



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE CIÊNCIAS**  
**DEPARTAMENTO DE COMPUTAÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

**GUSTAVO ANTONIO SOUSA PAZ E MOTA**

**ESTUDO DE VIABILIDADE DA ANÁLISE AUTOMÁTICA ATRAVÉS DE IMAGENS**  
**DE PISTAS DE POUSOS E DECOLAGENS QUANTO À RESISTÊNCIA À**  
**DERRAPAGEM**

**FORTALEZA**

**2024**

GUSTAVO ANTONIO SOUSA PAZ E MOTA

ESTUDO DE VIABILIDADE DA ANÁLISE AUTOMÁTICA ATRAVÉS DE IMAGENS DE  
PISTAS DE POUSOS E DECOLAGENS QUANTO À RESISTÊNCIA À DERRAPAGEM

Dissertação apresentada ao Curso de do  
Programa de Pós-Graduação em Ciência da  
Computação do Centro de Ciências da Universi-  
dade Federal do Ceará, como requisito parcial à  
obtenção do título de mestre em Computação  
Gráfica. Área de Concentração: Processamento  
Digital de Imagens e Visão Computacional.

Orientador: Prof. Dr. Yuri Lenon Bar-  
bosa Nogueira.

Coorientador: Prof. Dr. Joaquim Bento  
Cavalcante Neto.

FORTALEZA

2024

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)

---

M871e Mota, Gustavo Antonio Sousa Paz e.

Estudo de viabilidade da análise automática através de imagens de pistas de pousos e decolagens quanto à resistência à derrapagem / Gustavo Antonio Sousa Paz e Mota. – 2025.  
91 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Ecologia e Recursos Naturais, Fortaleza, 2025.

Orientação: Prof. Dr. Yuri Lenon Barbosa Nogueira.

Coorientação: Prof. Dr. Joaquim Bento Cavalcante Neto.

1. Imagens. 2. Coeficiente de Atrito. 3. Emborrachamento. 4. K-médias. 5. Aeroportos. I. Título.  
CDD 577

---

GUSTAVO ANTONIO SOUSA PAZ E MOTA

ESTUDO DE VIABILIDADE DA ANÁLISE AUTOMÁTICA ATRAVÉS DE IMAGENS DE  
PISTAS DE POUSOS E DECOLAGENS QUANTO À RESISTÊNCIA À DERRAPAGEM

Dissertação apresentada ao Curso de do  
Programa de Pós-Graduação em Ciência da  
Computação do Centro de Ciências da Universi-  
dade Federal do Ceará, como requisito parcial à  
obtenção do título de mestre em Computação  
Gráfica. Área de Concentração: Processamento  
Digital de Imagens e Visão Computacional.

Aprovada em: 11 de Novembro de 2024.

BANCA EXAMINADORA

---

Prof. Dr. Yuri Lenon Barbosa Nogueira (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Joaquim Bento Cavalcante  
Neto (Coorientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Creto Augusto Vidal  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Francisco Heber Lacerda de Oliveira  
Universidade Federal do Ceará (UFC)

---

Profa. Dra. Suelly Helena de Araújo Barroso  
Universidade Federal do Ceará (UFC)

À minha família, por sua capacidade de acreditar em mim e investir em mim. Mãe, seu cuidado e dedicação foi que deram, em alguns momentos, a esperança para seguir. Pai, sua presença significou segurança e certeza de que não estou sozinho nessa caminhada.

## **AGRADECIMENTOS**

Agradeço à Universidade Federal do Ceará e o Programa de Mestrado e Doutorado em Ciência da Computação pela oportunidade de realizar essa pesquisa. Agradeço também ao Programa de Pós-Graduação em Engenharia de Transportes Petran da UFC.

O presente trabalho foi realizado com apoio da Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico - Brasil (FUNCAP) - Código de Financiamento 001. O presente trabalho agradece também à Agência Nacional de Aviação Civil pelo suporte e pelos relatórios prestados para o desenvolvimento desta pesquisa. Ao Prof. Dr. Yuri Lenon Barbosa Nogueira, Prof. Dr. Joaquim Bento Cavalcante Neto, Prof. Dr. Creto Augusto Vidal, e Prof. Dr. Francisco Heber Lacerda de Oliveira pela excelente orientação. Ao Prof. Dr. Francisco Heber Lacerda de Oliveira por todo o suporte científico e tecnológico em engenharia de transportes e transporte aéreo. À professora Dra. Suelly Helena de Araújo Barroso por aceitar participar da banca examinadora, pelo tempo disponibilizado, pelas valiosas colaborações e sugestões. Ao professor Dr. João Paulo Pordeus Gomes pela elucidação de dúvidas na pesquisa.

Ao Prof. Me. Tiago Silveira de Andrade Aquino por compartilhar de seu conhecimento e contribuir com críticas e sugestões. À Me. Aldaianny de Oliveira Maia por seu trabalho anterior, que contribuiu com uma síntese de dados técnicos úteis que simplificou parte da complexidade do problema.

Aos colegas da turma de mestrado, pelas reflexões, críticas e sugestões recebidas. A todos os meus amigos que me deram suporte para atravessar com sucesso essa jornada.

"A vida é uma tarefa que não pode ser dividida  
com ninguém (QUEIROZ, Rachel de, 1975.)

## RESUMO

O transporte aéreo é uma atividade de grande importância para o desenvolvimento econômico de regiões conectadas por aeródromos. Em vista disso, a necessidade de monitorar a segurança operacional de pistas de pouso e decolagens (PPD) oferecida às aeronaves que nelas trafegam é vital para as atividades. Dentre elas, a segurança quanto à resistência à derrapagem. Contudo, os métodos tradicionais podem apresentar custos de tempo, recursos financeiros e humanos para a execução. O presente trabalho estuda a viabilidade do desenvolvimento de um modelo de Rede Neural Convolucional (RNC) capaz de classificar segmentos de pista por imagens quanto à segurança operacional referente à resistência à derrapagem pelo coeficiente de atrito. Essa classificação é baseada no acúmulo de borracha e seu impacto no coeficiente de atrito. O objetivo é a obtenção de uma ferramenta que auxilie na tomada de decisão dos operadores de aeródromos. O estudo utiliza imagens em escala de cinza, coletadas de uma pista de um aeroporto brasileiro via *Google Earth Pro*, e os dados técnicos obtidos de relatórios oficiais da Agência Nacional de Aviação Civil (ANAC). Além disso, são investigados métodos de processamento e análise de dados para gerar um conjunto de dados que contribua para o desenvolvimento de um modelo confiável e de baixo custo computacional. Dentre eles, algoritmo de K-médias e análise de Correlação de Pearson. O modelo demonstrou a viabilidade do desenvolvimento de um modelo capaz de classificar adequadamente as imagens processadas, reforçando o potencial dessa abordagem para a (PPD) estudada. O algoritmo de K-médias com  $K=3$ , usando todo o conjunto de dados com as imagens segmentadas apresentando a área de acúmulo de borracha, foi o mais eficiente dentre os demais experimentos realizados. Contudo, reforça a importância da criação de um conjunto de dados balanceado e rico em dados, prevenindo *overfitting* e outras limitações na modelagem.

**Palavras-chave:** imagens; coeficiente de atrito; emborrachamento; K-médias; aeroportos.



## ABSTRACT

Air transportation is an activity of key importance for the economic development of regions connected by airfields. In view of this, the need to monitor the operational safety of runways (RWY) offered to aircraft travelling on them is vital for these activities. These include safety in terms of skid resistance. However, traditional methods can be costly in terms of time, financial and human resources. This paper studies the feasibility of developing a Convolutional Neural Network (CNN) model capable of classifying lane segments by images in terms of operational safety in terms of skid resistance using the coefficient of friction. This classification is based on the accumulation of rubber and its impact on the coefficient of friction. The aim is to obtain a tool to help aerodrome operators make decisions. The study uses grey-scale images collected from a Brazilian airport runway via Google Earth Pro and technical data obtained from official ANAC reports. In addition, data processing and analysis methods are investigated to generate a data set that contributes to the development of a reliable model with low computational costs. These include the K-means algorithm and Pearson's correlation analysis. The model demonstrated the feasibility of developing a model capable of adequately classifying processed images, reinforcing the potential of this approach for the (RWY) studied. The K-means algorithm with  $K=3$  using the complete dataset with the segmented images showing the area of rubber accumulation was the most efficient among the other experiments carried out. However, it reinforces the importance of creating a balanced and data-rich dataset, preventing overfitting and other limitations in the modelling.

**Keywords:** images; friction; rubber accumulation; segmentation; airports; K-means.

## LISTA DE FIGURAS

Figura 1 – Ilustração das áreas de medição do coeficiente de atrito a 3 (vermelho) e 6 (azul) metros do eixo de pista. . . . .	21
Figura 2 – Ilustração das áreas de medição da macrotextura a 3 metros (verde) do eixo de pista alertando entre lado esquerdo e direito. . . . .	23
Figura 3 – Cilindro metálico que contém a areia e o carimbo utilizado nos movimentos circulares para gerar a mancha de areia durante o ensaio de medição da macrotextura. . . . .	23
Figura 4 – Etapas do ensaio da mancha de areia. . . . .	24
Figura 5 – Equações usadas no cálculo de macrotextura pelo ensaio da mancha de areia.	24
Figura 6 – <i>Grooving</i> no Aeroporto de Joinville, Santa Catarina, Brasil. . . . .	25
Figura 7 – Imagem panorâmica em escala <i>Red, Green e Blue</i> (RGB) com incongruência de tonalidades em diferentes regiões. . . . .	28
Figura 8 – Comparação dos resultados da aplicação de uma equalização por histograma e <i>Contrast Limited Adaptive Histogram Equalization</i> (CLAHE). . . . .	30
Figura 9 – Segmentação de imagem em escala de cinza por intensidades. . . . .	31
Figura 10 – Imagem RGB, sua projeção no plano 3D e as respectivas intensidades de cada nuvem após agrupamento em 5 <i>clusters</i> . . . . .	32
Figura 11 – Imagem em escala de cores RGB e a resultante da redução do espectro de cores após agrupamento em 3 <i>clusters</i> . . . . .	32
Figura 12 – Imagem em escala de cores RGB, centróides obtidos após aplicação do algoritmo de K-médias e a segmentação por centróide (K=6). . . . .	33
Figura 13 – Captura de um trecho de um pavimento asfáltico (à esquerda) e a respectiva imagem segmentando as fissuras da superfície asfáltica (à direita). . . . .	36
Figura 14 – Coleta de dados de macrotextura da PPD do Aeroporto Internacional de Birjand juntamente de uma captura, com auxílio de um tripé, da porção avaliada. . . . .	38
Figura 15 – Imagem original (à esquerda), segmentada (ao centro) e invertida (à direita) revelando os pontos profundos de uma amostra de superfície de uma Pista de pousos e decolagens (PPD). . . . .	39
Figura 16 – Captura de imagens em laboratório de uma superfície asfáltica. . . . .	42

Figura 17 – Exemplo de imagem coletada (esquerda) de uma amostra de superfície asfáltica e a textura obtida (direita). . . . .	42
Figura 18 – Demonstração do cálculo de Profundidade Média do Segmento ( <i>Mean Profile Depth</i> (MPD)) por meio de representação tridimensional. . . . .	43
Figura 19 – Representação tridimensional do pavimento (a) e a respectiva macrotextura (b) e microtextura (c). . . . .	44
Figura 20 – Representação do escoamento de água em superfície asfáltica ao longo do tempo (segundos) para a avaliação por imagens. . . . .	46
Figura 21 – Representação do escoamento de água em superfície asfáltica contendo os índices pela Transformada de Shearlet. . . . .	46
Figura 22 – Método de captura de imagens de PPD com auxílio de tripé por Elunai <i>et al.</i> (2011) . . . . .	47
Figura 23 – Estruturação da metodologia do presente trabalho. . . . .	51
Figura 24 – Diagrama da etapa de coleta de dados do presente trabalho. . . . .	52
Figura 25 – Exemplos de segmentos de uma PPD brasileira nos metros iniciais e finais. . . . .	54
Figura 26 – Mosaico montado de data 18/12/2016 em escala RGB. . . . .	54
Figura 27 – Imagem de data 18/12/2016 antes e após a equalização pro histograma local. . . . .	54
Figura 28 – Centróides obtidos ao aplicar K=3 para a imagem de data 18/12/2016 e as respectivas tonalidades e frequências. . . . .	56
Figura 29 – Fragmentos da imagem de data 18/12/2016 ao clusterizar em 3 agrupamentos. . . . .	57
Figura 30 – Etapas da aplicação do algoritmo de K-médias. . . . .	57
Figura 31 – Fragmentos do fatiamento resultante da imagem de data 18/12/2016 ao clusterizar em 3 agrupamentos. . . . .	58
Figura 32 – Diagrama da sequência de etapas do processamento das imagens por K-médias para o cálculo e análise de Correlação de Pearson no presente trabalho. . . . .	60
Figura 33 – Formação e organização das variáveis obtidas pelo processamento de imagens por K-médias e dos dados de coeficiente de atrito da PPD no presente trabalho. . . . .	61
Figura 34 – Diagrama de separação de conjuntos baseados nas diferenças de datas no presente trabalho. . . . .	62
Figura 35 – Diagrama da arquitetura da Rede Neural Convolucional adotada pelo presente trabalho. . . . .	65

Figura 36 – Diagrama da organização dos treinos por conjuntos e com ou sem uso do K-médias nas imagens de entrada no presente trabalho. . . . .	66
Figura 37 – Gráficos de treinamento, validação, teste e matrizes de confusão considerando as imagens da PPD utilizada no presente trabalho por conjunto formado sem K-médias. . . . .	70
Figura 38 – Gráficos de treinamento, validação, teste e matrizes de confusão com K-médias considerando as fatias iniciais da PPD utilizada no presente trabalho por conjunto formado. . . . .	72
Figura 39 – Gráficos de treinamento, validação, teste e matrizes de confusão com K-médias considerando as fatias intermediárias da PPD utilizada no presente trabalho por conjunto formado. . . . .	74
Figura 40 – Gráficos de treinamento, validação, teste e matrizes de confusão com K-médias considerando as fatias inferiores da PPD utilizada no presente trabalho por conjunto formado . . . . .	76
Figura 41 – Histogramas dos dados de coeficiente de atrito por conjunto formado. . . . .	91

## LISTA DE TABELAS

Tabela 1 – Frequências mínimas de medição de atrito . . . . .	20
Tabela 2 – Determinação das regiões de medição do coeficiente de atrito de acordo com o código de aeronave suportado pela PPD . . . . .	21
Tabela 3 – Padrões de medição de coeficiente de atrito para cada equipamento. . . . .	22
Tabela 4 – Análise dos trabalhos relacionados. . . . .	48
Tabela 5 – Pares de relatórios e imagens por data com as respectivas diferenças de dias referentes à PPD estudada . . . . .	55
Tabela 6 – Correlações de Pearson por fatia gerada ao clusterizar imagens por K=3. . .	63
Tabela 7 – Conjuntos formados e quantidades de elementos. . . . .	65
Tabela 8 – Datas das imagens da PPD utilizada no presente trabalho . . . . .	90

## LISTA DE ABREVIATURAS E SIGLAS

<i>Application Programming Interface, API</i>	Interface de programação de aplicações
<i>Graphical user interface - GUI</i>	Interface gráfica do utilizador
ANAC	Agência Nacional de Aviação Civil
CLAHE	<i>Contrast Limited Adaptive Histogram Equalization</i>
CTMeter	<i>Circular Track Meter</i>
FAA	<i>Federal Aviation Administration</i>
GLCM	Matriz de Coocorrência de Níveis de Cinza
HSI	<i>Hue Saturation Intensity</i>
IS	Instrução Suplementar
MPD	<i>Mean Profile Depth</i>
OACI	Organização da Aviação Civil Internacional
PDI	Processamento Digital de Imagens
PPD	Pista de pousos e decolagens
RBAC	Regulamento Brasileiro da Aviação Civil
RGB	<i>Red, Green e Blue</i>
RNC	Rede Neural Convolucional
ROI	<i>Region of Interest</i>
VANT	Veículo Aéreo Não-Tripulado
VC	Visão Computacional

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>15</b>
<b>1.1</b>	<b>Objetivos . . . . .</b>	<b>16</b>
<b>1.2</b>	<b>Objetivos específicos . . . . .</b>	<b>16</b>
<b>1.3</b>	<b>Organização do trabalho . . . . .</b>	<b>17</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA . . . . .</b>	<b>18</b>
<b>2.1</b>	<b>Operações em pistas de aeródromos . . . . .</b>	<b>18</b>
<b>2.2</b>	<b>Pousos, decolagens e deterioração da Pista . . . . .</b>	<b>19</b>
<b>2.3</b>	<b>Coeficiente de Atrito, macrotextura e grooving – características e medições</b>	<b>20</b>
<b>2.4</b>	<b>Agravantes do acúmulo de borracha em pistas aeroportuárias . . . . .</b>	<b>24</b>
<b>2.5</b>	<b>Capturas de imagens aéreas . . . . .</b>	<b>26</b>
<b>2.6</b>	<b>Representação de imagens e domínio de espaço e valor . . . . .</b>	<b>27</b>
<b>2.7</b>	<b>Processamento Digital de Imagens (PDI) e aprimoramento de imagens .</b>	<b>27</b>
<b>2.8</b>	<b>Aprimoramento de capturas únicas . . . . .</b>	<b>29</b>
<b>2.8.1</b>	<b><i>Segmentação em Imagens . . . . .</i></b>	<b>30</b>
<b>2.9</b>	<b>Matriz de coocorrência de níveis de cinza (GLCM) . . . . .</b>	<b>32</b>
<b>2.10</b>	<b>Métodos de análise de correlação . . . . .</b>	<b>33</b>
<b>2.11</b>	<b>Redes neurais . . . . .</b>	<b>34</b>
<b>3</b>	<b>TRABALHOS RELACIONADOS . . . . .</b>	<b>36</b>
<b>3.1</b>	<b>Avaliação de superfícies asfálticas . . . . .</b>	<b>36</b>
<b>3.2</b>	<b>Análise do coeficiente de atrito de superfícies diversas por meio de ima- gens digitais . . . . .</b>	<b>40</b>
<b>3.3</b>	<b>Análise do coeficiente de atrito e macrotextura de superfícies asfálticas por meio de imagens com representação 3D . . . . .</b>	<b>41</b>
<b>3.4</b>	<b>Análise do coeficiente de atrito e macrotextura de superfícies asfálticas por meio de imagens em domínio de frequência . . . . .</b>	<b>44</b>
<b>3.5</b>	<b>Análise do coeficiente de atrito e macrotextura de superfícies asfálticas por meio de imagens em domínio de espaço e valor . . . . .</b>	<b>47</b>
<b>3.6</b>	<b>Análise dos trabalhos relacionados . . . . .</b>	<b>48</b>
<b>3.7</b>	<b>Considerações finais sobre os trabalhos relacionados . . . . .</b>	<b>49</b>
<b>4</b>	<b>METODOLOGIA . . . . .</b>	<b>51</b>

<b>4.1</b>	<b>Coleta e preparação dos dados . . . . .</b>	<b>52</b>
<b>4.1.1</b>	<b><i>Coleta de dados de coeficiente de atrito da PPD estudada . . . . .</i></b>	<b>52</b>
<b>4.1.2</b>	<b><i>Coleta de imagens de PPD . . . . .</i></b>	<b>53</b>
<b>4.1.3</b>	<b><i>Pré-processamentos de imagem: montagem dos mosaicos . . . . .</i></b>	<b>53</b>
<b>4.1.4</b>	<b><i>Associação dos pares imagens x relatórios de coeficiente de atrito . . . . .</i></b>	<b>55</b>
<b>4.2</b>	<b>Subdivisão dos conjuntos de dados . . . . .</b>	<b>56</b>
<b>4.2.1</b>	<b><i>K-médias e segmentação . . . . .</i></b>	<b>56</b>
<b>4.2.2</b>	<b><i>Recorte e geração das listas de dados . . . . .</i></b>	<b>58</b>
<b>4.2.3</b>	<b><i>Análise de correlação . . . . .</i></b>	<b>59</b>
<b>4.2.4</b>	<b><i>Elaboração dos conjuntos de dados para desenvolvimento dos modelos . . . . .</i></b>	<b>62</b>
<b>4.3</b>	<b>Modelagem . . . . .</b>	<b>65</b>
<b>4.3.1</b>	<b><i>Arquitetura de rede . . . . .</i></b>	<b>65</b>
<b>4.3.2</b>	<b><i>Organização dos dados para entrada na rede . . . . .</i></b>	<b>66</b>
<b>4.3.3</b>	<b><i>Ambiente de implementação . . . . .</i></b>	<b>67</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÃO . . . . .</b>	<b>68</b>
<b>5.1</b>	<b>Apresentação dos dados das modelagens . . . . .</b>	<b>68</b>
<b>5.1.1</b>	<b><i>Sem K-médias . . . . .</i></b>	<b>68</b>
<b>5.1.2</b>	<b><i>Com K-médias . . . . .</i></b>	<b>71</b>
<b>5.1.3</b>	<b><i>Discussão comparativa dos dados obtidos com a modelagem . . . . .</i></b>	<b>77</b>
<b>5.1.4</b>	<b><i>Considerações finais . . . . .</i></b>	<b>78</b>
<b>6</b>	<b>CONCLUSÕES . . . . .</b>	<b>79</b>
<b>6.1</b>	<b>Principais contribuições . . . . .</b>	<b>80</b>
<b>6.2</b>	<b>Principais limitações . . . . .</b>	<b>81</b>
<b>6.3</b>	<b>Sugestões de trabalhos futuros . . . . .</b>	<b>82</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>83</b>
	<b>APÊNDICE A –TABELA COMPLETA DE DATAS DE IMAGENS . . . . .</b>	<b>90</b>
	<b>APÊNDICE B –HISTOGRAMAS DOS CONJUNTOS FORMADOS . . . . .</b>	<b>91</b>



## 1 INTRODUÇÃO

O transporte aéreo é uma atividade de impacto social e econômico regional. Permite não somente o transporte de passageiros, fomentando o turismo e a geração de empregos, como também o fluxo de recursos produzidos pela região que está inserido (SMITH; PEARCE, 2007). O desenvolvimento local acompanha a necessidade cada vez maior de investimentos de manutenção em aeródromos. Manter os pavimentos bem conservados e em adequadas condições de segurança é importante para a realização das atividades aéreas; do contrário, o aeródromo, no pior caso, terá suas atividades suspensas. A Agência Nacional de Aviação Civil (ANAC), no Brasil, estabelece normas de segurança a serem cumpridas seguindo os padrões da Organização da Aviação Civil Internacional (OACI). Dentre essas normas, estão as de monitoramento de contaminantes na pista de pousos e decolagens (PPD).

Em uma PPD, a superfície apresenta propriedades que previnem a formação de lâminas d'água, oferecendo resistência à derrapagem e adequado atrito pneu-pavimento em operação de pouso ou decolagem. Cada uma dessas operações ocasiona a impregnação de borracha da roda da aeronave na superfície da PPD. Consequentemente, o acúmulo desse contaminante prejudica essas propriedades, mensuradas, por exemplo, pela variável do coeficiente de atrito. Ao longo do tempo, a PPD vai perdendo qualidade nesse aspecto, apresentando insegurança às operações. Por essa razão, é importante monitorar o acúmulo de borracha e realizar remoções periódicas desse contaminante na PPD, evitando que ela atinja um estado crítico de ausência de resistência à derrapagem. Além disso, as limpezas podem, com o passar do tempo, danificar a pista também (MOTA *et al.*, 2022). Dessa forma, o monitoramento do pavimento é uma atividade constante a ser realizada pelos operadores de aeródromos.

Tendo em vista os elementos anteriormente citados, conclui-se que o monitoramento de uma PPD deve levar em consideração uma observação periódica, a inferência confiável do estado da pista quanto à segurança operacional referente à resistência à derrapagem, e a tomada de decisão adequada. Além disso, na literatura existem trabalhos que concluem a correlação inversamente proporcional entre o acúmulo de borracha na superfície da pista e o coeficiente de atrito. Consequentemente, há uma correlação entre o nível de acúmulo de borracha e o nível de segurança operacional quanto à resistência à derrapagem representada pela variável do coeficiente de atrito de uma PPD devido aos seus efeitos. Portanto, o aspecto visual da PPD permite uma avaliação desse nível por imagens (MOTA *et al.*, 2022; AQUINO *et al.*, 2022).

Imagens da PPD por satélite são capazes de capturar toda a sua extensão. O *Google*

*Earth Pro*<sup>1</sup>, por exemplo, é uma ferramenta que disponibiliza imagens por satélite de várias partes do mundo, incluindo PPD brasileiras, sem custos de acesso e *download*. Esse *software* permite o acesso a imagens em alta definição e em escala de cores RGB, ao longo de uma linha do tempo variando em anos e meses. Apesar das limitações que impedem o uso de algumas imagens, como a obstrução por presença de nuvens, esse método tem ainda o potencial de viabilizar esse tipo de análise pela disponibilidade de várias imagens capazes de serem usadas pelo perfeito estado e representação do alvo da captura. Assim, possibilitando a formação de um banco de dados de imagens de PPD. Portanto, esse *software* é trabalhado neste estudo para a coleta de imagens.

## 1.1 Objetivos

Diante do exposto, o presente trabalho tem por objetivo a viabilidade do desenvolvimento de um modelo de uma Rede Neural Convolutacional (RNC) para auxílio nas tomadas de decisão por operadores de aeródromo quanto à segurança operacional, baseada na resistência à derrapagem representada pelo coeficiente de atrito, de pistas de pousos e decolagens. O presente estudo se faz por meio de imagens de uma PPD brasileira considerando a área de acúmulo de borracha e seu impacto no coeficiente de atrito da respectiva pista, obtidos via relatórios oficiais de levantamentos da ANAC. As imagens, por sua vez, são provenientes de capturas via *Google Earth Pro* de diferentes datas. O modelo tem por objetivo retornar uma classificação da segurança operacional em duas classes - Bom e Moderado - para cada segmento de pista a cada 100m excluindo as cabeceiras. O estudo foca em identificar as melhores configurações de formação dos conjuntos de dados de desenvolvimento de um modelo que viabilize seu uso.

## 1.2 Objetivos específicos

Como objetivos específicos podem ser mencionados:

1. Desenvolver um método de captura e montagem de mosaicos de PPD a partir de fotos de satélite;
2. Desenvolver um algoritmo que quantifica o acúmulo de borracha em uma PPD por imagens por meio de técnicas de Processamento Digital de Imagens (PDI) e Visão Computacional (VC);

---

<sup>1</sup> <https://www.google.com/intl/pt-BR/earth/about/versions/>

3. Analisar a correlação entre os dados obtidos pelas imagens com os dados técnicos da PPD correspondentes;
4. Modelar uma RNC que classifica a segurança operacional, referente à resitência à derrapagem, de segmentos de pista com base no acúmulo de borracha e seu impacto no coeficiente de atrito;
5. Estudar a melhor composição do conjunto de dados para uso na modelagem que retorne as melhores métricas resultantes do treino, validação e teste.

### **1.3 Organização do trabalho**

Além deste capítulo introdutório, nos capítulos 2 e 3 o presente trabalho concentra-se em fazer um levantamento dos fundamentos teóricos e realizar um estudo bibliográfico relacionado. No Capítulo 4 é exposta a metodologia adotada. O Capítulo 5 apresenta os dados obtidos nos resultados dos experimentos realizados e os discute. Por fim, as conclusões.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, apresenta-se uma revisão bibliográfica de trabalhos relacionados ao monitoramento, avaliação e tomadas de decisão quanto à segurança operacional em pavimentos aeroportuários. Além disso, também encontram-se trabalhos relacionados à remoção de borracha acumulada, manutenção e reabilitação. Por fim, aos relacionados a tópicos voltados para o escopo computacional do presente trabalho, relacionados ao Processamento de Imagens (PDI), Visão Computacional (VC) e os seus usos aplicados em pavimentação aeroportuária.

As subseções introduzem os tópicos de: engenharia de transportes no tocante às pistas de pouso e decolagem, operações e manutenção; processamento de imagens, ajustes de imagens e segmentação e, por fim, avaliação de pavimentos computacionalmente.

### 2.1 Operações em pistas de aeródromos

Em pavimentos aeroportuários, todo pouso, decolagem e taxiamento de aeronaves são definidos como operações. Neste trabalho, define-se por operações em pistas de pousos e decolagens PPDs os pousos e as decolagens realizadas necessariamente por aviões. Elas, com o tempo, provocam uma deterioração da qualidade da pista e, conseqüentemente, uma redução da segurança operacional. Dessa forma, torna-se necessária a realização de manutenções periódicas em PPD para restaurar e preservar os níveis de segurança e qualidade.

Inúmeras intervenções diferentes são estudadas para prolongar a qualidade da pista antes da necessidade de uma eventual manutenção, que demanda tempo e recursos financeiros, materiais e humanos. Um procedimento-chave para determinar a qualidade, ou a necessidade de manutenção na pista, é o monitoramento da PPD.

No Brasil, essas atividades são reguladas pela Agência Nacional de Aviação Civil (ANAC), que determina tanto os procedimentos de manutenção como recomenda tomadas de decisão em casos específicos (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2017). No mundo, pode-se citar a *Federal Aviation Administration* (FAA), a autoridade de aviação civil dos Estados Unidos, que visa promover o mais seguro e eficiente sistema aéreo por meio de pesquisas e elaboração de normas (FEDERAL AVIATION ADMINISTRATION, 2022). Muitas vezes, a FAA contribui para elaborar métodos de monitoramento e manutenção em PPD no mundo.

## 2.2 Pousos, decolagens e deterioração da Pista

Para a realização de operações seguras em PPD, é necessário que a pista, por meio do seu revestimento, proporcione o atrito ideal durante o contato com o pneu da aeronave, para evitar derrapagem e contribuir para a frenagem (QUARIGUASI *et al.*, 2021). O parâmetro que mensura essa característica em PPD é chamado de coeficiente de atrito.

Além do coeficiente de atrito, a PPD deve ser capaz de proporcionar um adequado escoamento de água, evitando a formação de lâminas d'água no revestimento. Do contrário, em dias úmidos ou chuvosos, pode acontecer a hidroplanagem, que é um risco grave por provocar a derrapagem da aeronave devido à perda de contato dos pneus com a superfície do pavimento. Denomina-se por macrotextura da PPD a propriedade analisada para avaliar a qualidade desse parâmetro em uma PPD (OLIVEIRA; JÚNIOR, 2009; AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2023).

Devido às características da PPD, para que haja resistência à derrapagem e detenha índices de macrotextura e coeficiente de atrito adequados para a segurança das operações, o contato dos pneus da aeronave na superfície do pavimento desencadeia uma reação físico-química capaz de gerar depósitos de contaminantes no revestimento. Consequentemente, prejudica-se a qualidade da segurança operacional e, com o tempo, torna-se necessária manutenção como a remoção da borracha acumulada ou mesmo a reforma na PPD. Assim, torna-se importante monitorar o estado da pista para que tudo seja feito em tempo. Do contrário, pode ocorrer o fechamento do aeródromo por decisão da ANAC, ocasionando, assim, inúmeros prejuízos e transtornos à aviação civil.

Segundo AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (2021), é responsabilidade do operador de aeródromo monitorar o estado da pista e tomar decisões para a realização das medições dos parâmetros do coeficiente de atrito e de macrotextura. Além disso, tomar decisões de intervenção na pista caso os índices estejam em níveis que indicam insegurança.

O Regulamento Brasileiro da Aviação Civil (RBAC) número 153 estabelece a responsabilidade do operador de aeródromo de monitorar a área operacional (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2021). Ele deve determinar e informar à ANAC quais os mecanismos a serem adotados e suas especificações, atentando-se para cumprir com o monitoramento de todos os elementos exigidos pela legislação. Dentre eles, a fauna, a presença de indivíduos e também o estado da PPD.

Com um determinado número de operações ou de semanas desde a última intervenção

na PPD, é realizada uma medição dos valores de coeficiente de atrito e de macrotextura. Com a avaliação dos dados, é realizada uma limpeza da PPD. No geral, elas podem ocorrer em conjunto.

A medição de atrito tem frequências mínimas estabelecidas no RBAC 153 apresentadas na Tabela 1.

Tabela 1 – Frequências mínimas de medição de atrito

Faixas [1]	Média de pousos diários de aeronaves de asa fixa com motor à reação, na cabeceira predominante, no último ano [2]	Frequência de medições de atrito [3]
1	Menor que 16	Cada 360 dias
2	Maior ou igual a 16 e menor que 31	Cada 180 dias
3	Maior ou igual a 31 e menor que 91	Cada 90 dias
4	Maior ou igual a 91 e menor que 151	Cada 60 dias
5	Maior ou igual a 151 e menor ou igual a 210	Cada 30 dias
6	Maior que 210	Cada 15 dias

Fonte: RBAC N° 153 (2019).

### 2.3 Coeficiente de Atrito, macrotextura e grooving – características e medições

O coeficiente de atrito é um parâmetro calculado em algumas PPD brasileiras, por exemplo, por meio de *Grip Tester* (SALES *et al.*, 2022). Ele mensura o atrito proporcionado pela interação pneu-pavimento do pneu das aeronaves com a superfície da pista.

Essas medições podem ser feitas com diferentes equipamentos. Em grande parte dos aeródromos brasileiros, utiliza-se *grip tester*. A Instrução Suplementar (IS) 153.205-001B (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2023) determina a velocidade e os níveis mínimos de atrito mensurados de acordo com cada equipamento regulamentado para este fim (Tabela 3).

Cada equipamento deve fazer medições no intervalo máximo de 10 metros partindo da cabeceira de maior volume de operações de pousos ou decolagens em direção à de menor. O equipamento deve percorrer cada lado, esquerdo e direito, em relação ao eixo da pista sempre partindo da cabeceira de maior volume de operações.

A distância a partir do eixo varia de 3 a 6 metros a depender do tipo de aeronave que opera na PPD, de acordo com seu código (Tabela 2). O código da aeronave varia conforme seu tamanho (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2024).

A Figura 1 ilustra uma pista de aeródromo e as áreas de medição do coeficiente de atrito. Em vermelho, as medições a 3 metros à esquerda e à direita do eixo da pista. Em azul, as


Tabela 2 – Determinação das regiões de medição do coeficiente de atrito de acordo com o código de aeronave suportado pela PPD

Letra do código [1]	Localização da medição [2]	Quantidade mínima [3]
A, B ou C	A 3m do eixo da pista	Uma vez de cada lado em relação ao eixo da pista
D, E ou F	A 3m e 6m do eixo da pista	Uma vez de cada lado em relação ao eixo da pista, para cada distância da coluna [2]

Fonte: IS 153.205-001B (2023).

mesmas medições, mas a 6 metros do eixo da pista. Nota-se que o intervalo é o mesmo entre uma medição e outra.

Figura 1 – Ilustração das áreas de medição do coeficiente de atrito a 3 (vermelho) e 6 (azul) metros do eixo de pista.



Fonte: Elaborado pelo autor (2023).

Por sua vez, a macrotextura enquanto parâmetro, mensura o estado da textura superficial da pista quanto à sua porosidade e, consequentemente, sua capacidade de escoamento. A AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (2021) regula a metodologia de medição e a tomada de decisão com base nos valores obtidos nesses parâmetros, que parte desde uma classificação de segurança como também da frequência recomendada de medições.

No Brasil, a legislação determina que os valores retornados em uma medição estejam dentro de um intervalo indicativo de níveis satisfatórios de segurança das operações na PPD. AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (2019) apresenta os valores mínimos, representados na Tabela 3, para coeficiente de atrito para diferentes equipamentos de medição e suas configurações. Os dispositivos são alternativas disponíveis no mundo e usadas em diferentes aeródromos de vários países, sob legislação local.

O coeficiente de atrito pode ser comprometido pela presença de contaminantes na pista (FWA *et al.*, 1997). Tais contaminantes podem ser descritos como borracha, água, combustível de avião, partículas em pó, água, neve, gelo, lama, etc. Ao longo do tempo, contaminantes como esses, juntamente do desgaste natural da pista, vão alterando o coeficiente de atrito da PPD. Inclusive, climas extremos comprometem o coeficiente de atrito favorecendo acidentes e tornando necessária a medição precisa da qualidade do coeficiente na pista (NIU *et al.*, 2021).

Tabela 3 – Padrões de medição de coeficiente de atrito para cada equipamento.

Equipamento	Pneu Tipo	Pneu Pres- são (kPa)	Velocidade do Ensaio	Profundidade da Lâmina D'agua	Nível de Ma- nutenção	Mínimo
Mu-meter	A	70	65	1.0	0.52	0.42
	A	70	95	1.0	0.38	0.26
Skiddometer	B	210	65	1.0	0.60	0.50
	B	210	95	1.0	0.47	0.34
Surface Friction Tester Vehicle	B	210	65	1.0	0.60	0.50
	B	210	95	1.0	0.47	0.34
Runway friction Tester Vehicle	B	210	65	1.0	0.60	0.50
	B	210	95	1.0	0.54	0.41
Tatra	B	210	65	1.0	0.57	0.48
	B	210	95	1.0	0.52	0.42
Grip Tester	C	140	65	1.0	0.53	0.43
	C	140	95	1.0	0.36	0.24

Fonte: ANAC (2019).


Para a medição de macrotextura, IS 153.205-001B determina que a profundidade da macrotextura do pavimento deve ser monitorada por meio de medições conforme ensaio volumétrico tipo ensaio de mancha de areia. Isso significa que o método do ensaio da mancha de areia pode ser adotado, mas outro método que demonstre comprovação científica do seu poder de medição análogo ao do ensaio da mancha de areia pode ser usado. No entanto, essa comprovação deve ser apresentada juntamente com o planejamento de medição elaborado pelo operador de aeródromo para que a ANAC possa apurar.

A medição é feita em toda a extensão operacional da pista e não pode ser em pistas com *grooving* (definido mais adiante). Não há restrições de qual cabeceira a medição deve iniciar. A medição pelo ensaio da mancha de areia é estabelecida como a cada 100 metros partindo da cabeceira escolhida alternando entre 3 metros à esquerda e à direita do eixo. Cada área deve ter cerca de 3 medições no mínimo. O total dessas medições, manuais e rudimentares, é de, em média, 72 medições considerando uma pista com 2400 metros de comprimento. Seriam 24 áreas de medições com 3 ensaios cada. A Figura 2 ilustra uma pista de aeródromo com demarcações das áreas onde devem ocorrer as medições.

Cada medição pelo método da mancha de areia requer uma sequência de 3 passos básicos determinados pela IS 153.205-001B. Consiste no espalhamento de um volume conhecido de areia sobre uma área da superfície do pavimento. Usa-se um carimbo (espalhador) para esta finalidade em movimentos circulares. A Figura 3 ilustra os utensílios como o carimbo e o cilindro que contém a areia de volume conhecido. Após o espalhamento estar completo, isto é, não ser




Figura 2 – Ilustração das áreas de medição da macrotextura a 3 metros (verde) do eixo de pista alertando entre lado esquerdo e direito.



Fonte: Elaborado pelo autor (2023).

possível aumentar a área da mancha de areia resultante, são feitas medições dessa área circular. A Figura 4 ilustra o procedimento do ensaio da mancha de areia em um pavimento. As medidas são usadas no cálculo proposto e então infere-se a macrotextura por meio da profundidade.

Figura 3 – Cilindro metálico que contém a areia e o carimbo utilizado nos movimentos circulares para gerar a mancha de areia durante o ensaio de medição da macrotextura.



Fonte: IS 153.205-001B (2022).

A areia utilizada deve possuir 24 centímetros cúbicos. A areia deve possuir granulometria tal que passe pela peneira número 50 e seja retida na de número 100 conforme a ABNT. A mancha de areia deve ser medida com objetos de precisão milimétrica. Muitas das vezes, um caixote aberto em duas faces opostas pode ser usado para criar uma proteção contra vento. A Figura 5 contém as equações utilizadas como apresentadas na IS 153.205-001B.

A profundidade média de macrotextura deve ser maior ou igual a 0,60mm. Caso menor, ações devem ser adotadas. Como sabe-se, o ensaio da mancha de areia é rudimentar e pode consumir muito tempo e outros recursos como humanos. A pista do aeroporto de Fortaleza, por exemplo, possui cerca de 2700 metros após a expansão. Isso equivale a 27 áreas de medição, sendo 3 em cada, totalizando 81 medições pelo ensaio. Existem outros métodos a *laser* que podem ser implementados, mas que possuem custo financeiro muito maior que ao da mancha de areia (Figura 4).

Figura 4 – Etapas do ensaio da mancha de areia.



Fonte: Sousa (2018, p. 35).

Figura 5 – Equações usadas no cálculo de macrotextura pelo ensaio da mancha de areia.

$$\text{Profundidade da macrotextura de cada medição}_{(i)} = \frac{\text{Volume de areia}_{(i)}}{\text{Área coberta pela areia}_{(i)}} \quad (1)$$

$$\text{Profundidade da macrotextura} = \frac{\text{Soma das profundidades da macrotextura de cada medição}_{(i)}}{\text{Número total de medições realizadas de cada área}} \quad (2)$$

$$\text{Profundidade média da macrotextura} = \frac{\text{Soma das profundidades da macrotextura em cada terço}}{\text{Número total de áreas de medição em cada terço}} \quad (3)$$

Fonte: IS 153.205-001B (2023).

Uma alternativa adotada em diferentes aeródromos para contribuir com a preservação das propriedades de escoamento da água em PPD é aplicar o *grooving*. *Grooving*, segundo Pereira (2010), consiste em realizar ranhuras de propriedades de largura, espaçamento e profundidades uniformes no revestimento. Essas ranhuras são executadas quase de forma exclusiva em aeroportos de forma transversal ao eixo de pista. Os benefícios são a diminuição da distância de frenagem na presença de chuvas e diminuição de acúmulo de lâminas d'água na superfície. A Figura 6 mostra a PPD do Aeroporto de Joinville (SC) com *grooving*.

## 2.4 Agravantes do acúmulo de borracha em pistas aeroportuárias

Segundo Fwa *et al.* (1997), dentre os contaminantes que deterioram a qualidade de uma PPD, a borracha que vai se acumulando ao longo do tempo é o tipo de maior ocorrência dentre todos. Em média, apenas nas operações de pouso, uma aeronave deposita cerca de 500 a 700 gramas de borracha nas pistas (GRANSBERG, 2008). Levando em consideração que os

Figura 6 – *Grooving* no Aeroporto de Joinville, Santa Catarina, Brasil.



Fonte: Reprodução: G1 (2016).

maiores aeroportos do Brasil possuem centenas de pousos de aeronaves todos os meses, esse número pode facilmente se tornar perigoso (INTERNATIONAL AIRPORT REVIEW, 2015).

O acúmulo de borracha em um pavimento é capaz de gerar lâminas de água na pista, provocando hidroplanagem (JORDANIAN CIVIL AVIATION REGULATORY COMMISSION, 2010). Além disso, o acúmulo reduz o coeficiente de atrito pela perda de aderência da pista com o pneu das aeronaves. Isso ocorre pelo fato de que a borracha, sob a reação físico-química do atrito provocado, deposita-se na textura da PPD. Durante uma operação de pouso, a roda da aeronave está parada até o primeiro toque na PPD. Assim que o toque acontece, a roda está ganhando velocidade de rotação e, sob extrema pressão, há um aquecimento considerável na borracha, ocorrendo uma polimerização que transforma o material, espalhando-o na pista e preenchendo os poros do pavimento. Ao resfriar-se, forma-se uma camada endurecida, fina e lisa quase como vidro. Essa camada vai aos poucos preenchendo também a macrotextura da pista (QUARIGUASI, 2020).

Pelo exposto no parágrafo anterior, depreende-se que o escoamento de água na pista não acontece, bem como o atrito devido às propriedades físicas da película formada sobre a pista. A roda de uma aeronave é macia e flexível por ser projetada para absorver alguns dos choques durante o pouso. Dessa forma, a própria pista corre o risco de aderir essas propriedades em caso de acúmulos muito severos de borracha (JORDANIAN CIVIL AVIATION REGULATORY

COMMISSION , 2010).

O monitoramento do acúmulo de borracha é realizado por meio da medição do coeficiente de atrito e da macrotextura do pavimento, cujas normas de controle, equipamentos utilizados e frequência de monitoramento estão especificados no ANAC (2020, 2021). Uma forma de parametrizar o acúmulo, percebido também a olho nu, caracterizado por uma mancha mais escura que a do pavimento da PPD, é por imagens.

Tendo em vista a deterioração da pista em decorrência do acúmulo de borracha devido às operações, o procedimento de remoção de borracha acumulada se torna uma atividade essencial de manutenção de PPD. O objetivo é fazer com que o pavimento atinja padrões de resistência a derrapagens e parâmetros de qualidade sejam respeitados (FWA *et al.*, 1997); dentre eles, os mencionados coeficiente de atrito e de macrotextura.

Segundo Jordanian Civil Aviation Regulatory Commission (2010), existem quatro métodos de remoção de borracha acumulada, cujos usos nos aeroportos variam com base em uma série de razões (ambientais, disponibilidade de recursos etc.). Dentre os métodos, de acordo com Sales (2019), o hidrojateamento de alta pressão é o mais comumente utilizado nos aeródromos brasileiros. Inclusive, estudado acerca de seus possíveis impactos na vida útil de diferentes pavimentos, que pode incluir a perda de seus efeitos sobre os pavimentos a longo prazo.

## **2.5 Capturas de imagens aéreas**

A captura de imagens de satélite é uma maneira de obter imagens amplas da pista e sem necessidade de interromper o tráfego aéreo. Contudo, o uso de satélites próprios pode ser um meio de custos elevados, sendo que o uso de satélites de terceiros vem a ser uma alternativa de menor custo em relação ao de manter um satélite funcional. Porém, outros problemas vêm a surgir.

Por meio de imagens de satélite, pode não haver informações suficientes sobre a câmera utilizada ou controle sobre os pré-processamentos que ela pode estar aplicando a cada captura. Além disso, eventualmente, determinados objetos podem obstruir a pista. Entre eles, a presença de nuvens e de sombras provocadas por elas. Fatores meteorológicos podem limitar as capturas restringindo a determinados momentos do dia ou, inclusive, meses do ano. O uso de imagens de satélite pode passar por determinados problemas que podem comprometer a versatilidade e a liberdade de monitorar o estado da pista, sendo isso exatamente os elementos que se visa obter por um método alternativo de monitoramento (AQUINO *et al.*, 2022).

As capturas por Veículo Aéreo Não-Tripulado (VANT) oferecem maior controle às configurações de câmera que as de satélite. Além disso, traz maior liberdade para decidir o momento exato da captura e evitar problemas que a alta altitude podem oferecer, como obstrução por nuvens. A forma mais prática ocorre pelo emprego de drones que realizam voos de uma cabeceira para outra capturando várias imagens para gerar um mosaico final, que pode ser feito por meio de um *software* adequado para isso. Inclusive, voos rasantes fazem com que o sombreamento por nuvens cause apenas algumas imagens escurecidas na qual o mosaico final pode não demonstrar devido aos pré-processamentos realizados durante a montagem automática (MOTA *et al.*, 2022).

Outra vantagem com relação às capturas de satélite está a riqueza de detalhes ligeiramente maior. A análise de área emborrachada de pistas por meio de imagens pode ser melhor realizada considerando apenas a região mais próxima do eixo. Isto é, as zonas de toque das aeronaves. Assim, as análises podem tornar-se mais viáveis pelo corte das laterais da pista estabelecendo uma faixa em metros a partir do eixo e então realizando o ajuste pelo equivalente em pixels na imagem. Inclusive, viabiliza o mapeamento por imagens de regiões da pista onde ocorreram determinadas medições ou outras intervenções (MOTA *et al.*, 2022).

## **2.6 Representação de imagens e domínio de espaço e valor**

As imagens podem ser representadas por matrizes nas quais cada posição contém as intensidades de um *pixel*, que é a menor unidade de informação contida em uma imagem. Essas intensidades, em geral, são valores entre 0 e 255, para que sejam armazenados em até 8 bits. Esses valores variam de acordo com a escala de cores da imagem. Em escala de cinza, apenas um valor é armazenado e indica se o pixel é branco, preto ou algum grau de cinza de acordo com a grandeza do valor; em escala de cores codificado em RGB, por exemplo, são três valores os quais representam os tons de vermelho, verde e azul. Somados, formam as outras tonalidades do espectro de cores. Essas imagens com o propósito de serem exibidas em telas e outros monitores se dizem estar em domínio de espaço e valor (GONZÁLEZ; WOODS, 2008).

## **2.7 Processamento Digital de Imagens (PDI) e aprimoramento de imagens**

Processamento Digital de Imagens (PDI) é um campo de estudos que aplica algoritmos e diferentes técnicas para processar dados que, neste caso, são imagens. Geralmente se

divide em etapas que agregam desde a coleta das imagens como a representação ou descrição dos dados obtidos pelas imagens que contribuem diretamente para a correta interpretação deles. O presente trabalho considera PDI como sendo a “Ciência de Dados aplicada a imagens”. Por essa razão, é importante atentar-se aos aspectos gerais que envolvem a captura a até como os resultados são gerados, representados e validados.

A aplicação de pré-processamentos para tornar imagens mais homogêneas é alvo de estudos em diferentes problemas que possuem capturas de grandes ou longos objetos em partes. Dentre eles, está a criação de imagens panorâmicas, sejam elas apenas capturas gerais, ou também para composição de cenários de Realidade Virtual (LAFRUIT; TERATANI, 2021).

Nesses tipos de capturas, uma sequência de várias imagens de uma mesma figura final é capturada. No entanto, elas podem ter variações quanto ao brilho e contraste entre si. Sem nenhum tratamento, a figura final após a junção das diversas capturas pode resultar em uma imagem com regiões completamente incongruentes e heterogêneas (XIONG; PULLI, 2010). A Figura 7 mostra um exemplo de captura panorâmica com regiões destoantes quanto ao espectro de cores entre si. Portanto, aplica-se métodos que tornam as capturas cada vez mais homogêneas de modo a tornar a imagem final mais íntegra e verossímil como se fosse uma captura única.

Figura 7 – Imagem panorâmica em escala RGB com incongruência de tonalidades em diferentes regiões.



Fonte: Xiong e Pulli (2010, p. 3).

Uma sequência de imagens de um mesmo alvo em regiões ou momentos diferentes pode estar sob variações de tonalidades. Segundo Pham e Pringle (1995), variações de claridade do ambiente podem ser suficientes para este fenômeno. Para então equilibrar as tonalidades, faz-se necessário mapear as regiões coincidentes dentre as imagens e minimizar o erro, que é determinado pelas diferenças dos pixels das regiões. Inclusive, algumas imagens podem conter objetos cujas tonalidades não pertencem às regiões que coincidem. Portanto, a aplicação de métodos de ajustes pode criar regiões com cores totalmente inexistentes no alvo capturado ou que fogem do espectro de cores. Pham e Pringle (1995) estudam ainda os cálculos que podem evitar que o ajuste leve a esses fenômenos como codificar imagens, por exemplo, usando uma



função sigmoide, evitando o problema.

Dessa forma, entende-se que aplicar uma calibragem nas imagens é realizar a aplicação de um algoritmo de modo que:

- a Seja mapeada uma região comum entre as imagens para estabelecer, de forma confiável, a diferença de tonalidades;
- b Seja feito o cálculo para identificar se as demais regiões de pelo menos uma das imagens durante a calibragem possuem, ou não, tonalidades bem diferenciadas das áreas comuns entre elas: evita-se artefatos e falhas de calibragem e sugere-se usar o cálculo da distância euclidiana;
- c Seja realizado o ajuste das tonalidades.


## 2.8 Aprimoramento de capturas únicas

Não somente em capturas sequenciais pode haver necessidade de calibragem de imagens. Em capturas únicas, pode haver a necessidade de ajustar determinados parâmetros para ampliar a sua qualidade e auxiliar em métodos de PDI. Imagens de captura única podem necessitar de calibragem aproveitando-se exclusivamente das tonalidades de suas sub-regiões para a realização do aprimoramento de suas intensidades e podem ser realizados de maneira automática.

Sousa (2018) trabalha com um problema de avaliar a textura de um pavimento por imagens das quais alguns agregados se tornam muito escuros, dificultando a performance. Inclusive, aponta para o fato de que o horário e condições climáticas do momento da captura afeta as condições de brilho e contraste da captura gerada. Um método para ajuste automático é a equalização por histograma (GONZÁLEZ; WOODS, 2008), que pode contornar a ocorrência desse tipo de problema. Akagic *et al.* (2018) desenvolveram uma aplicação capaz de detectar fissuras por imagens que são difíceis de identificar. No entanto, as imagens mantinham as propriedades problemáticas de Sousa (2018), mas o desempenho final não foi afetado devido a presença de equalização por histograma presente em uma das etapas.

Muitos métodos de detecção de objetos e segmentação são positivamente auxiliados por calibrações. Muitos deles exigem que diferentes parâmetros adequados para cada imagem sejam encontrados. Esses parâmetros podem variar muito de imagem para imagem e estudos de métodos automáticos como o de Campos *et al.* (2019) visam propor uma automatização dessas aplicações e a calibragem também ajuda nesse problema. Nesse estudo, o alvo é a equalização

de contraste adaptativo CLAHE (ZUIDERVELD, 1994; OPENCV, 2024). Nesse algoritmo, uma equalização por histograma é feita localmente. Assim, evita um aumento no brilho que pode fazer com que regiões originalmente escuras fiquem ainda menos visíveis. Contudo, caso haja ruído, ele será amplificado. Isso é evitado implementando um limiar de contraste. Na biblioteca *OpenCV*, os padrões são janelas de 8x8 e limiar de contraste de até 40 nos bins do histograma. Caso ultrapasse, são redistribuídos para outros (OPENCV, 2024).



(a) Original.

(b) Equalização por histograma. (c) CLAHE.

Figura 8 – Comparação dos resultados da aplicação de uma equalização por histograma e CLAHE.

Fonte: *OpenCV* (2024).

Messina *et al.* (2003) estudam o ajuste de exposição de imagens de captura única feitas por dispositivo portáteis para melhorar a qualidade geral. Todavia, detectando a melhor exposição para reproduzir com mais qualidade as regiões mais importantes da imagem. Essa detecção acontece por meio da medição de luminância das sub-regiões de uma imagem e análise do espectro de cores para identificar pele humana, atribuindo assim maior peso de “importância” para aquela área da imagem.

### 2.8.1 Segmentação em Imagens

A segmentação em imagens é o recorte de uma imagem. Pode ele ser para filtrar objetos mantendo apenas os de interesse ou para remover qualquer informação que não seja importante para a aplicação correspondente. Assim, preserva a região de interesse (do inglês, *Region of Interest* (ROI)) enquanto que o restante, o *background*, é eliminado (GONZÁLEZ; WOODS, 2008). A segmentação detecta os objetos da ROI, de forma geral, por meio das intensidades dos *pixels* correspondentes. Algoritmos de segmentação podem utilizar-se apenas das intensidades dos pixels, como mostra a Figura 9. Métodos mais sofisticados podem utilizar-se de redes neurais dedicadas a essa detecção.

Lai e Westland (2020) apresentam um método de segmentação por meio do espectro



Figura 9 – Segmentação de imagem em escala de cinza por intensidades.



(a) Original

(b) Segmentado

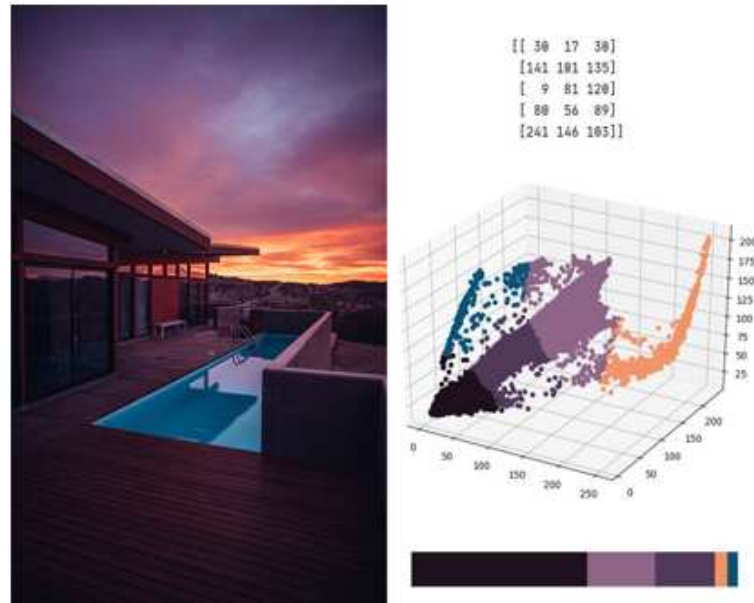
Fonte: González e Woods (2008).

de cores em imagens de passarelas de desfiles de moda. Nessa abordagem, o interesse é extrair cores presentes nas peças vestidas pelos modelos por meio de um algoritmo. Um algoritmo de agrupamento, ou *clusterização* (que vem do inglês *cluster*, ou nuvem em tradução livre), foi aplicado para esse objetivo. Dessa forma, cada objeto é representado por uma intensidade e ela é apresentada. Esses algoritmos são aplicados em dados que normalmente, ao serem projetados em um plano, exibem agrupamentos, os *clusters*, e podem ser facilmente divididos em subconjuntos de acordo com os agrupamentos identificados. Imagens são dados que apresentam esse tipo de comportamento por meio das cores de cada *pixel*. A Figura 10 representa essas etapas.

Esse tipo de técnica permite que uma imagem em escala de cores passe por uma redução do espectro de cores apresentado por ela. Uma vez que cada agrupamento é determinado, cada *pixel* pertencente a cada *cluster* pode ser substituído pelo centróide que representa esse subconjunto. A Figura 11 representa uma imagem e a respectiva resultante desse processo.

Consequentemente, essa técnica permite a segmentação de objetos de acordo com a cor predominante apresentada por eles. Isto é, filtrar objetos de acordo com o agrupamento ao qual pertencem os seus *pixels*. Uma vez que cada ROI está representada pelo seu centróide, é possível gerar uma imagem que contenha uma de cada vez. Mota *et al.* (2023) aplicou o algoritmo de agrupamento K-médias em imagens de PPD para segmentar de acordo com as tonalidades de cada região. A Figura 12 representa as etapas dessa aplicação.

Figura 10 – Imagem RGB, sua projeção no plano 3D e as respectivas intensidades de cada nuvem após agrupamento em 5 *clusters*.



Fonte: Ailephant (2020).

Figura 11 – Imagem em escala de cores RGB e a resultante da redução do espectro de cores após agrupamento em 3 *clusters*.



(a) Original




(b) Resultado

Fonte: Medium (2021).

## 2.9 Matriz de coocorrência de níveis de cinza (GLCM)

Propostas por Haralick *et al.* (1973), essas matrizes representam características de textura de imagens, sejam aéreas ou microfotografias, baseadas na dependência de tonalidade e nível de cinza. Cada elemento de posição  $i, j$  dessa matriz representa a frequência com que um *pixel*  $i$  de determinada intensidade ocorre de forma adjacente a determinado *pixel*  $j$  na imagem de origem. Por meio dessa matriz, é possível obter características como contraste, homogeneidade, energia (uniformidade dos níveis de cinza na imagem) e correlação entre os *pixels*. Essas características podem ser usadas para descrever diferentes texturas em uma imagem.

Figura 12 – Imagem em escala de cores RGB, centróides obtidos após aplicação do algoritmo de K-médias e a segmentação por centróide (K=6).



Fonte: Mota *et al.* (2023, p. 4).

## 2.10 Métodos de análise de correlação

Os métodos de análise de correlação investigam a relação ou associação entre duas, ou mais variáveis quantitativas (GOGTAY; THATTE, 2017). Dentre esses métodos, está o coeficiente de correlação de Pearson. Esse coeficiente avalia a correlação linear entre duas variáveis, ou seja, se determinadas variáveis aumentam proporcionalmente ou desproporcionalmente. Além disso, há o terceiro caso onde não há correlação linear. O método de Correlação de Spearman avalia a relação dentre duas variáveis não presumindo uma correlação linear entre elas. Esse coeficiente mensura a relação monotônica dentre as variáveis. A correlação de Pearson introduzida por Galton em 1877, mas desenvolvida mais tarde por Pearson em 1896; a correlação de Spearman, em 1906 (ZOU *et al.*, 2003). Neto *et al.* (2013) estudou a implementação do coeficiente de correlação de Pearson para analisar imagens em um sistema autônomo em tempo real para decidir se o *frame*<sup>1</sup> capturado deveria ser processado ou não. Dessa forma, a tomada de decisão contribuiria com a poupança de energia gasta com um possível processamento pelo sistema em imagens que não contribuiriam com a aplicação em desenvolvimento.

<sup>1</sup> Imagem fixa de um vídeo em um segundo.

## 2.11 Redes neurais

Redes Neurais são modelos de aprendizagem de máquina profunda paramétricos e supervisionados que realizam tarefas de reconhecimento de padrões com propósito de regressão ou classificação sobre os dados. São compostas por um conjunto de neurônios, que são, no geral, funções polinomiais que recebem um estímulo, valor de entrada, e retornam uma saída para os neurônios seguintes sucessivamente. Eles são organizados em camadas, na qual a que recebe os dados é chamada de camada de entrada. Caso existam dados de diferentes tipos, como, por exemplo, imagens e atributos adicionais em valores contínuos, é possível a implementação de mais de uma camada de entrada para cada tipo (LI *et al.*, 2023).

A camada responsável pela saída (a classificação final ou o valor resultante da regressão) é chamada de camada de saída que conta com a função de ativação. Por fim, os neurônios internos são chamados de camada oculta. O número de neurônios e camadas varia de acordo com o problema e somente as etapas de treino, teste e validação podem contribuir para que esses parâmetros sejam encontrados, além de qual função de ativação é mais adequada.

O processo de treino de uma rede neural consiste em reunir os dados e alimentar a rede, que irá disseminar por todo o modelo até a camada de saída. Esse é o *forward propagation* (HAYKIN, 2009; DEISENROTH *et al.*, 2020). Após isso, ocorrem os ajustes nos pesos dos neurônios de acordo com o cálculo de erro. Quanto maior o erro da classificação ou regressão final, maior o impacto, e vice-versa. Essa etapa é o *back propagation* (HAYKIN, 2009; DEISENROTH *et al.*, 2020). Essa arquitetura é uma forma básica de rede neural. Existem outras arquiteturas desenvolvidas de acordo com o tipo de problema. Dentre elas, estão as redes neurais convolucionais. A primeira grande diferença está na convolução, que é um filtro aplicado em, por exemplo, dados matriciais ou vetoriais. Esses dados podem ser imagens ou sinais (KIRANYAZ *et al.*, 2019).

Uma importante etapa é a de preparação dos dados para submeter ao treinamento. O conjunto de dados nesse tipo de modelo divide-se entre conjuntos de treino e teste. Um terceiro conjunto é necessário, chamado validação (DEISENROTH *et al.*, 2020). O primeiro é utilizado para que a rede ajuste seus pesos; o segundo para analisar a performance da rede com dados nunca vistos antes pelo modelo; o terceiro, para analisar os hiperparâmetros. Além disso, caso o modelo seja de classificação, pode ser necessário o chamado *One-Hot encoding* para codificar as classes em um formato que o modelo seja capaz de usar no treinamento em razão das métricas de ajuste dos pesos (HANCOCK; KHOSHGOFTAAR, 2020). A depender da

Interface de programação de aplicações (*Application Programming Interface*, API) empregada na implementação do modelo, pode não ser necessário, exceto nos dados de saída da rede que podem vir nessa codificação. Outro fator importante para a preparação dos dados é a normalização. Sejam imagens ou sejam atributos numéricos, contínuos ou discretos, mantê-las numa escala entre zero e um contribui para evitar estouros de memória (MURPHY, 2012).

Ressalta-se ainda que as redes neurais convolucionais (RNC) são particularmente eficazes na classificação de imagens, uma vez que suas camadas convolucionais permitem a filtragem automática das características relevantes nas imagens. Esse processo de convolução atua como um pré-processamento, extraíndo padrões como bordas, texturas e formas, o que facilita a identificação e categorização de objetos de maneira mais precisa e eficiente. Assim, as CNNs reduzem a necessidade de intervenções manuais, otimizando a análise visual em diversas aplicações, como reconhecimento facial, detecção de objetos e diagnósticos médicos por imagem.

As métricas para avaliação dependem se a rede é de regressão ou de classificação. Para classificação, há as matrizes de confusão que revelam o grau de acerto do modelo em cada classe. Essas matrizes também podem ser conhecidas como matrizes de erro (STEHMAN, 1997). Há um eixo para os rótulos reais e um eixo para os rótulos atribuídos pelo modelo, e cada posição indica o volume de acertos ou erros baseado no rótulo atribuído pelo modelo e qual seria o real.


### 3 TRABALHOS RELACIONADOS

Nesta seção, são apresentados os trabalhos relacionados que avaliam a macrotextura e o coeficiente de atrito por meio de imagens. Os dados são, de forma geral, provenientes de pavimentos rodoviários, PPD, e outras superfícies. Os algoritmos implementados vão desde filtros em domínio de espaço e valor até os de domínio de frequência. Os dados são extraídos e sintetizados, diversas vezes, na forma de índices que, com uso de modelos de regressão linear, por exemplo, encontram-se correlação forte e uso prático do método desenvolvido.

#### 3.1 Avaliação de superfícies asfálticas

O uso de algoritmos e técnicas computacionais para avaliação de pavimentos asfálticos, seja de trechos urbanos, rodoviários ou até mesmo aeroportuários, vem crescendo há vários anos. Akagic *et al.* (2018), por meio de imagens superficiais de pavimentos, obtiveram satisfatório desempenho em detectar fissuras em pavimentos por meio de segmentação. A Figura 13 apresenta um exemplo. No entanto, há uma baixa disponibilidade de imagens de pavimentos contendo esses defeitos publicamente, afirmam os autores.

Figura 13 – Captura de um trecho de um pavimento asfáltico (à esquerda) e a respectiva imagem segmentando as fissuras da superfície asfáltica (à direita).



Fonte: Akagic *et al.* (2018, p. 6).

Com relação às PPD, Luca *et al.* (2016) desenvolveu um estudo preliminar sobre o decaimento do coeficiente de atrito em razão do acúmulo de borracha ao longo do tempo. A análise contou com uma robusta aparelhagem para coleta de dados para então aplicar algoritmos de aprendizagem de máquina, como os de clusterização e classificação, ou regressão. No entanto, o procedimento demanda uma base de dados cuja coleta de seus dados se dá pelo método tradicional e custoso em tempo e dinheiro, sendo adequado para aeródromos com bases já formadas.

A carência de uma base de dados consolidada de um aeródromo pode ser um fator limitante sobretudo para aeródromos que não possuem nenhuma base digitalizada e de prático acesso, como apontado por Sales (2019) e Quariguasi (2020). Esse desafio, sobretudo nos aeródromos brasileiros, se dá pela carência de desenvoltura tecnológica. Isso vem do fato de que os aeroportos brasileiros contam com instalações que datam da Segunda Guerra Mundial, e que investimentos em ampliação e construção de novos terminais foram realizados somente por volta dos anos 1990, mas sem investimentos expressivos desde então (OLIVEIRA, 2016).

Por outro lado, essas tecnologias fomentam o potencial de prevenir problemas de conservação de PPD. Quariguasi *et al.* (2021) destacam, por meio de redes neurais, a viabilidade de uma aplicação computacional contribuindo para a tomada de decisões de manutenção em PPD. Revela ainda que parâmetros como umidade do ar, idade do pavimento, temperatura, etc., e número de operações (entre remoções de borracha) podem ser fatores de influência significativos no coeficiente de atrito. Dessa forma, é completamente viável o uso de aparatos computacionais de monitoramento que indicam a condição de segurança de PPD.

Metodologias que se utilizam de dados tradicionais do pavimento, ou de outros fatores de influência na preservação como tráfego, temperatura etc., podem estar limitadas justamente a tais dados. Caso esses dados não estejam disponíveis, ou a sua coleta seja custosa, a solução proposta é comprometida. Uma alternativa é o uso de imagens. Por exemplo, empregar o uso de veículos e um *smartphone* no painel do automóvel para coletar imagens para submeter a um modelo de detecção de objetos avaliando o número de defeitos em um pavimento rodoviário (MOTA *et al.*, 2021). Isso contribui para a avaliação de superfícies que contam com defeitos difíceis de detectar ou de quantificar o seu grau de severidade, como fissuras (AKAGIC *et al.*, 2018).

Ghaderi e Abedini (2022) levantam um estudo da macrotextura da PPD do Aeroporto Internacional de Birjand, no Irã. Realiza-se o ensaio da mancha de areia e logo acompanhado



de uma captura da porção de pista avaliada pelo ensaio (Figura 14). Ghaderi e Abedini (2022) demonstram uma correlação significativa entre as imagens e os dados de macrotextura. As imagens foram filtradas de modo a revelar as ranhuras da pista e, então, quantificá-las e comparar com os dados do ensaio. No entanto, o método de captura depende de um tripé e da mobilização de recursos humanos e possível interdição de pista para seguir esta alternativa. Além disso, ressalta-se a necessidade de ampliar o volume de dados oriundos da pista para melhor performance dos estudos do gênero.

Figura 14 – Coleta de dados de macrotextura da PPD do Aeroporto Internacional de Birjand juntamente de uma captura, com auxílio de um tripé, da porção avaliada.




Fonte: Ghaderi e Abedini (2022, p. 5).

Por outro lado, Sousa (2018) usou também da mesma base metodológica, exceto que o PDI aplicado foi o de segmentação para mapear os pontos profundos na textura da pista. A Figura 15 ilustra esse procedimento.

Sousa (2018) aponta como fator limitante o horário do dia, e a possível condição climática, devido ao impacto no brilho e contraste da captura final. Imagens escuras dificultam a performance. Para Ghaderi e Abedini (2022), as discrepâncias de tonalidades entre as imagens devido ao brilho e ao contraste diferenciado não prejudicaram a performance, dado



Figura 15 – Imagem original (à esquerda), segmentada (ao centro) e invertida (à direita) revelando os pontos profundos de uma amostra de superfície de uma PPD.



Fonte: Sousa (2018, p. 10).

que se utilizam de equalização por histograma e filtro gaussiano para calibração e filtragem de microtextura. Contudo, o sombreamento de componentes na textura sobre vales de microtextura não contribuiu positivamente com a filtragem de ruído, apesar de não prejudicar a análise como um todo. Dessa forma, indica que a calibração de imagens para contornar problemas de brilho e contraste, bem como evitar limitação de condição de luminosidade ambiente, é necessária para a melhor performance desse tipo de análise.

Sousa (2018) revela que encontrar um único limiar de segmentação que possa adequar-se a todas as imagens é de baixa correlação devido às propriedades de cada imagem. Dessa forma, isso se torna um indicador de que, para este fim, seria necessário tornar as imagens mais homogêneas quanto às suas propriedades, ou adequar as capturas para um momento do dia (e possivelmente época do ano) que proporcione imagens em condições ideais de brilho e contraste para a aplicação.

A captura de imagens de PPD de aeródromos por VANTs ou por tripés, por exemplo, pode tornar-se mais desafiadora devido à legislação vigente que preza pela segurança do local. Contudo, as técnicas de segmentação, detecção de objetos e texturas, dentre outras, que podem ser desenvolvidas em imagens de pavimentos rodoviários e aplicadas em imagens de PPD, podem dar a composição física das pistas.

Para as análises, é necessário que haja dados da PPD. No Brasil, a plataforma Dados Abertos disponibiliza relatórios, como o de avaliação do coeficiente de atrito, e outros dados sobre PPD de diversos aeródromos, tais como extensão e material do revestimento.

### 3.2 Análise do coeficiente de atrito de superfícies diversas por meio de imagens digitais

Pavimentos com revestimentos asfálticos são implementados não apenas em rodovias como também em PPD de aeródromos. No entanto, o estudo do coeficiente de atrito não está atrelado apenas a esses tipos de revestimentos. Em robótica, o desenvolvimento de máquinas autônomas capazes de inferir o atrito da superfície na qual se deslocam por meio de uma câmera é um problema de interesse (ZHANG *et al.*, 2017; TAMURA; KAMBAYASHI, 2016)

Zhang *et al.* (2017) extraíram atributos chave de imagens de diferentes texturas, como tapetes, vidro, papel, entre outros, para inferência do coeficiente de atrito no desenvolvimento de um robô autônomo. A máquina possui uma câmera com a qual captura imagens da superfície onde ela se locomove, cuja inferência do coeficiente de atrito é muito importante para a tomada de decisões de locomoção. Tamura e Kambayashi (2016) implementam o mesmo tipo de método de captura e tomada de decisão. Entretanto, o processamento das imagens diverge completamente.

A Matriz de Coocorrência de Níveis de Cinza (GLCM) é implementada por Zhang *et al.* (2017) para processar as aproximadamente 100 imagens convertidas para o sistema *Hue Saturation Intensity* (HSI). Essas imagens são de materiais como papel, plástico, pedras, tapetes, entre outros. Dessa forma, a GLCM permite a extração dessas características. A quantidade reduzida de imagens ocasionou um erro elevado durante o treinamento. No entanto, o uso de técnicas de *data-augmentation* nesse conjunto de dados reduziu esse erro. Por sua vez, Tamura e Kambayashi (2016) implementam filtros não lineares para extrair características de sombras, profundidades dos sulcos e suas formas, devido à sua natureza mais complexa e para contribuir com a redução de ruído. Além disso, Tamura e Kambayashi (2016) usam análise discriminante em imagens de diferentes ângulos em relação à superfície, com ou sem *flash*, para determinar o tipo de superfície na qual o robô se locomove.

Um modelo de rede neural é utilizado por Zhang *et al.* (2017) para avaliar se há correlação entre os dados obtidos e os dados reais de coeficiente de atrito; Tamura e Kambayashi (2016) utilizam modelos de regressão linear multivariada para esse fim. A diferença ocorre para obter um modelo funcional e prático (ZHANG *et al.*, 2017), enquanto o outro se concentra em estudar a correlação (TAMURA; KAMBAYASHI, 2016). Ambos indicam a existência de uma correlação forte entre os dados e a possibilidade do uso de imagens para inferir o coeficiente de atrito. A necessidade de converter as imagens do espaço de cores RGB para HSI, segundo Zhang *et al.* (2017), se deu pelo fato de que os canais *Red*, *Green* e *Blue* são afetados pela condição de iluminação e a correlação entre os componentes é alta; em HSI, as informações de cor e

iluminação são independentes. Tamura e Kambayashi (2016) não realizam esse procedimento.

### **3.3 Análise do coeficiente de atrito e macrotextura de superfícies asfálticas por meio de imagens com representação 3D**


Um dos métodos que demonstra forte correlação entre os dados obtidos pelos seus algoritmos e os dados reais é o de processamento de dados tridimensionais do pavimento. Esses dados podem ser obtidos por meio de múltiplas capturas (YUTAO *et al.*, 2022; SLIMANE *et al.*, 2008), ou pela geração de nuvem de pontos para extração de dados do pavimento (HUYAN *et al.*, 2020; PRANJIĆ; DELUKA-TIBLJAŠ, 2022; TIAN *et al.*, 2020). Essas capturas requerem câmeras adequadas, que implicam custos de aquisição maiores do que os tradicionais, e alto controle das condições de captura, como a luminosidade ambiente.

Pranjić e Deluka-Tibljšaš (2022) utilizam imagens de amostras de asfalto capturadas em laboratório sob ambiente controlado. O método gera movimentos para o uso de técnicas de fotogrametria, como demonstra a Figura 16. A superfície asfáltica foi limpa e a câmera posicionada de modo que as imagens possuísem condições de ângulo, iluminação e distância da lente padronizadas. Geralmente, o uso de capturas em laboratório como esse exige amostras do pavimento, ou seja, são destrutivas. Slimane *et al.* (2008), por sua vez, trabalha com um dispositivo de captura de imagens de pavimentos em campo. O dispositivo é construído e configurado de modo a assegurar que as condições de iluminação são uniformes entre as imagens com uso de um sensor de câmera CCD. Os dados obtidos pelo processamento dessas imagens são comparados com os de captura à *laser* no respectivo pavimento. A textura tridimensional é gerada a partir das capturas como na Figura 17. Entretanto, os custos e a complexidade para montagem e preservação das condições ideais de captura são de complexidade equivalente às de Pranjić e Deluka-Tibljšaš (2022).

De modo geral, essas metodologias exigem várias capturas para gerar a representação tridimensional do objeto. Para Pranjić e Deluka-Tibljšaš (2022), cerca de 90 imagens são processadas em sua metodologia para gerar a nuvem de pontos da superfície representada. Tian *et al.* (2020) contam com 790 imagens capturadas para gerar nuvens de pontos, devido a obtenção ser por meio de câmera de *smartphone* acoplada no painel de um carro que percorria o pavimento alvo dos estudos. Ao longo das capturas, leituras por equipamento à *laser* da macrotextura equivalente a cada captura são realizadas.


Slimane *et al.* (2008) não deixam claro o tamanho do conjunto de dados, assim como

Figura 16 – Captura de imagens em laboratório de uma superfície asfáltica.



Fonte: Pranjić e Deluka-Tibljša (2022).

Figura 17 – Exemplo de imagem coletada (esquerda) de uma amostra de superfície asfáltica e a textura obtida (direita).




Fonte: Slimane *et al.* (2008).

Huyan *et al.* (2020) que, entretanto, trabalham com nuvens de pontos geradas durante a própria coleta com equipamento adequado para essa finalidade. A coleta de dados por Huyan *et al.* (2020) é também laboratorial em revestimentos criados para esse propósito.

Diferentes algoritmos podem ser aplicados nesses objetos e nuvens de pontos para extrair características relevantes do pavimento. Tian *et al.* (2020) processam a sua nuvem de pontos pela matriz de macrotextura que usa as alturas apresentadas pelos pontos como na Figura 18. Os valores eficazes são calculados para obter a amplitude da distribuição das profundidades. A partir dessa matriz, várias métricas são obtidas que contribuem para a caracterização da

macrotextura. O método contribui como sendo uma alternativa robusta, por meio de um sistema *binocular-stereo*, que retorna vários indicadores pelo processamento de uma nuvem de pontos.

Figura 18 – Demonstração do cálculo de Profundidade Média do Segmento (MPD) por meio de representação tridimensional.



Fonte: Tian *et al.* (2020).

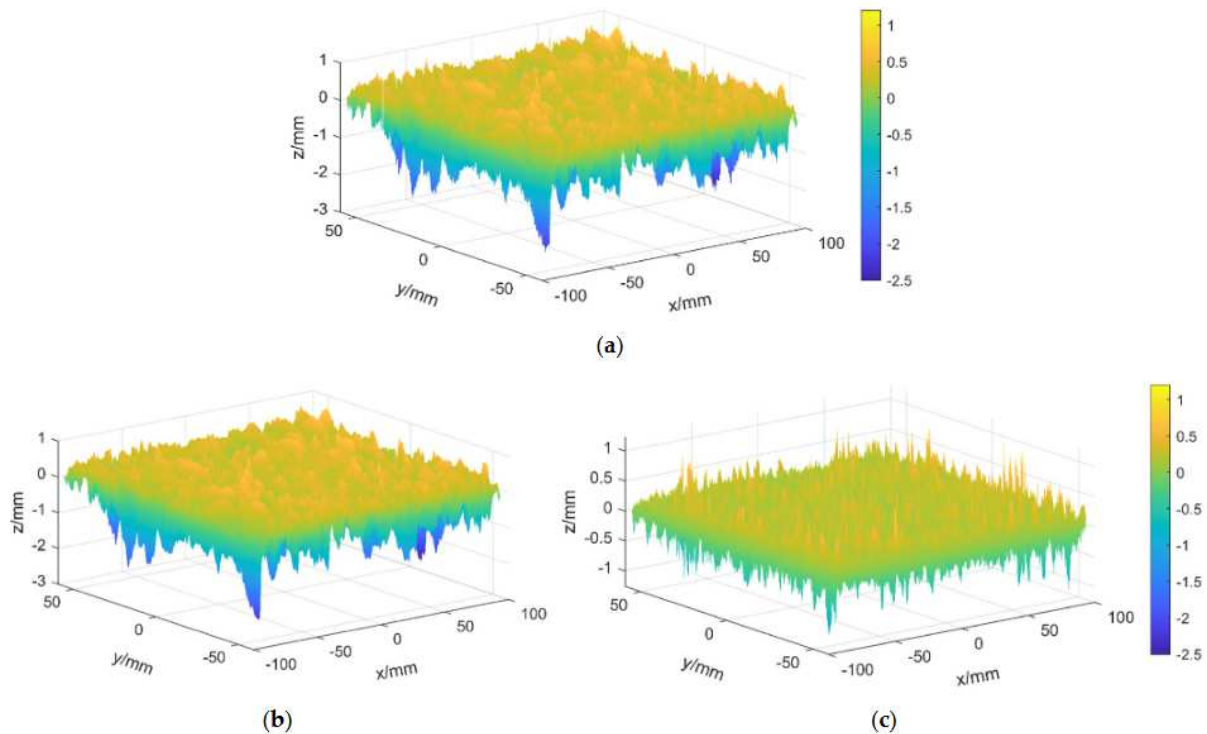
O método de Slimane *et al.* (2008) se diferencia por aplicar uma combinação geométrico-frequencial para caracterizar as formas e as profundidades da superfície. As imagens são também processadas de modo a separar características de cores e de superfície. Um modelo Lambertiano é aplicado para correlacionar as características de cores, escala de cinza e de textura.

Por outro lado, Yutao *et al.* (2022) aplicam métodos de detecção e tratamento de *outliers* pela GLCM, teoria dos fractais, dentre outros, para obter dados de textura em laboratório. O método de captura se distingue dos anteriores com uso de nuvens de pontos por já utilizar câmeras 3D que já geram um objeto tridimensional a partir da superfície. Um dos objetivos é a separação da textura entre macro e microtexturas, como na Figura 19. O coeficiente de correlação de Pearson foi utilizado para analisar os diferentes dados obtidos. O uso de imagens 3D se provou eficaz para analisar a textura do pavimento pela alta correlação entre os dados e pelos indicadores descritivos do pavimento obtidos. Em suas conclusões, diz-se que esses indicadores possuem forte correlação entre si e contribuem com a sustentação do potencial de uso desses algoritmos em problemas futuras aplicações.

Pranjić e Deluka-Tibljajš (2022) concluem que os métodos de análise de imagens são mais capazes de descrever as propriedades de uma superfície asfáltica do que métodos tradicionais. Os parâmetros de saída dessas análises possuem relação com os dados de coeficiente de atrito da respectiva superfície. Os resultados de Tian *et al.* (2020) são coerentes com os anteriores e demonstram que o seu método é comparável ao de análise de dados coletados



Figura 19 – Representação tridimensional do pavimento (a) e a respectiva macrotextura (b) e microtextura (c).



Fonte: Yutao *et al.* (2022).

diretamente por meio de equipamentos à *laser*.

Nessas metodologias, observa-se que há dispositivos de captura com elevados custos de aquisição. Além disso, mesmo a coleta de dados em campo costuma ser menos prática que capturas tradicionais por *smartphones*, ou outras câmeras, em um veículo em movimento. Os custos computacionais também são mais elevados, podendo onerar os ganhos em relação aos métodos tradicionais com confiabilidade estabelecida no mercado.

Em todos os métodos anteriores, conclui-se que é exigido muito poder de processamento computacional; a coleta de dados é mais custosa pela necessidade de câmeras especiais ou de múltiplas capturas variando ângulo, ou pelo controle das condições de captura. Sendo essas, portanto, algumas das desvantagens dessas aplicações.

### 3.4 Análise do coeficiente de atrito e macrotextura de superfícies asfálticas por meio de imagens em domínio de frequência

Uma das alternativas aos métodos tradicionais é usar dados em domínio de frequência. Um método tradicional de medição de macrotextura é por meio de *Circular Track Meter* (CTMeter). O equipamento possui um sensor a *laser* que avalia as elevações da superfície em

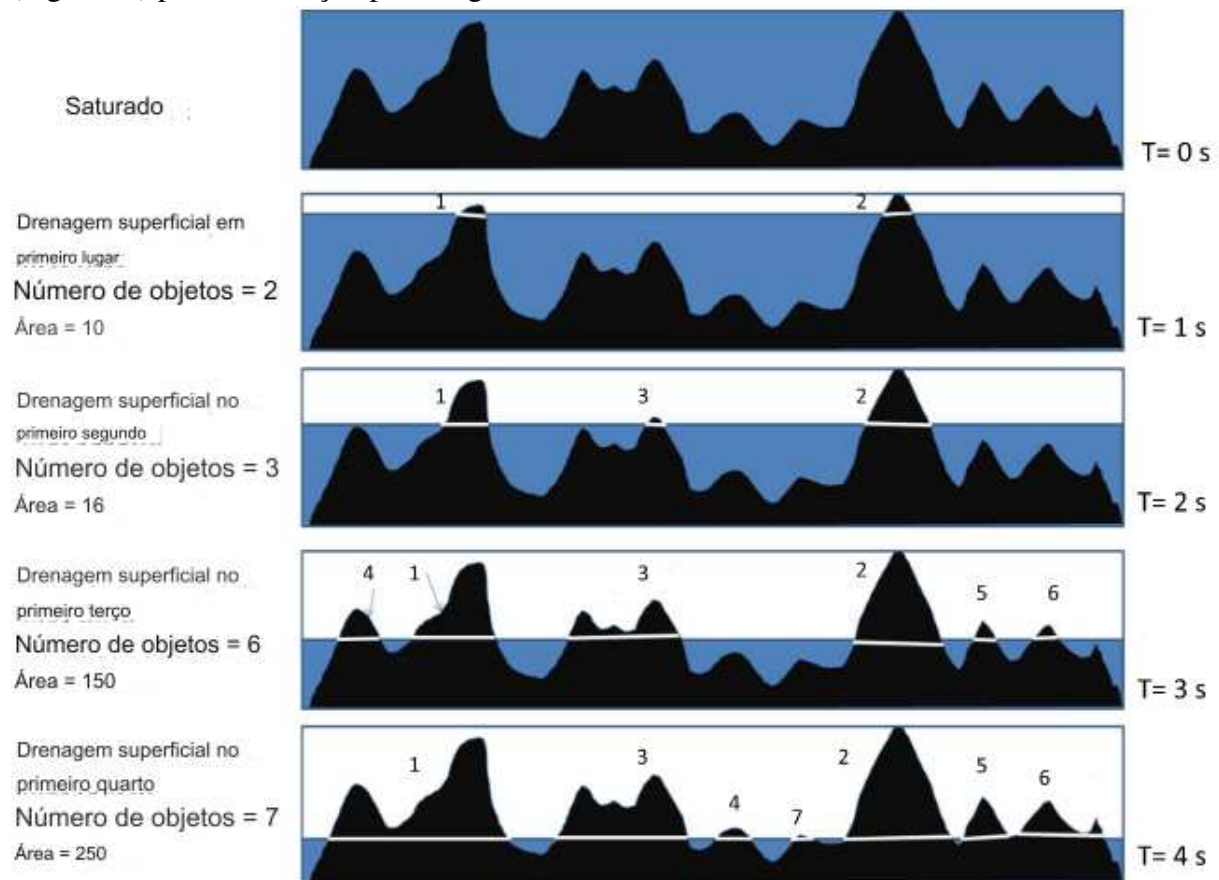
intervalos regulares. Zelelew e Izeppi (2013) utilizam o equipamento para coletar esses dados em domínio de frequência, ou seja, está coletando no formato de sinais. A aplicação dos *Wavelets* para examinar a macrotextura por meio desses dados se demonstrou altamente correlacionada com os dados de profundidade média de relevo. Essa metodologia é capaz de superar o método padrão do ensaio de mancha de areia. Entretanto, exige intervenção na pista pela necessidade de percorrê-la com o equipamento, ainda que com ganho de tempo em comparação.

O emprego de imagens que são posteriormente convertidas ao domínio de frequência é outro procedimento que aproveita as vantagens de algoritmos e técnicas desse domínio, aliando-os aos benefícios inerentes ao uso de imagens. Dentre eles, o custo-benefício de tempo e recursos nas capturas de imagens do pavimento. Nejad *et al.* (2016), por exemplo, investigam o problema da hidroplanagem. As imagens são capturadas por um sistema automático de captura elaborado pelos autores, composto por uma câmera, um computador e uma engrenagem para locomoção pelo pavimento em campo. As imagens são pré-processadas pela Transformada de Fourier para serem convertidas ao domínio de frequência. Assim, aplicam as transformadas de *wavelets* subdividindo as imagens em componentes de frequência (sub-bandas horizontal, vertical e diagonal). Esses componentes representam uma direção específica de informações de textura na superfície do pavimento. Cada direção tem um efeito diferente no índice de resistência ao escorregamento (SR). As sub-bandas contribuem para encontrar índices que ajudam a estimar o índice SR.

De acordo com o trabalho de Mataei *et al.* (2018), investiga-se o problema da hidroplanagem em pavimentos por meio de simulações com imagens. O método captura imagens da superfície do pavimento seco e simula o acúmulo de água com auxílio de equipamentos especiais. A cada 2s uma imagem é capturada e armazenada. A Figura 20 representa a macrotextura durante a ação de escoamento. Os picos formados são alvo de análise pelas imagens.

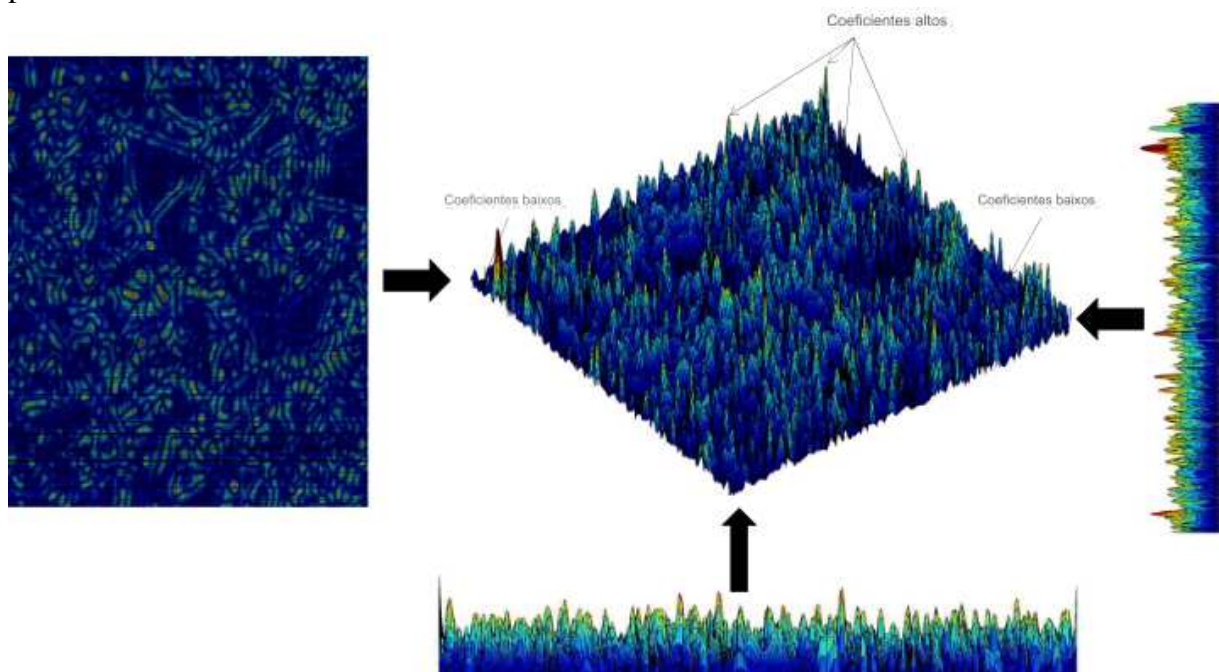
Logo, aplicam-se filtros de redução de ruídos, compressão, análise morfológica e limiarização, avaliando a taxa de escoamento da água. A Transformada de Shearlet é aplicada na etapa de simulação do escoamento de água. Um diagrama é montado representando os picos formados pelos agregados durante o escoamento, e a detecção deles e a extração de características, como o formato e tamanho, são realizadas para obter índices relacionados ao desempenho do escoamento. A Figura 21 representa esses dados. Por meio desses índices, a tomada de decisão é feita para classificar se a qualidade do escoamento é boa, normal ou ruim.

Figura 20 – Representação do escoamento de água em superfície asfáltica ao longo do tempo (segundos) para a avaliação por imagens.



Fonte: Mataei *et al.* (2018).

Figura 21 – Representação do escoamento de água em superfície asfáltica contendo os índices pela Transformada de Shearlet.




Fonte: Mataei *et al.* (2018).



### 3.5 Análise do coeficiente de atrito e macrotextura de superfícies asfálticas por meio de imagens em domínio de espaço e valor

Elunai *et al.* (2011) propõem o método da granulometria para estimar a aspereza de pavimentos por imagens. As imagens de alta resolução são coletadas em campo com dois ângulos distintos ( $60^\circ$  e  $90^\circ$ ) em movimento com o uso de uma câmera de 7.2 megapixel *Panasonic Lumix DMC-FZ8* a 80cm de altura. A Figura 22 representa o método de captura por meio de um tripé. Uma das técnicas aplicadas nessa metodologia é o de um filtro de convolução de detecção de arestas de Canny. As detecções ajudam a descobrir os tamanhos e a distribuição dos agregados à superfície do pavimento. Dessa forma, viabilizando a aplicação de técnicas de conectividade de arestas (*edge linking*), que usam da dilatação e cálculo de distâncias entre objetos em imagens, conectando arestas divididas pelo processamento. Isso ocorre em razão de que a técnica reduz ruído nas imagens, prevenindo a detecção de múltiplas arestas em um único ponto. Os dados finais representam a macrotextura que então é comparada com os dados obtidos por equipamento a *laser*.

Figura 22 – Método de captura de imagens de PPD com auxílio de tripé por Elunai *et al.* (2011)



Fonte: Elunai *et al.* (2011).

Ghaderi e Abedini (2022) avaliam a macrotextura de pavimentos aeroportuários em capturas com ajuda de um tripé junto de medições pelo ensaio da mancha de areia. As imagens foram processadas de modo a detectar as arestas e mensurar na imagem a quantidade delas. Para tanto, é necessário um filtro de redução de ruído, suavizando a imagem. Além disso, aplica-se a equalização por histograma para melhoria das características de brilho e contraste, realçando os agregados da superfície. Por fim, os dados originários do processamento das imagens são comparados com os dados de Profundidade Média do Perfil (do inglês, *Mean Profile Depth - MPD*) da pista. A análise de regressão é implementada para avaliar a correlação entre os dados.

O coeficiente de determinação  $R^2$  (medida estatística que indica a proporção de variabilidade de uma variável, variando entre 0 e 1) apontou uma alta correlação entre eles. Dentre os métodos de mensurar as arestas (contagem de pixels de arestas e detecção *fuzzy* de arestas), o método *fuzzy* apresentou maior eficácia ao detectar agregados com diferentes formas, tamanhos e mesmo em regiões sombreadas.

Baqersad *et al.* (2017) propõem um método alternativo não-destrutivo para a identificação de segregação em pavimentos. Comumente utiliza-se a inspeção visual *in-loco* para identificar essas regiões com diferenças de materiais. A abordagem propõe o uso de imagens para calcular o desvio padrão de seus histogramas para identificar as regiões segregadas. A análise de discriminante linear é implementada para determinar as regiões segregadas e as não-segregadas com base nos desvios padrões obtidos. A inspeção visual é utilizada para avaliar o método, que demonstrou potencial de ser usado como *app* de *smartphone* para detecção *in-loco* em pavimentos de asfalto.

### 3.6 Análise dos trabalhos relacionados

A Tabela 4 reúne um levantamento dos trabalhos relacionados deste capítulo que tratam do uso de PDI e VC. Nela, constam informações quanto ao uso de imagens 2D ou 3D e se houve custos elevados de coleta de imagens e implementação do método trabalhado. Define-se por coleta custosa aquela que leva tempo e requer mobilização de equipamento na superfície avaliada. A implementação define-se por cara quando ela exige elevados recursos computacionais, segundo os próprios autores.

Tabela 4 – Análise dos trabalhos relacionados.

Trabalho	3D	2D	Coleta custosa?	Implementação cara?
Slimane <i>et al.</i> (2008)	X	✓	Sim	Não
Elunai <i>et al.</i> (2011)	X	✓	Sim	Sim
Nejad <i>et al.</i> (2016)	X	✓	Sim	Sim
Tamura e Kambayashi (2016)	X	✓	Não	Não
Baqersad <i>et al.</i> (2017)	X	✓	Não	Não
Zhang <i>et al.</i> (2017)	X	✓	Não	Não
Akagic <i>et al.</i> (2018)	X	✓	Não	Não
Mataei <i>et al.</i> (2018)	X	✓	Sim	Não
Sousa (2018)	X	✓	Sim	Não
Huyan <i>et al.</i> (2020)	✓	X	Sim	Sim
Tian <i>et al.</i> (2020)	✓	X	Sim	Sim
Pranjić e Deluka-Tibljajš (2022)	✓	X	Sim	Sim
Yutao <i>et al.</i> (2022)	✓	X	Sim	Não

Fonte: Elaborado pelo autor (2023).

Com base na Tabela, nota-se que os trabalhos que usam dados tridimensionais possuem, majoritariamente, implementações de seus métodos mais caras. Dos 5 trabalhos a partir do ano de 2020, somente 1 trabalha com dados de imagens 2D. Os trabalhos mais antigos usam imagens 2D, mas, em sua maioria, a coleta é custosa. Quanto aos trabalhos que utilizam imagens 2D e são de coleta barata e sem implementação cara, uma grande desvantagem para o uso prático está no método de captura: os conjuntos de dados foram formados com capturas locais ou extração de amostras da respectiva superfície. Apesar de sua facilidade, a mobilização de uma câmera ou de outro equipamento para coleta das amostras na superfície para a captura de imagens onera a vantagem obtida.

### **3.7 Considerações finais sobre os trabalhos relacionados**

O problema do acúmulo de borracha e suas consequências sobre a resistência à derrapagem em PPD impõe a necessidade de monitoramento e tomadas de decisão relativas à segurança operacional rápidas e precisas por parte dos operadores de aeródromos e da autoridade de aviação civil. O monitoramento, de forma geral, é realizado pela observação de variáveis que descrevem essas propriedades, como o coeficiente de atrito. Entretanto, o levantamento dessas variáveis possui custos elevados de recursos e tempo. Urge a necessidade de métodos mais rápidos e confiáveis para contribuir com o monitoramento e a tomada de decisão sobre PPD.

Considerando a revisão bibliográfica dos fundamentos aos trabalhos relacionados, percebe-se que na área há uma concentração de esforços em implementar métodos computacionais com uso de modelagem tridimensional nos estudos relacionados à PPD. Esses métodos são percebidos pela complexidade computacional exigida para os seus algoritmos. Além disso, a coleta dos dados utilizados por eles é também, muitas vezes, de custo de tempo, financeiro e de recursos humanos elevados.

Metodologias que usam imagens 2D para avaliação de PPD demonstram potencial para contribuir com o monitoramento e tomadas de decisão de estratégias de reabilitação. Imagens coletadas por satélite permitem o acesso às imagens da PPD evitando entraves burocráticos, além da necessidade de fechamento da pista para coleta por Veículos Aéreos Não-Tripulados (VANT), por exemplo. Além disso, imagens de alta qualidade não necessariamente dependem de câmeras muito robustas e não necessariamente exigem aparelhagem demasiada para a realização das capturas. Entretanto, há poucos trabalhos que exploram a fundo essa metodologia em

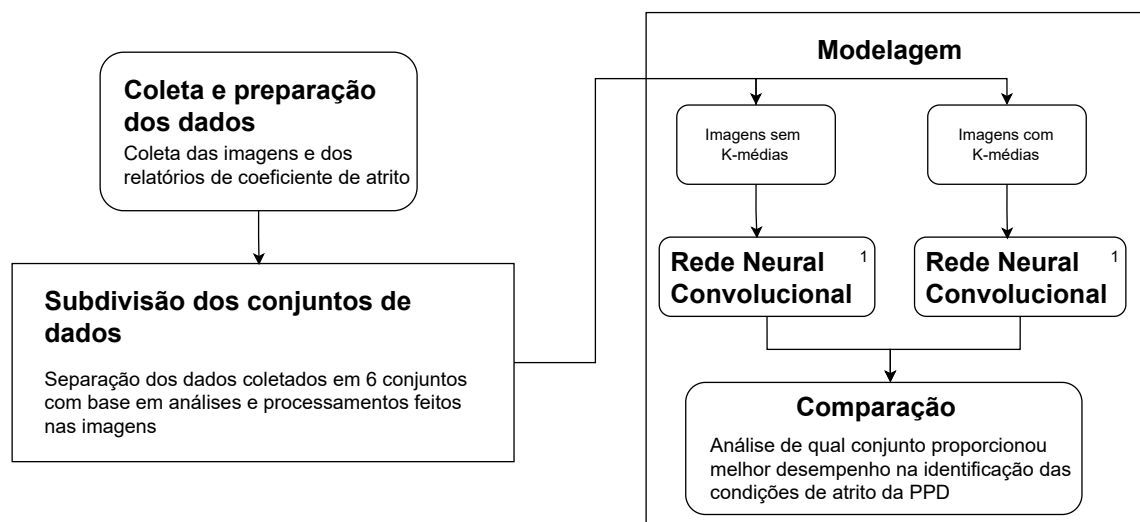
comparação com as que usam modelagem de dados tridimensionais.

## 4 METODOLOGIA

O presente capítulo apresenta a metodologia implementada neste trabalho. O diagrama da Figura 23 representa o método de cada parte que será discutida nas subseções seguintes. A presente seção se divide em apresentar a coleta de dados, os métodos de análise e pré-processamento utilizados para a separação dos conjuntos de dados e, por fim, a modelagem e arquitetura de rede trabalhada.

A proposta do presente trabalho é realizar um estudo sobre a viabilidade de desenvolvimento de um método de rápida coleta de imagens e baixo custo computacional para a análise de uma pista de pouso e decolagem (PPD) brasileira. O estudo usa imagens de satélites e aplica algoritmos de Processamento Digital de Imagens (PDI) e Redes Neurais Convolucionais (RNC). Destacando-se, dessa forma, em comparação aos trabalhos na literatura da área vistos anteriormente. Não somente tendo em vista seus métodos de captura que mobilizam recursos financeiros, humanos e de equipamento, como também em relação à implementação de modelos cuja implementações exigem alta performance computacional. No presente trabalho, a investigação visa também estudar pré-processamentos e critérios para separações de conjuntos de dados que amplifiquem a performance de uma RNC com hiperparâmetros que não exigem muito poder de processamento computacional para treino, teste e validação.

Figura 23 – Estruturação da metodologia do presente trabalho.



<sup>1</sup> Mesma arquitetura de rede para ambas

Fonte: Elaborado pelo autor (2024).

## 4.1 Coleta e preparação dos dados

A presente seção apresenta a coleta de dados, as fontes e a preparação utilizada. A Figura 24 ilustra esta etapa. Foram reunidos dados técnicos da PPD referentes ao coeficiente de atrito e imagens correspondentes por meio do *Google Earth Pro* <sup>1</sup>.

Figura 24 – Diagrama da etapa de coleta de dados do presente trabalho.



Fonte: Elaborado pelo autor (2024).

### 4.1.1 Coleta de dados de coeficiente de atrito da PPD estudada

Os dados para a realização do presente trabalho são obtidos a partir de relatórios oficiais da Agência Nacional de Aviação Civil (ANAC). Maia (2023) sintetizou dados de 3 aeroportos brasileiros em uma base de dados contendo todos os dados de relatórios correspondentes a esses aeródromos ao longo de vários anos. Dos 3 aeródromos disponíveis na base de dados de Maia (2023), os dados de apenas um deles foram utilizados no presente trabalho.

A razão da escolha do aeródromo escolhido se deu pelo fato de que as imagens das pistas provenientes dos outros dois excluídos, obtidas pelo *Google Earth Pro*, apresentavam problemas que inviabilizavam seu uso. Os problemas num deles eram que uma PPD estava apresentando diferentes datas em diferentes trechos de sua extensão em relação à selecionada na ferramenta do *Google*; a outra, por sua vez, apresentava uma baixa quantidade de capturas por data armazenada na ferramenta de coleta. Isso impactaria na modelagem pela baixa quantidade de dados.

Assim, o presente trabalho irá se referir ao utilizado aqui por PPD dado que é apenas uma única pista de um único aeródromo de origem. O presente trabalho utiliza a mesma base de dados, cedidos a pedido, e reúne imagens correspondentes ao período de coleta deles.

<sup>1</sup> <https://www.google.com/intl/pt-BR/earth/about/versions/>

#### 4.1.2 Coleta de imagens de PPD

As imagens são de satélite e foram obtidas via *Google Earth Pro*. O *software* provê imagens ao longo do tempo como uma de suas funcionalidades e permite salvar imagens exibidas na tela. Para aumentar a riqueza de detalhes, a visualização de cada PPD foi configurada de modo que a câmera do observador estivesse a cerca de 100m de altura. Entretanto, apenas parte da PPD fica visível (correspondente ao trecho que a câmera é posicionada) e, conseqüentemente, seria salva. Portanto, é necessário deslocar a exibição na tela para salvar mais partes da PPD para, posteriormente, montar o mosaico correspondente à pista inteira.

O procedimento descrito anteriormente é passível de falha humana, pois é praticamente manual. Tendo isso em vista, foi desenvolvido um *bot* para automatizar esses passos, evitando que falhas humanas causem problemas ao montar o mosaico, por exemplo, com o desalinhamento entre as peças. O *bot* foi desenvolvido por meio do *software AutoIt 4.4.6v*<sup>2</sup>. Por meio dele, abre-se o *Google Earth Pro*, posiciona-se uma das cabeceiras da PPD na tela, e então, iniciam-se as operações do *bot*. Ele é responsável por realizar operações de arrasta-e-solta, cliques, escrever texto (nomes das imagens), entre outros. Portanto, as únicas operações manuais passam a ser as de posicionar a imagem na tela para iniciar as coletas, armazenar as imagens em pastas separadas e alterar a data na linha do tempo do *Google Earth Pro*. Assim, todos os comandos são idênticos e evitam quaisquer problemas ocasionados por falha humana em tais operações manuais. Todas as datas de capturas das imagens da PPD utilizada no presente trabalho estão no Apêndice A.

#### 4.1.3 Pré-processamentos de imagem: montagem dos mosaicos

Os mosaicos foram montados por meio de um *script* em linguagem *Python*. Devido ao processo de coleta exigir comandos manuais idênticos, tal como o deslocamento da imagem em exibição na tela, a área de sobreposição é a mesma em todas as imagens. Após a montagem dos mosaicos, as imagens são recortadas de modo que contenham apenas o revestimento e não áreas do entorno com vegetação. Além disso, há de se recortar ainda as regiões que sinalizam as cabeceiras inicial e final, representadas na Figura 25b de uma outra PPD brasileira para evitar identificação. Isso ocorre pelas medições de coeficiente de atrito iniciarem, em alguns relatórios,

<sup>2</sup> O *AutoIt* é um *software* gratuito projetado para automatizar a Interface gráfica do utilizador (*Graphical user interface* - GUI) do *Windows* e *scripts* em geral. Ela usa uma combinação de pressionamentos simulados de teclas, movimento do mouse e manipulação de janelas/controles para automatizar tarefas.

apenas após os 100m iniciais - equivalentes ao comprimento da cabeceira de início da PPD. Ademais, essas regiões não são relevantes para o presente trabalho e podem representar *outliers* durante a modelagem.



(a) Cabeceira inicial

(b) Cabeceira final

Figura 25 – Exemplos de segmentos de uma PPD brasileira nos metros iniciais e finais.

Fonte: Google Earth Pro (2021)

Algumas imagens são rotacionadas em razão da inclinação presente devido ao posicionamento da câmera do observador no momento de iniciar a coleta. Após a montagem dos mosaicos, as imagens foram inspecionadas quanto à presença de nuvens, sombreamento de nuvens ou pela presença de outros objetos que poderiam prejudicar o uso. A Figura 26 exemplifica um mosaico montado.


Figura 26 – Mosaico montado de data 18/12/2016 em escala RGB.



Fonte: Google Earth Pro (2016).

Após a montagem dos mosaicos, as imagens foram convertidas para escala de cinza e, também, foi aplicada uma equalização por histograma local em todas elas como forma de equilibrar os tons e aumentar as distâncias para os algoritmos seguintes. A execução foi feita com os parâmetros-padrão do comando via *OpenCV*. A Figura 27 apresenta a imagem de data 18/12/2016 antes (superior) e após (inferior) a equalização por histograma. Observa-se que a imagem superior está mais escura de modo que seus detalhes são mais difíceis de serem percebidos em comparação com a inferior.

Figura 27 – Imagem de data 18/12/2016 antes e após a equalização por histograma local.



Fonte: Elaborado pelo autor (2024).



#### 4.1.4 Associação dos pares imagens x relatórios de coeficiente de atrito

As imagens e os relatórios não coincidem nas datas. Ao todo, são 57 imagens e 54 relatórios de coeficiente de atrito. Contudo, há relatórios sem imagens para associar e imagens sem relatórios correspondentes considerando uma margem de tempo de até 30 dias. Essa margem foi escolhida por ser a margem de erro para as imagens do *Google*, dado que o mês e ano são precisos, mas o dia exato pode ter alguma variação (GOOGLE, 2022). Tendo isso em vista, foram analisadas para cada imagem e relatório os pares possíveis de formar com menor diferença possível em dias dentro da margem de 30 dias. Não foi um fator eliminatório se as imagens foram capturadas após, ou antes, das emissões dos respectivos relatórios associados.

As imagens dos pares utilizados são distinguidas como: (i) as imagens de diferença positiva em relação à emissão do relatório, e (ii) as imagens de diferença negativa em relação à emissão do relatório associado. Ao todo, foi possível formar 15 pares (Tabela 5) revelando a relação final de Imagem x Relatório x Diferença de Dias. Todos foram enumerados por um índice para facilitar a compreensão.

Tabela 5 – Pares de relatórios e imagens por data com as respectivas diferenças de dias referentes à PPD estudada

Índice	Relatório	Imagem	Diferença	Índice	Relatório	Imagem	Diferença
01	05/12/2018	16/12/2018	+11	09	28/07/2020	13/07/2020	-15
02	05/01/2019	24/12/2018	-12	10	27/08/2020	24/08/2020	-3
03	03/03/2019	28/02/2019	-3	11	26/09/2020	10/09/2020	-16
04	01/04/2019	29/04/2019	+26	12	26/10/2020	23/10/2020	-3
05	01/07/2019	11/07/2019	+10	13	28/04/2021	26/04/2021	-2
06	02/10/2019	27/09/2019	-5	14	27/07/2021	30/07/2021	+3
07	31/12/2019	18/12/2019	-13	15	22/10/2021	25/09/2021	-27
08	14/05/2020	07/05/2020	+12	-	-	-	-

Fonte: Elaborado pelo autor (2023)

## 4.2 Subdivisão dos conjuntos de dados

A presente seção apresenta a metodologia de subdivisão do conjunto de todas as imagens até chegar nos 6 conjuntos adotados neste estudo. Para essas subdivisões, são levadas em consideração a diferença de dias e também as correlações de Pearson. Essa correlação é realizada sobre as imagens resultantes de uma técnica de segmentação implementada pelo algoritmo de K-médias.

### 4.2.1 K-médias e segmentação


As imagens foram processadas pelo algoritmo de clusterização K-médias. Definem-se, empiricamente, 10 tentativas de agrupamento para cada imagem de cada conjunto, de modo que não seja nem muito alto e nem muito baixo devido ao número de *pixels*. A distância euclidiana foi implementada para esse algoritmo. Ele retorna os centróides de cada agrupamento formado. O valor considerado para esse trabalho foi o de  $K = 3$ , estabelecido por ser a quantidade dos principais elementos de uma PPD neste trabalho: área de acúmulo de borracha, superfície comum do pavimento (sem acúmulo de borracha e sem pintura) e pintura de sinalização. A Figura 28 apresenta os centróides ao clusterizar, por exemplo, a imagem de data 18/12/2016 em  $K=3$  e a Figura 29 apresenta um fragmento da respectiva imagem original (a) juntamente da respectiva figura resultante (b).

Figura 28 – Centróides obtidos ao aplicar  $K=3$  para a imagem de data 18/12/2016 e as respectivas tonalidades e frequências.

	Intensidade	Frequencia
0	82	8332013
1	134	12814956
2	208	5493031

Fonte: Elaborado pelo autor (2023).

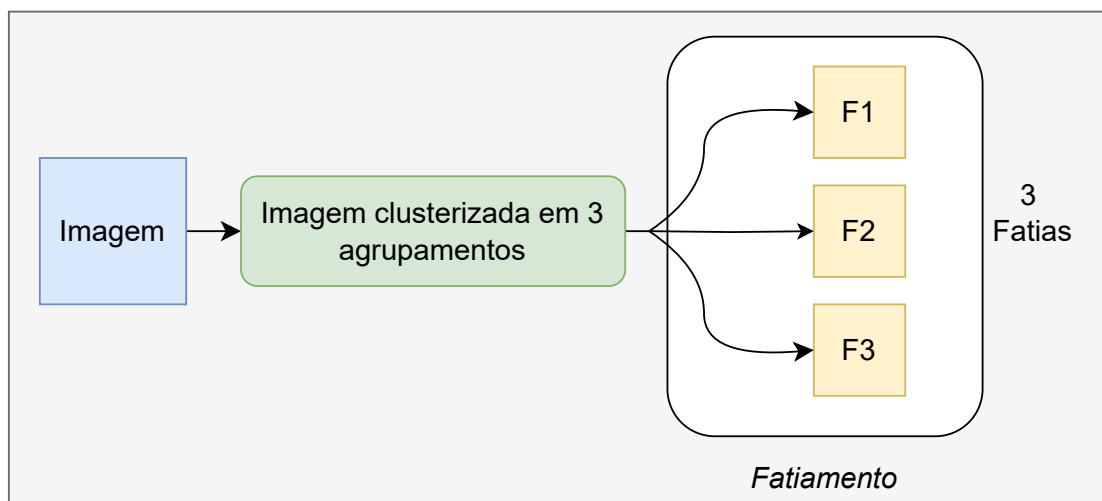
Figura 29 – Fragmentos da imagem de data 18/12/2016 ao clusterizar em 3 agrupamentos.



Fonte: Elaborado pelo autor (2023).

Após essa etapa, os três diferentes agrupamentos formados são responsáveis por formar imagens das quais os *pixels* brancos são aqueles que pertencem ao respectivo agrupamento e pretos aqueles ausentes. Esse procedimento é chamado, no presente trabalho, de *fatiamento*. Cada fatia representa um agrupamento que, por sua vez, representa uma região da imagem de acordo com suas intensidades. A Figura 30 representa a geração delas para uma imagem arbitrária e demonstra quantas novas podem ser formadas. As Figura 31 exemplifica ao apresentar fragmentos da imagem de data 18/12/2016, clusterizada em três agrupamentos após o fatiamento. Dado que as imagens, a partir daqui, estão com valores ou 0 ou 1, não há necessidade de normalização. Apenas o produto entre os *pixels* por 255 é necessário para fins de visualização.

Figura 30 – Etapas da aplicação do algoritmo de K-médias.



Fonte: Elaborado pelo autor (2023).

Figura 31 – Fragmentos do fatiamento resultante da imagem de data 18/12/2016 ao clusterizar em 3 agrupamentos.



Fonte: Elaborado pelo autor (2023).

#### 4.2.2 Recorte e geração das listas de dados

Os coeficientes de atrito são medições contínuas a cada 1, 2 ou 5m partindo da cabeceira predominante da PPD distantes 3m e 6m tanto no lado esquerdo como no direito, em relação ao eixo. Nos relatórios técnicos, esses valores são simplificados para uma média a cada 100m ainda dividindo-se em 3m e 6m à esquerda e à direita do eixo. Entretanto, um recorte das imagens aéreas de satélite representando uma exata região a 3m e 6m nas mesmas condições da medição do coeficiente de atrito, podem resultar em figuras pequenas com pouca informação da superfície. Essa informação reduzida pode ser decorrente de limitações quanto à riqueza de detalhes de textura de pista consequentes da origem dos dados.

Assim, opta-se por cortar as imagens a cada 100m partindo da cabeceira predominante sem separação em lados esquerdo e direito. Por essa razão, a média dos coeficientes de atrito a 3m e 6m para obter uma só medição do lado esquerdo (Equação 4.1) e direito (Equação 4.2) para, consequentemente, uma média final representando aqueles 100m é calculada (Equação 4.3).

$$Esquerdo = \frac{6m_{esquerdo} + 3m_{esquerdo}}{2} \quad (4.1)$$

$$Direito = \frac{6m_{direito} + 3m_{direito}}{2} \quad (4.2)$$

$$Lados\_combinados = \frac{Esquerdo + Direito}{2} \quad (4.3)$$

Para associar cada recorte de segmento equivalente a 100m de PPD ao respectivo coeficiente de atrito médio, é preciso considerar o início das medições de coeficiente de atrito na

PPD e a extensão total dela utilizada no presente trabalho. Dado o recorte excluindo as regiões de sinalização de cabeceira, a extensão até então trabalhada passa de 2277m para 2077m.

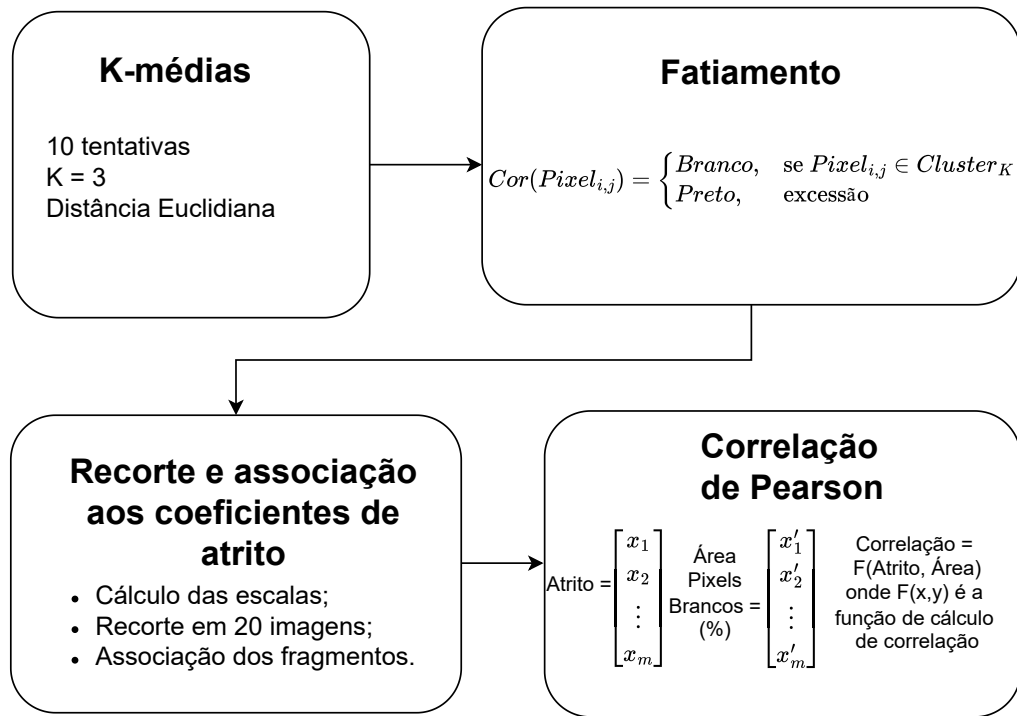
Realizando medições a cada 100m, restam 77m finais que seriam também considerados na medição. Opta-se por descartar essa extensão remanescente. Logo, a PPD passou de 2077m de extensão para 2000m de extensão. Dessa forma, para cada mosaico, os recortes geraram 20 imagens, cada uma representando um segmento de 100m e com seu respectivo coeficiente de atrito médio.

Para que esses recortes dos mosaicos fossem feitos adequadamente, foi calculada a escala da relação de metros por *pixel*. Com esse valor, sabe-se quantos *pixels* de extensão deve possuir cada recorte para poder equivaler a 100m do mosaico. Assim, os recortes foram feitos respeitando a representação da área de medição de cada coeficiente de atrito médio obtido na Equação 4.3.

#### **4.2.3 *Análise de correlação***

Para avaliar a hipótese de que pode ser possível identificar os melhores exemplos para a modelagem baseada na qualidade da representação do acúmulo de borracha em cada conjunto de imagens, é calculado o Coeficiente de Correlação de Pearson considerando o coeficiente de atrito correspondente e a porcentagem de *pixels* brancos na área da respectiva imagem. As imagens utilizadas são as resultantes de K-médias e essa etapa ajuda a formar mais alguns conjuntos para o estudo, ou seja, novas subdivisões. A Figura 32 representa a sequência de etapas da aplicação do K-médias até o cálculo de correlação de Pearson.

Figura 32 – Diagrama da sequência de etapas do processamento das imagens por K-médias para o cálculo e análise de Correlação de Pearson no presente trabalho.



Fonte: Elaborado pelo autor (2024).

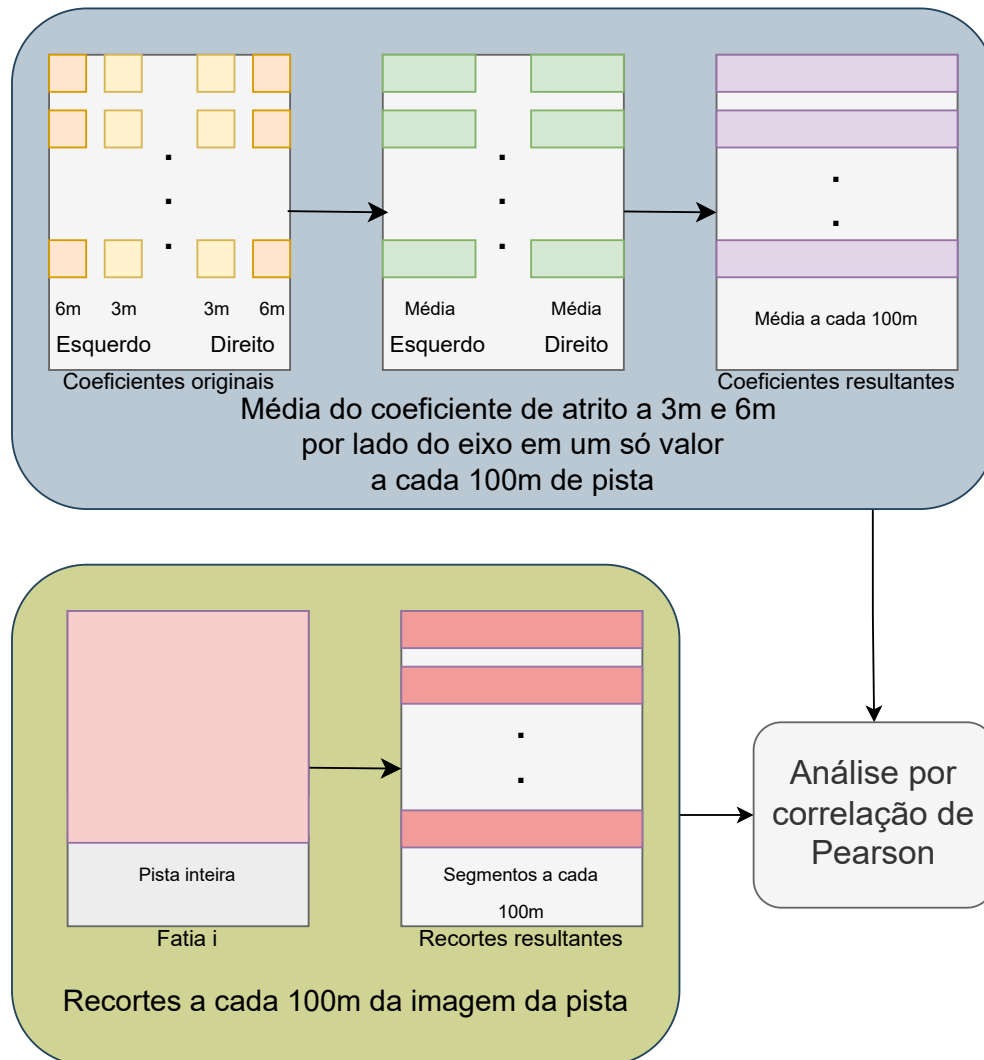
As variáveis para comparação são: vetores de coeficientes de atrito (Equação 4.4), no qual cada valor é um coeficiente medido a cada 100m; vetores de percentuais de área segmentada (Equação 4.5) pelo trecho equivalente na imagem ao do atrito medido naquela região. Ambos são representados na Figura 32 pelos nomes "Atrito" e "Área *Pixels* Brancos (%)", respectivamente. A Equação 4.6 representa a função que calcula a Correlação de Pearson utilizando esses vetores (NUMPY, 2024). Os coeficientes de atrito que compõem os vetores são, cada um, obtidos pelo cálculo da Equação 4.3. A Figura 33 ilustra a formação de cada um desses vetores para a análise de correlação.

$$Atrito = \{X_{100}, X_{200}, \dots, X_n\} \quad (4.4)$$

$$Imagem = \{X'_{100}, X'_{200}, \dots, X'_n\} \quad (4.5)$$

$$r = \frac{Cov(Atrito, Imagem)}{\sigma_{Atrito} \sigma_{Imagem}} \quad (4.6)$$

Figura 33 – Formação e organização das variáveis obtidas pelo processamento de imagens por K-médias e dos dados de coeficiente de atrito da PPD no presente trabalho.



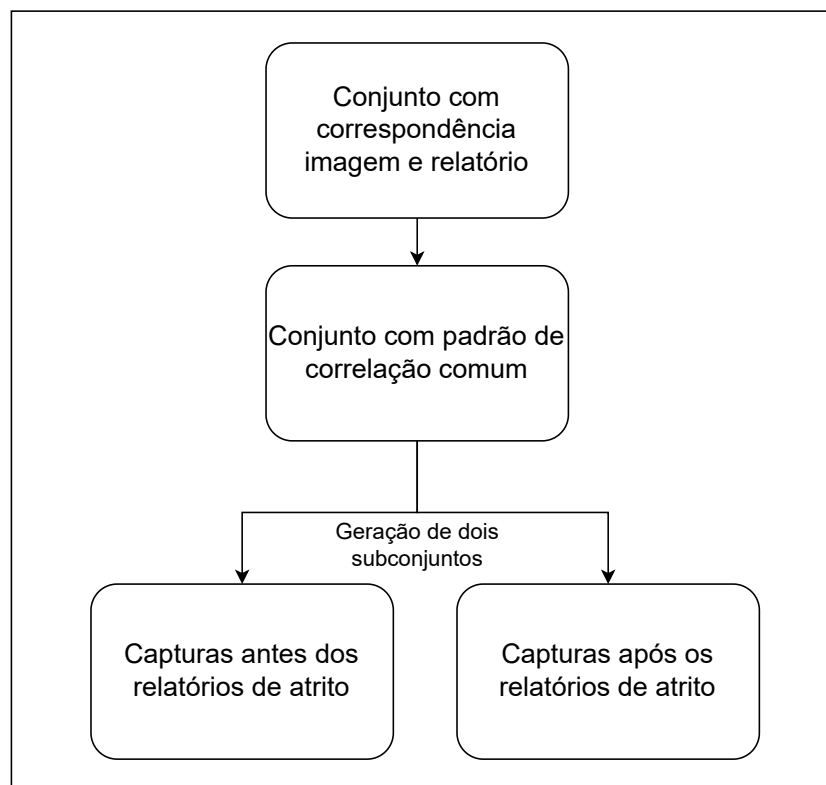
Fonte: Elaborado pelo autor (2023).

As correlações são analisadas por meio de figuras contendo tabelas com os dados referentes aos de cada par de fatia e coeficiente de atrito por valor de K. Os dados também foram submetidos a um teste de normalidade de Kolmogorov-Smirnov, mas alguns deles não passaram. Por essa razão, a análise de correlação de Spearman foi descartada. O presente trabalho concentrou-se em considerar a presença de correlação direta ou inversamente proporcional e não considerou avaliar a força.

#### 4.2.4 *Elaboração dos conjuntos de dados para desenvolvimento dos modelos*

Pelas datas das imagens, é possível selecionar aquelas cujas datas são anteriores à emissão do relatório correspondente e as após, dado que, geralmente, antes da emissão há uma remoção de borracha. Portanto, esses subconjuntos podem ter maior ou menor poder de representação das propriedades contidas no relatório. Esses subconjuntos também são formados após a pré-seleção dos melhores exemplos baseada na análise de correlação (Figura 34). Entender qual a possível melhor abordagem dentre essas duas ajuda em futuras modelagens. O trabalho assume ainda que, apesar da margem de erro nos dias exatos de capturas das imagens, elas mantêm suas propriedades de captura se anterior ou após à emissão do respectivo relatório associado.

Figura 34 – Diagrama de separação de conjuntos baseados nas diferenças de datas no presente trabalho.



Fonte: Elaborado pelo autor (2024).

Após isso, a seleção de índices baseada no gráfico dos Coeficientes de Correlação de Pearson são feitas subdividindo os conjuntos a depender desses resultados. Pela finalidade de classificar o nível de segurança da PPD, o presente trabalho considera duas classes possíveis: Adequado e Moderado. Para obtê-las, busca-se encontrar um limiar no qual acima dele, os segmentos seriam rotulados como "Adequado" quanto ao valor do coeficiente de atrito associ-



ado; abaixo, o rótulo será "Moderado". O limiar que pudesse oferecer as mais proporcionais quantidades de exemplos de ambas as classes para determinado conjunto formado seria o escolhido. Assim, representando uma tentativa de prevenir problemas de treinamento devido a um desbalanceamento entre as classes (BUDA *et al.*, 2018).

A Tabela 6 apresenta as correlações de Pearson por fatia ao processar as imagens em K=3. Dos 15 índices, que representam os pares da Tabela 5, os que apresentam diferença negativa são: 2, 3, 6, 7, 9, 10, 11, 12, 13 e 15, totalizando 10 exemplos. O restante, de diferença positiva, são: 1, 4, 5, 8 e 14, totalizando 5 exemplos.

Tabela 6 – Correlações de Pearson por fatia gerada ao clusterizar imagens por K=3.

Fatia	01	02	03	04	05	06	07	08
0	0.28	0.58	-0.16	0.41	0.25	-0.04	-0.11	-0.02
1	-0.32	-0.56	0.58	-0.2	-0.16	0.53	0.48	-0.26
2	0.03	0.01	-0.48	-0.35	-0.12	-0.66	-0.45	0.43
Fatia	09	10	11	12	13	14	15	-
0	0.7	0.1	-0.25	0.37	0.65	0	-0.08	-
1	-0.45	0.1	0.37	-0.49	-0.74	0.33	0.19	-
2	-0.49	-0.34	-0.38	0.14	0.31	-0.51	-0.2	-

Fonte: Elaborado pelo autor (2024)

Observando as correlações, somente os índices 2, 12 e 13 do conjunto de diferença negativa entre as datas as imagens e respectivos relatórios apresentam o padrão de que as primeiras fatias e as últimas são de correlação diretamente proporcional. Quanto às intermediárias, são todas de correlação inversamente proporcional. Esses índices podem formar um conjunto para análise.

Por sua vez, os índices 3, 6, 7, 11 e 15 são aqueles que apresentam, nas mesmas fatias, correlação inversamente proporcional - nas fatias intermediárias, a correlação é diretamente proporcional. Logo, um segundo conjunto pode ser formado. Quanto aos de diferença positiva, dos 5 índices 1, 4, 5, 8 e 14, somente os índices 1 e 8 apresentam o padrão no qual as fatias iniciais e finais possuem correlação direta, mas o índice 8 apresenta para a fatia 0 correlação inversamente proporcional; índices 4, 5 e 14 apresentam correlação inversamente proporcional na fatias iniciais e finais, exceto que o índice 14 apresenta, para a fatia 0, correlação nula. Para a representação dos conjuntos de diferença positiva, além de todos os exemplos, resta também considerar um conjunto formado pelos mosaicos de índices 1, 4 e 5 excluindo os índices problemáticos 8 e 14 com base na correlação de Pearson.

Os seguintes conjuntos são os 6 trabalhados no presente estudo. Cada conjunto é

formado pelos recortes a cada 100m da imagem da PPD e seu respectivo rótulo com base no coeficiente de atrito associado:

1. conjunto de todas as imagens (conjunto TD - *todas*);
2. conjunto composto por todas as imagens cuja captura foi realizada antes da emissão do relatório, ou seja, de diferença negativa de dias no par Imagem x Relatório sem análise de correlação (conjunto 03);
3. conjunto composto por todas as imagens cuja captura foi realizada antes da emissão do relatório, ou seja, de diferença negativa de dias no par Imagem x Relatório cuja análise de correlação revelou que as fatias iniciais e finais possuem correlação diretamente proporcional (conjunto 01);
4. conjunto composto por todas as imagens cuja captura foi realizada antes da emissão do relatório, ou seja, de diferença negativa de dias no par Imagem x Relatório cuja análise de correlação revelou que as fatias iniciais e finais possuem correlação inversamente proporcional (conjunto 02);
5. conjunto composto por todas as imagens cuja captura foi realizada depois da emissão do relatório, ou seja, de diferença positiva de dias no par Imagem x Relatório sem análise de correlação (conjunto 04);
6. conjunto composto por todas as imagens cuja captura foi realizada depois da emissão do relatório, ou seja, de diferença positiva de dias no par Imagem x Relatório com análise de correlação desconsiderando os índices 8 e 14 (conjunto 05).

A Tabela 7 apresenta as quantidades de peças de mosaicos e de imagens resultantes após os recortes de 100m, bem como ao fazer as separações em conjuntos de treino, teste e validação. Além disso, os limiares e as quantidades de exemplos para cada classe. Além disso, ela também atribui índices aos conjuntos para melhor referenciá-los posteriormente. Os histogramas dos conjuntos adotados estão no Apêndice B. A subdivisão do conjunto das imagens de diferença positiva baseada na correlação de Person analisando padrões nas fatias não foi adotada pelo presente trabalho devido ao baixo número de exemplos resultante em cada.

Tabela 7 – Conjuntos formados e quantidades de elementos.

Conjunto	QTD de imagens	Índices das imagens	Recortes	Limiar	Moderados	Bons	Treino (60%)	Teste (20%)	Validação (20%)
01	3	2, 12 e 13	60	0.70	25	35	36	12	12
02	5	3, 6, 7, 11 e 15	100	0.75	49	51	60	20	20
03	10	2, 3, 6, 7, 9 ao 13, 15	200	0.70	107	93	120	40	40
04	5	1, 4, 5, 8 e 14	100	0.66	50	50	60	20	20
05	5	1, 4, 5	60	0.66	30	30	36	12	12
TD	15	1 ao 15	300	0.70	150	150	180	60	60

Fonte: Elaborado pelo autor (2024)

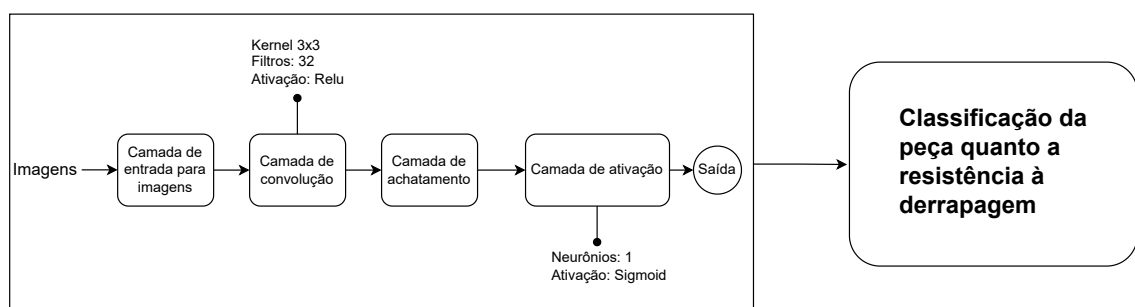
### 4.3 Modelagem

A presente seção apresenta os detalhes da implementação do modelo utilizado neste trabalho. Além disso, apresenta a organização dos dados dos experimentos realizados como, também, do ambiente de implementação.

#### 4.3.1 Arquitetura de rede

A modelagem ocorreu por meio de uma Rede Neural Convolutacional (RNC) cuja arquitetura é representada pela Figura 35. A camada de entrada recebe as imagens e em seguida conecta-se com a camada de convolução. Essa camada é implementada com um kernel de 3x3, 32 filtros e função *ReLU* como hipótese inicial para a arquitetura. A razão para a escolha do número de filtros ocorreu pela evidência em diversos trabalhos de que ao menos 32 filtros são suficientes para uma performance adequada (AHMED; KARIM, 2020; CHAKRABORTY; THARINI, 2020; SINGH *et al.*, 2020; MUJTABA *et al.*, 2021; GARCIA *et al.*, 2022; NASERI; MEHRDAD, 2023).

Figura 35 – Diagrama da arquitetura da Rede Neural Convolutacional adotada pelo presente trabalho.



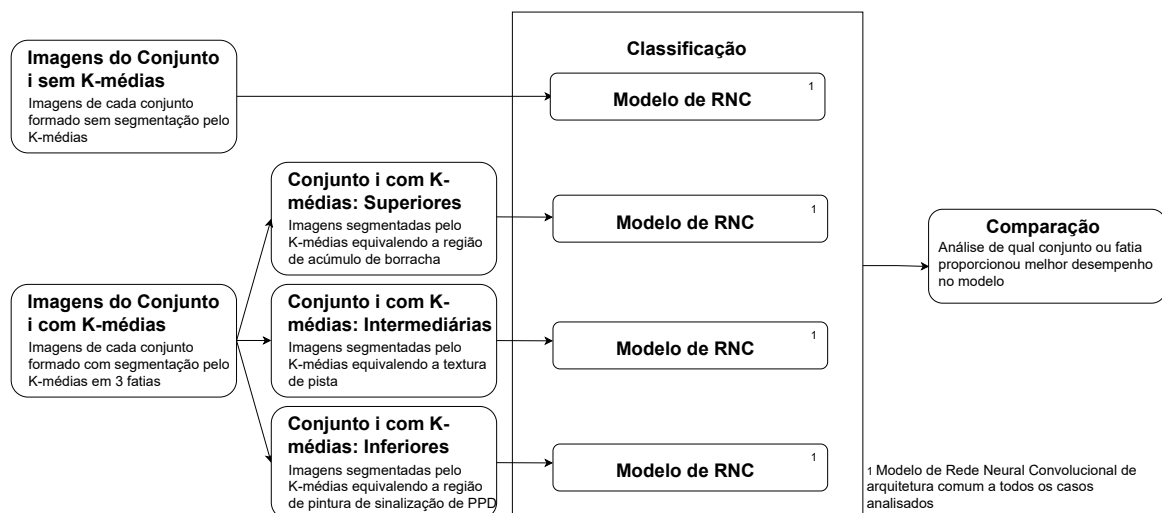
Fonte: Elaborado pelo autor (2024).

Os dados são submetidos à camada de achatamento e, por fim, camada de ativação com função de ativação Sigmoide contendo apenas um neurônio. Isso ocorre pelo problema ser de classificação e por se tratarem de apenas duas classes. Logo, um neurônio pode ser considerado suficiente. A função de perda (*loss function*) é a de Entropia Cruzada (*Binary Cross-Entropy*) devido à escolha da função de ativação (TENSORFLOW, 2024). Isso ocorre pela saída da função Sigmoide ser uma distribuição de probabilidade e essa função de perda medir a diferença entre duas distribuições de probabilidade (GOODFELLOW *et al.*, 2016). O otimizador é o *Adam* por ser considerado uma adequada escolha inicial para esse tipo de hiperparâmetro (KINGMA; BA, 2014).

#### 4.3.2 Organização dos dados para entrada na rede

Conforme a Figura 36, os conjuntos separados na etapa de Subdivisão dos conjuntos de dados foram reunidos seguindo duas vertentes: com o K-médias e sem o K-médias para a entrada da rede. Os dados sem o K-médias significam que as imagens da PPD sem qualquer processamento adicional, a não ser aplicação do filtro de escala de cinza e ajuste por histograma local foram inseridas na rede. O conjunto com o K-médias significa que as 3 segmentações geradas por cada imagem pelo algoritmo de K-médias (fatia superior - área de acúmulo de borraça; intermediária - textura de pista; e inferior - pintura de sinalização) foram, separadamente, inseridas na rede. Todos os conjuntos formados foram usados, mas a diferença está no uso de imagens, para cada conjunto, sem ou com K-médias e, nesse caso, qual fatia.

Figura 36 – Diagrama da organização dos treinos por conjuntos e com ou sem uso do K-médias nas imagens de entrada no presente trabalho.



Fonte: Elaborado pelo autor (2024).

A separação final dos dados para a modelagem se deu pelas proporções de: 60% para conjunto de treino, 20% para teste e 20% para validação. Esses números foram optados devida à baixa quantidade de dados no conjunto e pelo risco de numa eventual separação desses subconjuntos para treino, teste e validação, uma das classes em alguma iteração acabar sem nenhum exemplo em algum desses conjuntos.

#### ***4.3.3 Ambiente de implementação***

Os processamentos e a modelagem são desenvolvidas em um ambiente *Windows 10*, em linguagem *Python* com uso de ferramentas e bibliotecas: *Conda* (criação de ambientes virtuais para o projeto), *OpenCV* (manipulação de imagens), *Numpy* (álgebra linear), *Matplotlib.pyplot* (geração de gráficos), *Pandas* (manipulação de bases de dados em *.csv* ou *.xlsx*), *SkLearn* (métricas de avaliação) e *TensorFlow* (modelagem da rede neural). *Hardware* de processador *Intel i5 9gen* e placa dedicada *NVIDIA GTX 1650*.

## 5 RESULTADOS E DISCUSSÃO

O presente capítulo apresenta os resultados dos experimentos de modelagem dos conjuntos de dados formados e discute comparativamente os dados obtidos. Os gráficos de treino e validação são apresentados com as métricas de teste e a matriz de confusão correspondente. A apresentação dos dados e discussão comparativa realizam-se em seções separadas em função da discussão detalhar considerando todos os dados em concomitância.

### 5.1 Apresentação dos dados das modelagens

A presente seção apresenta os dados obtidos pela modelagem por cada um dos 6 conjuntos formados. Os dados são reunidos em duas subseções para fins de apresentação: com e sem o K-médias nas imagens de entrada na Rede Neural Convolucional RNC. Ressalta-se que os conjuntos que levam em consideração a análise de Correlação de Pearson implicam na utilização do algoritmo de K-médias para fins da análise; o não uso como entrada da rede não impacta na metodologia da análise de correlação. Ademais, os experimentos com uso de K-médias implicam em mais 3 agrupamentos de resultados para fins de apresentação: as imagens segmentadas pelo K-médias correspondendo às de acúmulo de borracha (fatias superiores); as imagens segmentadas pelo K-médias correspondendo às de superfície de pista (fatias intermediárias); as imagens segmentadas pelo K-médias correspondendo às de pintura de sinalização de pista (fatias inferiores).

#### 5.1.1 Sem K-médias

A Figura 37 apresenta os dados de treino, validação e métricas de teste, bem como as matrizes de confusão para os conjuntos formados, considerando imagens da PPD sem K-médias ao submetê-las à rede neural.

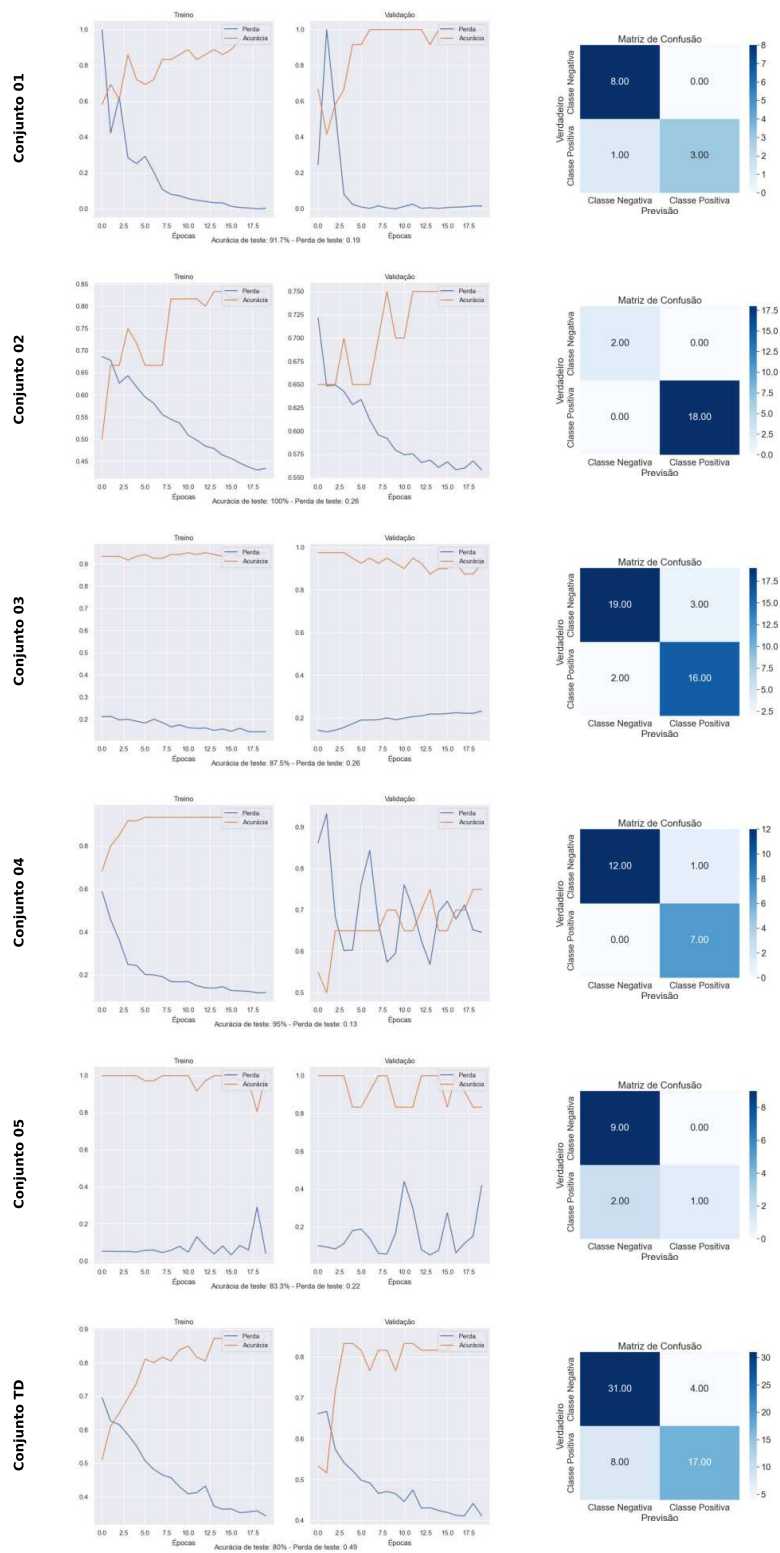
Em relação ao desempenho de treino e validação, o Conjunto TD e o Conjunto 01 foram os de melhor desempenho. Considerando as matrizes de confusão, ambos foram satisfatórios também, mas o Conjunto 01 possuiu proporcionalmente menos erros em relação aos acertos. Os dados dele de teste também foram melhores em relação aos do Conjunto TD, observando os 91,7% de acurácia e 0.19 de perda frente aos 80% e 0,49, respectivamente. Os dados do Conjunto 02 indicam um sobreajuste (*overfitting*) devido aos 100% de acerto no teste e na matriz de confusão, considerando ainda a baixa quantidade de exemplos.

No caso das amostras sem o K-médias, o Conjunto 03 inicialmente apresentou adequados resultados, mas à medida que as épocas progrediam na validação, a acurácia começou a decair, enquanto a perda aumentava. Esse comportamento sugere que o modelo começou a "esquecer" os padrões aprendidos. Por outro lado, no Conjunto 04, houve uma oscilação entre a perda e a acurácia, no qual em certos momentos a perda era maior que a acurácia e, posteriormente, essa relação se invertia. Essa flutuação sugere que o modelo estava tentando se ajustar, mas não conseguia estabilizar seu aprendizado nos dados sem o K-médias.

Os dados do Conjunto 05 revelam que o modelo não foi capaz de aprender os padrões. Isso é evidenciado pela perda e a acurácia manterem-se estáveis até a décima época de treino. Após isso, passam a oscilar. Por sua vez, na validação, essa oscilação é presente a partir da segunda época. Na matriz de confusão, há mais erros proporcionais que acertos para a classe positiva.

Figura 37 – Gráficos de treinamento, validação, teste e matrizes de confusão considerando as imagens da PPD utilizada no presente trabalho por conjunto formado sem K-médias.

Imagens sem Framework



Fonte: Elaborado pelo autor (2024)



### 5.1.2 Com K-médias

A Figura 38 apresenta os dados de treino, validação e métricas de teste, bem como as matrizes de confusão para os conjuntos formados, considerando imagens da PPD com K-médias ao submetê-las à rede neural. As fatias consideradas são as superiores, correspondendo à área de acúmulo de borracha.

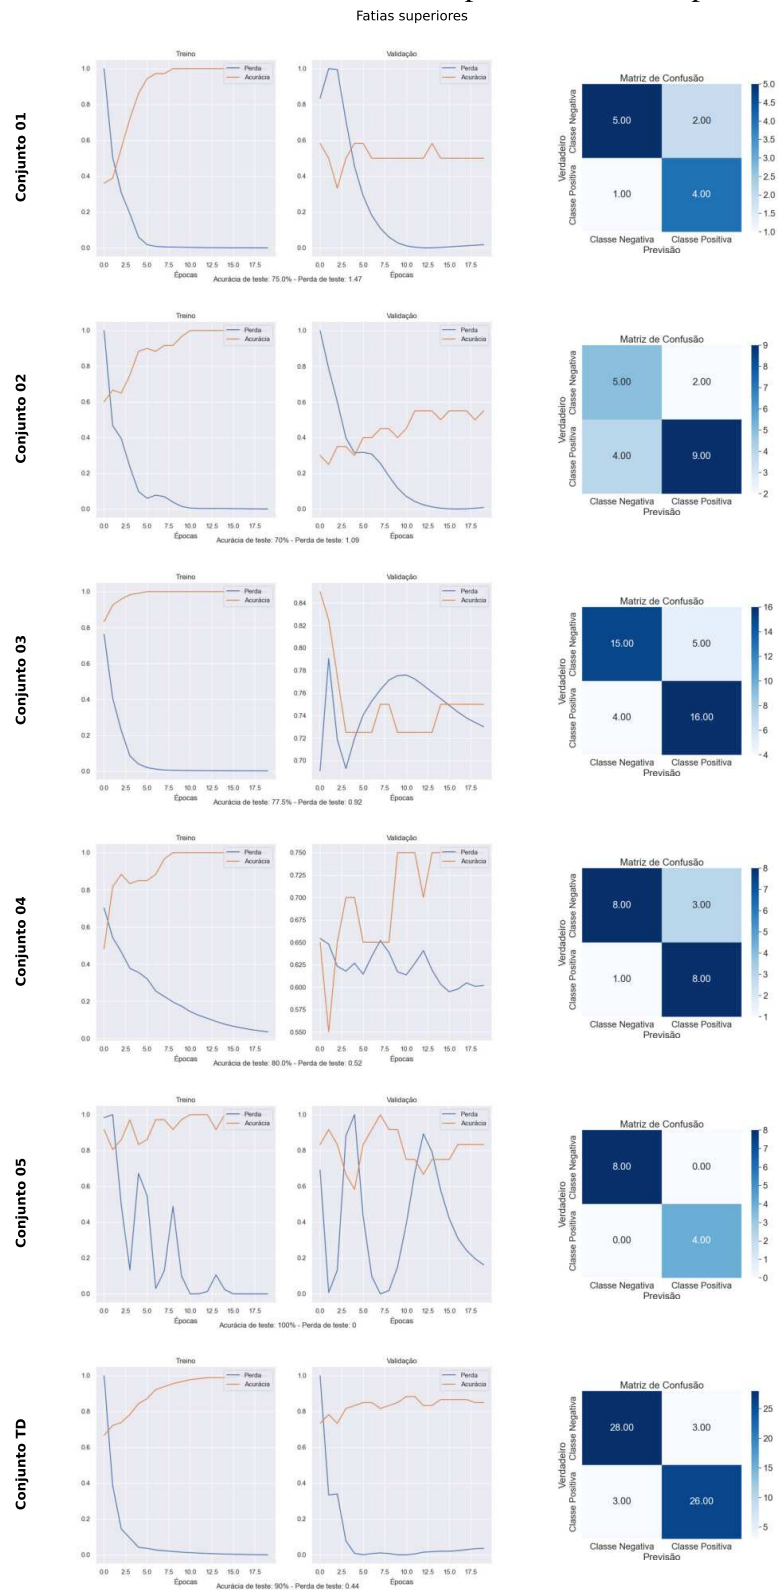
Para os dados do Conjunto 01, a validação apresentou acurácia menor que a apresentada no treino e um crescimento da perda. A matriz da confusão apresenta elevados erros proporcionais em relação aos acertos em comparação a esse mesmo conjunto no caso anterior. O Conjunto 02 apresentou uma péssima matriz de confusão onde os erros chegavam a quase metade dos acertos. A acurácia de validação foi menor que a de treinamento.

Para o Conjunto 03, a acurácia de validação foi ainda menor em relação à de treinamento. Nota-se ainda que a perda possui significativa queda que não se refletiu na acurácia. Considerando os conjuntos 01, 02 e 03, as métricas de acurácia e perda para teste foram inferiores em relação aos respectivos conjuntos no caso anterior. Em torno de 70% para acurácia e perda ultrapassando 1.0 em alguns casos.

O comportamento das amostras superiores do Conjunto 03 não foi satisfatório. Houve uma oscilação tanto na acurácia quanto na perda, sugerindo instabilidade no processo de validação, apesar do treino ser satisfatório. Além disso, a matriz de confusão indicou um número considerável de exemplos errôneos na soma de ambas as classes, revelando a ineficácia do modelo em capturar padrões consistentes nos dados superiores desse conjunto. Isso pode estar relacionado a uma variabilidade nos dados, tornando difícil a tarefa de classificação. Para o Conjunto 04, apesar de certa oscilação na validação, a acurácia seguiu uma tendência de aumento e a perda de queda. Contudo, a matriz de confusão apresentou erros proporcionalmente altos. Comparadas as métricas de teste com as da modelagem sem o K-médias, há uma queda de performance.

O Conjunto 05 indica um claro *overfitting* pelos 100% de acurácia de teste, zero de perda e 100% de acertos na matriz de confusão. O Conjunto TD foi de melhor desempenho, apesar da acurácia de validação ser menor em relação à de treino: acurácia de teste em 80%, perda de teste de 0.44 e matriz de confusão com erros não chegando a quase metade dos acertos, como observado anteriormente.

Figura 38 – Gráficos de treinamento, validação, teste e matrizes de confusão com K-médias considerando as fatias iniciais da PPD utilizada no presente trabalho por conjunto formado.



Fonte: Elaborado pelo autor (2024)

A Figura 39 apresenta os dados de treino, validação e métricas de teste, bem como as matrizes de confusão para os conjuntos formados considerando imagens da PPD com K-médias

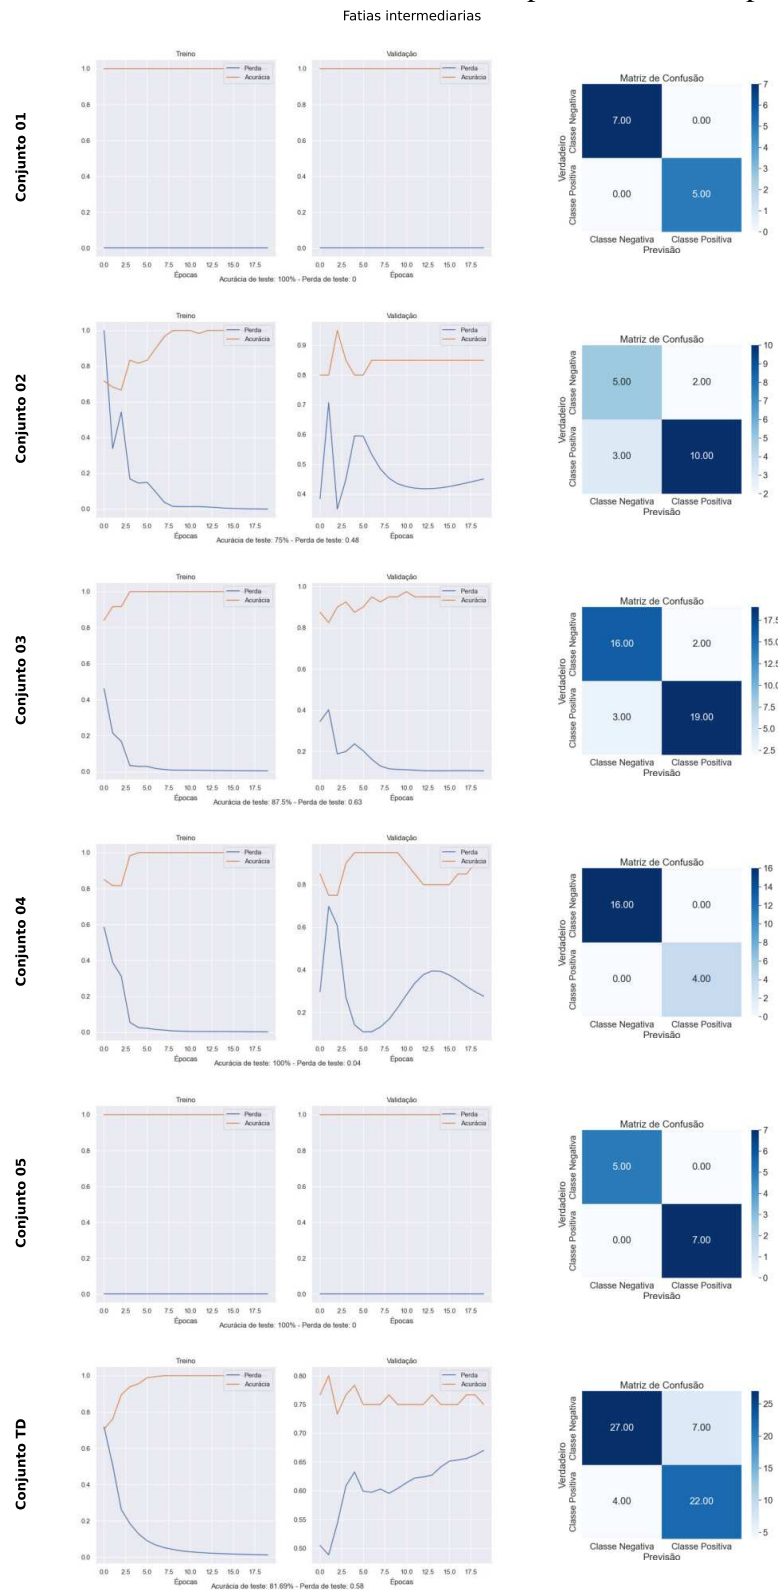
ao submetê-las à rede neural. As fatias consideradas são as intermediárias, correspondendo à superfície da PPD desconsiderando pintura ou área de acúmulo de borracha.

O Conjunto 01 apresentou um claro *overfitting* pelo 100% de acurácia no treino, validação, teste e matriz de confusão. Além disso, por zero perda em treino, validação e teste. O Conjunto 05 apresentou o mesmo fenômeno. O Conjunto 02 apresentou uma acurácia de validação menor que a de treino, mas a perda apresentava crescimento ao final das épocas. Os erros para a Classe Negativa foram, proporcionalmente, elevados em relação aos acertos por serem quase metade.

Apesar do Conjunto TD apresentar uma matriz de confusão com valores adequados de erros e acertos e também de dados de teste, a validação não foi satisfatória. A perda seguia aumentando e a acurácia seguia decaindo conforme as épocas aumentavam.

As amostras das fatias intermediárias do Conjunto 03 obtiveram um desempenho adequado, com resultados consistentes entre treino e validação. Isso sugere que o modelo conseguiu aprender padrões úteis desses dados e generalizar de maneira eficiente. Em contraste, no Conjunto 04, observou-se um *overfitting*, no qual o modelo conseguiu memorizar adequadamente os dados durante o treino, mas teve dificuldades em manter esse desempenho em dados de validação. O *overfitting* é uma indicação de que o modelo ajustou-se demais às peculiaridades do conjunto de treino, em detrimento da generalização ao validar. A acurácia de teste foi de 100% e a perda muito baixa, sustentando essa observação.

Figura 39 – Gráficos de treinamento, validação, teste e matrizes de confusão com K-médias considerando as fatias intermediárias da PPD utilizada no presente trabalho por conjunto formado.



Fonte: Elaborado pelo autor (2024)

A Figura 40 apresenta os dados de treino, validação e métricas de teste bem como as matrizes de confusão para os conjuntos formados considerando imagens da PPD com K-médias

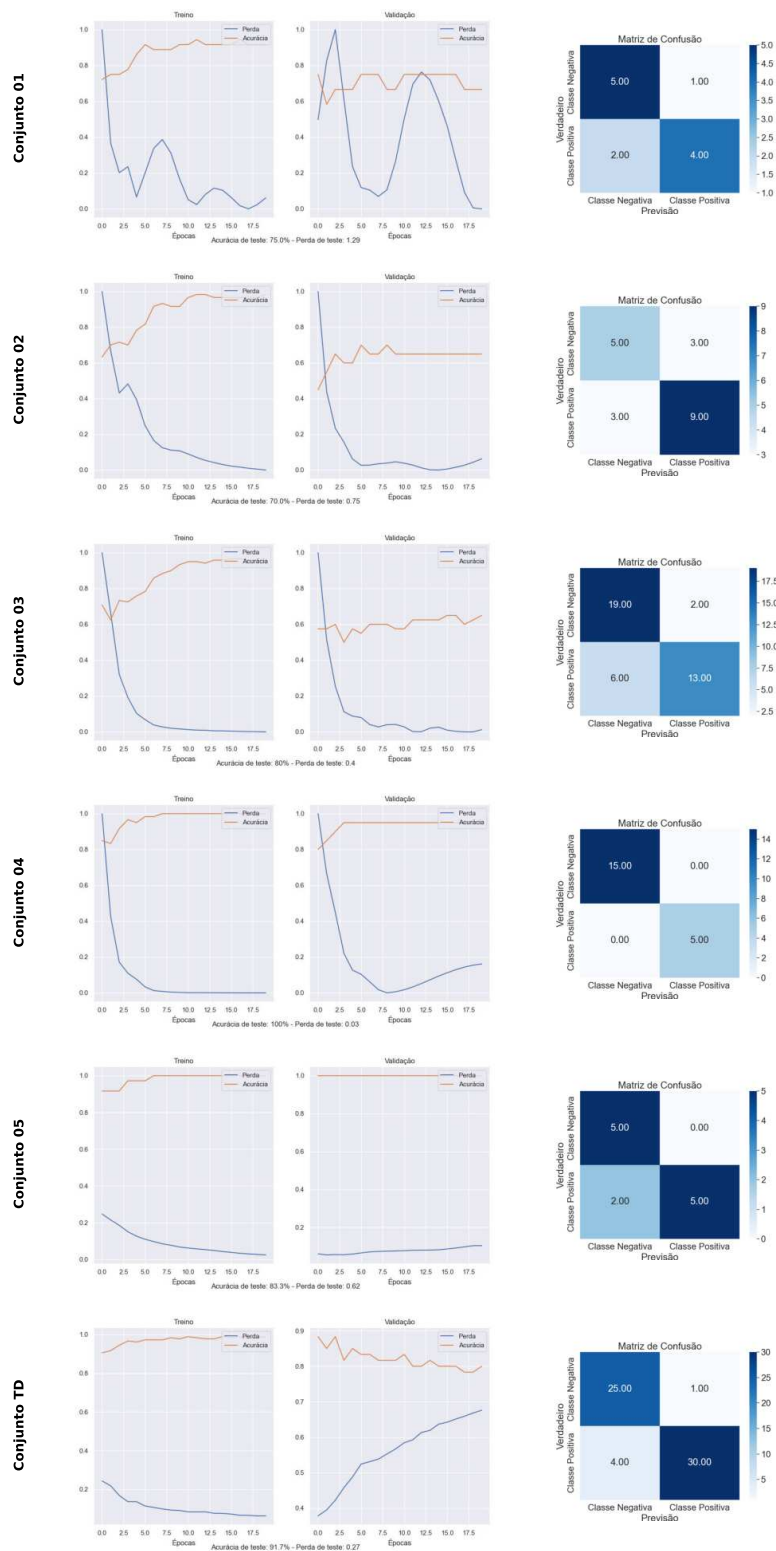
ao submetê-las à rede neural. As fatias consideradas são as inferiores, correspondendo à pintura de sinalização.

O Conjunto 01 apresentou dados insatisfatórios na matriz de confusão na qual a Classe Positiva possui quase metade de erros em relação a acertos. A acurácia de validação foi menor que a de treino, e a acurácia de teste foi de 75%. Esse valor é considerado baixo visto que outros casos os conjuntos apresentaram dados acima de 80%. O Conjunto 02 também apresentou acurácia de validação menor que a de treino. A acurácia de teste foi de 70%, um valor também considerado baixo como no Conjunto 01. A perda de teste em ambos é elevada sendo acima de 1 para o Conjunto 01 e 0.7 para o Conjunto 02 em relação a outros casos nos quais os conjuntos apresentaram, geralmente, perda abaixo de 0.5.

No Conjunto 03, as amostras das fatias inferiores apresentaram uma acurácia de validação mais baixa, sugerindo uma dificuldade do modelo em generalizar esses dados. A baixa acurácia pode indicar que o modelo encontrou padrões inconsistentes ou pouco informativos, prejudicando sua capacidade de fazer previsões corretas. Por sua vez, no Conjunto 04, houve uma tendência de aumento da perda ao longo do tempo, o que indica uma piora progressiva na capacidade de aprendizado do modelo sobre esses dados. Esse aumento da perda pode ser atribuído à dificuldade do modelo em capturar os padrões presentes nas amostras das fatias inferiores do Conjunto 04.

O Conjunto 05 apresentou alta acurácia de validação como a de treino. Porém, a perda de validação foi elevando-se ao final das épocas. A matriz de confusão é satisfatória pelos erros não serem quase metade dos acertos. A acurácia de teste foi acima de 80%, mas a perda foi de 0.62. O Conjunto TD foi o de pior desempenho de validação no qual a perda foi aumentando ao passo que a acurácia foi decaindo. Contudo, obteve 91,7% de acurácia de teste e 0.27 de perda. A matriz de confusão apresentou poucos erros, proporcionalmente, em relação aos acertos.

Figura 40 – Gráficos de treinamento, validação, teste e matrizes de confusão com K-médias considerando as fatias inferiores da PPD utilizada no presente trabalho por conjunto formado



Fonte: Elaborado pelo autor (2024)

### 5.1.3 Discussão comparativa dos dados obtidos com a modelagem

A análise do Conjunto 01 revela um desempenho insatisfatório em termos gerais, possivelmente devido ao número reduzido de exemplos, o que pode ter limitado a capacidade do modelo de aprender padrões robustos. Tanto para as fatias superiores quanto às inferiores apresentaram quedas na acurácia de validação, associadas a matrizes de confusão com um alto número de erros, indicando dificuldade na classificação correta desses exemplos. As fatias intermediárias mostraram sinais de *overfitting*, com o modelo ajustando-se bem aos dados de treino, mas falhando em generalizar para os dados de validação. Curiosamente, o conjunto sem o K-médias destacou-se como uma exceção, com um desempenho adequado em comparação aos demais, sugerindo que os dados sem o K-médias talvez tenham padrões mais consistentes ou mais simples de serem aprendidos.

A análise do Conjunto 05 revelou um desempenho insatisfatório em todas as subdivisões. Nas fatias intermediárias e inferiores, observou-se um *overfitting*, com o modelo se ajustando bem aos dados de treino, mas falhando em generalizar para validação e teste. As fatias superiores foram marcadas por uma oscilação significativa, mostrando que o modelo teve dificuldade em capturar padrões consistentes nesses exemplos. No conjunto sem o K-médias, embora também tenha havido dificuldades no aprendizado, o problema foi agravado pelo aumento da perda e queda de acurácia ao longo do tempo, além de uma matriz de confusão insatisfatória, embora não tão problemática quanto a das fatias superiores.

A performance do Conjunto 02 foi insatisfatória em todos os cenários analisados. Embora a acurácia tenha mostrado uma tendência de crescimento e a perda uma queda ao longo do tempo, as matrizes de confusão revelaram erros proporcionalmente altos de quase metade dos acertos, especialmente quando proporcionalizados ao número de exemplos por classe. Com o K-médias, observou-se uma queda na acurácia de validação, o que comprometeu ainda mais a capacidade do modelo de generalizar. Embora as acurácias de teste tenham sido, no geral, adequadas, outros conjuntos tiveram desempenhos superiores e as perdas se mantiveram relativamente altas. Sem o uso do *framework*, a acurácia chegou a 100%, um forte indicativo de *overfitting*, sugerindo que o modelo ajustou-se excessivamente aos dados de treino, perdendo a capacidade de generalizar.

O Conjunto TD destacou-se como o melhor desempenho entre os analisados. O conjunto sem o K-médias apresentou resultados satisfatórios, embora a matriz de confusão não tenha sido ideal, sugerindo que, apesar de uma boa performance geral, o modelo ainda cometeu

erros consideráveis em algumas classificações. Para os dados de fatias superiores, ou seja, fatia da área de acúmulo de borracha da pista, o desempenho foi consistente, com uma matriz de confusão equilibrada. Embora tenha ocorrido uma queda na acurácia de validação, as métricas de acurácia e perda no teste foram as melhores, indicando uma satisfatória generalização do modelo nesse conjunto. Por sua vez, para as fatias intermediárias, o desempenho foi insatisfatório, com uma matriz de confusão ruim e um aumento na perda de validação, apesar da acurácia não ter caído de forma significativa. Quanto às fatias inferiores, o desempenho também foi ruim, com aumento de perda e queda na acurácia de validação, embora a matriz de confusão tenha apresentado menos erros nas classes em relação às intermediárias, sugerindo que o modelo teve mais dificuldade em aprender com esses dados.

#### **5.1.4 Considerações finais**

Tendo em vista os resultados apresentados e discutidos anteriormente, foi demonstrada a viabilidade do desenvolvimento de um modelo de classificação de segmentos da PPD estudada quanto à segurança operacional com base no acúmulo de borracha e seu impacto no coeficiente de atrito. Dos conjuntos formados, foi observada a viabilidade já por meio dos conjuntos compostos por todas as imagens - com ou sem K-médias nos dados de entrada. Isto é, não há evidências de que subdivisões em conjuntos baseados na data de captura da imagem com relação à emissão do relatório poderiam impactar, nem mesmo de que a correlação de Pearson contribuiria para a melhoria da performance de aprendizagem e classificação do modelo.

Dentre os dois conjuntos mais bem-sucedidos, o conjunto em que se aplicou o algoritmo de K-médias para segmentar a região de acúmulo de borracha (fatias superiores) apresentou melhor desempenho de teste. Assim, dada a necessidade de um modelo que fosse o mais confiável em virtude da segurança operacional de uma PPD ser de suma importância, elenca-se esse conjunto como o mais adequado. Dessa forma, indica-se o uso segmentando as imagens por K-médias com  $K=3$  e usando as fatias superiores, ou seja, que correspondem à região de acúmulo de borracha para que sejam classificadas nos segmentos equivalentes a 100m de pista partindo da cabeceira principal (excluindo os 100m iniciais referentes à cabeceira em si).



## 6 CONCLUSÕES

O presente trabalho permitiu a investigação da correlação entre dados técnicos de uma pista de pouso e decolagens (PPD) brasileira e imagens segmentadas pelo algoritmo de K-médias. Além disso, permitiu também a modelagem de uma Rede Neural Convolucional (RNC) para a classificação da PPD quanto à segurança operacional, referente à resistência à derrapagem, baseada no acúmulo de borracha e no coeficiente de atrito. Objetivando, portanto, o estudo e a proposição de uma metodologia para o suporte às tomadas de decisão por operadores de aeródromos de forma mais rápida e menos custosa em execução, recursos financeiros e humanos. Para isso, utilizaram-se dados técnicos de relatórios oficiais disponibilizados pela Agência Nacional de Aviação Civil (ANAC) e imagens obtidas via *Google Earth Pro* de um aeródromo brasileiro.

As imagens via *Google Earth Pro* são uma fonte ampla de dados de PPD quanto ao aspecto visual que permite a avaliação do acúmulo de borracha. O acesso é constante, sem custos financeiros de obtenção e sem necessidade de interrupção das atividades na PPD. O recurso humano pelo trabalho manual pode ser semi-automatizado por meio de um algoritmo de automação da captura da imagem na tela e salvamento. O presente trabalho viabilizou essa tarefa implementando um algoritmo por meio do *software AutoIt*.

Os dados de coeficiente de atrito, provenientes de relatórios oficiais de medição dessa variável, foram obtidos pelo trabalho de Maia (2023). Isso significa que nenhuma medição adicional dessa variável na PPD alvo do presente trabalho foi necessária para obtenção desses dados, uma vez que essas informações já foram coletadas. Assim, o presente trabalho evitou metodologias que necessitassem de novas atividades na PPD alvo.

O algoritmo de K-médias permitiu a segmentação das imagens em escala de cinza. Assim, permitindo quantificar a região correspondente à área de acúmulo de borracha na PPD. O K-médias é um método de aprendizado não supervisionado que agrupa *pixels* com base em suas intensidades, dividindo-os em 3 *clusters*. Essa quantidade de *clusters* foi suficiente para segmentar a área de acúmulo de borracha separando-a das demais (pintura de sinalização e superfície restante).

A RNC implementada no presente trabalho permitiu a análise da correlação entre os dados dos relatórios e os provenientes das imagens em diferentes composições de conjuntos. Por meio dos resultados dos experimentos submetidos à RNC, foi identificada que há uma correlação e qual a melhor composição de conjunto de dados para a metodologia apresentada.

Com base no presente estudo, é evidente que a eficácia da modelagem de uma RNC varia entre os diferentes conjuntos de dados (Imagens 2D), apontando que as limitações não estão intrinsecamente ligadas à arquitetura da RNC, mas, sim, à composição e ao tamanho dos conjuntos de dados utilizados. A viabilidade de desenvolver uma ferramenta de classificação eficaz para a segurança operacional referente à resistência à derrapagem, especialmente no que diz respeito ao acúmulo de borracha baseado no coeficiente de atrito, é confirmada pela performance positiva observada em alguns conjuntos.

## 6.1 Principais contribuições

Em um dos conjuntos formados para análise (todas as imagens considerando fatias superiores - área de acúmulo de borracha) o uso do algoritmo de K-médias processando imagens de entrada da RNC demonstrou um impacto na melhoria do desempenho do modelo, especialmente em relação aos dados de teste, provando ser uma adição valiosa ao processo de modelagem. Embora o desenvolvimento de um modelo sem o uso de K-médias processando as imagens de entrada também seja viável, a performance inferior nos testes destaca a importância do algoritmo nos dados de entrada da rede, especialmente considerando que a segurança operacional em pistas de pouso e decolagem é importante. Essas diferenças de desempenho podem ter implicações para os operadores de aeródromos, reforçando a confiança no uso da modelagem com emprego do K-médias. Ressalta-se o uso do algoritmo de K-médias, com  $K=3$ , processando as imagens de entrada da RNC segmentando a área de acúmulo de borracha, utilizando-a então como imagem resultante de entrada.

Além disso, o presente trabalho ilustra a eficiência do algoritmo de K-médias para segmentar imagens a partir de capturas aéreas, aproveitando as tonalidades dos *pixels*. Contudo, o método apresentou limitações em evitar problemas de *overfitting*, aos quais se apresentaram com indicativos de serem causados pelo número reduzido de dados nos conjuntos formados. Isso sugere que melhorias em modelagens dependem ainda de um volume adequado de exemplos. O algoritmo de K-médias também mostrou potencial para identificar e segmentar informações que impactam negativamente o treinamento. Isso foi evidenciado pelo comportamento anômalo em conjuntos sem o K-médias e que se repetiu em apenas uma fatia resultante, mas não nas demais. Isso sugere que a ausência de informações problemáticas pode levar a um desempenho mais eficaz e essa ausência é viável de se implementar pelo método estudado.

O critério de separação baseado em limiares equilibrados foi um fator importante

na subdivisão dos conjuntos. Destaca-se que o presente estudo considerou essa separação e a rotulação dos dados, baseada no coeficiente de atrito, em duas classes categóricas, pautando-se na distribuição dos dados de forma proporcional. Ou seja, não considerou um limiar de separação baseado em um valor funcional pela limitação do número de dados. Contudo, o modelo de classificação foi capaz de reconhecer e distinguir as classes satisfatoriamente. Portanto, assume-se que, em vista disso e havendo dados suficientes, qualquer valor de limiar que rotule segmentos de pistas em duas ou mais classes quanto ao coeficiente de atrito é viável e funcional.

Assim, tomando em evidência os dados obtidos com os experimentos, recomenda-se o uso do conjunto TD com a implementação do K-médias (com  $K=3$ ) usando-se das fatias superiores, na qual a performance mostrou-se mais promissora. Essa análise reforça a necessidade de um pré-processamento que considere a segmentação das informações relevantes, contribuindo para a tarefa de modelagem de RNC e, conseqüentemente, para o monitoramento e tomadas de decisões referentes à resistência à derrapagem com base no coeficiente de atrito.

## **6.2 Principais limitações**

A correlação de Pearson aplicada à área segmentada em cada fragmento e seu respectivo coeficiente de atrito não trouxe os resultados esperados, possivelmente devido ao número baixo de exemplos após as subdivisões. Portanto, evidencia-se que a quantidade disponível de dados ao presente trabalho é uma limitação.

Além disso, há de se ressaltar que a separação de conjuntos em imagens antes e após a emissão dos relatórios baseou-se na hipótese de que, apesar da margem de erro, os pares poderiam manter essa propriedade de diferença de dias. Contudo, por se tratar de uma margem de erro, é possível que, em razão dela, em alguns dos dados utilizados, essa propriedade não tenha sido preservada. Isto é, um par com uma imagem de data após a emissão do relatório poderia ter, na verdade, a data real de alguns dias antes da emissão. Assim, sendo essa a possível razão pela qual não tenha expressado resultados aceitáveis. Dessa forma, essa característica apresenta-se como uma limitação que inviabiliza técnicas e processamentos que dependem de datas exatas.

### 6.3 Sugestões de trabalhos futuros

1. Explorar outros valores de K e em outras codificações de cores como RGB, CMYK, HSV, por exemplo;
2. Investigar como o impacto de um pré-processamento de ajuste das propriedades de contraste das imagens entre si pode afetar o desempenho dos modelos e nas correlações de Pearson;
3. Investigar possíveis diferenças nas pinturas de sinalização de pista entre aeródromos e seus impactos ao modelar uma rede neural que utiliza essas informações;
4. Implementar modelos com imagens clusterizadas sem necessariamente fatiar com base nos agrupamentos formados;
5. Implementar modelagens usando dados de vários aeródromos e avaliar casos de reuso do modelo em novos aeródromos;
6. Desenvolvimento de um método de análise de PPD por imagens de VANT;
7. Criação de um banco de dados de imagens com datas exatas e medições de coeficiente de atrito em mesma data;
8. Estudo da aplicação da presente metodologia em pavimentos rodoviários para identificação de defeitos.

## REFERÊNCIAS

- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **Manual de Sistema Gerenciamento de Pavimentos Aeroportuários - SGPA**. Brasília: ANAC, 2017. 55 p. Disponível em: <https://www.gov.br/anac/pt-br/centrais-de-conteudo/aeroportos-e-aerodromos/manuais-e-cartilhas/manual-para-sgpa-v3.pdf/view>. Acesso em: 18 jan. 2023.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **REGULAMENTOS BRASILEIROS DA AVIAÇÃO CIVIL - RBAC N° 153 EMENDA N° 04: AERÓDROMOS - OPERAÇÃO, MANUTENÇÃO E RESPOSTA À EMERGÊNCIA**. Brasília: ANAC, 2019.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **INSTRUÇÃO SUPLEMENTAR - IS N° 153.205-001 - Monitoramento da irregularidade longitudinal, atrito e macrotextura do pavimento da pista pouso e decolagem**. Brasília: ANAC, 2020.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **REGULAMENTOS BRASILEIROS DA AVIAÇÃO CIVIL - RBAC no 153 Emenda 6 Aeródromos - Operação, Manutenção e Resposta à emergência**. Brasília: ANAC, 2021.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **INSTRUÇÃO SUPLEMENTAR - IS N° 153.205-001 Revisão C**. ANAC, 2023. Disponível em: <https://www.anac.gov.br/assuntos/legislacao/legislacao-1/iac-e-is/is/is-153-205-001>. Acesso em: 28 jun. 2024.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **REGULAMENTOS BRASILEIROS DA AVIAÇÃO CIVIL - RBAC N° 154 PROJETO DE AERÓDROMOS**. Brasília: ANAC, 2024. Disponível em: [https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-154/@@display-file/arquivo\\_norma/RBAC154EMD06.pdf](https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-154/@@display-file/arquivo_norma/RBAC154EMD06.pdf). Acesso em: 12 ago. 2024.
- AHMED, W.; KARIM, A. The impact of filter size and number of filters on classification accuracy in cnn. **2020 International Conference on Computer Science and Software Engineering (CSASE)**, Duhok, Iraq, v. 3, n. 1, p. 88–93, 04 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:220668470>. Acesso em: 9 Abr. 2022.
- AILEPHANT. **Finding the dominant colors in an image with k-means**. 2020. Disponível em: <https://ailephant.com/dominant-colors-in-image-with-k-means/>. Acesso em: 11 Abr. 2023.
- AKAGIC, A.; BUZA, E.; OMANOVIC, S.; KARABEGOVIĆ, A. Pavement crack detection using otsu thresholding for image segmentation. **2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)**, p. 1092–1097, 2018.
- AQUINO, T.; OLIVEIRA, F. H.; MOTA, G. Caracterização do acúmulo de borracha por meio de processamento de imagens e por análise das operações de pousos e decolagens. **Air Transportation Symposium SITRAER**, Joinville, Santa Catarina, p. 635–644, 10 2022. Disponível em: [https://www.sitraer.ita.br/sitraer2022/Proceedings/Proceedings\\_Files/Proceedings\\_SITRAER2022.pdf](https://www.sitraer.ita.br/sitraer2022/Proceedings/Proceedings_Files/Proceedings_SITRAER2022.pdf). Acesso em: 28 jan. 2023.
- BAQERSAD, M.; HAMED, A.; MOHAMMADAFZALI, M.; ALI, H. A. Asphalt mixture segregation detection: Digital image processing approach. **Advances in Materials Science and Engineering**, v. 2017, p. 1–6, 2017. Disponível em: <https://api.semanticscholar.org/CorpusID:54021524>.

BUDA, M.; MAKI, A.; MAZUROWSKI, M. A. A systematic study of the class imbalance problem in convolutional neural networks. **Neural Networks**, Elsevier BV, v. 106, p. 249–259, out. 2018. ISSN 0893-6080. Disponível em: <http://dx.doi.org/10.1016/j.neunet.2018.07.011>.

CAMPOS, G. F. C.; MASTELINI, S. M.; AGUIAR, G. J.; MANTOVANI, R. G.; MELO, L. F. de; JR, S. B. Machine learning hyperparameter selection for contrast limited adaptive histogram equalization. **2019 EURASIP Journal on Image and Video Processing**, 2019.

CHAKRABORTY, P.; THARINI, C. Pneumonia and eye disease detection using convolutional neural networks. **Engineering, Technology and Applied Science Research**, v. 10, p. 5769–5774, 06 2020. Disponível em: <https://www.etasr.com/index.php/ETASR/article/view/3503>. Acesso em: 6 nov. 2022.

DEISENROTH, M. P.; FAISAL, A. A.; ONG, C. S. **Mathematics for Machine Learning**. 1. ed. Cambridge: Cambridge University Press, 2020.

ELUNAI, R.; CHANDRAN, V.; GALLAGHER, E. Asphalt concrete surfaces macrotexture determination from still images. **IEEE Transactions on Intelligent Transportation Systems**, v. 12, n. 3, p. 857–869, 2011.

FEDERAL AVIATION ADMINISTRATION. **FEDERAL AVIATION ADMINISTRATION: ABOUT**. 2022. Disponível em: <https://www.faa.gov/about>. Acesso em: 11 fev. 2022.

FWA, T. F.; ASCE; CHAN, W. T.; LIM, C. T. Decision framework for pavement friction management of airport runways. **Journal of Transportation Engineering**, American Society of Civil Engineers, v. 123, p. 429–435, 1997.

G1. **Aeroporto de Joinville recebe grooving para melhorar atrito na pista**. 2016. Disponível em: <https://g1.globo.com/sc/santa-catarina/noticia/2016/04/aeroporto-de-joinville-recebe-grooving-para-melhorar-atrito-na-pista.html>. Acesso em: 13 nov. 2023.

GARCIA, A. J.; AOUTO, A.; LEE, J.-M.; KIM, D.-S. Cnn-32dc: An improved radar-based drone recognition system based on convolutional neural network. **ICT Express**, v. 8, n. 4, p. 606–610, 2022. ISSN 2405-9595. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2405959522000686>.

GHADERI, O.; ABEDINI, M. Evaluation of the airport runway flexible pavement macro-texture using digital image processing technique (dipt). **International Journal of Pavement Engineering**, Taylor Francis, v. 23, n. 13, p. 4587–4599, 2022. Disponível em: <https://doi.org/10.1080/10298436.2021.1968393>. Acesso em: 22 nov. 2023.

GOGTAY, N.; THATTE, U. Principles of correlation analysis. **The Journal of the Association of Physicians of India**, v. 65, p. 78–81, 03 2017.

GONZÁLEZ, R. C.; WOODS, R. E. **Digital image processing**. 3. ed. New Jersey: Pearson Education, 2008.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>. Acesso em: 2 jun. 2022.

GOOGLE, F. do. **Data de Captura das Imagens**. 2022. Disponível em: <https://support.google.com/maps/thread/58907256/data-de-captura-das-imagens?hl=pt-BR>. Acesso em: 28 jun. 2023.

GRANSBERG, D. A. **Impact of Airport Rubber Removal Techniques on Runways**. Washington, DC: The National Academies Press, 2008. Disponível em: <https://nap.nationalacademies.org/catalog/2221/impact-of-airport-rubber-removal-techniques-on-runways>. Acesso em: 6 nov. 2023.

HANCOCK, J. T.; KHOSHGOFTAAR, T. M. Survey on categorical data for neural networks. **Journal of Big Data**, v. 7, n. 1, p. 28, Apr 2020. ISSN 2196-1115. Disponível em: <https://doi.org/10.1186/s40537-020-00305-w>.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, SMC-3, n. 6, p. 610–621, 1973.

HAYKIN, S. S. **Neural networks and learning machines**. 3rd. ed. [S. l.]: Pearson Education, 2009.

HUYAN, J.; LI, W.; TIGHE, S.; SUN, Z.; SUN, H. Quantitative analysis of macrotexture of asphalt concrete pavement surface based on 3d data. **Transportation Research Record**, v. 2674, n. 8, p. 732–744, 2020. Disponível em: <https://doi.org/10.1177/0361198120920269>. Acesso em: 23 jun. 2022.

INTERNATIONAL AIRPORT REVIEW. **Runway rubber removal is not about rubber removal**. 2015. Disponível em: <https://www.internationalairportreview.com/news/19926/runway-rubber-removal-is-not-about-rubber-removal/>. Acesso em: 4 nov. 2023.

JORDANIAN CIVIL AVIATION REGULATORY COMMISSION (Ed.). **Rubber Removal Techniques Technical Information Paper**: Dass information paper. Amã, Jordânia: CARC, 2010. Disponível em: <https://carc.gov.jo/sites/default/files/inline-files/091829rubber-removal-technique-information-paper.pdf>. Acesso em: 28 nov. 2022.

KINGMA, D.; BA, J. Adam: A method for stochastic optimization. **International Conference on Learning Representations**, 2014. Disponível em: <https://arxiv.org/abs/1412.6980>. Acesso em: 3 dez. 2022.

KIRANYAZ, S.; INCE, T.; ABDELJABER, O.; AVCI, O.; GABBOUJ, M. 1-d convolutional neural networks for signal processing applications. In: **ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. Brighton, UK: [S. n.], 2019. p. 8360–8364. Disponível em: <https://ieeexplore.ieee.org/document/8682194>. Acesso em: 19 ago. 2023.

LAFRUIT, G.; TERATANI, M. **Virtual Reality and Light Field Immersive Video Technologies for Real-World Applications**. [S. l.]: IET The Institution of Engineering and Technology, 2021. v. 1. ISBN 9781785615788.

LAI, P.; WESTLAND, S. Machine learning for colour palette extraction from fashion runway images. **International Journal of Fashion Design, Technology and Education**, Taylor Francis, v. 13, n. 3, p. 334–340, 2020. Disponível em: <https://doi.org/10.1080/17543266.2020.1799080>. Acesso em: 27 mai. 2023.

LI, Z.; HE, X.; LI, Y.; NIKKHOO, S.; YANG, W.; THIELE, L.; LIU, C. **MIMONet: Multi-Input Multi-Output On-Device Deep Learning**. 2023. Disponível em: <https://arxiv.org/pdf/2307.11962>. Acesso em: 13 mai. 2024.

LUCA, M. D.; ABBONDATI, F.; PIROZZI, M.; ZILIONIENE, D. Preliminary study on runway pavement friction decay using data mining. **Transportation Research Procedia**, v. 14, p. 3751–3760, 12 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352146516304677>. Acesso em: 11 abr. 2022.

MAIA, Aldaianny de Oliveira. **Caracterização e análise estatística e visual das condições de aderência de pavimentos aeroportuários brasileiros**. 2020. 98 f. Dissertação (Mestrado em Engenharia de Transportes) – Programa de Pós-Graduação em Engenharia de Transportes: Departamento de Engenharia de Transportes, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2023.

MATAEI, B.; NEJAD, F. M.; ZAHEDI, M.; ZAKERI, H. Evaluation of pavement surface drainage using an automated image acquisition and processing system. **Automation in Construction**, v. 86, p. 240–255, 2018. Disponível em: <https://api.semanticscholar.org/CorpusID:115511162>. Acesso em: 24 abr. 2022.

MEDIUM. **Image Segmentation using K-Means Clustering**. 2021. Disponível em: <https://medium.com/swlh/image-segmentation-using-k-means-clustering-46a60488ae71>. Acesso em: 13 nov. 2023.

MESSINA, G.; CASTORINA, A.; BATTIATO, S.; BOSCO, A. Image quality improvement by adaptive exposure correction techniques. **2003 International Conference on Multimedia and Expo. ICME '03. Proceedings (Cat. No.03TH8698)**, Baltimore, Maryland, v. 1, p. I–549, 2003. Disponível em: [https://www.researchgate.net/publication/4027747\\_Image\\_quality\\_improvement\\_by\\_adaptive\\_exposure\\_correction\\_techniques](https://www.researchgate.net/publication/4027747_Image_quality_improvement_by_adaptive_exposure_correction_techniques). Acesso em: 10 jun. 2022.

MOTA, G. A. S. P. e; OLIVEIRA, F. H. de L.; ALMEIDA, L. C. de; BABADOPULOS, L. F. D. A. L.; GOMES, J. P. P.; SOARES, J. B.; SERAFIM, M. de O.; SOUSA, C. A. de. Comparação de arquiteturas de redes neurais convolucionais na detecção automática de defeitos em imagens de pavimentos capturadas com smartphone. **46ª Reunião Anual de Pavimentação RAPv**, Brasília, p. 1–12, 2021. Disponível em: <https://rapvenacor.com.br/wp-content/uploads/2021/10/Anais-1807-5568-46RAPv-2021.pdf>. Acesso em: 25 jul. 2022.

MOTA, G. A. S. P. e; OLIVEIRA, F. H. de L.; NOGUEIRA, Y. L. Estudo do processamento digital de imagens no acúmulo de borracha em pista de pousos e decolagens. **47ª Reunião Anual de Pavimentação RAPv**, Bento Gonçalves, Rio Grande do Sul, p. 1–12, 8 2022. Disponível em: [https://rapvenacor.com.br/wp-content/uploads/2022/09/Anais-completo\\_V5.1.pdf](https://rapvenacor.com.br/wp-content/uploads/2022/09/Anais-completo_V5.1.pdf). Acesso em: 3 mar. 2023.

MOTA, G. A. S. P. e; OLIVEIRA, F. H. L. de; NOGUEIRA, Y. L. B.; NETO, J. B. C.; VIDAL, C. A. avaliação do acúmulo de borracha por imagens em pistas de pousos e decolagens. **48ª Reunião Anual de Pavimentação**, Foz do Iguaçu, Paraná, p. 1143–1151, 2023. Disponível em: <https://www.rapvenacor.com.br/publicacao-anais/anais-2023/>. Acesso em: 2 fev.2024.

MUJTABA, O.; DADVANDIPOUR, S.; LONE, M. A. Effect of filter sizes on image classification in cnn: a case study on cfir10 and fashion-mnist datasets. **IAES International Journal of Artificial Intelligence (IJ-AI)**, v. 10, n. 4, p. 872–878, 12 2021. ISSN 2252-8938. Disponível em: <https://ijai.iaescore.com/index.php/IJAI/article/view/20718>. Acesso em: 24 abr. 2023.



MURPHY, K. P. **Machine Learning: A Probabilistic Perspective**. 1. ed. Cambridge, Massachusetts: The MIT Press, 2012. ISBN 0262018020.

NASERI, H.; MEHRDAD, V. Novel cnn with investigation on accuracy by modifying stride, padding, kernel size and filter numbers. **Multimedia Tools and Applications**, v. 82, p. 23673–23691, 02 2023. Disponível em: <https://link.springer.com/article/10.1007/s11042-023-14603-x>. Acesso em: 19 mai. 2022.

NEJAD, F. M.; KARIMI, N.; ZAKERI, H. Automatic image acquisition with knowledge-based approach for multi-directional determination of skid resistance of pavements. **Automation in Construction**, v. 71, p. 414–429, 2016. Disponível em: <https://api.semanticscholar.org/CorpusID:114409791>. Acesso em: 9 jun. 2023.

NETO, A. M.; VICTORINO, A. C.; FANTONI, I.; ZAMPIERI, D. E.; FERREIRA, J. V.; LIMA, D. A. Image processing using pearson's correlation coefficient: Applications on autonomous robotics. In: **2013 13th International Conference on Autonomous Robot Systems**. [S. n.], 2013. p. 1–6. Disponível em: <https://ieeexplore.ieee.org/document/6623521>. Acesso em: 12 jul. 2023.

NIU, Y.; JIANG, X.; MENG, F.; WANG, R.; JU, G.; ZHANG, S.; MENG, Z. Techniques and methods for runway friction measurement: A review of state of the art. **IEEE Transactions on Instrumentation and Measurement**, v. 70, p. 1–17, 2021. Disponível em: <https://ieeexplore.ieee.org/document/9464230>. Acesso em: 16 jun. 2023.

NUMPY. **Numpy API reference: numpy.corrcoef**. 2024. Disponível em: <https://numpy.org/doc/stable/reference/generated/numpy.corrcoef.html>. Acesso em: 11 abri. 2024.

OLIVEIRA, F. H. L. d.; JÚNIOR, E. F. N. Considerações sobre a macrotextura e o atrito na avaliação funcional de pavimentos aeroportuários. **IV Simpósio Internacional de Avaliação de Pavimentos e Projetos de Reforço**, Fortaleza, p. 12, 10 2009. Disponível em: <https://marcosporto.eng.br/wp-content/uploads/2018/01/Considera%C3%A7%C3%B5es-Sobre-a-Macrotextura-e-o-Atrito-Na-Avalia%C3%A7%C3%A3o-Funcional-de-Pavimentos-Aeroporto%C3%A1rios.pdf>. Acesso em: 11 abr. 2023.

OLIVEIRA, Francisco Heber Lacerda de. **Desenvolvimento de um modelo de gerenciamento de pavimentos aeroportuários como apoio à tomada de decisão sobre estratégias de manutenção e reabilitação**. 2016. 178 f. Tese (Doutorado em Engenharia de Transportes) – Programa de Pós-Graduação em Engenharia de Transportes: Departamento de Engenharia de Transportes, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2016.

OPENCV. **Histograms - 2: Histogram Equalization**. 2024. Disponível em: [https://docs.opencv.org/4.x/d5/daf/tutorial\\_py\\_histogram\\_equalization.html](https://docs.opencv.org/4.x/d5/daf/tutorial_py_histogram_equalization.html). Acesso em: 20 ago. 2024.

PEREIRA, Cláudia Azevedo. **Análise da aderência pneu-pavimento em rodovias do Estado de Pernambuco e da Paraíba com elevado índice de acidentes**. 2010. 236 f. Tese (Tese de doutorado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil: Universidade Federal de Pernambuco, Recife, 2010.

PHAM, B.; PRINGLE, G. Color correction for an image sequence. **IEEE Computer Graphics and Applications**, v. 15, n. 3, p. 38–42, 1995. Disponível em: <https://ieeexplore.ieee.org/document/376611>. Acesso em: 8 mar. 2023.

PRANJIĆ, I.; DELUKA-TIBLJAŠ, A. Pavement texture-friction relationship establishment via image analysis methods. **Materials**, v. 15, n. 3, 2022. ISSN 1996-1944. Disponível em: <https://www.mdpi.com/1996-1944/15/3/846>. Acesso em: 26 mai. 2023.

QUARIGUASI, José Breno Ferreira. **PREVISÃO DO COEFICIENTE DE ATRITO EM PISTA DE POUSO E DECOLAGEM UTILIZANDO REDES NEURAIS ARTIFICIAIS**. 2020. 98 f. Dissertação (Mestrado em Engenharia de Transportes) – Programa de Pós-Graduação em Engenharia de Transportes: Departamento de Engenharia de Transportes, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2020.

QUARIGUASI, J. B. F.; OLIVEIRA, F. H. L. de; REIS, S. D. Soares e. Modelo de previsão do coeficiente de atrito para pista de pouso e decolagem com uso de redes neurais artificiais. **TRANSPORTES**, v. 29, n. 2, p. 2401, ago. 2021. Disponível em: <https://www.revistatransportes.org.br/anpet/article/view/2401>. Acesso em: 19 ago. 2023.

SALES, Renata de Souza. **Análise do Processo de Remoção de Borracha em Revestimentos Aeroportuários: Influência na Aderência Pneu-Pavimento**. 2019. 103 f. Monografia (Trabalho de Conclusão de Curso) – Curso de Engenharia Civil: Departamento de Engenharia de Transportes, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2019.

SALES, R. de S.; OLIVEIRA, F. H. L. de; PRADO, L. de A. Performance of tire-asphalt pavement adherence according to rubber removal on runways. **International Journal of Pavement Engineering**, Taylor Francis, v. 23, n. 10, p. 3566–3576, 2022. Disponível em: <https://doi.org/10.1080/10298436.2021.1907577>.

SINGH, S.; WANG, L.; PADMANABHAN, P.; GULYAS, B. Shallow 3d cnn for detecting acute brain hemorrhage from medical imaging sensors. **IEEE Sensors Journal**, v. 21, n. 13, p. 14290–14299, 2020. Disponível em: <https://ieeexplore.ieee.org/document/9195108>. Acesso em: 3 mar. 2023.

SLIMANE, A. B.; KHOUDEIR, M.; BROCHARD, J.; DO, M.-T. Characterization of road microtexture by means of image analysis. **Wear**, v. 264, n. 5, p. 464–468, 2008. ISSN 0043-1648. 10th International Conference on Metrology and Properties of Engineering Surfaces. Disponível em: <https://www.sciencedirect.com/science/article/pii/S004316480700169X>. Acesso em: 5 out. 2023.

SMITH, M.; PEARCE, B. Aviation Economic Benefits **Measuring the Economic rate of return on investment in the aviation industry**: report. Canadá, 2007. 38 p. (IATA Economics Briefings N°8).

SOUSA, Elisa da Silva. **VERIFICAÇÃO DO PARAMETRO DE MACROTEXTURA DE PAVIMENTOS EM SERVIÇO POR MEIO DO PROCESSAMENTO DIGITAL DE IMAGENS**. 2018. 67 f. Monografia (Trabalho de Conclusão de Curso) – Curso de Engenharia Civil: Departamento de Engenharia de Transportes, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2018.

STEHMAN, S. V. Selecting and interpreting measures of thematic classification accuracy. **Remote Sensing of Environment**, v. 62, n. 1, p. 77–89, 1997. ISSN 0034-4257. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425797000837>.

TAMURA, H.; KAMBAYASHI, Y. Estimation of coefficient of static friction of surface by analyzing photo images. In: CZARNOWSKI, I.; CABALLERO, A. M.; HOWLETT, R. J.; JAIN,

L. C. (Ed.). **Intelligent Decision Technologies 2016**. Cham: Springer International Publishing, 2016. p. 15–26. ISBN 978-3-319-39627-9.

TENSORFLOW. **TensorFlow v2.16.1: tf.keras.losses.BinaryCrossentropy**. 2024. Disponível em: [https://www.tensorflow.org/api\\_docs/python/tf/keras/losses/BinaryCrossentropy](https://www.tensorflow.org/api_docs/python/tf/keras/losses/BinaryCrossentropy). Acesso em: 22 mar. 2024.

TIAN, X.; XU, Y.; WEI, F.; GUNGOR, O.; LI, Z.; WANG, C.; LI, S.; SHAN, J. Pavement macrotexture determination using multi-view smartphone images. **Photogrammetric Engineering Remote Sensing**, v. 86, p. 643–651, 10 2020.

XIONG, Y.; PULLI, K. Color matching of image sequences with combined gamma and linear corrections. **ACM Multimedia**, Florence, 10 2010. Disponível em: <https://people.csail.mit.edu/kapu/papers/GammaColorCorrection.pdf>. Acesso em: 11 mar. 2022.

YUTAO, L.; YUANHUAN, Q.; HUI, W.; SHAODONG, X.; SHENGLIN, L. Study of texture indicators applied to pavement wear analysis based on 3d image technology. **Sensors**, v. 22, n. 13, 2022. Disponível em: <https://www.mdpi.com/1424-8220/22/13/4955>. Acesso em: 13 abr. 2023.

ZELELEW, A. T. P. H. M.; IZEPPPI, E. D. de L. Pavement macro-texture analysis using wavelets. **International Journal of Pavement Engineering**, Taylor Francis, v. 14, n. 8, p. 725–735, 2013. Disponível em: <https://doi.org/10.1080/10298436.2012.705004>.

ZHANG, P.; WANG, D.; ZHANG, Y. Analysis of correlation between image texture and friction coefficient of materials. In: **2017 IEEE International Conference on Imaging Systems and Techniques (IST)**. [S. l.: s. n.], 2017. p. 1–6.

ZOU, K. H.; TUNCALI, K.; SILVERMAN, S. G. Correlation and simple linear regression. **Radiology**, v. 227, p. 617–622, 06 2003.

ZUIDERVELD, K. J. Contrast limited adaptive histogram equalization. In: **Graphics gems**. [S. l.: s. n.], 1994.

## APÊNDICE A – TABELA COMPLETA DE DATAS DE IMAGENS

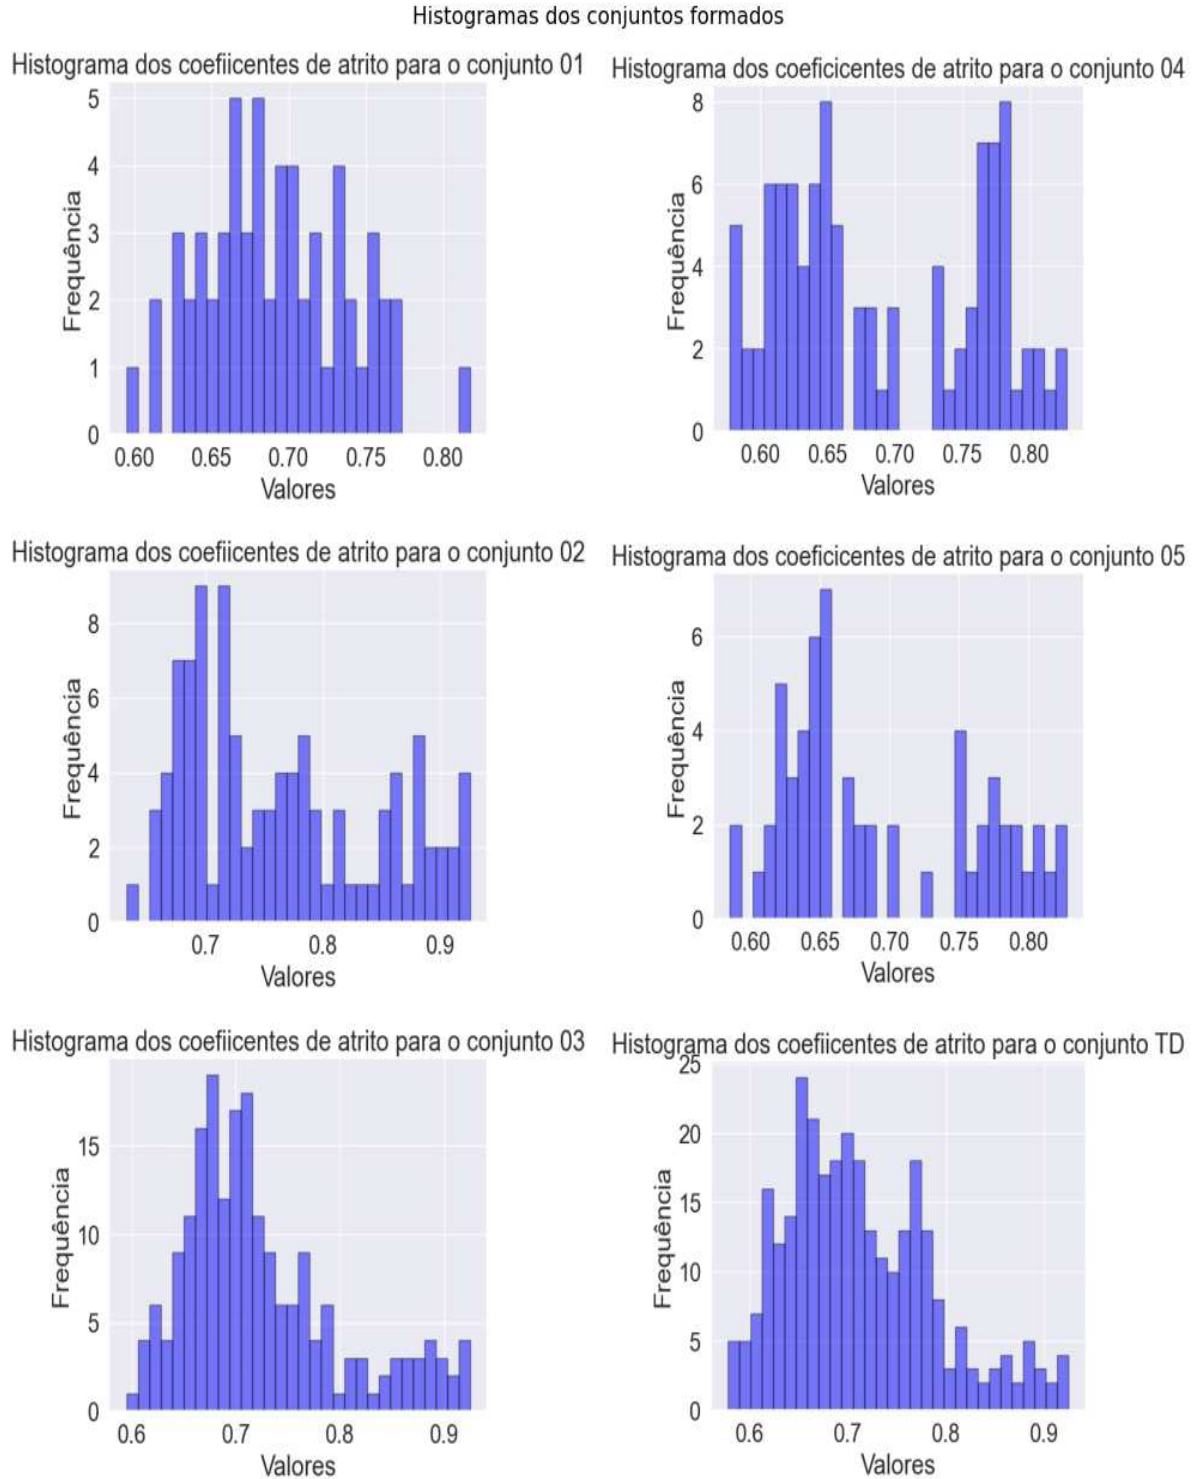
Tabela 8 – Datas das imagens da PPD utilizada no presente trabalho

Data	Nº	Data	Nº	Data	Nº	Data	Nº	Data	Nº
2018/12/16	01	2020/08/26	13	2021/04/26	25	2021/12/18	37	2022/09/04	49
2018/12/24	02	2020/09/10	14	2021/05/02	26	2021/12/29	38	2022/09/09	50
2019/02/28	03	2020/10/11	15	2021/05/25	27	2022/01/13	39	2022/09/23	51
2019/04/29	04	2020/10/23	16	2021/05/29	28	2022/02/01	40	2022/09/24	52
2019/07/11	05	2020/11/13	17	2021/06/24	29	2022/03/03	41	2022/10/04	53
2019/09/27	06	2020/11/24	18	2021/07/09	30	2022/03/21	42	2022/11/17	54
2020/01/13	07	2020/12/24	19	2021/07/17	31	2022/04/18	43	2022/11/19	55
2019/12/18	08	2021/01/08	20	2021/07/21	32	2022/05/07	44	2022/12/08	56
2020/04/22	09	2021/03/06	21	2021/07/30	33	2022/06/30	45	2023/04/27	57
2020/05/07	10	2021/03/19	22	2021/08/06	34	2022/08/05	46	-	-
2020/07/13	11	2021/04/07	23	2021/09/25	35	2022/08/24	47	-	-
2020/08/24	12	2021/04/22	24	2021/11/23	36	2022/08/25	48	-	-

Fonte: Elaborado pelo autor (2023)

## APÊNDICE B – HISTOGRAMAS DOS CONJUNTOS FORMADOS

Figura 41 – Histogramas dos dados de coeficiente de atrito por conjunto formado.



Fonte: Elaborado pelo autor (2024).