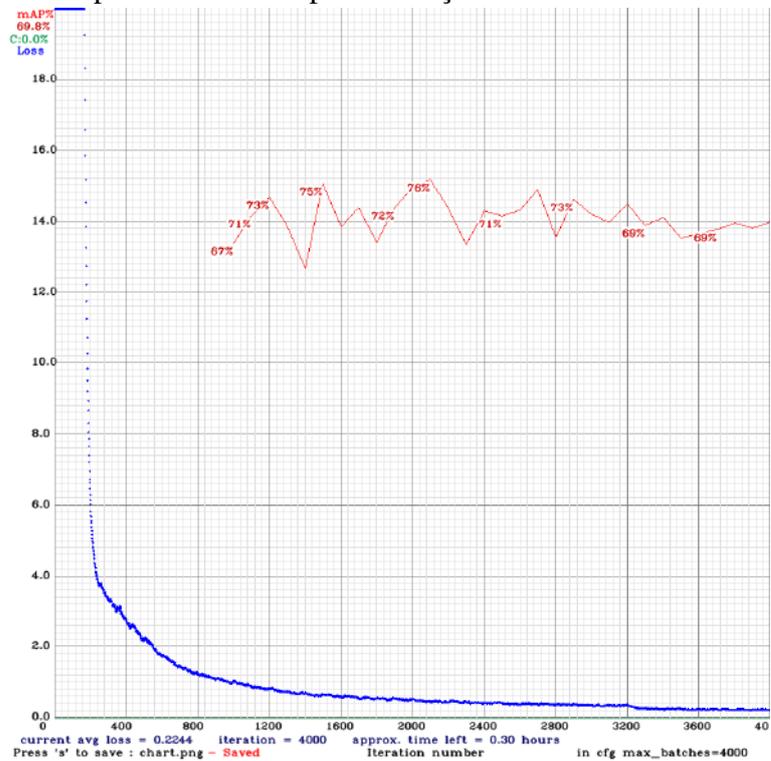
Iniciando pelos primeiros dois treinos realizados, pode-se concluir que o *dataset* 1 (iPhone FHD) apresentou melhores métricas combinadas se comparado ao *dataset* 2 (iPhone 4K), de modo que houve um aumento em todas as métricas, com exceção dos verdadeiros positivos (VP). Embora o enquadramento da câmera seja idêntico para os dois *datasets*, o conjunto de imagens 4K apresentou resultados bastante inferiores ao *dataset* de imagens *FullHD* do iPhone. As Figuras 35 e 36 mostram o gráfico da perda média e do mAP nos *datasets* 1 e 2, respectivamente. Percebe-se uma grande divergência no mAP, de modo que seus valores se mantêm entre 67% e 72% nas iterações do treinamento do *dataset* iPhone 4K, enquanto no *dataset* iPhone FHD fica entre 70% e 75% em sua maioria.

Figura 35 – Gráfico da perda e do mAP pelas iterações do Treinamento do iPhone FHD



Fonte: O Autor (2022).

Figura 36 – Gráfico da perda e do mAP pelas iterações do Treinamento do iPhone 4K

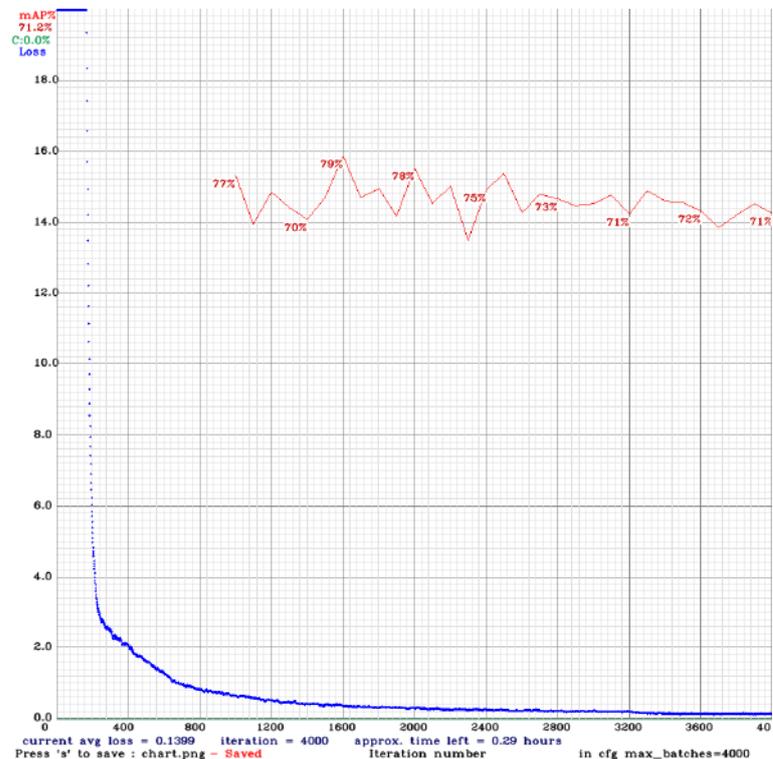


Fonte: O Autor (2022).

No que se refere à comparação entre os *datasets* 3 (S20 FHD) e 4 (S20 4K), o aprendizado do conjunto de dados 4K apresentou resultados iguais ou superiores para *precision*, *recall*, *F1* e verdadeiros positivos (VP) em relação ao conjunto *FullHD*, no entanto houve uma diferença para mais no número de falsos positivos (FP) e falsos negativos (FN) o que comprometeu o resultado global do *dataset* 4. Provavelmente, uma maior quantidade de imagens no processo de treinamento geraria resultados melhores.

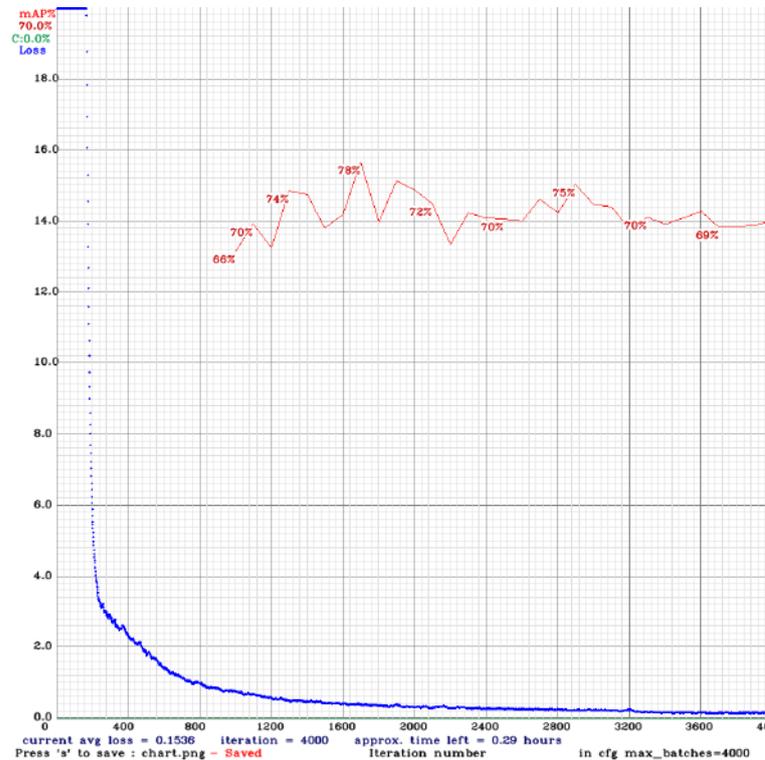
Os valores do mAP durante as iterações dos treinamentos dos *datasets* S20 FHD e S20 4K mostraram-se relativamente diferentes ao comparar as Figuras 37 e 38. Os valores do mAP no *dataset* 3 estão sempre mais elevados.

Figura 37 – Gráfico da perda e do mAP pelas iterações do Treinamento do S20 FHD



Fonte: O Autor (2022).

Figura 38 – Gráfico da perda e do mAP pelas iterações do Treinamento do S20 4K

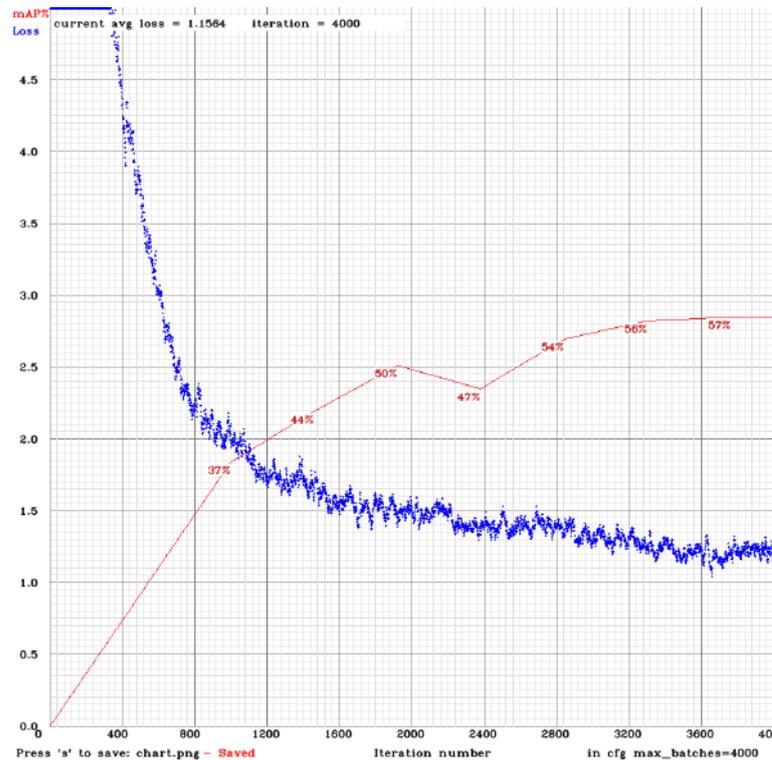


Fonte: O Autor (2022).

Os treinamentos realizados nos *smartphones* tiveram exatamente o mesmo enquadramento de câmera. No entanto, os *datasets* do iPhone 4K e do S20 4K apresentaram mais falsos positivos do que os seus respectivos em FHD. Embora isso tenha ocorrido, percebe-se que os *datasets* dos *smartphones* pairam entre 70% e 80% na média global (mAP) e entre 81% e 86% no *precision*.

O *dataset 5* (GARMIN) apresentou o pior resultado entre os treinamentos realizados no YOLOv3. Na Figura 39 nota-se que a perda permanece bastante elevada e o mAP muito baixo. Levando em consideração que esse *dataset* possui a maior quantidade de imagens rotuladas se comparado aos demais, ele deveria ter os melhores resultados, uma vez que a rede possui mais dados para aprender. No entanto, o processo de aquisição das imagens foi realizado fora de um padrão, onde as imagens apresentaram pouca informação visual da rodovia e uma má visibilidade dos defeitos no pavimento.

Figura 39 – Gráfico da perda e do mAP pelas iterações do Treinamento da GARMIN

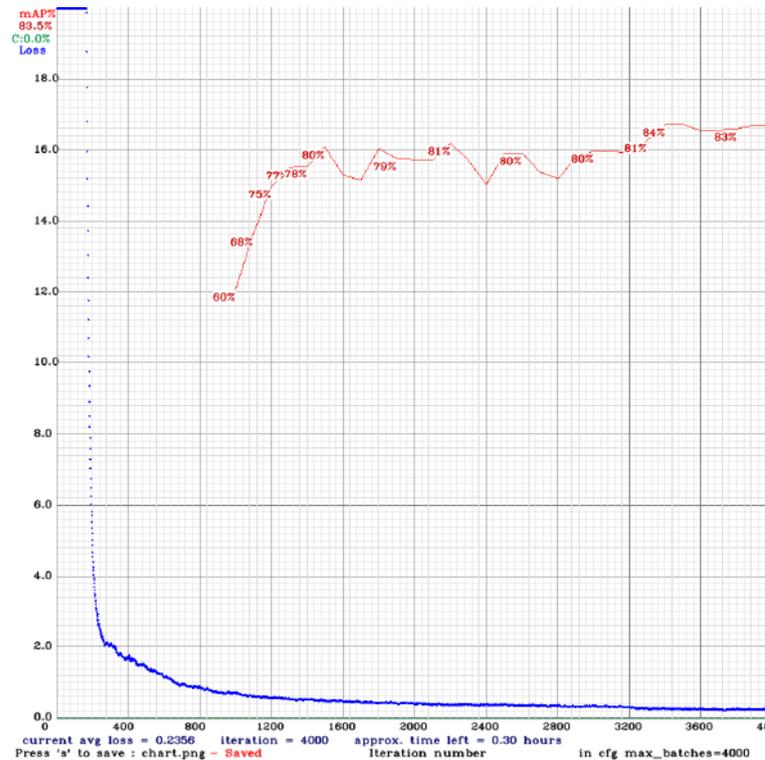


Fonte: O Autor (2022).

O *dataset* 6 (GOPRO), apresentou os melhores resultados em todas as métricas. Neste *dataset* o enquadramento da câmera ficou totalmente focado e com zoom no pavimento, enquanto todos os outros *datasets* tiveram uma visão panorâmica da via. Além disso, as imagens ficaram bastante nítidas e os defeitos apresentados nas imagens tiveram uma visualização excelente.

No gráfico da Figura 40 o mAP cresce constantemente e a perda alcança uma média de 0,23 ao final das 4.000 iterações. De acordo com a literatura, é recomendado encerrar o treinamento quando o erro não diminui à medida que as iterações ocorrem, ou quando o valor de mAP não apresenta mais incrementos relevantes. Observando o gráfico do *dataset* da GOPRO presente na Figura 40, e considerando que os melhores resultados estão na iteração 3.400 e 4.000, espera-se que, pela tendência do gráfico, o mAP aumente ainda mais com o acréscimo de iterações superiores a 4.000 e que a perda diminua.

Figura 40 – Gráfico da perda e do mAP pelas iterações do Treinamento da GARMIN



Fonte: O Autor (2022).

4.2 Discussões

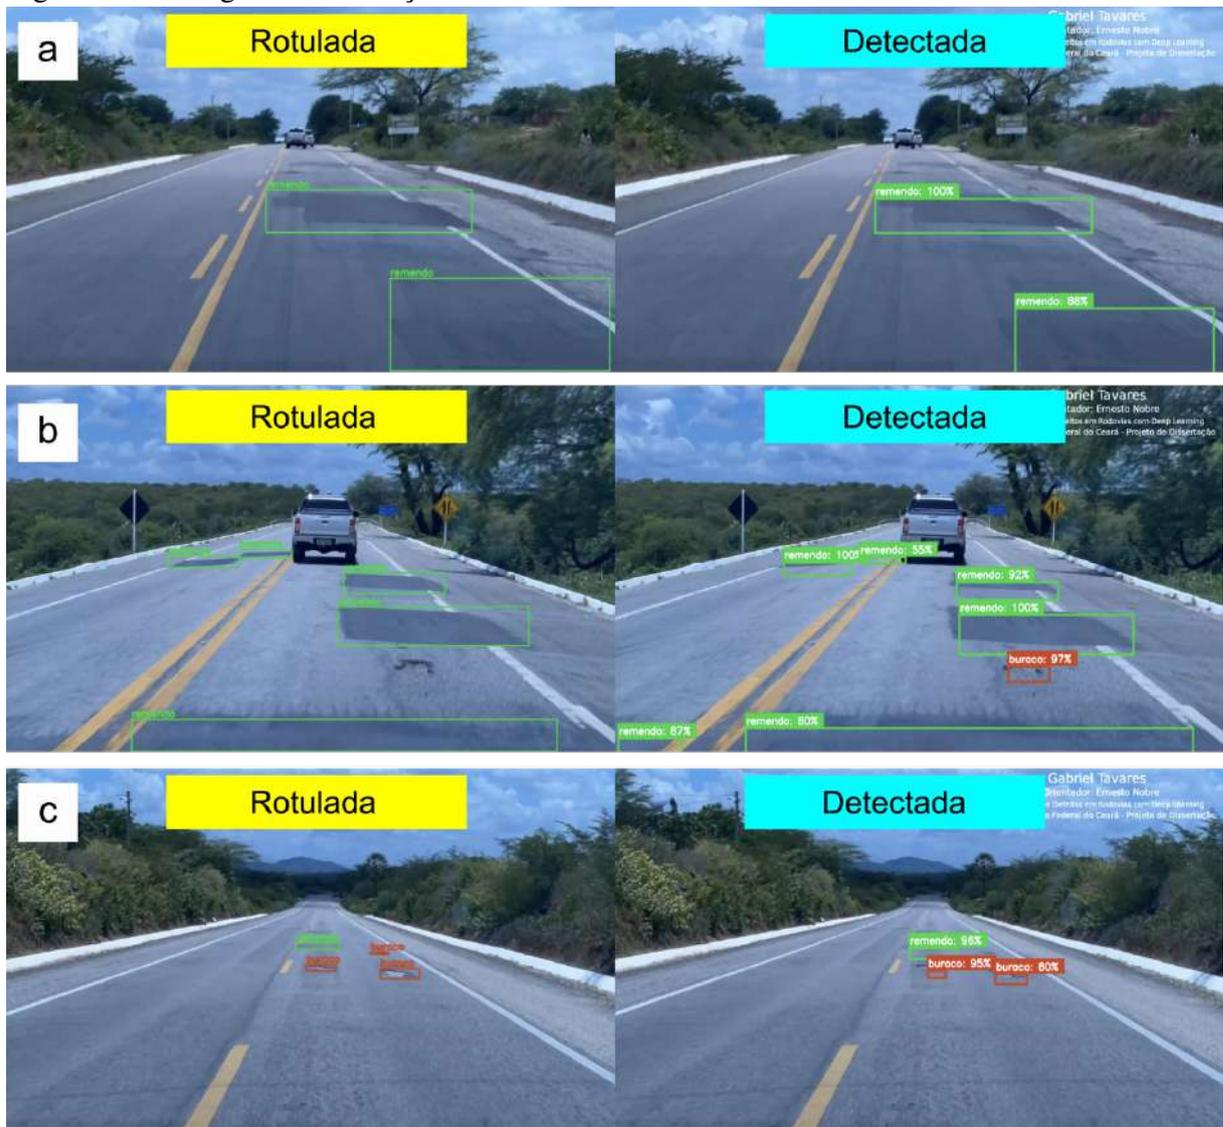
Neste tópico iremos analisar as imagens geradas no processo de validação do algoritmo, de modo que estas imagens foram rotuladas pelo autor dessa dissertação, porém elas não são utilizadas na etapa de treinamento. Com isso, o YOLOv3 as utiliza para fins medição de assertividade e geração de métricas.

A análise deste tópico é uma comparação subjetiva, onde serão abordados os principais casos que se repetiram na validação. Dessa forma, será feito um comparativo das imagens rotuladas (à esquerda) com as imagens detectadas (à direita) e demonstrado situações em que houve casos de verdadeiros positivos e falsos negativos.

A Figura 41 apresenta três cenários do *dataset* do iPhone FHD. O cenário da Figura 41a representa um caso de sucesso, onde os dois remendos rotulados foram detectados pelo algoritmo. No cenário da Figura 41b um buraco deixou de ser rotulado, porém o algoritmo identificou o defeito. Apesar de ser um caso bom, significando que o algoritmo aprendeu de forma eficaz, esta situação representa um falso negativo para métricas geradas pelo YOLOv3 e por isso faz-se necessário analisar cada caso isoladamente. No terceiro cenário (Figura 41c),

demonstra uma situação em que o buraco que está mais distante não foi detectado, isto porque o objeto está pouco perceptível por conta do seu tamanho da imagem. No entanto, devido a frequência das imagens, os defeitos mais afastados serão identificados na imagem registrada a frente.

Figura 41 – Imagens de validação do *dataset* do iPhone FHD

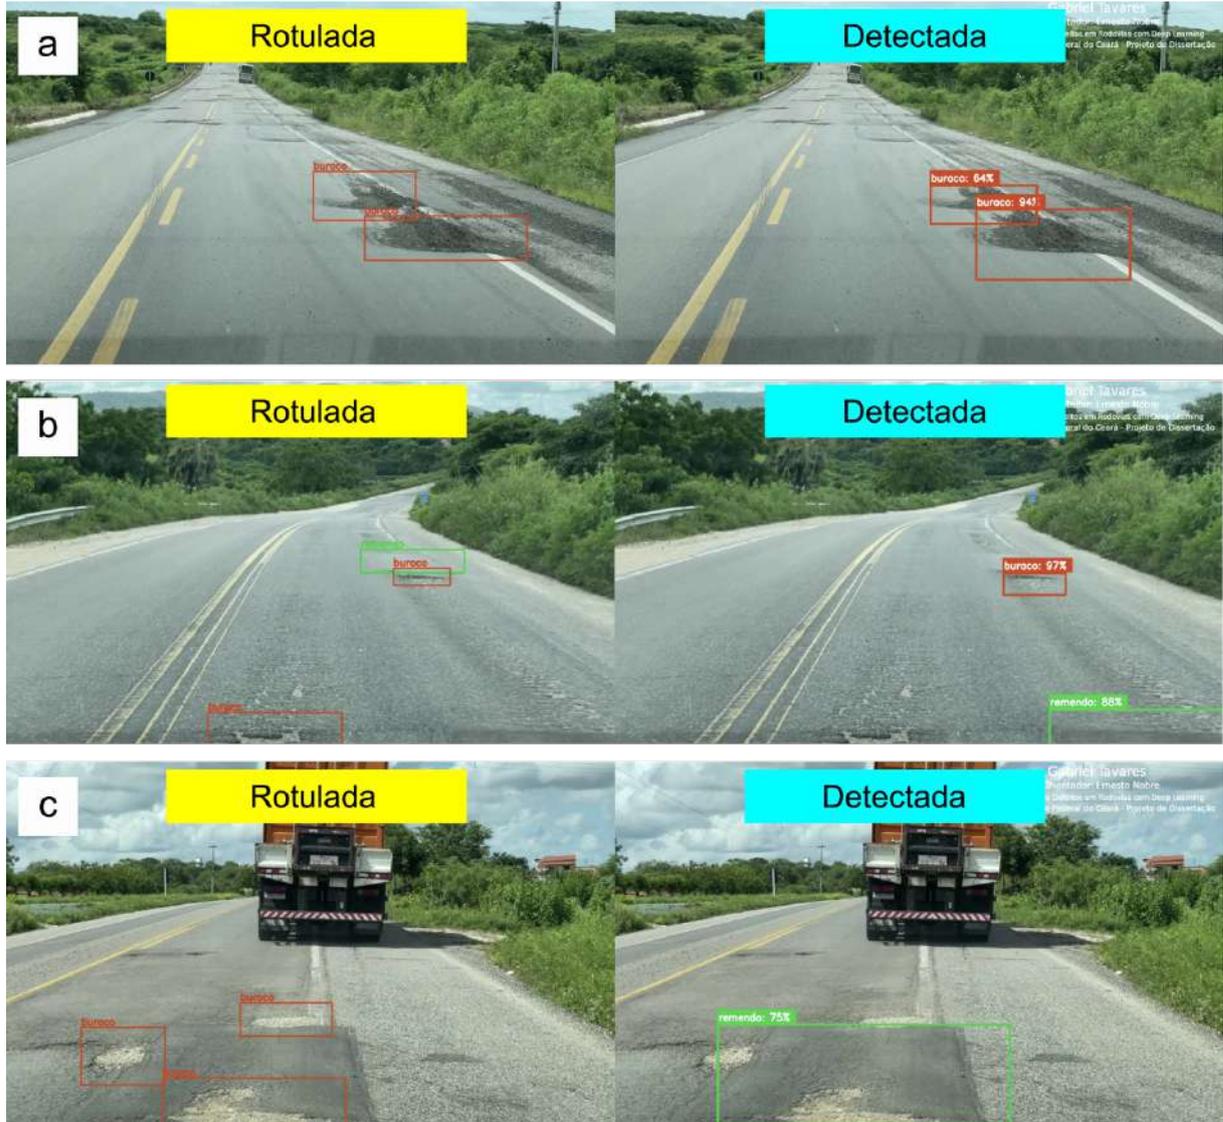


Fonte: O Autor (2022).

A Figura 42 também apresenta três cenários, neste caso para o *dataset* do iPhone 4K. O cenário da Figura 42a representa um caso bem-sucedido, onde os dois buracos rotulados foram identificados corretamente na fase de detecção. Na Figura 42b temos uma situação em que dois defeitos rotulados não foram encontrados e um defeito não rotulado foi detectado. Neste cenário, temos um falso negativo, como ocorreu no cenário da Figura 41b. Porém temos dois defeitos não identificados, e este caso provavelmente ocorreu por falta de um aprendizado melhor.

O terceiro e último cenário (Figura 42c), também se teve um falso negativo, no entanto três defeitos também não foram detectados. Este terceiro caso se assemelha bastante com o segundo. Portanto, sugere-se a realização de um novo treinamento contendo a inclusão de mais imagens neste *dataset*. Portanto, sugere-se a realização de um novo treinamento contendo a inclusão de mais imagens neste *dataset* com a revisão dos rótulos realizados.

Figura 42 – Imagens de validação do *dataset* do iPhone 4K

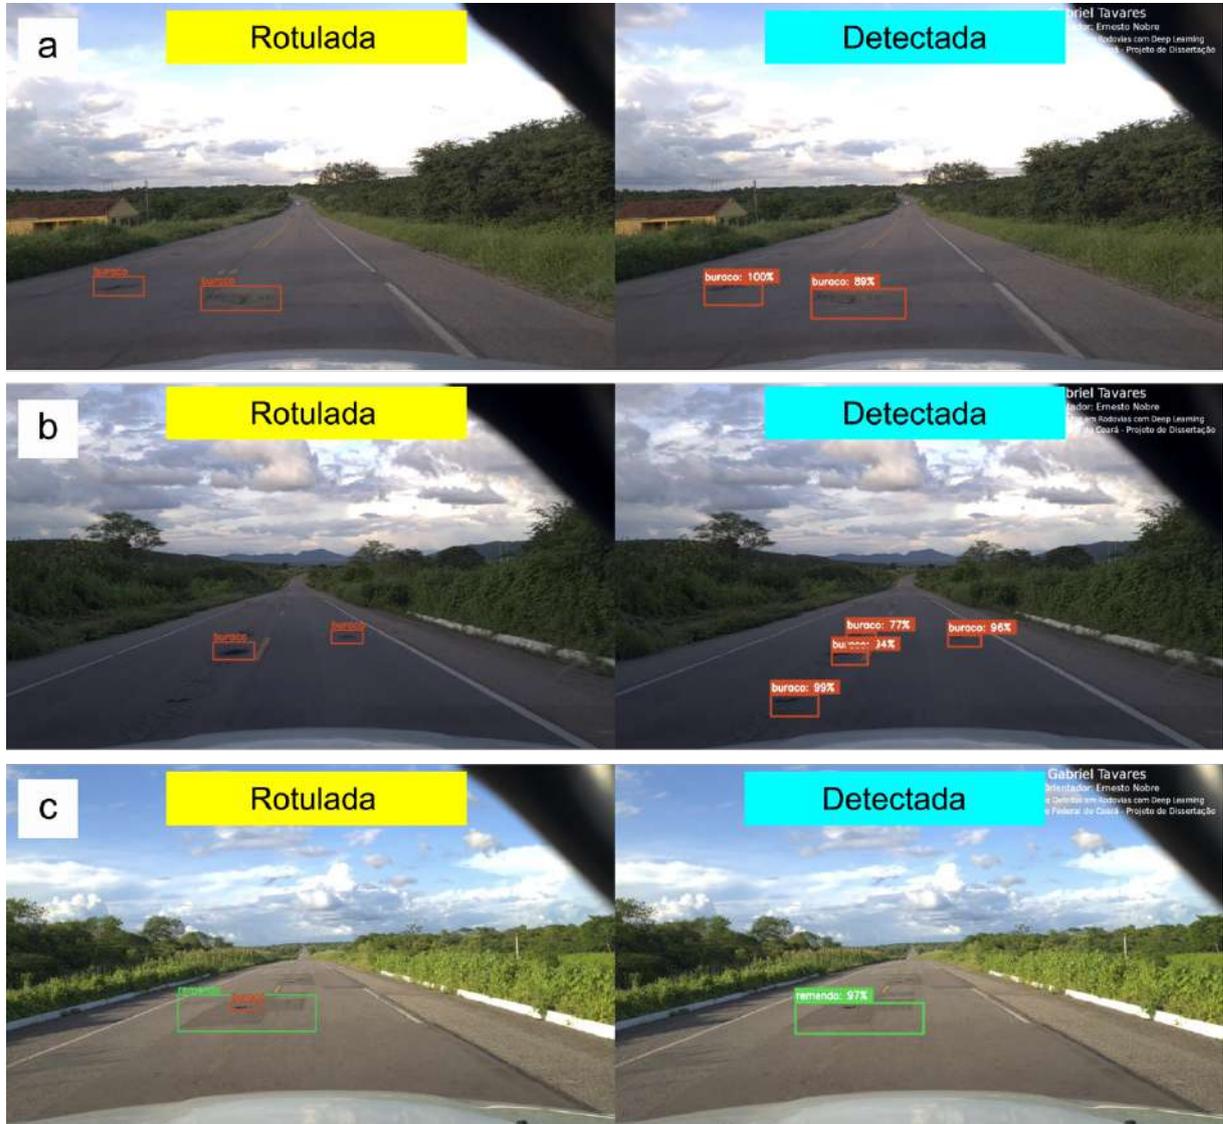


Fonte: O Autor (2022).

A Figura 43 apresenta os três cenários para o *dataset* do S20 FHD. No primeiro caso (Figura 43a) demonstra uma situação bem-sucedida, onde os dois defeitos foram identificados corretamente. No segundo (Figura 43b), temos dois falsos negativos, o que representa um problema na geração das métricas, porém indica que o algoritmo reconheceu até mesmo situações em que a rotulação não foi realizada. Na Figura 43c, temos um problema de não identificação

de um buraco. Este terceiro cenário pode ter sido causa de poucas imagens no *dataset*, e provavelmente pode ser resolvido através da rotulação de mais defeitos em um novo treinamento.

Figura 43 – Imagens de validação do *dataset* do S20 FHD

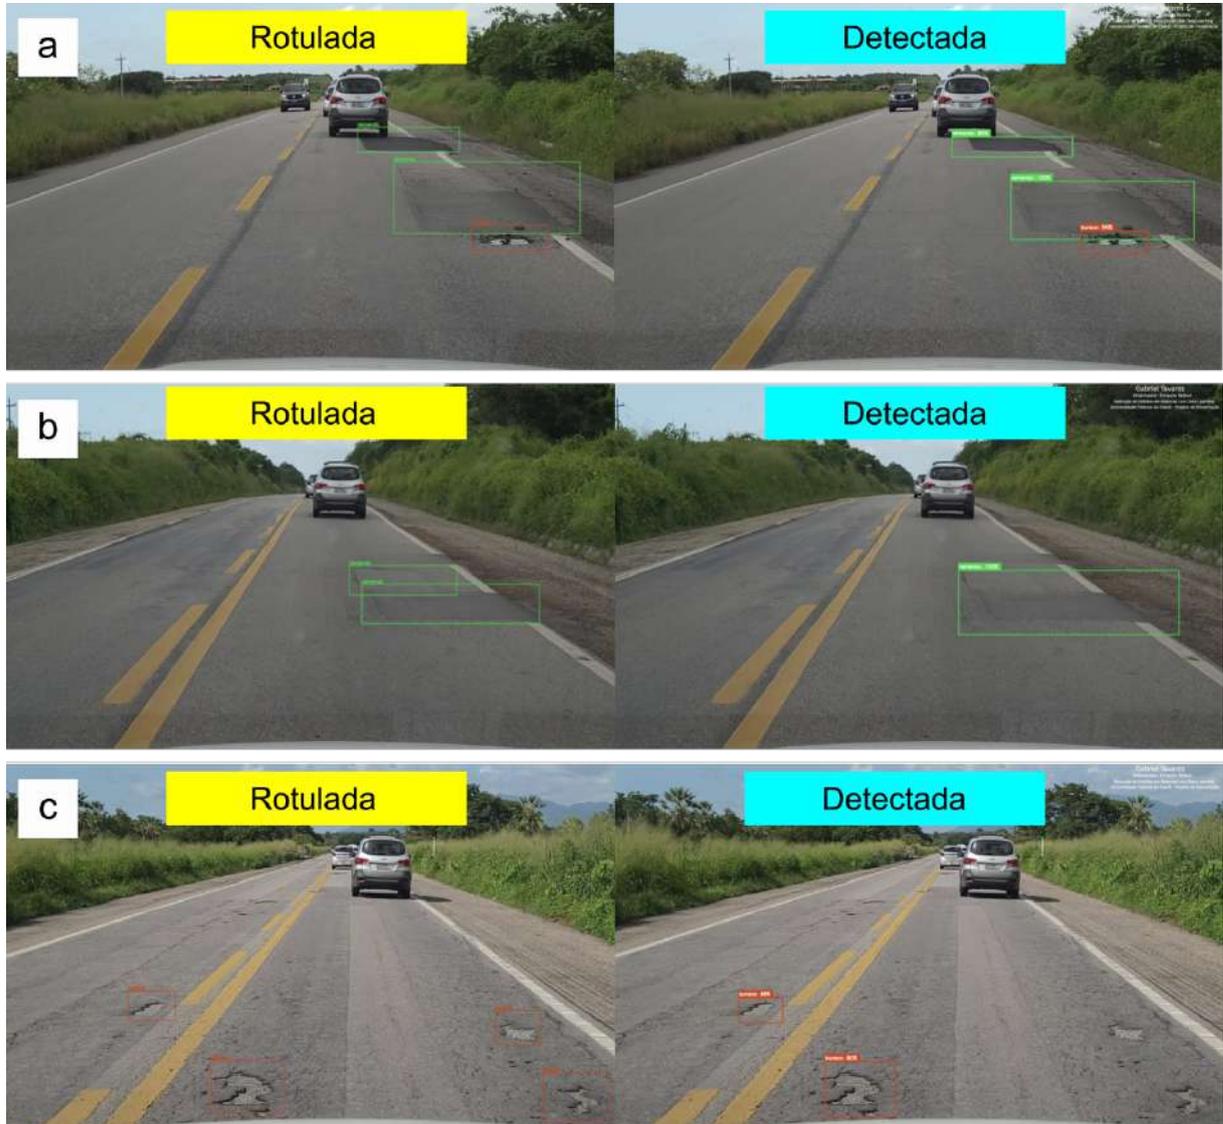


Fonte: O Autor (2022).

Na Figura 44 temos três cenários para o *dataset* do S20 4K. Seguindo a mesma lógica dos cenários anteriores, o apresentamos um primeiro caso de sucesso (Figura 44a), onde os defeitos foram detectados tal qual realizados na fase de rotulação. No segundo cenário (Figura 44b), percebe-se um fato interessante: foram rotulados 2 remendos, entretanto o algoritmo detectou esses dois como sendo um único defeito. Isso porque durante a rotulação houve casos em que dois remendos foram tratados como sendo um único. Significa dizer que o algoritmo aprendeu que a identificar o que é um remendo de forma correta. Haverá situações que ele irá identificar de forma separada e outras em que serão identificados de forma única. Na Figura 44c,

identificou dois buracos e deixou de identificar dois. O segundo e o terceiro cenário da Figura 44, irão melhorar à medida que houver mais imagens no *dataset*.

Figura 44 – Imagens de validação do *dataset* do S20 4K

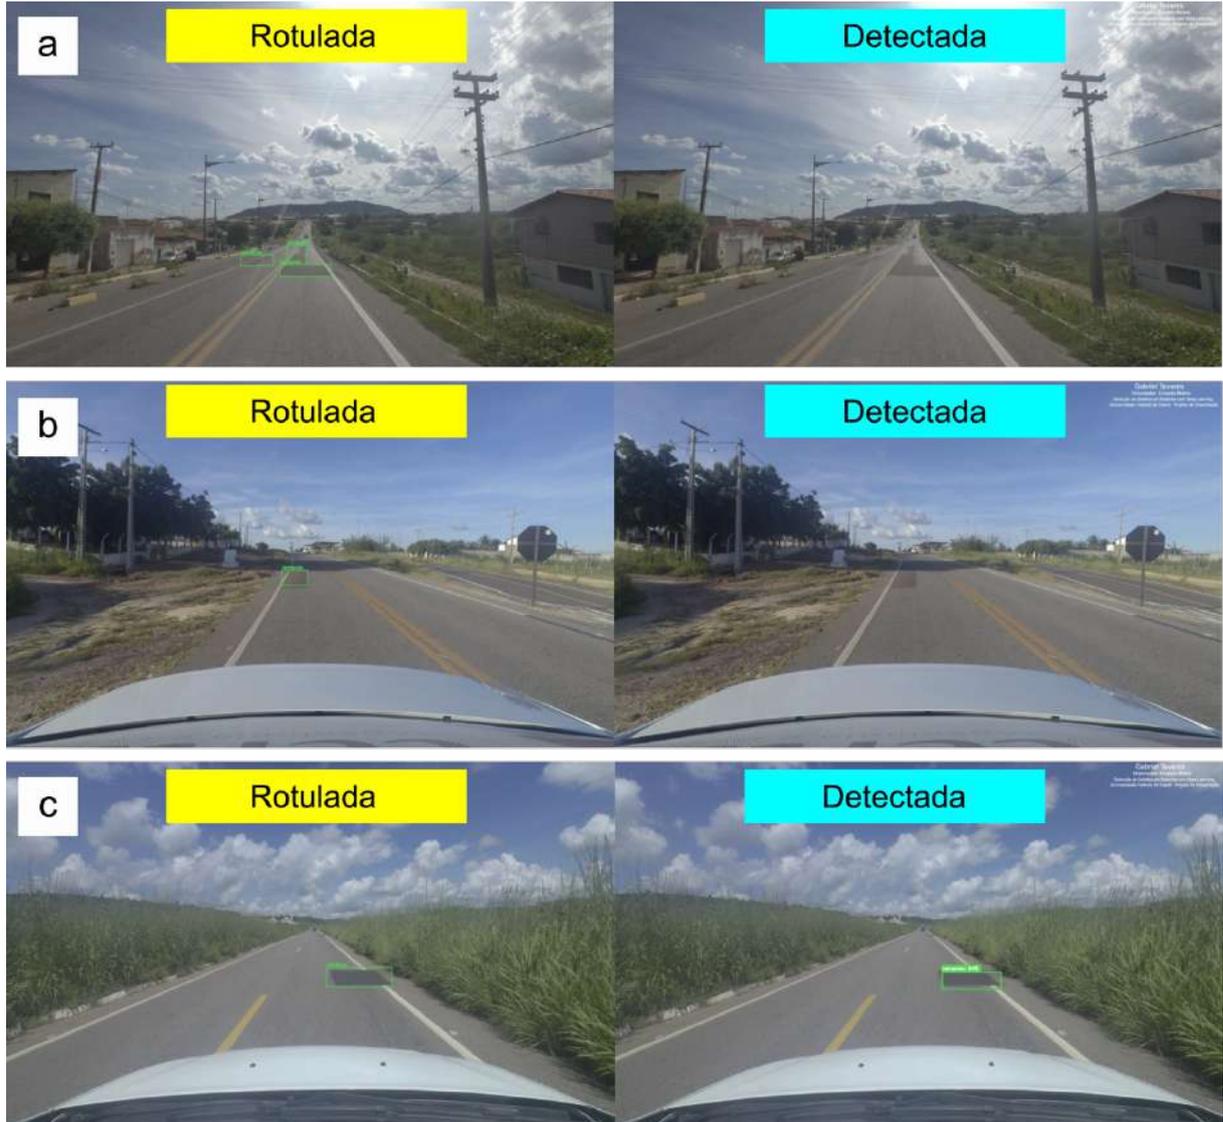


Fonte: O Autor (2022).

Os resultados do *dataset* da GARMIN são apresentados na Figura 45. No primeiro e no segundo cenário (Figura 45a e Figura 45b), o algoritmo encontrou os defeitos. Como a imagem possui uma visão panorâmica muito ampla, os defeitos mais distantes ficaram muito pequenos e com pouca nitidez, o que dificultou a detecção. Vale ressaltar, que neste *dataset* é muito comum acontecer casos com este, o que tornaria o *software* ineficaz. No terceiro cenário (Figura 45c), o objeto em cena encontra-se mais nítido e mais próximo da câmera, tornando possível a detecção. Podemos aferir que o problema principal deste *dataset* é a vasta ampliação da câmera, tornando o cenário poluído, pois o que interessa são apenas os defeitos do

pavimento. No entanto, ainda assim, é possível realizar a detecção mesmo com um grau baixo de assertividade. No entanto, ainda assim, é possível realizar a detecção mesmo com um grau baixo de assertividade. Para melhorar o grau de assertividade neste *dataset*, pode-se aumentar a frequência de captura das imagens em campo (uma imagem a cada 5 metros), de modo que os defeitos mais longes seriam identificados na imagem subsequente.

Figura 45 – Imagens de validação do *dataset* da GARMIN



Fonte: O Autor (2022).

Na Figura 46 foi demonstrado um outro exemplo de detecção no *dataset* da GARMIN. Nota-se que na imagem há mais informação de céu que de rodovia, de modo que, o céu ocupa quase 70% da imagem. Neste *dataset* as imagens foram registradas em 4K, no entanto essa imagem é redimensionada para 512 *pixels* de largura durante o treinamento, diminuindo cerca de oito vezes. Isso significa que os defeitos ficaram extremamente pequenos após o

redimensionamento e, com isso, o algoritmo teria maior dificuldade na detecção dos objetos.

Figura 46 – Resultado de um caso de detecção do Treinamento da GARMIN



Fonte: Empresa A (2022).

Os resultados do *dataset* da GOPRO são exibidos na Figura 47. No cenário da Figura 47a, temos um caso de sucesso, de modo que o algoritmo identificou todos os defeitos. No segundo caso (Figura 47b), temos falsos negativos, de modo que o algoritmo detectou defeitos que não foram rotulados. No terceiro (Figura 47c), o algoritmo não identificou o buraco coberto com água no final da imagem. Neste último, poucos rótulos semelhantes a este foram passados para o algoritmo, pois houve um intervalo curto de tempo chuvoso durante o levantamento. Sugere-se mais situações dessa natureza a fim de melhorar sua acurácia, caso haja necessidade de o algoritmo realizar a identificação de buracos com água. Vale ressaltar que este *dataset* apresentou os melhores resultados em termos de métricas, e fazendo uma análise detalhada de cada caso isoladamente o algoritmo poderia melhorar ainda mais através do aumento do imagens. Destaca-se que este *dataset* teve uma visão ampliada dos objetos em cena, de modo que defeitos permaneceram com boa visibilidade, nitidez e tamanho adequado para ser identificado na rede YOLOv3.

Figura 47 – Imagens de validação do *dataset* da GOPRO



Fonte: O Autor (2022).

Olhando para a Tabela 13, é possível perceber facilmente que o *dataset* da GOPRO apresenta valores de AP maiores se comparado ao valor dos *datasets* gerados pelos *smartphones* e que por sua vez também apresentam valores de AP melhores que os do *dataset* da GARMIN. Uma possível explicação para isso é que os defeitos registrados nas imagens do *dataset* da GARMIN ocupam um espaço muito pequeno na imagem, pois a rodovia ocupa em torno de 30% da imagem (o restante é céu), fato este que dificulta sua visualização, enquanto os defeitos registrados no *dataset* da GOPRO ocupam um espaço considerável da imagem na maioria dos casos.

Segundo testes reportados por diversos desenvolvedores, o YOLOv3 apresenta

dificuldade em detectar objetos pequenos¹, sendo essa, portanto, uma possível justificativa para os resultados obtidos junto ao *dataset* da GARMIN. Logo, pode-se destacar que a precisão média (AP) no treinamento do conjunto de dados da GOPRO gerou como saída 99,89% de precisão para buracos e 95,91% para remendos. Portanto, a utilização de imagens em que a câmera estivesse voltada para o pavimento surtiu um efeito positivo.

¹ <https://github.com/pjreddie/darknet/issues/1535>

5 CONCLUSÕES E RECOMENDAÇÕES

Este capítulo contempla as principais conclusões do trabalho e sugestões para estudos futuros, que resultaram da elaboração de um *software* para identificação de defeitos em pavimentos rodoviários visando auxiliar nas decisões dos engenheiros a respeito das tarefas de manutenção da via. Ressalta-se que as conclusões obtidas estão vinculadas às especificidades do estudo aqui descrito e a partir delas, pôde-se conhecer melhor as potencialidades e as limitações do *software* proposto.

5.1 Conclusões

Apesar dos grandes avanços na automação de tarefas relacionadas à detecção de objetos, onde as aplicações começam a apresentar resultados cada vez mais precisos e confiáveis, ainda existem muitos desafios pela frente. Se considerarmos a qualidade e variação das imagens registradas, teremos um trabalho bastante desafiador.

Detectar defeitos em pavimentos rodoviários, embora seja um problema mais comum em países emergentes, é importante em diversos cenários. Os levantamentos visuais contínuos (LVC) são solicitados por órgãos rodoviários para realização do mapeamento dos defeitos e da severidade observada. Através desse mapeamento, é possível tomar diversas decisões nos departamentos de manutenção de estradas.

Apresentamos neste trabalho um *software* que detecta de buracos e remendos em rodovias pavimentadas através imagens capturadas de câmeras ou *smartphones*. As imagens foram enviadas para um Notebook a fim de serem utilizadas no processamento do algoritmo. O algoritmo foi desenvolvido utilizando o YOLOv3, uma rede de *Deep Learning* com foco em visão computacional e que processa imagens em tempo real. O YOLO foi utilizado para aprender os padrões de defeitos do tipo buraco e remendo em pavimentos rodoviários asfálticos.

Constatou-se que o advento da tecnologia aplicada neste processo tem levado a uma maior agilidade na resposta da identificação das condições do pavimento, uma vez que a avaliação do estado da malha é muitas vezes realizada por intervenção humana. Estes algoritmos poderão auxiliar nas tarefas dos engenheiros e técnicos dos órgãos rodoviários, já que a tecnologia desenvolvida atingiu uma boa performance, permitindo obter resultados de 99,89% e 95,91% de precisão para buracos e remendos, respectivamente, nos melhores cenários.

Vale ressaltar que o algoritmo desenvolvido também pode ser utilizado em locais

onde a gestão rodoviária possui poucos recursos financeiros para monitorar a condição do pavimento. Neste sistema proposto, o órgão pode realizar uma coleta de dados contínua e enviar as imagens para o algoritmo realizar a detecção dos defeitos, sendo possível visualizar essas detecções através do *software* de apoio ao inventário que foi desenvolvido nesta pesquisa (Apêndice D).

Por fim, conclui-se que os algoritmos de detecção utilizando *Deep Learning* se apresentam como uma alternativa viável na detecção de defeitos no pavimento, pois através das imagens obtidas e do correto treinamento dos dados, pode auxiliar as tomadas de decisão dos órgãos de conservação rodoviária e concessionárias. Essa tecnologia abordada possui um baixo custo, fácil operação e alta produtividade com potencial de melhoria, podendo ser utilizada em larga escala.

5.2 Sugestões para trabalhos futuros

A seguir serão apresentadas algumas sugestões para trabalhos futuros relacionados ao uso de *Deep Learning* para a detecção de defeitos nos pavimentos:

- a) Aplicar técnicas mais avançadas no pré-processamento das imagens, como recortar a área de interesse. Esta técnica poderia diminuir a quantidade de falsos positivos na área exterior ao pavimento e eliminar a influência de outros atributos irrelevantes da imagem no processo de treinamento;
- b) Obter um conjunto de dados mais extenso para cada *dataset*, e fazer as rotulações incluindo outros tipos de defeitos presentes na rodovia;
- c) Treinar novamente a rede YOLO para cada *dataset* utilizando novos parâmetros e com rótulos balanceados;
- d) Utilizar técnicas de *Data Augmentation* a fim de aumentar a quantidade de cópias das imagens ligeiramente modificadas;
- e) Obter novos parâmetros a fim de determinar índices de condição ou aptidão dos pavimentos;
- f) Estimar a vida restante dos pavimentos;
- g) Permitindo a inserção de outras informações relacionadas a rodovia no *software* de apoio ao inventário.

REFERÊNCIAS

- AASHTO. **Guide for Design Management Systems**. Washington DC: American Association of State Highway and Transportation Officials, 1990.
- ADLINGE, S. S.; GUPTA, A. K. Pavement deterioration and its causes. **International Journal of Innovative Research and Development**, v. 2, n. 4, p. 437–450, 2013.
- ALMEIDA, L. C. **Aplicativo para smartphone destinado à medição da irregularidade longitudinal em rodovias**. 2018. 93 f. Dissertação (Mestrado em Engenharia de Transportes) — Universidade Federal do Ceará, Fortaleza, 2018. Disponível em: <http://www.repositorio.ufc.br/bitstream/riufc/35669/3/2018_dis_lcalmeida.pdf>. Acesso em: 19 ago. 2021.
- AMERICAN SOCIETY FOR TESTING AND MATERIALS. **ASTM E-867-82A**: Standard definition of terms relating to traveled surface characteristics. Philadelphia, 1982.
- APS, M.; BALBO, J. T.; SEVERI, A. A. Avaliação superficial de pavimentos asfálticos em vias urbanas utilizando o método do pci. **ABPV. REUNIÃO ANUAL DE PAVIMENTAÇÃO**, São Paulo, 1998.
- BALBO, J. T. **Pavimentação asfáltica: materiais, projeto e restauração**. São Paulo: Oficina de Textos, São Paulo, 2007.
- BARBOSA, L. D. C.; MOURA, M. A. D. **Estudo de patologias em pavimento asfáltico no trecho dique estrada na cidade de Maceió-AL**. 2018. 34 f. Dissertação (Bacharelado em Engenharia Civil) — Curso de Engenharia Civil, Centro Universitário CESMAC, Maceió, 2018.
- BARELLA, R. M. **Contribuição para a avaliação da irregularidade longitudinal de pavimentos com perfilômetros inerciais**. 2008. Tese (Doutorado em Engenharia de Transportes) — Universidade de São Paulo, São Paulo, 2008.
- BARTHOLOMEU, D. B.; FILHO, C.; VICENTE, J. Impactos econômicos e ambientais decorrentes do estado de conservação das rodovias brasileiras: um estudo de caso. **Revista de Economia e Sociologia Rural**, v. 46, p. 703–738, 2008.
- BARTHOLOMEU, D. B. *et al.* Quantificação dos impactos econômicos e ambientais decorrentes do estado de conservação das rodovias brasileiras. Piracicaba, SP, 2006.
- BAUSANO, J.; CHATTI, K.; WILLIAMS, R. C. Reliability-based use of pms data for determining the life expectancy of preventive maintenance fixes for asphalt surfaces pavements. **Transportation Research Board, 83rd Annual Meeting**, Washington, DC, 2004.
- BERNNETT, M. Intercultural communication: A current perspective. **Basic Concepts of Intercultural Communication**, 1998.
- BERNUCCII, L. A.; MOTTA, L. M. G.; CERATTI, J. A. P.; SOARES, J. B. **Pavimentação Asfáltica**: Formação básica para engenheiros. Rio de Janeiro, 2008.
- BERTOLLO, S. A. M.; FERNANDES JUNIOR, J. L. Considerações sobre a gerência de pavimentos urbanos em nível de rede. 1997.
- CATION, K. A. e. a. Development of a preventive maintenance algorithm for use in pavement management systems. 1987.

CERTIFIC NET. **Tutorial de Utilização do SmartIRI: Versão 2.0**. 2019. Disponível em: <<https://firebasestorage.googleapis.com/v0/b/smartiriapp-prod.appspot.com/o/config\2FTutorial\20SmartIRI.pdf?alt=media&token=2689d87f-77f9-4cd3-857a-26be65afec68>>. Acesso em: 08 abr. 2022.

CHANG, K.; CHANG, J.; LIU, J. Detection of pavement distresses using 3d laser scanning technology. In: **Computing in civil engineering (2005)**. [S.l.: s.n.], 2005. p. 1–11.

CHETLUR, S. e. a. cudnn: Efficient primitives for deep learning. **arXiv preprint arXiv:1410.0759**, 2014.

CHOI, J. e. a. Gaussian yolov3: An accurate and fast object detector using localization uncertainty for autonomous driving. **Proceedings of the IEEE/CVF International Conference on Computer Vision**, p. 502–511, 2019.

CHOLLET, F. **Deep Learning with Python, 1stedn**. [S.l.]: Manning Publications Co., Greenwich, CT, USA, 2017.

CNT. **Malha rodoviária em maio de 2018**. 2018. Disponível em: <<https://anuariodotransporte.cnt.org.br/2018/Rodoviario/1-3-1-1-1-/Malha-rodovi%C3%A1ria-total>>. Acesso em: 22 abr. 2021.

CNT. **Pesquisa de Rodovias de 2019**. 2019. Disponível em: <<https://pesquisarodovias.cnt.org.br/downloads/ultimaversao/gerencial.pdf>>. Acesso em: 22 fev. 2022.

CNT. **Malha rodoviária em maio de 2021**. 2021. Disponível em: <<https://anuariodotransporte.cnt.org.br/2021/Rodoviario/1-3-1-1-1-/Malha-rodovi%C3%A1ria-total>>. Acesso em: 22 abr. 2022.

COPELAND, M. What's the difference between artificial intelligence, machine learning and deep learning. 2016. Disponível em: <<https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/>>. Acesso em: 17 ago. 2021.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES - INSTITUTO DE PESQUISAS RODOVIÁRIAS. **DNIT-IPR 745/2011**: Manual de gerência de pavimentos. Rio de Janeiro, 2011.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES - INSTITUTO DE PESQUISAS RODOVIÁRIAS. **DNIT 006/2003 – PRO**: Avaliação objetiva da superfície de pavimentos flexíveis e semi-rígidos. Rio de Janeiro, 2003.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES - INSTITUTO DE PESQUISAS RODOVIÁRIAS. **DNIT 007/2003 – PRO**: Avaliação objetiva da superfície de pavimentos flexíveis e semi-rígidos. Rio de Janeiro, 2003.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES - INSTITUTO DE PESQUISAS RODOVIÁRIAS. **DNIT 008/2003 – PRO**: Levantamento visual contínuo para avaliação da condição de superfície de pavimentos flexíveis e semi-rígidos. Rio de Janeiro, 2003.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES - INSTITUTO DE PESQUISAS RODOVIÁRIAS. **DNIT 009/2003 – PRO**: Avaliação subjetiva da superfície de pavimentos flexíveis e semi-rígidos. Rio de Janeiro, 2003.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES - INSTITUTO DE PESQUISAS RODOVIÁRIAS. **NORMA DNIT 062/2004 - PRO**: Pavimento rígido - avaliação objetiva - procedimento. Rio de Janeiro, 2004.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES - INSTITUTO DE PESQUISAS RODOVIÁRIAS. **NORMA DNIT 063/2004 - PRO**: Pavimento rígido – avaliação subjetiva – procedimento. Rio de Janeiro, 2004.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES - INSTITUTO DE PESQUISAS RODOVIÁRIAS. **DNIT-IPR 740/2005**: Manual de conservação rodoviária. Rio de Janeiro, 2005.

DNER. **Manual de Reabilitação de Pavimentos Asfálticos**. Rio de Janeiro, 1998. 243 p.

DNER-PRO 182/94. : Medição da irregularidade de superfície de pavimento com sistemas integradores ipr/usp e maysmeter. Rio de Janeiro, 1994.

DOMINGUES, F. A. A. Mid: manual de identificacao de defeitos de revestimentos asfalticos de pavimentos. 1993.

EL NAQA, I.; MURPHY, M. J. **What Is Machine Learning?** [S.l.]: Springer, 2015.

EVERINGHAM, M.; GOOL, L. V.; WILLIAMS, C. K.; WINN, J.; ZISSERMAN, A. The pascal visual object classes (voc) challenge. **International journal of computer vision**, Springer, v. 88, n. 2, p. 303–338, 2010.

FARIAS, M. M.; SOUZA, R. O. Irregularidade longitudinal e sua influência na avaliação funcional de pavimentos. **VII Encontro Nacional de Conservação Rodoviária – ENACOR**, Vitória, ES, 2010.

FENG, X.; JIANG, Y.; YANG, X.; DU, M.; LI, X. Computer vision algorithms and hardware implementations: A survey. **Integration**, Elsevier, v. 69, p. 309–320, 2019.

FERNANDES JÚNIOR, J. L.; ODA, S.; ZERBINI, L. F. *et al.* Defeitos e atividades de manutenção e reabilitação em pavimentos asfálticos. 2003.

FLECK, L. e. a. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47–57, 2016.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. [S.l.]: Editora Blucher, 2000.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. [S.l.]: MIT press, 2016.

HAAS, R.; HUDSON, W. R. **Pavement management systems**. [S.l.: s.n.], 1978.

HAAS, R.; HUDSON, W. R.; ZANIEWSKI, J. P. **Modern Pavement Management**. [S.l.: s.n.], 1994.

HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2016. p. 770–778.

- HINTON, G. E. Learning multiple layers of representation. **Trends in cognitive sciences**, Elsevier, v. 11, n. 10, p. 428–434, 2007.
- HOANG, N.-D. An artificial intelligence method for asphalt pavement pothole detection using least squares support vector machine and neural network with steerable filter-based feature extraction. **Advances in Civil Engineering**, 2018.
- 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**, Elsevier, v. 104, p. 312–321, 2013.
- INSTITUTO DO ASFALTO. **A Pavement Rating System for Low Volume Asphalt Roads**. [S.l.: s.n.], 1981.
- JÄHNE, B. **Digital Image Processing**. [S.l.]: Berlin: Springer, 2005.
- KHAN, A. I.; AL-HABSI, S. Machine learning in computer vision. **Procedia Computer Science**, Elsevier, v. 167, p. 1444–1451, 2020.
- KIM, T.; RYU, S.-K. A guideline for pothole classification. **International Journal of Engineering and Technology**, Citeseer, v. 4, n. 10, p. 618–622, 2014.
- KOCH, C.; BRILAKIS, I. Pothole detection in asphalt pavement images. **Advanced Engineering Informatics**, Elsevier, v. 25, n. 3, p. 507–515, 2011.
- KOCH, C.; JOG, G. M.; BRILAKIS, I. Automated pothole distress assessment using asphalt pavement video data. **Journal of Computing in Civil Engineering**, American Society of Civil Engineers, v. 27, n. 4, p. 370–378, 2013.
- KOVÁCS, Z. L. **Redes neurais artificiais**. [S.l.]: Editora Livraria da Física, 2002.
- LANDERS, S.; FALLS, L. C.; CHEETHAM, A. Development of a pavement surface performance measure for the british columbia pavement management system. In: **Fifth International Conference on Managing Pavements Washington State Department of Transportation Foundation for Pavement Preservation International Society for Asphalt Pavements Federal Highway Administration Transportation Research Board**. [S.l.: s.n.], 2001.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- MAEDA, H.; SEKIMOTO, Y.; SETO, T.; KASHIYAMA, T.; OMATA, H. Road damage detection using deep neural networks with images captured through a smartphone. **arXiv preprint arXiv:1801.09454**, 2018.
- MARCON, A. **Contribuição ao Desempenho de um Sistema de Gerência de Pavimentos para a Malha Rodoviária Estadual de Santa Catarina**. 1996. Tese (Tese de Doutorado) — ITA, São José dos Campos, SP, 1996.
- MARGAPURI, V.; LAVEZZI, G.; STEWART, R.; WAGNER, D. Bombus species image classification. **arXiv preprint arXiv:2006.11374**, 2020.
- MEDINA, J. **Mecânica dos Pavimentos**. [S.l.]: COPPE/UFRJ, 1997.

MITCHELL, T. M. **The discipline of machine learning**. [S.l.]: Carnegie Mellon University, School of Computer Science, Machine Learning Department, 2006.

MURPHY, K. P. **Machine learning: A Probabilistic Perspective**. [S.l.]: Cambridge, Mass, USA: MIT Press, 2012.

OLIVEIRA, R.; ALBUQUERQUE, F. Avaliação de perfil longitudinal de pavimento de concreto de cimento portland com perfilômetro inercial a laser. **TRANSPORTES**, v. 25, n. 1, p. 82–92, 2017.

PADILLA, R.; NETTO, S. L.; SILVA, E. A. D. A survey on performance metrics for object-detection algorithms. In: **2020 international conference on systems, signals and image processing (IWSSIP)**. [S.l.: s.n.], 2020. p. 237–242.

PATERSON, W. D. **Road deterioration and maintenance effects: Models for planning and management**. [S.l.: s.n.], 1987.

PATTERSON, J.; GIBSON, A. **Deep learning: A practitioner's approach**. [S.l.]: O'Reilly Media, Inc., 2017.

POWERS, D. M. Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation. **arXiv preprint arXiv:2010.16061**, 2020.

PRINCE, S. J. **Computer vision: models, learning, and inference**. [S.l.]: Cambridge University Press, 2012.

RADOVIC, M.; ADARKWA, O.; WANG, Q. Object recognition in aerial images using convolutional neural networks. **Journal of Imaging**, MDPI, v. 3, n. 2, p. 21, 2017.

RAUBER, T. W. Redes neurais artificiais. **Universidade Federal do Espírito Santo**, v. 29, 2005.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2016. p. 779–788.

RODRIGUES, R. M. **Projeto de Reforço de Pavimentos Rodoviários e Aeroportuários pelo Método da Resiliência; Uma Nova Versão do Programa TECNAPAV**. 1987. Tese (Tese de Doutorado) — COPPE/UFRJ, Rio de Janeiro, 1987.

ROSEBROCK, A. **Deep learning for computer vision with python: starter bundle**. [S.l.]: PyImageSearch, 2017.

RUSSAKOVSKY, O.; DENG, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MA, S.; HUANG, Z.; KARPATY, A.; KHOSLA, A.; BERNSTEIN, M.; BERG, A. C.; FEI-FEI, L. ImageNet Large Scale Visual Recognition Challenge. **International Journal of Computer Vision (IJCV)**, v. 115, n. 3, p. 211–252, 2015.

SASAKI, Y. The truth of the f-measure. 2007. Disponível em: <<https://www.cs.odu.edu/~mukka/cs795sum09dm/Lecturenotes/Day3/F-measure-YS-26Oct07.pdf>>. Acesso em: 20 fev. 2022.

SAYERS, M. W.; KARAMIHAS, S. M. The little book of profiling. 1998. Disponível em: <<https://deepblue.lib.umich.edu/handle/2027.42/21605>>. Acesso em: 21 out. 2021.

SHAHIN, M. Y.; KHON, S. D. **Development of a Pavement Condition Rating Procedure for Roads, Streets, and Parking Lots: Distress identification manual.** cerl-tr-m-268. U.S, 2005. (Vol.2).

SHRP. **Distress Identification Manual for the Long Term Pavement Performance Project.** [S.l.]: Strategic Highway Research Program, National Academy of Sciences, 1993.

TYAGI, V. **Understanding digital image processing.** [S.l.]: CRC Press, 2018.

VAZ, A. Introdução teórica a neural network — deep learning. 2018. Disponível em: <<https://medium.com/data-hackers/neural-network-deep-learning-parte-1-introdu%C3%A7%C3%A3o-te%C3%B3rica-5c6dcd2e5a79>>. Acesso em: 23 out. 2019.

YODER, E. J.; WITCZAK, M. W. **Principles of pavement design.** [S.l.]: Wiley-Interscience Publication, 1975.

YSHIBA, J. K. **Modelos de Desempenho de Pavimentos: Estudo de Rodovias do Estado do Paraná.** 2003. Tese (Tese de Doutorado) — EESC, São Paulo, 2003.

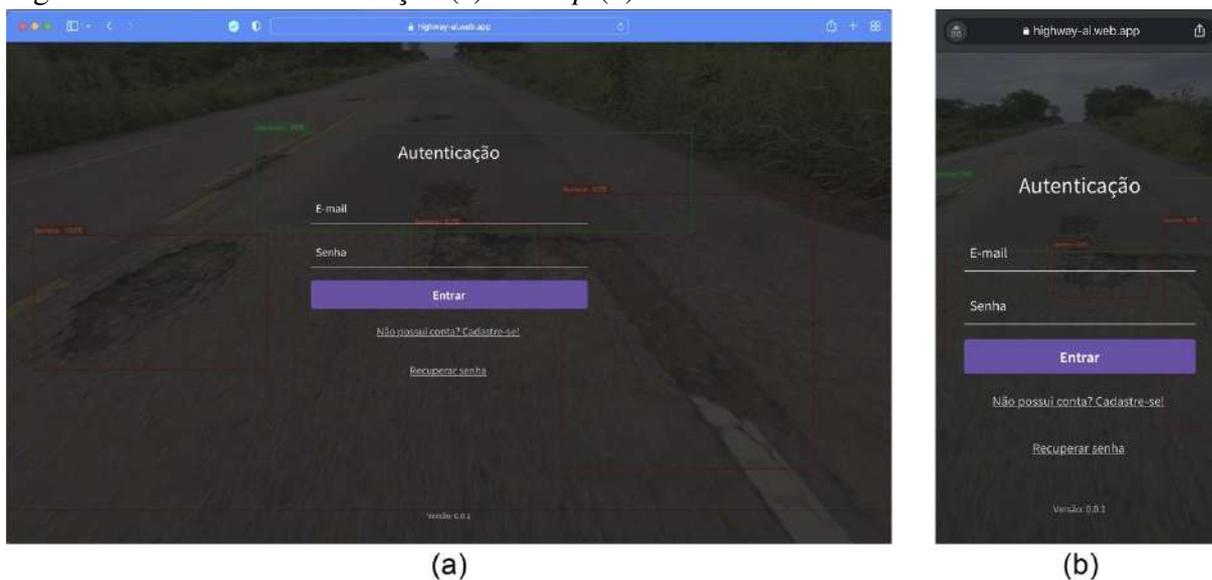
YU, B. X.; YU, X. Vibration-based system for pavement condition evaluation. In: **Applications of advanced technology in transportation.** [S.l.: s.n.], 2006. p. 183–189.

APÊNDICE D – SOFTWARE DE APOIO AO INVENTÁRIO

Nesta pesquisa foi criado um algoritmo para servir de apoio no processo de avaliação das condições do pavimento. Portanto, neste tópico descreveremos o *software* de apoio ao inventário, o qual foi desenvolvido para executar na plataforma *web* e possibilitar a visualização das imagens do inventário. Na implementação foi utilizada a linguagem de programação *Javascript* juntamente com códigos em HTML e CSS. O intuito dessa ferramenta é mostrar as informações da detecção de uma forma mais clara e objetiva para o usuário, uma vez que ela poderá servir de apoio na tomada de decisão por parte dos pesquisadores, engenheiros, analistas e técnicos da área de engenharia de transportes.

Para sua utilização, basta acessar um endereço no navegador do seu computador pessoal ou dispositivo móvel. Uma vez acessada, será exibida uma página de autenticação em que para ter acesso é necessário solicitar a autorização ao administrador do sistema (Figura 48).

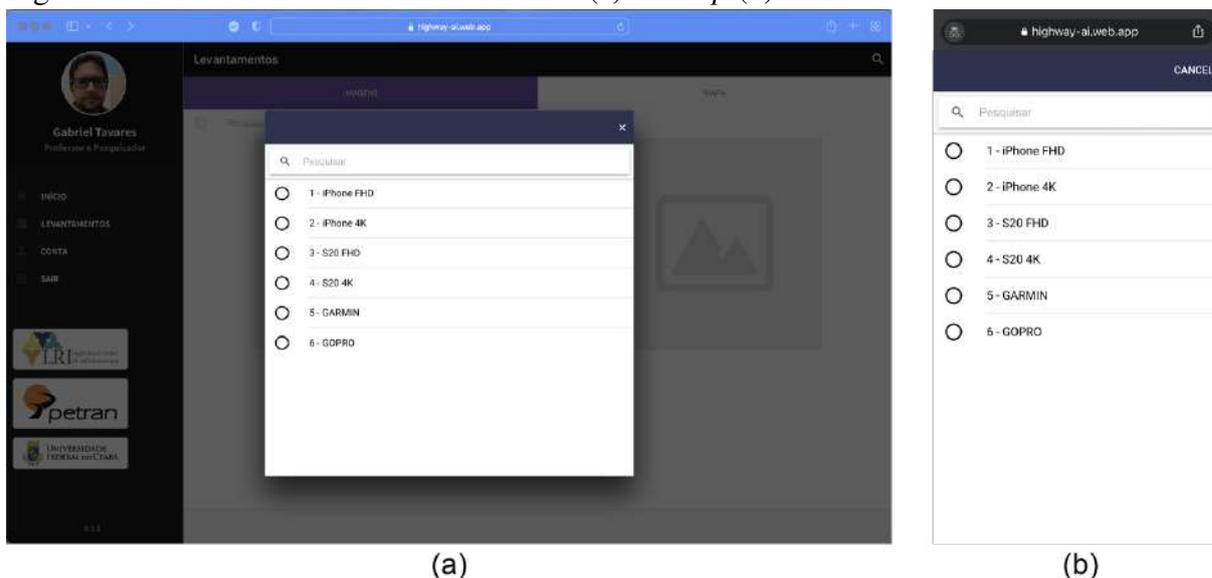
Figura 48 – Tela de Autenticação (a) *desktop* (b) *mobile*



Fonte: O Autor (2022).

Após se autenticar no *software*, a tela de visualização dos dados dos *datasets* pode ser acessada através do menu “Levantamentos”. Para visualizar os *datasets* é necessário clicar na lupa (no canto direito da barra superior), selecionar o *dataset* em uma lista e confirmar (Figura 49). Após escolher o *dataset*, serão carregadas todas as imagens desse *dataset*.

Figura 49 – Tela de Busca do Levantamento (a) *desktop* (b) *mobile*

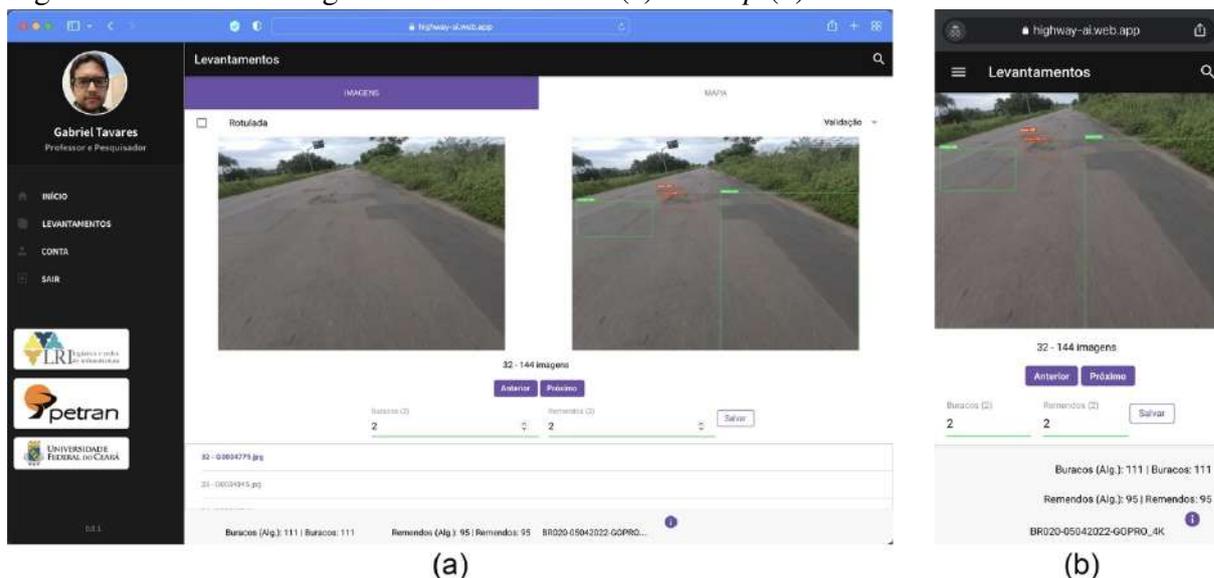


Fonte: O Autor (2022).

A principal interface gráfica do *software* é a tela de Levantamentos. Esta tela, possui duas abas: Imagens e Mapas. Na aba de Imagens, é apresentada a imagem original, a imagem contendo as detecções e uma lista em que permite o usuário navegar por todas as imagens do *dataset* selecionado. Na aba de Mapa, as imagens são exibidas em formato de marcadores posicionados em um mapa dinâmico embarcado no *software*. Na barra inferior é exibida a quantidade de buracos e remendos total detectados neste *dataset*.

Na aba de Imagens, foi incluído dois campos de entrada (um para buracos e outro para remendos) com o intuito de permitir com que o usuário insira a quantidade correta que ele visualiza na imagem, possibilitando uma análise subjetiva. Ao salvar, são atualizados na barra inferior a quantidade total de buracos e remendos contabilizados tanto pelo algoritmo quanto pelo que o usuário definiu. As informações definidas por “Buracos (Alg.)” e “Remendos (Alg.)” representam a quantidade total de buracos e remendos que o algoritmo detectou neste *dataset*. As informações definidas por “Buracos” e “Remendos” representam a contagem total de buracos e remendos que o usuário inseriu. Na Figura 50 é apresentado a aba Imagens da tela de Levantamentos.

Figura 50 – Tela de Imagens do Levantamento (a) *desktop* (b) *mobile*



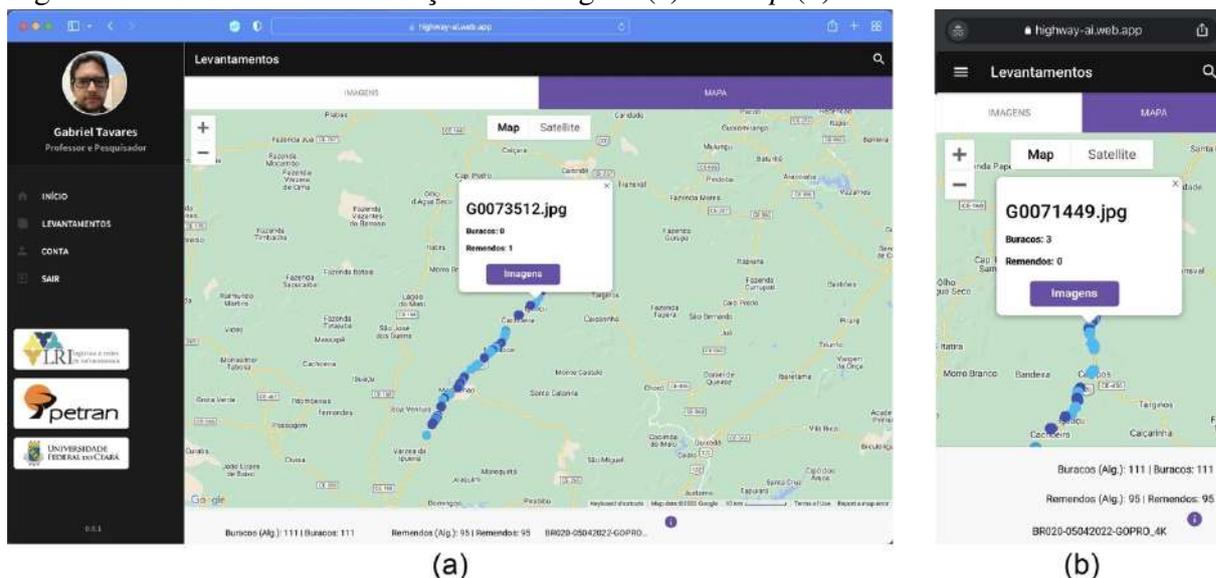
Fonte: O Autor (2022).

Vale ressaltar que na aba de Imagens foi colocado um Checkbox¹ chamado “Rotulada”. Ao marcar esta opção será visualizados rótulos dos defeitos realizados no processo de rotulação, apresentado na seção 3.4 deste trabalho. Este recurso foi implementado a fim de facilitar na validação dos dados por parte de uma análise subjetiva dos pesquisadores. Dessa forma é possível analisar de forma visual se o algoritmo de detecção detectou de fato os defeitos rotulados. Esta funcionalidade será fundamental na avaliação dos resultados.

Na aba Mapas (Figura 51), as imagens são apresentadas através de marcadores coloridos conforme sua geolocalização foi registrada no momento da captura. As cores foram definidas mediante a quantidade de defeitos encontrados: 1 defeito (azul claro), 2 ou 3 defeitos (azul escuro), 4 ou 5 defeitos (roxo), maior que 5 defeitos (vermelho). Além disso, ao clicar no marcador é mostrada uma janela suspensa contendo os dados quantitativos e um botão “Imagens” que permite visualizar a imagem registrada naquele ponto.

¹ https://pt.wikipedia.org/wiki/Caixa_de_sele%C3%A7%C3%A3o

Figura 51 – Tela de Geolocalização das Imagens (a) *desktop* (b) *mobile*



Fonte: O Autor (2022).

As métricas geradas no processo de treinamento podem ser acessadas através do botão roxo representado pelo ícone “i” localizado na barra inferior da tela de Levantamentos. Ao clicá-lo, será aberto na janela suspensa um gráfico (Figura 52) contendo as informações geradas durante o treinamento, são elas: porcentagem de mAP e *Loss* em cada iteração, e o *AVG Loss*. Para visualizar todas as métricas, pode-se baixar um arquivo texto contendo essas informações através do botão “Métricas” na janela suspensa.

Figura 52 – Tela de Métricas do Treinamento (a) *desktop* (b) *mobile*



Fonte: O Autor (2022).

Vale ressaltar que todas as telas foram implementadas utilizando as melhores práticas

de interface do usuário, de modo que o sistema pode ser acessado tanto em telas grandes (*notebooks* e computadores) quanto em dispositivos móveis (*smartphones* e *tablets*).