

INSTITUTO TECNOLÓGICO DE AERONÁUTICA



Caio Chacon da Rocha Brasil

**IDENTIFICAÇÃO AUTOMATIZADA DE
PADRÕES DE TRINCAS EM PAVIMENTOS**

Trabalho de Graduação

2021

Curso de Engenharia Civil-Aeronáutica

Caio Chacon da Rocha Brasil

**IDENTIFICAÇÃO AUTOMATIZADA DE
PADRÕES DE TRINCAS EM PAVIMENTOS**

Orientador

Prof. Dr. Cláudia Azevedo Pereira (ITA)

ENGENHARIA CIVIL-AERONÁUTICA

SÃO JOSÉ DOS CAMPOS

INSTITUTO TECNOLÓGICO DE AERONÁUTICA

2021

Dados Internacionais de Catalogação-na-Publicação (CIP)**Divisão de Informação e Documentação**

<p>Brasil, Caio Chacon da Rocha Identificação automatizada de padrões de trincas em pavimentos / Caio Chacon da Rocha Brasil São José dos Campos, 2021. 60f.</p> <p>Trabalho de Graduação – Curso de Engenharia Civil-Aeronáutica – Instituto Tecnológico de Aeronáutica, 2021. Orientador: Prof. Dr. Cláudia Azevedo Pereira.</p> <p>1. Pavimentos. 2. Defeitos. 3. Trincas. 4. Aprendizado de máquina. I. Instituto Tecnológico de Aeronáutica. II. Título</p>
--

REFERÊNCIA BIBLIOGRÁFICA

Brasil, Caio Chacon da Rocha. **Identificação automatizada de padrões de trincas em pavimentos**. 2021. 60f. Trabalho de Conclusão de Curso. (Graduação em Engenharia Civil-Aeronáutica) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

CESSÃO DE DIREITOS

NOME DO AUTOR: Caio Chacon da Rocha Brasil

TÍTULO DO TRABALHO: Identificação automatizada de padrões de trincas em pavimentos.

TIPO DO TRABALHO/ANO: Trabalho de Conclusão de Curso (Graduação) / 2021

É concedida ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias deste trabalho de graduação e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte deste trabalho de graduação pode ser reproduzida sem a autorização do autor.



Caio Chacon da Rocha Brasil

Rua H8A, 114

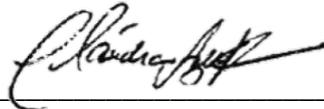
12228-460, São José dos Campos - SP

IDENTIFICAÇÃO AUTOMATIZADA DE PADRÕES DE DEFEITOS EM PAVIMENTOS

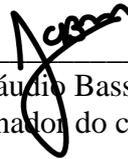
Essa publicação foi aceita como Relatório Final de Trabalho de Graduação



Caio Chacon da Rocha Brasil
Autor



Prof. Dr. Cláudia Azevedo Pereira (ITA)
Orientador



Prof. Dr. João Cláudio Bassan de Moraes
Coordenador do curso

SÃO JOSÉ DOS CAMPOS, 16 DE NOVEMBRO DE 2021

Dedico este trabalho a todos os mestres e professores que contribuíram para meu desenvolvimento e formação como aluno, cidadão e ser humano.

Agradecimentos

Gostaria de agradecer ao apoio e suporte de todos que contribuíram diretamente ou indiretamente com a concretização da minha graduação e deste trabalho. À minha família, todo carinho e amor incondicional, estiveram juntos em todos os momentos, especialmente na jornada anterior ao ingresso do instituto e, também, no ano de 2020. Aos colegas, professores e funcionários, meu singelo apreço, particularmente àqueles os quais compuseram o grupo nos projetos das disciplinas, tanto no curso fundamental, quanto no profissional.

"Descobrir consiste em olhar para o que todo mundo está vendo e pensar uma coisa diferente".

(Roger Von Oech)

Resumo

O gerenciamento ativo de pavimentos preocupa-se, entre outras diretrizes, com as condições de serviço de estradas e pavimentos com o intuito de preservar a segurança e conforto dos usuários. Por esse motivo, a verificação da presença de defeitos é uma preocupação. No presente estudo, foi proposto uma metodologia para realizar o processo de identificação de defeitos em pavimentos de modo a reduzir custos operacionais, já que a intervenção precoce acarreta melhor aplicação dos recursos, além de auxiliar e agilizar o processo de monitoramento. Partindo-se de um banco de dados de 40.000 imagens de concreto de resolução 227 x 227, realizou-se um procedimento específico com a intenção de obter um algoritmo capaz de classificar cada imagem de maneira autônoma e com alta acurácia. Cada rótulo atribuído, refere-se a presença ou não de defeito, ou tipo de trinca para aqueles apontados com defeito. Neste estudo, as trincas foram classificadas conforme três disposições geométricas: diagonal, longitudinal ou transversal. O pré-processamento das imagens é composto das técnicas de filtro de suavização bilateral, sobreposição orientável em kernel gaussiano e projeção de eixo. Em seguida, os dados do banco de 500 imagens de trincas em cada classe foram submetidos a um processo de Aprendizado de Máquina (AM), em que quatro diferentes técnicas são aplicadas comparativamente. Em geral, a que teve o melhor desempenho foi o algoritmo de *K-Nearest Neighbors* (KNN), o qual correspondeu a cerca de 93% e 87% em acurácia na classificação quanto à presença de defeitos e identificação do tipo de trinca, respectivamente.

Palavras-chave: 1. Pavimentos. 2. Defeitos. 3. Trincas. 4. Aprendizado de máquina.

Abstract

The active management of pavements is concerned, among other guidelines, with the service conditions of roads and pavements in order to preserve the safety and comfort of users. For this reason, checking for the presence of distresses is a need for constant concern. In the present study, a methodology was proposed to carry out the process of identifying distresses in pavements in order to reduce operating costs, since early intervention leads to better application of resources, in addition to helping and speeding up the monitoring process. Starting from a database of 40,000 concrete images of 227x227 resolution, a specific procedure was performed with the intention of obtaining an algorithm capable of classifying each image autonomously and with high accuracy. Each label assigned refers to the presence or absence of a distress, or type of crack for those indicated as distress. In this study, cracks were classified according to three geometric arrangements: diagonal, longitudinal or transversal. The pre-processing of the images is composed of the techniques of bilateral smoothing filter, steerable filter in Gaussian kernel and axis projection. Then, the data from the bank of 500 images of cracks in each class were submitted to a machine learning process, in which four different techniques are applied comparatively. In general, the one with the best performance was the K-Nearest Neighbors (KNN) algorithm, which corresponded to about 93% and 87% in accuracy in classifying the presence of distress and identification of the type of crack, respectively.

Keywords: 1. Pavements. 2. Distresses. 3. Cracks. 4. Machine learning.

Lista de Figuras

FIGURA 1: Desempenho de um pavimento (RODRIGUES, 2020).....	19
FIGURA 2: Diferentes tipos de defeitos que podem afetar a estrutura de um pavimento (VAITKUS <i>et al</i> , 2016).....	19
FIGURA 3: Trincas em pavimento flexível em diferentes graus de severidade. (SHAHIN, 2009).....	26
FIGURA 4: comparativo de uma imagem original (à esquerda) submetida a FSB (a direita). (Tutorials Point, 2021).....	28
FIGURA 5: Comparativo de uma imagem submetida a SF (LANMAN, 2006).....	29
FIGURA 6: Etapas classificatórias.....	35
FIGURA 7: Relação de PVE acumulada para os 45 primeiros CP do conjunto de dados de imagens após realizado o pré-tratamento.	37
FIGURA 8: Metodologia desenvolvida.....	39
FIGURA 9: Disposição de elementos da primeira etapa de classificação no espaço vetorial dos CP.....	41
FIGURA 10: Disposição de elementos da segunda etapa de classificação no espaço vetorial dos CP.....	41
FIGURA 11: Gráfico resultante dos dados de pré-tratamento de uma amostra de imagem de TD tipo 1.....	42
FIGURA 12: Gráfico resultante dos dados de pré-tratamento de uma amostra de imagem de TD tipo 2.....	43
FIGURA 13: Gráfico resultante dos dados de pré-tratamento de uma amostra de imagem de TT.	43
FIGURA 14: Gráfico resultante dos dados de pré-tratamento de uma amostra de imagem de TL.	44

FIGURA 15: Relação de erro de classificação em função do tamanho da árvore de decisão da 1ª etapa.....	45
FIGURA 16: Relação de erro de classificação em função do tamanho da árvore de decisão da 2ª etapa.....	45
FIGURA 17: Diagrama representativo sequencial de tomada de decisão para classificação da primeira etapa.	46
FIGURA 18: Diagrama representativo sequencial de tomada de decisão para classificação da segunda etapa.....	46
FIGURA 19: Comparativo do desempenho do método de análise preditiva de CART.....	47
FIGURA 20: Comparativo do desempenho do método de análise preditiva de SVM.....	47
FIGURA 21: Relação da acurácia de classificação em função da quantidade de vizinhos mais próximos, 1ª etapa.....	48
FIGURA 22: Relação da acurácia de classificação em função da quantidade de vizinhos mais próximos, 2ª etapa.....	48
FIGURA 23: Comparativo do desempenho do método de análise preditiva de KNN.....	49
FIGURA 24: Relação da acurácia de classificação em função da quantidade de camadas internas, 1ª etapa.	50
FIGURA 25: Relação da acurácia de classificação em função da quantidade de camadas internas, 2ª etapa.	50
FIGURA 26: Comparativo do desempenho do método de análise preditiva de ANN.....	51
FIGURA 27: Comparativo de acurácia de classificação em função da técnica de AM, 1ª etapa.	52
FIGURA 28: Comparativo de acurácia de classificação em função da técnica de AM, 2ª etapa.	52

FIGURA 29: Conjunto das 25 primeiras imagens incorretamente classificadas na segunda etapa.....	54
FIGURA 30: Conjunto das 25 imagens seguintes incorretamente classificadas na segunda etapa.....	55
FIGURA 31: Conjunto das 10 imagens seguintes incorretamente classificadas na segunda etapa.....	56

Lista de Tabelas

TABELA 1: Matriz de confusão da predição realizada pelo método KNN sobre o conjunto de dados de teste na segunda etapa.	53
TABELA 2: Conjunto de métricas individualmente descritas para cada classe de predição...	53

Lista de Abreviaturas e Siglas

AM	Aprendizado de Máquina
CJ	Couro de jacaré
TD	Trinca Diagonal
TL	Trinca Longitudinal
TT	Trinca Transversal
RGB	Red, Green, Blue
NC	Níveis de Cinza
FSB	Filtro de Suavização Bilateral
SF	<i>Steerable Filter</i>
PI	Projeção Integral
PH	Projeção Horizontal
PV	Projeção Vertical
PD	Projeção Diagonal
tp	verdadeiro positivo
fp	falso positivo
fn	falso negativo
tn	verdadeiro negativo
CP	Componentes Principais
PVE	Proporção de Variância Explicada
CART	<i>Classification and Regression Trees</i>
KNN	<i>K-Nearest Neighbors</i>
SVM	<i>Support Vector Machines</i>
ANN	<i>Artificial Neural Networks</i>

RStudio

software livre de desenvolvimento integrado para R

MATLAB

software de computação numérica da empresa MathWorks

Sumário

1. Introdução	18
1.1. Problema.....	20
1.2. Objetivo geral.....	20
1.3. Objetivos específicos.....	20
1.4. Justificativas	21
1.5. Estrutura do trabalho	21
2. Pavimentos	22
2.1. Caracterização geral de pavimentos	22
2.2. Projeto de pavimentos	22
2.3. Deterioração de pavimentos	24
2.4. Trincas	25
3. Inteligência Artificial.....	27
3.1. Técnicas de pré-processamento de imagens.....	27
3.1.1. Filtro de Suavização Bilateral (FSB).....	27
3.1.2. Filtro de Sobreposição Orientável (SF).....	28
3.1.3. Projeção integral (PI).....	29
3.1.4. Conversão de escalas	30
3.2. Técnicas de processamento de imagens.....	30
3.2.1. Componentes principais (CP).....	31
3.2.2. Árvore de decisão (CART).....	32
3.2.3. K-ésimo Vizinho mais Próximo (KNN).....	32
3.2.4. Máquina de vetores de suporte (SVM).....	32
3.2.5. Redes Neurais (ANN).....	33
4. Metodologia.....	34
4.1. Características do conjunto de dados.....	34
4.2. Organização do conjunto de dados.....	35
4.3. Pré-tratamento de imagens	36
4.3.1. A técnica de pré-processamento	36
4.4. Tratamento de dados	37
4.4.1. Decomposição em CP.....	37
4.4.2. Divisão da base de dados	38
4.5. Métodos de classificação	38
4.5.1. Modelo de CART	38
4.5.2. Modelo de SVM.....	38
4.5.3. Modelo de KNN	39
4.5.4. Modelo de ANN.....	39

5. Resultados.....	40
5.1. Análise exploratória de dados	40
5.1.1. PI	42
5.1.2. CART	44
5.1.3. SVM	47
5.1.4. KNN	48
5.1.5. ANN	49
5.2. Comparativo de desempenho	51
5.2.1. Resultados do método KNN.....	53
5.3. Visualização de erros	53
6. Considerações finais	57
Referências	59

1. Introdução

Dentre todas as estruturas, os pavimentos são os que estão mais sujeitos a deterioração ao longo do tempo, visto que estão constantemente expostos a intempéries ambientais e a ação frequente de cargas de serviço. Por isso, passíveis à perda gradual de serventia (funcionalidade), não é adequado ignorar-se as condições de conservação de qualquer pavimento mesmo que no médio ou longo prazo. Ademais, o estado de um pavimento também deve ser objeto de preocupação de diversos atores sociais indiretamente envolvidos, dado que os custos operacionais de transporte rodoviário devem entrar na gestão orçamentária de qualquer atividade econômica que dependa desse modal.

Por outro lado, o pavimento é o elemento de custo mais elevado na infraestrutura de transportes da rede rodoviária, porém cuja despesa de manutenção é diminuta comparada aos problemas mecânicos que veículos estão sujeitos a apresentar caso façam uso constante de uma superfície de rolamento inadequada. Além disso, outras situações inoportunas podem ser advindas, como acidentes de trânsito e intermitência do fluxo requerido por ingerências no pavimento.

É de grande importância, outrossim, que a manutenção do pavimento seja realizada no momento e grau de deterioração adequada, visto que a eficiência das técnicas de reparo de defeitos é maior à medida que o grau de severidade seja reduzido. Por outro lado, caso o estado de conservação do pavimento faça não ser viável o reparo dos defeitos, em que um nível crítico é detectado, a única solução de melhoria executável é a reconstrução, que tem custo elevado, comparado a intervenções graduais executadas ao longo da vida útil por um sistema gerencial.

Em geral, os problemas relacionados à conservação de um pavimento não ocorrem abruptamente, mas sim de maneira gradual desde a abertura ao tráfego. Sendo assim, faz-se necessário a definição de um parâmetro que denota a condição do pavimento ao longo da vida de serviço. Desse modo, relaciona-se o nível de conforto ao rolamento e segurança de uma rodovia com o conceito de grau de serventia, no método AASHTO (1986), utiliza-se uma escala de 0 a 5 para avaliar esse parâmetro. A variação da serventia ao longo do tempo é definida como desempenho (RODRIGUES, 2020). O desempenho de um pavimento genérico pode ser entendido como a curva do gráfico na Figura 1.

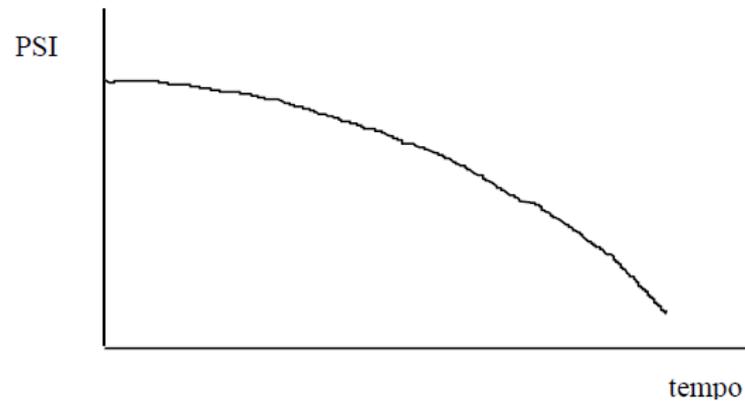


FIGURA 1: Desempenho de um pavimento (RODRIGUES, 2020).

Os mecanismos pelos quais os defeitos são propagados são complexos e não completamente modelados, no entanto o gestor de pavimentos pode utilizar-se de métricas o qual deformações plásticas e formação de trincas são indicativos de perecibilidade do material.

Na Figura 2, a seguir, observa-se uma série de diferentes tipos de defeitos os quais os pavimentos estão sujeitos a apresentar durante sua vida útil.



FIGURA 2: Diferentes tipos de defeitos que podem afetar a estrutura de um pavimento (VAITKUS *et al*, 2016).

1.1. Problema

A inspeção e realização de ensaios é a melhor maneira de caracterização em que um gestor pode tomar conhecimento do atual estado de conservação de um pavimento, desde que sejam realizadas corriqueiramente, é plausível o monitoramento e análise da necessidade de intervenção com fins de manutenção. No entanto, quando se pensa em um sistema rodoviário, em que quilômetros de estradas são construídas, ou até mesmo em uma pista simples de pouso e decolagem, torna-se difícil a tarefa de apuração de catalogação periódica, seja por incapacidade em cobrir extensas áreas ou altos custos material e profissional. Na situação do pavimento aeroportuário, o qual é ainda mais necessário assegurar a qualidade do material devido a critérios de segurança e serviço, uma inspeção de rotina necessitaria a paralisação momentânea do fluxo de aeronaves no local, o que gera prejuízos financeiros para as companhias que operam no local.

1.2. Objetivo geral

O presente estudo tem como proposta estabelecer uma metodologia que possa ser empregada para aprimoramento dos processos de gestão e manutenção de pavimentos em vias automotivas ou pistas de pouso e decolagem (estradas e aeroportos) no que se refere a detecção e apontamento de defeitos na sua superfície. Parte-se do entendimento de automatização de processos como um viés o qual provê a diminuição de custos operacionais, capaz de auxiliar e agilizar o processo de monitoramento, além de poder ser utilizado em situações que inspeções tradicionais não sejam viáveis.

1.3. Objetivos específicos

Propõe-se, portanto:

- Empregar imagens de pavimento como veículo de inspeção, verificação e apontamento de defeitos. As imagens, a princípio, podem ser obtidas de diferentes maneiras, inclusive remotamente utilizando-se veículos não tripulados, respaldado pelos sistemas de sensoriamento remoto.
- Realizar um tratamento específico, denominado pré-processamento, o qual tem como objetivo melhorar a qualidade da imagem com os fins a que ela se destina.
- Modelar um processo de AM preditivo com fins verificar a presença de defeitos em um trecho do pavimento, em seguida o processamento é capaz de identificar o padrão de trinca específico o qual aquele defeito se adequa melhor.

1.4. Justificativas

Esses dados poderão, a posterior, servir como base para geração de relatórios integrados, os quais servidos de apoio das devidas métricas, poderão indicar com maior grau de assertividade e automação os trechos de pavimento com maior ou menor necessidade de intervenção, sendo uma importante ferramenta no processo de gerenciamento do pavimento.

Além disso, a literatura científica, principalmente em língua portuguesa, ainda carece de estudos mais aprofundados no tema a fim de aperfeiçoar e otimizar as técnicas de pré-processamento e AM. As que foram desenvolvidas neste estudo foram uma tentativa de melhor adaptar o banco de imagens utilizados com os fins, eventuais modificações são necessárias de acordo com a resolução utilizada, tipo de pavimento, distância fotografada, presença de ruído nas imagens ou outras variáveis a serem consideradas.

1.5. Estrutura do trabalho

Este trabalho de graduação é constituído por 5 capítulos, sendo organizados da seguinte forma:

- O capítulo 1 é dedicado a introduzir o assunto progressivamente, o qual é apresentado o contexto, a necessidade do estudo e a proposta de implantação.
- O capítulo 2 e 3 apresentam uma revisão bibliográfica, o qual aprofundam-se, respectivamente, nas teorias já desenvolvidas nos assuntos, tanto no que se refere aos sistemas de gerência de pavimentos e propagação de trincas, quanto nos algoritmos de tratamento de imagens a fim de classificar segundo algum critério.
- O capítulo 4 elucida a metodologia utilizada no trabalho. É apresentado todas as etapas que foram seguidas para a construção das modelagens, incluindo extração e tratamento de dados, criação e construção dos parâmetros.
- O capítulo 5 é dedicado a apresentar os resultados obtidos com a aplicação da metodologia, apresentando métricas de desempenho e confrontando a sua aplicabilidade em uma situação real. Em seguida, é feita uma comparação a fim de determinar quais foram as técnicas com melhor eficácia no tratamento das imagens.
- O capítulo 6 apresenta a conclusão do trabalho, em que análises críticas são tecidas aos resultados e metodologia. Aqui é discutido o progresso acerca do que já foi feito e ainda pode ser desenvolvido a fim de aperfeiçoar o objetivo geral.

2. Pavimentos

2.1. Caracterização geral de pavimentos

O sistema de transporte terrestre, mais especificamente o rodoviário, é composto por vias com ou sem a presença de pavimentos. A sua ausência, comumente associada a regiões de baixa condições de infraestrutura, muitas vezes está relacionada ao trânsito direto em revestimento primário (cascalho ou solo-brita), ou simplesmente em subleito compactado. Haja visto que esse tipo de via implica em adversidades ocasionadas pelos efeitos deletérios ambientais: propagação de poeira, deformabilidade, acúmulo de águas pluviais, é interessante buscar desenvolver o sistema rodoviário com a construção da estrutura pavimentada (RODRIGUES, 2020).

O pavimento é uma estrutura cuja função é proporcionar uma superfície de rolamento assentada em fundação devida para que o deslocamento terrestre de veículos possa se desenvolver em condições apropriadas. As especificidades de um pavimento dependem do fim a que se destina e das características de solo em que estará apoiado, por esse motivo tecnologias e estudos diferentes podem ser implementados para solucionar as diferentes necessidades (RODRIGUES, 2020).

De acordo com Rodrigues (2020, v. 1, p. 6), as estruturas de pavimento podem ser classificadas quanto a seu uso e materiais constituintes, a saber:

- Vias de transporte rodoviário e pistas de aeroportos contam com uma superestrutura apoiada em fundação em camadas: sub-base, reforço de subleito e subleito.
- Vias ferroviárias tem superestrutura como sendo os trilhos e fixadores e que está apoiada em fundação em camadas: lastro, sublastro e subleito.
- Pátios de estacionamento e manobras, pavimento com estrutura semelhante aos anteriores, porém projetado a fim de lidar com a aplicação de cargas elevadas estacionárias e a exposição de substâncias corrosivas em sua superfície (óleo e combustíveis).

2.2. Projeto de pavimentos

A engenharia de pavimentos é o ramo da engenharia civil destinada a conceber, projetar, construir, realizar manutenção e avaliação de pavimentos, reservada as devidas demandas e limitações técnicas e econômicas. Conforme descrito por Rodrigues (2020, v. 1, p. 16):

“Projetar um pavimento significa determinar a combinação de materiais, espessuras e posição das camadas constituintes que seja a mais econômica, dentre todas as alternativas viáveis que atendam aos requisitos funcionais especificados”, o projeto de pavimentos constitui uma atividade que segue a tradicional metodologia de qualquer outro tipo de estrutura. No entanto, à proporção que se desenvolvem novas tecnologias a fim de solucionar as demandas de concepção, técnicas de gerenciamento devem ser implementadas no intuito de se adotar o enfoque na minimização do Custo Total no Ciclo de Vida (CCV) do pavimento, que é a composição do custo inicial de construção, conservação e restauração.

Desse modo, é válido destacar a aplicação e abordagem de modelos de previsão de desempenho mecanístico-empíricos a fim de prever as condições de serviço e necessidade de manutenção ao longo da vida útil da estrutura. A utilização desses modelos é de grande serventia em um sistema de gerência de pavimentos, no entanto o engenheiro deve estar atento às condições fenomenológicas dos processos, uma vez que as suas aplicações sempre estarão sujeitas a fatores limitantes de conexão entre a teoria à realidade, ou o que se observa para o que realmente acontece. Por esse motivo, a calibração local de modelos ganha importância à medida que se exige maior qualidade de previsão e que novos dados vão sendo obtidos pelo monitoramento das vias pavimentadas.

Um dos principais objetivos do projeto de pavimentos é distribuir as tensões provenientes do tráfego de veículos aos componentes da estrutura e ao solo de suporte, de modo a preservar a capacidade de suporte dos diversos materiais utilizados nas camadas, mas também manter as características de serviço, aderência e deformabilidade dos segmentos ao longo das vias. Os requisitos de projeto são encabeçados por duas vertentes, tanto as que denotam a fase de implantação e construção, quanto a de tráfego e usabilidade.

Dadas as correlações de desempenho adotadas como critério de projeto das camadas correspondentes de uma estrutura de pavimento, as especificações devem ser capazes de atender as demandas de projeto com um certo nível de confiabilidade a fim de que defeitos incipientes na vida útil tenham uma probabilidade baixa e irreduzível de causar falha na estrutura. Isso se deve ao fato de que o custo para aumentar a espessura dos materiais constituintes a fim de anular o risco de falha excederia o custo da maioria das manutenções prováveis.

Por fim, é importante compreender que não há um determinado tipo ou configuração de estrutura de pavimento que seja ideal para todas ou maioria das situações, o melhor a ser feito é que, dadas as condições de exigências, sejam feitas diversas análises de alternativas com fins comparativos. Essa metodologia é importante no sentido de possibilitar a escolha da solução mais adequada em conformidade aos fatores econômicos e operacionais, sejam os que

envolvem o CCV, até mesmo os de viabilidade: cumprimento de prazos, disponibilidade de material e profissional, orçamento previsto.

2.3. Deterioração de pavimentos

Conforme exposto anteriormente, os pavimentos são o tipo de estrutura que mais está suscetível à deterioração conforme está exposto aos efeitos deletérios das ações físico-ambientais. É de fundamental importância entender os mecanismos de deterioração os quais os pavimentos estão sujeitos a fim de poder controlar a propagação de defeitos e, assim, evitar consequências negativas mais severas.

Em resumo, o pavimento do tipo flexível compreende aqueles cujo revestimento é uma camada asfáltica com camada de base granular. É característico desse material, a distribuição de tensões e deformações geradas pelas cargas de tráfego de modo a haver um alívio de tensões no subleito devido a alta capacidade resistente cisalhante. Por esse motivo, é comum a ocorrência de trincamento por fadiga, ao mesmo tempo que a repetição de cargas pode também gerar afundamento em formações de trilho de roda. Esse tipo de estrutura pode ser encarado como sendo um sistema de camadas infinitas e elásticas, sobrepostas e perfeitamente aderidas.

Segundo Rodrigues (2020, v. 1, p. 24), os pavimentos flexíveis se deterioram por meio de:

- Formação e crescimento de trincas nas camadas asfálticas do revestimento;
- Geração de afundamentos em trilha de roda ou de ondulações na superfície;
- Desgaste com exposição de agregados e perda da macrotextura da superfície do pavimento
- Envelhecimento do ligante betuminoso por oxidação

Em contrapartida, o pavimento do tipo rígido é constituído em geral por placas de concreto, o qual alivia as tensões provenientes das cargas de tráfego por meio de alta rigidez a flexão. A sub-base corresponde a uma das camadas subjacentes cuja capacidade de suporte é inferior àquelas utilizadas nos pavimentos flexíveis. Além disso, a estrutura de pavimento rígido deve ser analisada conforme a teoria de placas, uma vez que os efeitos de fronteira são substancialmente significativos. Em adicional, destaca-se que usualmente a construção de uma estrutura de pavimento rígido compreende a execução de cortes de baixa profundidade, denominados juntas de dilatação. Esses espaçamentos são necessários uma vez que os efeitos de contração no processo de cura do concreto imprimem ao material tensões de tração que provocam eventuais trincas, mesmo que a área não seja liberada para o tráfego.

Conforme detalhado por Rodrigues (2020, v. 1, p. 24), os pavimentos semi-rígidos se deterioram por meio de:

- Trincamento da base cimentada, seguido da rápida reflexão das trincas através da espessura do revestimento asfáltico.
- Trincamento longitudinal do revestimento nas trilhas de roda, por meio de trincas que se originam na superfície e se propagam para baixo
- Afundamentos em trilha de roda

Conforme detalhado por Rodrigues (2020, v. 1, p. 25), os pavimentos rígidos se deterioram por meio de:

- Trincamento por fadiga da placa de CCP;
- Redução da eficiência do sistema de transferência de carga nas juntas, devido à perda de ligação entre as barras de transferência e o concreto;
- Erosão da sub-base, por falha de selagem das juntas;

2.4. Trincas

Como se pode verificar, o surgimento de trincas em qualquer tipo de pavimento tem diversas causas e consequências negativas que podem acarretar na perda de vida útil da estrutura, destaca-se o trincamento por meio do mecanismo de reflexão o qual é alvo de estudos e preocupação, sendo incluído no desenvolvimento de sistemas Anti-Reflexão de Trincas e de Juntas. Neste estudo, procurou-se abordar os defeitos visíveis ao revestimento de pavimentos convencionais, porém devido a importância, as trincas tiveram acentuado destaque e foram objeto central de estudo.

Quatro tipos de trincas são válidos para trabalhar-se ao objetivo a que o trabalho se propõe, a saber Couro de Jacaré (CJ), trinca diagonal (TD), trinca longitudinal (TL) e trinca transversal (TT). Essas classes são facilmente identificadas por um observador dotado de imagens, visto que as diferenças são as disposições geométricas, como se pode observar na Figura 3, o qual a coluna da esquerda remete-se a trincas CJ, enquanto que a da direita a trincas longitudinais ou transversais.

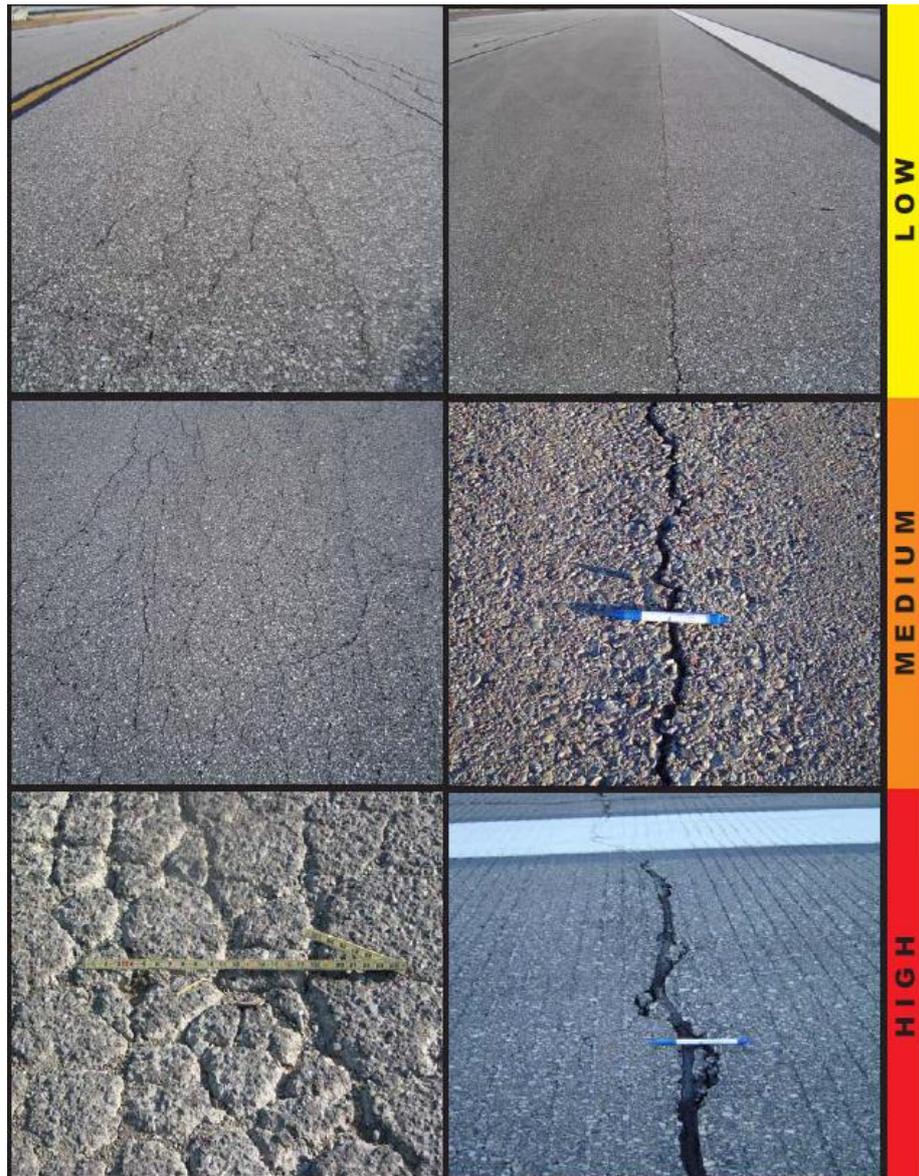


FIGURA 3: Trincas em pavimento flexível em diferentes graus de severidade. (SHAHIN, 2009).

Exceto pela trinca CJ, que é uma composição generalizada de trincas, as demais trincas podem ser “convertidas” por meio de rotações simples, já que a sua direção é fator determinante da sua classe. A TL configura-se como uma trinca com direção específica e paralela a de deslocamento da via, a TT, contudo é perpendicular. No entanto, é válido salientar que, do ponto de vista da Engenharia de Pavimentos, cada trinca tem uma causa e tratamento específico apesar de parecerem tão semelhantes.

3. Inteligência Artificial

3.1. Técnicas de pré-processamento de imagens

Nas etapas de pré-processamento, rotinas computacionais são empregadas a fim de converter e adequar os dados disponíveis em formato de imagem para formatos legíveis aos processos de AM que seguem esta etapa. A grosso modo, pode-se compreender qualquer imagem digital como sendo uma matriz de tamanho bem definido, que se refere a resolução, em que cada elemento dessa matriz é um pixel, os quais armazenam valores numéricos que são associados a uma cor do espectro visível, que é representado pelo sistema *Red, Green, Blue* (RGB) ou em Níveis de Cinza (NC) para imagens não coloridas. Ambos as formas de representação RGB ou NC podem ser interconvertidas, enquanto que a imagem RGB é melhor e mais agradável para o observador, por apresentar “mais detalhes”, a imagem em NC é mais adequada ao trabalhar-se com o processamento das imagens, assim sendo mais adequado a conversão entre as escalas de pixel.

3.1.1. Filtro de Suavização Bilateral (FSB)

Assim como qualquer outro filtro, pode ser compreendido como sendo uma conversão dos valores de pixel da imagem como um todo. O FSB substitui a intensidade de cada pixel por uma média ponderada dos valores dos pixels próximos, os pesos aplicados são calculados conforme uma distribuição Gaussiana bem definida. (HOANG, 2018).

Ele tem como objetivo suavizar a imagem a fim de diminuir os efeitos negativos da presença de ruído no processo de AM, tem como características ser não linear e preservação de bordas, o que significa que não distorce os limites da imagem. Observa-se a aplicação do FSB em uma imagem na Figura 4, a seguir.



FIGURA 4: comparativo de uma imagem original (à esquerda) submetida a FSB (a direita).
(Tutorials Point, 2021)

3.1.2. Filtro de Sobreposição Orientável (SF)

Outra técnica de conversão de pixel, no entanto, diferentemente do FSB, o objetivo do SF é melhorar as características de uma imagem submetida a análise de detecção de bordas, textura orientada ou forma a partir do sombreamento (HOANG, 2018).

O SF pode ser compreendido por uma sobreposição em vários ângulos de direcionamento da convolução em combinações lineares das derivadas de segunda ordem da distribuição gaussiana. Para uma matriz-imagem $I(x, y)$, a distribuição gaussiana, associada a um parâmetro fixo ajustável r , é:

$$G(x, y) = \frac{1}{\sqrt{2\pi}r} e^{-\frac{x^2+y^2}{2r^2}} \quad (\text{Eq. 1})$$

Dada um direcionamento θ de transformação, a combinação linear associada é:

$$F(x, y, r, \theta) = G_{xx}(\theta) + 2G_{xy}\cos(\theta) \cdot \text{sen}(\theta) + G_{yy}(\theta) \quad (\text{Eq. 2})$$

Finalmente, o valor da transformação, para um dado θ , é:

$$R(x, y) = F(x, y, \sigma, \theta) * I(x, y) \quad (\text{Eq. 3})$$

Onde o “*” indica o operador convolucional, o resultado final da transformação em SF é dado pela combinação linear de cada matriz transformada quando se faz θ variar em um

conjunto de valores específicos. Observa-se a aplicação do SF em uma imagem da Figura 5, a seguir, o qual a figura mais inferior às demais corresponde à matriz de transformação $F(x, y)$.

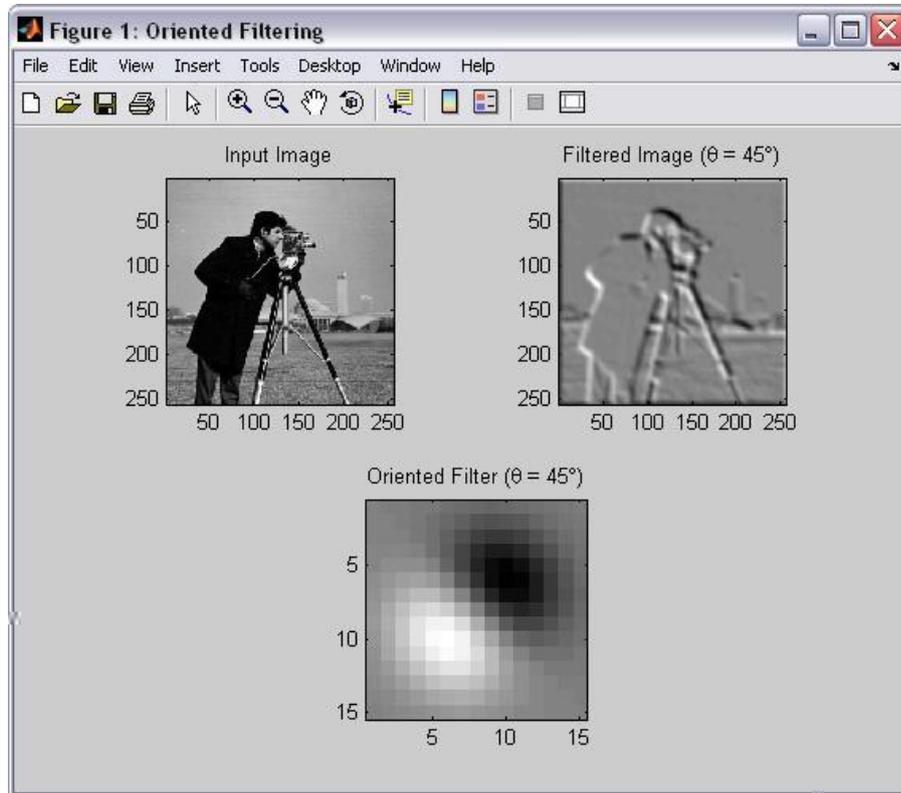


FIGURA 5: Comparativo de uma imagem submetida a SF (LANMAN, 2006).

3.1.3. Projeção integral (PI)

Diferente dos filtros anteriores, esta técnica tem como objetivo a obtenção de um arranjo linear da imagem associado a cada eixo, podendo ser uma Projeção Horizontal (PH) ou projeção vertical (PV). As funções utilizadas para construção da PI estão referenciadas abaixo:

$$PH(y) = \sum_{i \in x_y} I(i, y) \quad (\text{Eq. 4})$$

$$PV(x) = \sum_{i \in y_x} I(x, i) \quad (\text{Eq. 5})$$

Existe uma contrapartida na utilização destes tipos de técnicas, quando se trabalha com imagens de TD, em que as direções de projeção que se destacam não são paralelas aos eixos principais da figura, para tanto, realiza-se a técnica de Projeção Diagonal (PD), o qual faz uso de uma imagem rotacionada em 45° ou -45° e recortada na sua porção central, então a imagem é submetida a uma PH.

3.1.4. Conversão de escalas

A conversão de escalas utiliza combinações lineares para converter os valores de uma matriz para outra equivalente. Neste estudo foram utilizados dois tipos de conversão de escalas. A primeira corresponde a conversão de RGB para NC, os quais os pixels de uma imagem colorida são convertidos para preto e branco, porém sem prejuízo de informação. Em uma imagem colorida, cada pixel é uma combinação de intensidade de três canais que tradicionalmente podem assumir valores de 0 a 255. A conversão para NC se dá basicamente pela combinação linear do resultado da intensidade em cada canal em uma escala de 0 a 1, ou seja, o valor anterior dividido por 255.

A segunda conversão é a normalização de escalas, etapa final do processo de pré-tratamento de imagens, o qual a matriz que concatena o agrupamento final de arranjos de dados é adequada a uma escala em que os valores são divididos pela variação máxima observada no conjunto.

3.2. Técnicas de processamento de imagens

Dotado dos dados de pré-processamento, o processo de AM pode finalmente ser aplicado. Não há uma técnica mais eficaz para todas as situações, por isso se faz necessário uma análise comparativa fazendo uso de métricas de avaliação conforme o objetivo a que se destina. No processo de AM de classificação supervisionada, o algoritmo é capaz de processar um conjunto de dados de treinamento e, assim, retornar a previsão de outro conjunto, também previamente classificado (MURÇA, 2020, f).

Os resultados podem ser melhor organizados em forma de tabela, denominada matriz de confusão, ela confronta a quantidade de elementos do conjunto de teste que foram classificados corretamente ou não, em cada classe. Para uma classificação binária, a matriz de confusão tem a dimensão 2×2 , onde os elementos estão dispostos nos subconjuntos de: verdadeiro positivo (tp), falso positivo (fp), falso negativo (fn) ou verdadeiro negativo (tn). Enquanto para n classes, ela tem dimensão $n \times n$. Os resultados mais procurados são os que estão localizados na diagonal principal da matriz de confusão, pois se referem às quantidades de elementos do conjunto de teste corretamente classificados pelo processo de AM.

A soma da diagonal principal dividida pela quantidade total de previsões corresponde a acurácia da previsão, essa métrica é a mais relevante ao verificar o desempenho final de um processo de AM, porém ela pode não ser a mais adequada em certas situações. Supondo-se que a previsão possa ser considerada um processo enviesado, fazendo com que, embora a acurácia

possa ser alta, uma das classes tenha tido qualidade de previsão deixando a desejar. Para isso, é preciso uma métrica que avalie o desempenho de previsão individual de cada classe, sendo elas a precisão e a revocação, enquanto que o *F1-score* é a média harmônica de ambas.

$$\text{Acurácia} = \frac{tp+tn}{tp+tn+fp+fn} \quad (\text{Eq. 6})$$

$$\text{Precisão} = \frac{tp}{tp+fp} \quad (\text{Eq. 7})$$

$$\text{Revocação} = \frac{tp}{tp+fn} \quad (\text{Eq. 8})$$

É importante salientar que as Equações 6, 7 e 8, acima, são válidas em um processo de classificação binário, para três ou mais classes, a precisão, a revocação e o *F1-score* devem ser calculados para cada classe independentemente. A única métrica que analisa o processo globalmente é a acurácia (BRANCO, 2016).

3.2.1. Componentes principais (CP)

Inicialmente o conjunto de dados pré-processados de n imagens de mesma resolução pode ser encarado como uma matriz de n linhas, em que cada arranjo vertical pode ser entendido como um vetor de uma base vetorial específica. É conhecido da álgebra linear, que qualquer conjunto de vetores linearmente dependentes pode ser reduzido sem prejuízo de representação. Porém como os arranjos trabalhados são longos, dificilmente haverá algum conjunto com essas características específicas, no entanto algumas adaptações podem ser aplicadas ao passo que se utiliza uma métrica para mensurar a quantidade de informação da base vetorial que se perde (RASCHKA, 2015).

Assim, realiza-se a mudança de base do conjunto de vetores para a base que representa os vetores dos Componentes Principais (CP) daquela dimensão, à métrica descrita se denomina de Proporção de Variância Explicada (PVE). Os CP da base são ordenados conforme a PVE e assim, calcula-se a PVE acumulada para que possa se reduzir a dimensionalidade da base vetorial com uma margem conhecida e tolerável de perda de informações (MURÇA, 2020, a).

Com essa técnica de redução de dimensionalidade da base de dados, o conjunto pode ser reduzido substancialmente com baixo prejuízo de processamento de dados.

3.2.2. Árvore de decisão (CART)

A árvore de decisão pode ser definida como sendo uma estrutura hierárquica formada por um conjunto de regras utilizadas sequencialmente com fins de tomada de decisão. O algoritmo de CART, portanto, é uma rotina computacional com potencial de construir um modelo de árvore de decisão que pode ser utilizada para a previsão de classes dado um certo atributo (WITTEN; FRANK; HALL, 2011).

O algoritmo processa os dados de maneira que realiza o particionamento recursivo do espaço de entrada de atributo de modo a maximizar a homogeneidade da partição resultante. Para avaliar a homogeneidade de uma partição ou a impureza dos nós resultantes de um particionamento, é utilizada uma métrica quantitativa, sendo a mais frequente o índice de Gini. Um processo de poda da árvore pode ser utilizado com fins de evitar erros de sobreajuste de classificação (MURÇA, 2020, b).

3.2.3. K-ésimo Vizinho mais Próximo (KNN)

O algoritmo do KNN procura mapear uma base de dados de treinamento de modo a construir uma fronteira de decisão com formato arbitrário que segrega as classes atribuídas a cada elemento. A previsão de uma classe é dada pela avaliação dos k-vizinhos mais próximos de dado elemento, a classe mais frequente é, portanto, aquela atribuída (MURPHY, 2012).

Para que se inicie o processo, requer-se a definição de dois parâmetros que vão reger as métricas de modelagem, sendo eles o número de vizinhos mais próximos (k) e uma função de distância (ie. Euclidiana, Manhattan, Hamming, etc). A escolha da função de distância é arbitrária e depende do tipo de atributo, para classes categóricas a função de Hamming pode ter a melhor utilização. Para evitar que um atributo seja incorretamente metrificado na função de distância, os dados devem ser normalizados de tal forma que os atributos tenham média nula e variância unitária (MURÇA, 2020, c).

O parâmetro arbitrário k deve ser avaliado por meio de um processo de validação cruzada, ou seja, vários modelos devem ser criados com diferentes valores, aquele que minimiza o erro deve ser escolhido com fins de otimização do algoritmo.

3.2.4. Máquina de vetores de suporte (SVM)

Diferentemente dos métodos de KNN e CART, o SVM utiliza um processo paramétrico para definir o aspecto da fronteira de decisão de classes no espaço de atributos. A hipótese do SVM é de um processo de classificação linear, ou seja, existe um hiperplano a ser atribuído como fronteira de decisão linear com fins de separar as observações de diferentes classes.

Formalmente, o método SVM constitui-se na determinação do hiperplano ótimo que vai maximizar a margem de separação entre as classes. Esta margem é definida como sendo a distância entre o hiperplano e a observação de cada classe mais próxima, os chamados vetores de suporte (RASCHKA, 2015).

Há dois principais problemas que a hipótese linear pode ocasionar, o primeiro é a existência de dados não muito bem separáveis por uma fronteira de decisão linear, o que pode ser expresso como sendo ruído. Além disso, os dados podem-se comportar como um espaço de classificação de fronteira não linear. A solução para o empecilho é introduzir variáveis de folga na métrica de distância das observações ao hiperplano, de tal maneira haja a flexibilização das restrições do problema de otimização. Enquanto que para o segundo empecilho do espaço de classificação, a solução é mapear a região para outro espaço de maior dimensão, em que as classes são linearmente separáveis (MURÇA, 2020, d).

3.2.5. Redes Neurais (ANN)

O modelo matemático de um neurônio artificial consiste em uma unidade que recebe atributos de entrada, processa os valores e, por fim, retorna um atributo de saída. Em ciência de dados, o processamento dos valores se dá pelo cálculo de soma ponderada dos atributos de entrada, somado a um *bias* e convertido por uma função de ativação arbitrária. A rede neural, em resumo, é uma sequência de camadas constituídas por uma malha de neurônios, de tal maneira que cada camada recebe os atributos de saídas da camada anterior, e assim sucessivamente (RASCHKA, 2015).

A primeira camada de uma rede neural tem uma quantidade de neurônios igual a quantidade de atributos de entrada do conjunto de dados, nas camadas intermediárias (escondidas) o número de neurônios é arbitrário, obtido tipicamente por um processo de validação cruzada. Por fim, a última camada, tem uma quantidade de neurônios compatível com a quantidade de classes do conjunto de dados, em problemas de classificação binário ou de regressão, a camada de saída tem apenas um neurônio (MURÇA, 2020, e).

4. Metodologia

Inicialmente foi feita uma revisão da literatura em relação a processos de AM envolvendo análise de defeitos em pavimentos. Então, buscou-se um banco de imagens com características interessantes às pretensões em estudo, que estão detalhadas a seguir:

- Quantidade elevada de amostras em cada classe de caracterização;
- Resolução adequada;
- Padronização uniforme em relação a distância de superfície e iluminação.

Os critérios 1 e 2 são subjetivos e não podem ser pré-determinados a rigor, uma vez que só é possível impor critérios mais rigorosos quando se obtêm resultados preliminares. O que se pode afirmar é que quanto maior a quantidade de amostras melhor a qualidade do treinamento, uma vez que os algoritmos de AM utilizados irão adequar-se melhor às diferentes características aleatórias que uma classe de dados possa vir a apresentar. A resolução, no entanto, tem uma faixa adequada de trabalho, uma vez que, embora o processamento de dados de imagens em alta resolução possa trazer alto grau de precisão ao modelo, irá também alocar poder computacional dispendioso em relação ao nível de aumento de precisão comparado ao modelo baseado em imagens de resolução ligeiramente inferior.

Por fim, o critério 3 é necessário, visto que para que se possa variar substancialmente as características da obtenção de imagens, dever-se-á aumentar bruscamente a quantidade de amostras utilizadas, além que sejam uniformes nas variabilidades apresentadas, ou seja, para cada amostra do tipo 1, em um conjunto de dois tipos, deverá haver aproximadamente o mesmo número de amostras do tipo 2.

4.1. Características do conjunto de dados

O conjunto de dados contém imagens de superfícies de concreto com ou sem trincas. Os dados são coletados de vários edifícios do Campus METU. Dividido em duas classes de imagens, as de fissuras negativas ou positivas com fins de classificação. Cada classe possui 20.000 imagens, no total de 40.000 imagens com 227 x 227 pixels com canais RGB. O conjunto de dados é gerado a partir de 458 imagens de alta resolução (4032x3024 pixels) com o método proposto por Zhang et al (2016) e desenvolvido por Özgenel (2018). É válido destacar que as imagens de alta resolução podem variar em termos de acabamento de superfície e condições de iluminação, além disso nenhum aumento de dados em termos de rotação ou inversão aleatória é aplicado.

4.2. Organização do conjunto de dados

A primeira etapa de elaboração do modelo de AM é desenvolver uma rotina computacional capaz de distinguir imagens com ou sem a presença de trincas e outra rotina capaz de classificar as imagens de modo a diferenciar o tipo de trinca presente, sendo as três classes trabalhadas neste estudo a TD, TT e TL. Para tanto, reservou-se do conjunto de dados quantidades de imagens que se julgou ser suficiente para o treinamento do modelo em questão. Com fins de facilitar o entendimento, as classificações da primeira etapa são designadas 1 ou 2 (com ou sem trinca), enquanto que da segunda etapa 1, 2 ou 3 (TD, TT e TL), respectivamente.

Sendo assim, na construção da primeira etapa, destinou-se um diretório do sistema contendo 1000 imagens selecionadas aleatoriamente do conjunto de 20.000 imagens classificadas com defeito. Outro diretório com mesmas características também foi reservado para imagens classificadas sem defeitos.

Para a segunda etapa, reservou-se três diretórios do sistema, cada um contendo um conjunto de 500 amostras oriundas do conjunto de 20.000 imagens classificadas com defeito. Cada diretório representa uma classe de defeito o qual se deseja obter distinção.

Na Figura 6 observa-se um organograma representativo das etapas classificatórias.

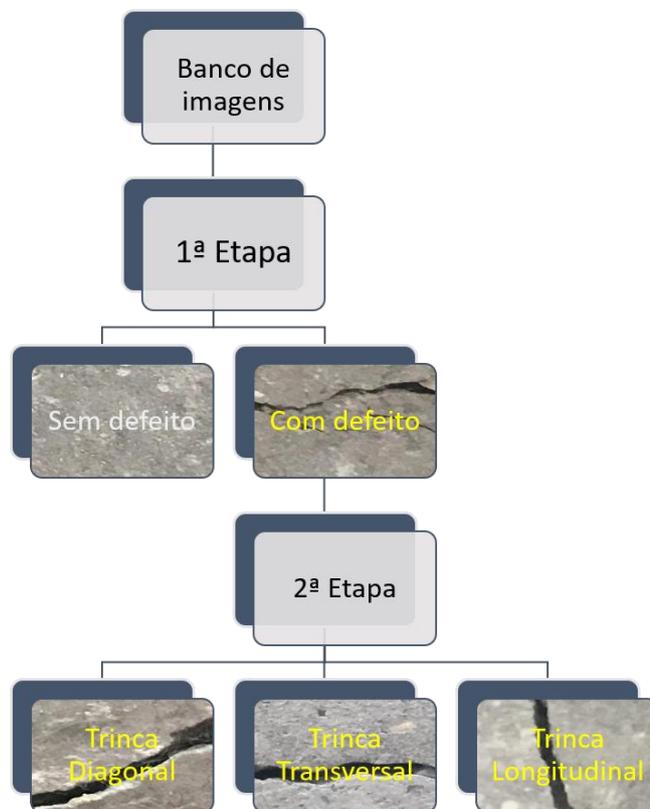


FIGURA 6: Etapas classificatórias.

4.3. Pré-tratamento de imagens

Realizou-se uma sequência de técnicas a fim de converter os dados em formato de pixel em arranjos de valores potencialmente mais eficientes no desenvolvimento do processo de AM.

Com o suporte da ferramenta computacional MATLAB®, rotinas computacionais foram desenvolvidas com a intenção de realizar o pré-processamento. No que se refere às transformações, funções foram implementadas para realização do SF e PI, enquanto que o FSB utilizou-se de uma função pré-definida do sistema, assim como a conversão de escalas, a fim de se trabalhar em NC no lugar da escala de pixels original, em RGB.

4.3.1. A técnica de pré-processamento

As técnicas de conversão sequencialmente aplicadas a cada imagem a ser trabalhada na construção do modelo são enunciadas a seguir:

- Conversão de escalas, RGB para NC;
- Aplicação do FSB;
- Aplicação do SF;
- Aplicação da PI;
- Normalização de escalas.

Na utilização do FSB, calcula-se a variância de valores, de uma porção arbitrária da imagem, no tamanho de 50 x 50 pixels. Este valor é utilizado como parâmetro da função “`imbilatfilt`”, algoritmo proprietário da ferramenta computacional MATLAB.

Na utilização do SF, utilizou-se o parâmetro ajustável no valor de $r = 1.2$, enquanto que o direcionamento θ variou no conjunto de argumentos de 0 a 360°, em passo de 30°.

Realizando-se o conjunto de técnicas para uma imagem específica do conjunto de dados, a rotina computacional armazena o retorno do arranjo de dados correspondente na forma de uma linha de matriz de tal forma que cada novo arranjo da sequência é armazenado na linha subsequente. Na necessidade de agregar atributos à matriz de dados, a última coluna corresponde a informação referente a classificação pré-definida atribuída à imagem original, essa informação é passada na forma de um número inteiro. No que se refere à primeira rotina atribui-se 1 ou 2 referentes às classes de com defeito (positiva) ou sem defeito (negativa), respectivamente. À segunda rotina, atribui-se 1, 2 ou 3 como sendo referentes às classes TD, TL e TT, respectivamente.

4.4. Tratamento de dados

Em posse das matrizes de dados referentes ao pré-processamento do conjunto de imagens a ser trabalhado. Com o suporte da ferramenta computacional RStudio®, rotinas computacionais foram desenvolvidas com a intenção de realizar o tratamento de dados.

4.4.1. Decomposição em CP

Como descrito em 4.3.1, os dados trabalhados no processamento estão na forma de matrizes de dados sobrepostos. As imagens do banco em questão são compostas por um conjunto de 227 x 227 pixels e, ao se realizar a PI em cada um dos eixos (vertical, horizontal e diagonal), obtêm-se um arranjo de 774 dados referentes a cada imagem. A partir de então, o conjunto de todos os arranjos de imagens do banco a ser trabalhado pode ser entendido como vetores de um espaço vetorial arbitrário.

A técnica de CP visa reduzir a dimensionalidade desse conjunto a fim de otimizar os processos computacionais. No tratamento do conjunto de dados deste estudo, pode-se observar que, de acordo com a métrica de PVE acumulada, a quantidade de CP a ser empregada restringe-se a 29, caso almeje-se trabalhar com PVE acumulada de mais de 95%, enquanto que se restringe a 42, caso almeje-se mais de 99%.

Visando-se melhores resultados, neste estudo optou-se por utilizar o número de CP como sendo 45, o que corresponde a, cerca de PVE acumulada de 99,8%. Na Figura 7 a seguir, verifica-se melhor como se comporta a relação do PVE. É válido salientar, que após a decomposição da imagem em CP, o estudo restringiu-se a trabalhar a base de dados com esses 45 primeiros CP do conjunto de dados.

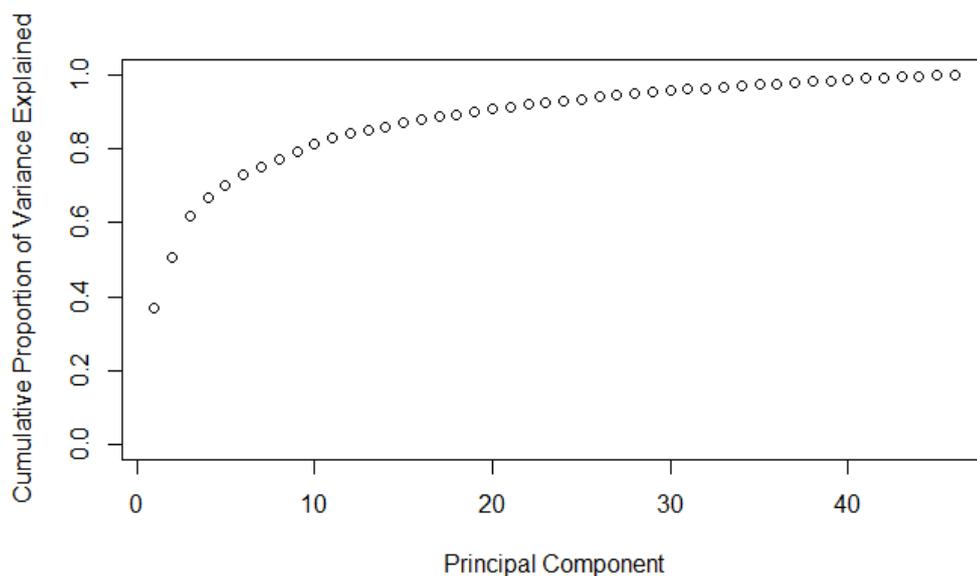


FIGURA 7: Relação de PVE acumulada para os 45 primeiros CP do conjunto de dados de imagens após realizado o pré-tratamento.

4.4.2. Divisão da base de dados

A fim de proceder-se com as técnicas de AM, que compõe os processos de treinamento e validação, o conjunto de dados passou por uma etapa de divisão aleatória na proporção de 70% para treinamento e 30% para validação. Os rótulos da primeira porção de dados servem para construção do modelo preditivo, enquanto que os da segunda servem para confirmação ou negação da previsão a ser realizada por esse modelo.

4.5. Métodos de classificação

Como descrito anteriormente, o tratamento de dados sucedeu-se sequencialmente aplicando-se as quatro técnicas de AM para o conjunto de dados de treinamento. O RStudio tem funções pré-estabelecidas para realização de cada uma, apenas os parâmetros de cada uma devem ser cuidadosamente selecionados com fins de construção de modelos melhores.

4.5.1. Modelo de CART

Conforme discutido, quando a árvore completa é gerada, incorre-se no risco de sobreajuste. Assim, é importante realizar um processo de validação para podar a árvore de decisão e reduzir a complexidade dela. Para isso, utilizou-se da função "cv.tree".

Para tanto, é necessário realizar um processo de validação cruzada K-fold a fim de obter-se árvores podadas de diferentes tamanhos a partir da árvore completa gerada inicialmente. Utiliza-se 10 partições (K=10) no processo de validação cruzada K-fold, a função `set.seed(1)` foi utilizada com o objetivo de gerar os mesmos números aleatórios para partição da base de treinamento em K-folds, de forma que o resultado possa ser replicado.

4.5.2. Modelo de SVM

O modelo de SVM tem como objetivo gerar um hiperplano capaz de segregar os diferentes atributos de classificação dentro do espaço de vetores em questão. Para tanto, é preciso definir-se dois parâmetros que irão conduzir o algoritmo na construção do modelo. O primeiro é o kernel, que estabelece a hipótese de disposição dos elementos dentro do hiperespaço, esse parâmetro visa contornar o primeiro problema discutido em 3.2.4.

O segundo parâmetro a ser definido é o custo, que é o peso atribuído aos atributos não completamente inseridos nas porções do hiperespaço segregados pelo hiperplano a ser construído, conhecido como termo de regularização na formulação de Lagrange.

Neste estudo, trabalhou-se segundo a hipótese de kernel linear, enquanto que o modelo teve melhor desempenho para uma função custo de valor 0,1.

4.5.3. Modelo de KNN

O modelo de KNN aplicado à base de dados em estudo teve a particularidade de eleger um valor de número de vizinhos mais próximos por meio do processo de validação cruzada K-fold a fim de avaliar o valor de k que denota o modelo de melhor desempenho preditivo. Para tanto, variou-se k num intervalo de 1 a 30 e registrou-se a acurácia da previsão para cada valor. Por fim, busca-se o modelo cujo índice representa o menor erro entre as demais.

4.5.4. Modelo de ANN

Em um modelo de ANN simples, as camadas de entrada e saída são de certo modo bem definidas, no entanto fica a cargo do desenvolvedor especificar a quantidade de camadas internas (escondidas). Além disso, definiu-se a função de ativação logística, uma função diferenciável usada para suavizar o resultado do produto vetorial da covariável ou neurônios e os pesos.

Para tanto, elaborou-se outro processo de validação cruzada K-fold a fim de avaliar a quantidade de camadas internas que denota o modelo de melhor desempenho preditivo. Para tanto, variou-se num intervalo de 2 a 10 e registrou-se a acurácia da previsão para cada valor. Por fim, buscou-se o modelo cujo índice representa o menor erro entre as demais.

Na Figura 8 observa-se um fluxograma representativo que resume a metodologia desenvolvida neste estudo

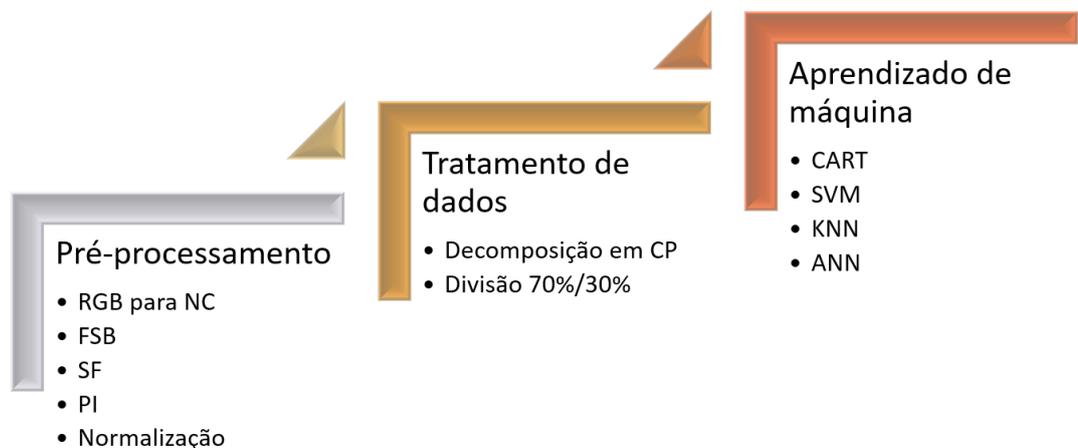


FIGURA 8: Metodologia desenvolvida.

5. Resultados

O processo de pré-tratamento e AM se deu em duas etapas cada um, a primeira voltada para identificação da presença ou ausência de defeitos, sendo, portanto, uma etapa inicial e necessária, visando o processo em seguida, que é a identificação das classes de trincas apresentados. Vale ressaltar, que embora os processos são imaginados como complementares, eles foram construídos de maneira independente neste estudo, dado que o conjunto de dados de entrada da segunda etapa não são os resultados positivamente identificados na primeira, mas sim conforme descrito em 4.2.

Além disso, a diferença básica no processamento das duas etapas é a quantidade de classes preditas final, enquanto na primeira há duas, na segunda há três. É válido ressaltar que o entendimento dos resultados irá diferir por causa da complexidade da matriz de confusão, uma vez que a métrica de F1 score não pode ser aplicada globalmente, mas sim a cada classe predita individualmente, por isso a acurácia tem sua importância ressaltada, uma vez que pode ser utilizada com fins comparativos diretamente.

5.1. Análise exploratória de dados

Conforme descrito em 4.4.1, o conjunto de dados foi convertido com a finalidade de trabalhar-se a partir dos CP de cada etapa. Nas Figura 9 e Figura 10, a seguir, verifica-se os gráficos bidimensionais da disposição de cada elemento e etapa, respectivamente, com atributos de classe adequadamente identificados por legenda, nas coordenadas dos dois primeiros CP. Esses gráficos são importantes ao passo que se verifica a existência branda de uma fronteira de decisão, ou seja, alguma separação no espaço dos vetores de CP.

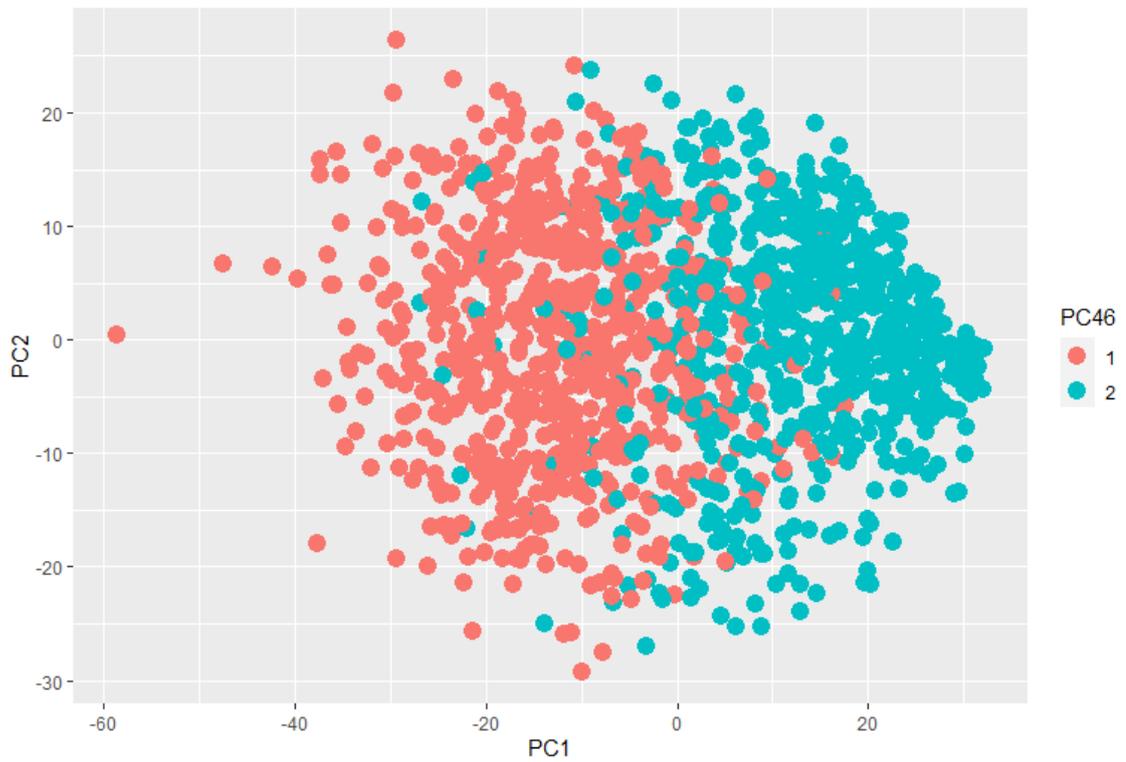


FIGURA 9: Disposição de elementos da primeira etapa de classificação no espaço vetorial dos CP.

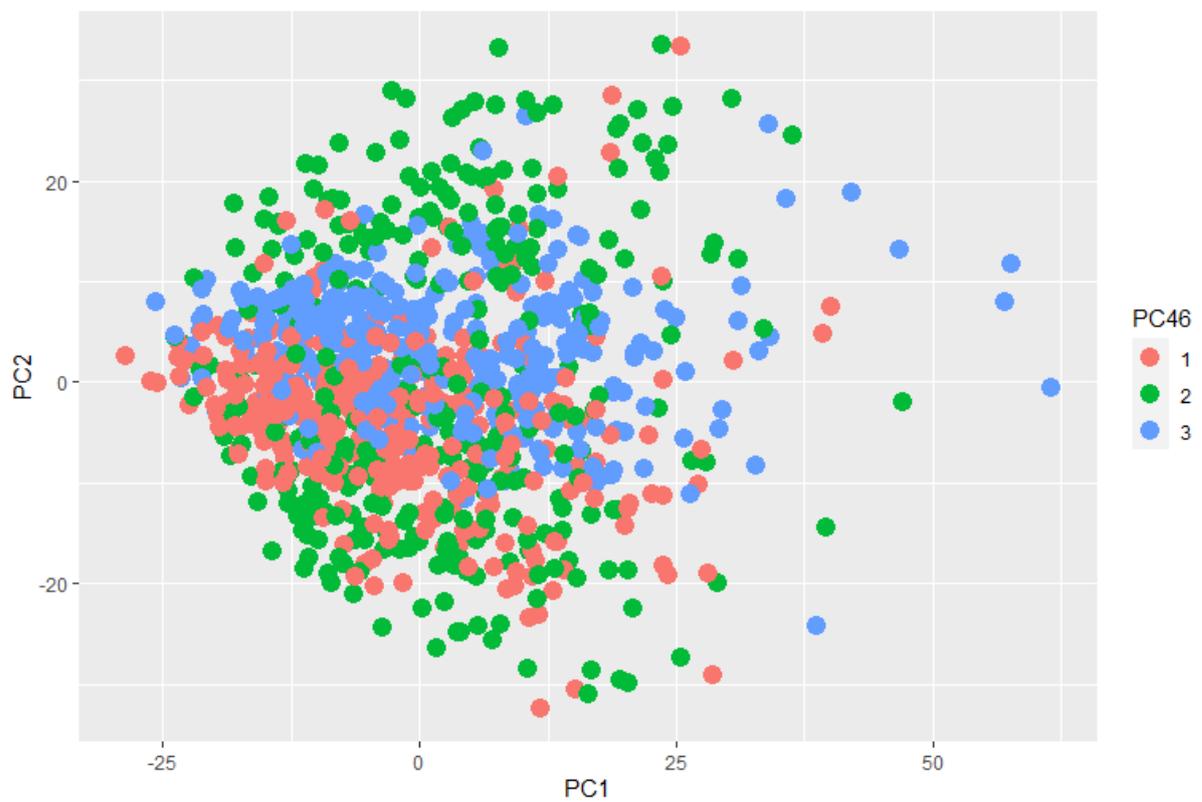


FIGURA 10: Disposição de elementos da segunda etapa de classificação no espaço vetorial dos CP.

5.1.1. PI

Em seguida, encontram-se os gráficos referentes a PI em cada eixo de projeção, diagonal 1 e 2, horizontal e vertical, nas Figuras 11, 12, 13 e 14, respectivamente, oriundo de alguns exemplos de imagens do banco de dados de treinamento. Para tanto, selecionou-se uma amostra de cada tipo, sendo a diagonal duas amostras cada, com o intuito de destacar graficamente a PI em cada respectivo eixo.

É válido destacar que até mesmo a análise gráfica simples consegue verificar o tipo de padrão de trinca a qual se refere a imagem, uma vez que há uma elevação acentuada na projeção de um eixo específico, fazendo com que esse pico indique claramente a classe à qual pertence o elemento.

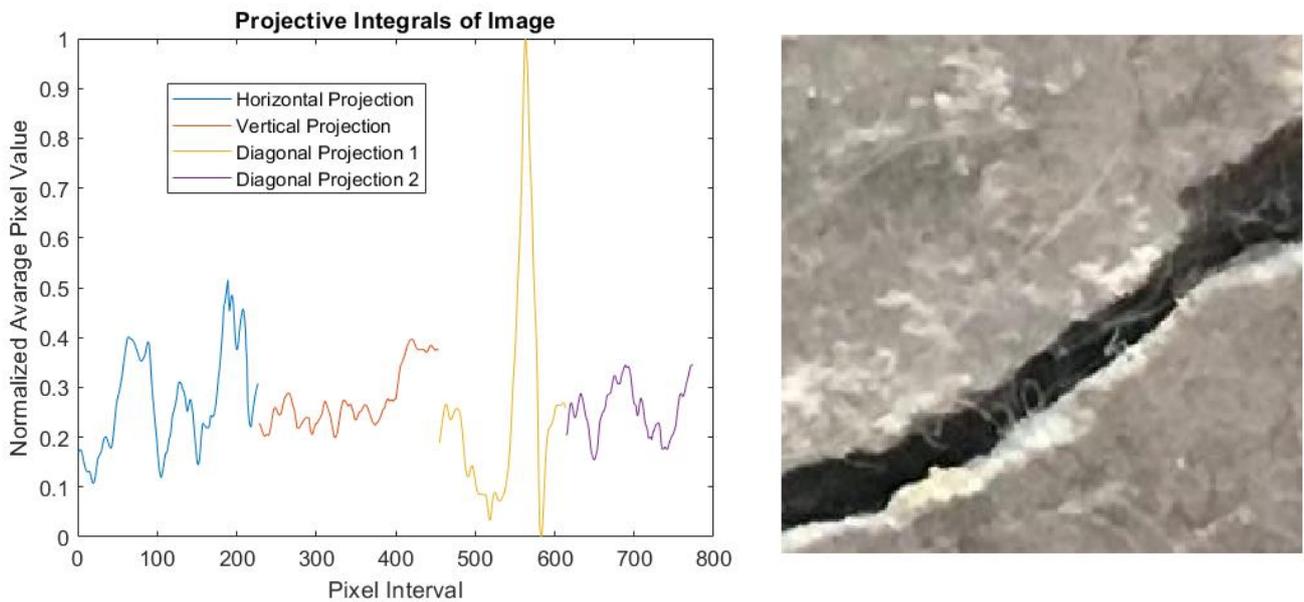


FIGURA 11: Gráfico resultante dos dados de pré-tratamento de uma amostra de imagem de TD tipo 1.

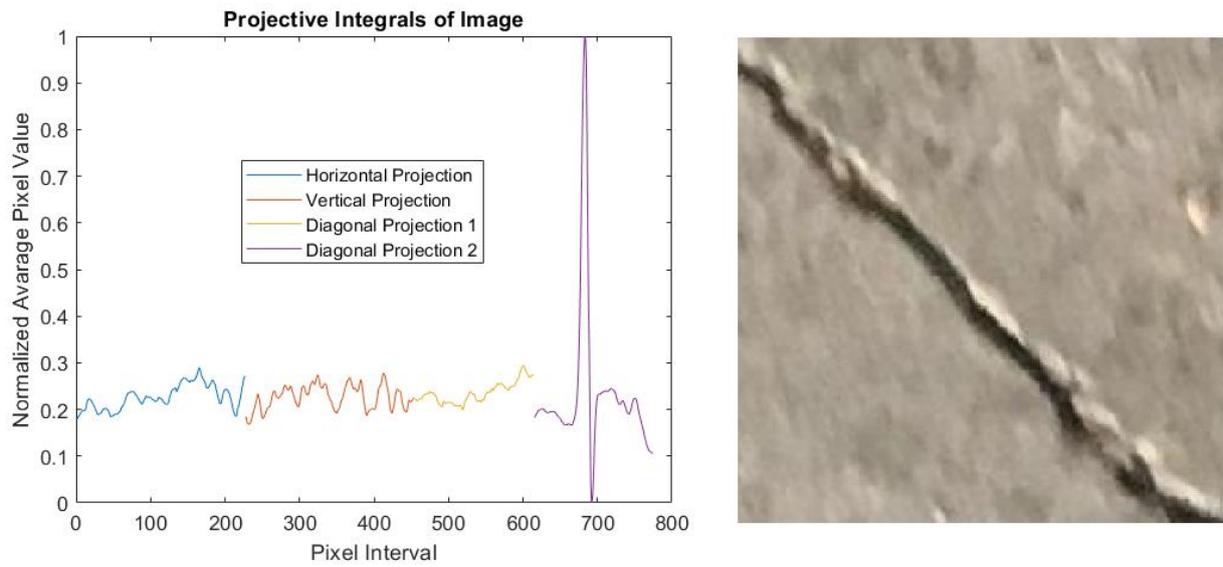


FIGURA 12: Gráfico resultante dos dados de pré-tratamento de uma amostra de imagem de TD tipo 2.

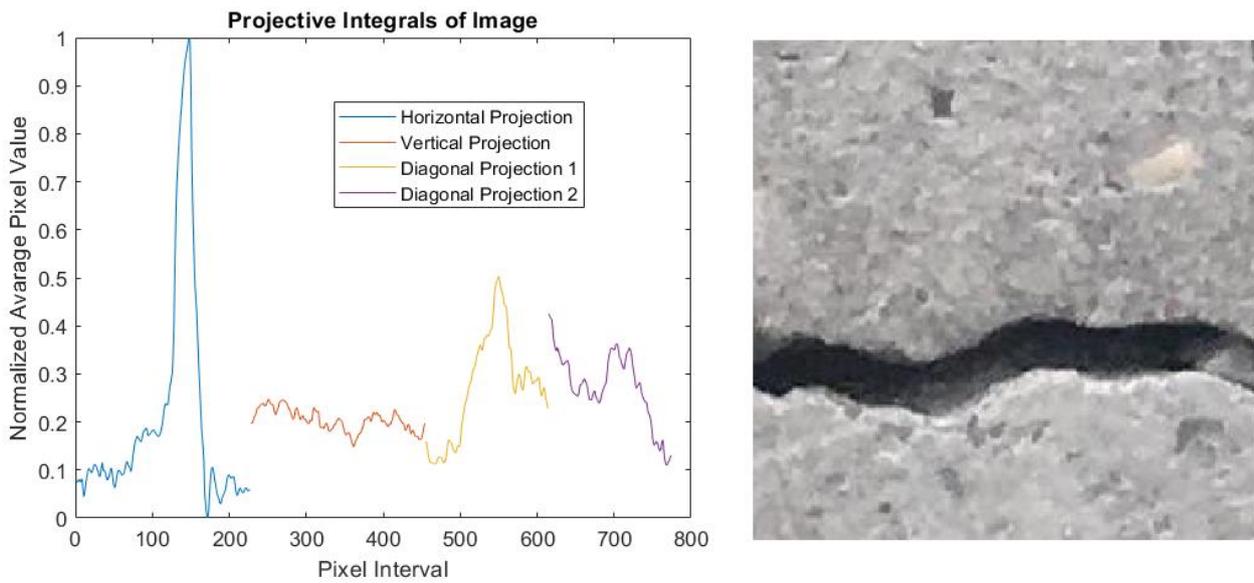


FIGURA 13: Gráfico resultante dos dados de pré-tratamento de uma amostra de imagem de TT.

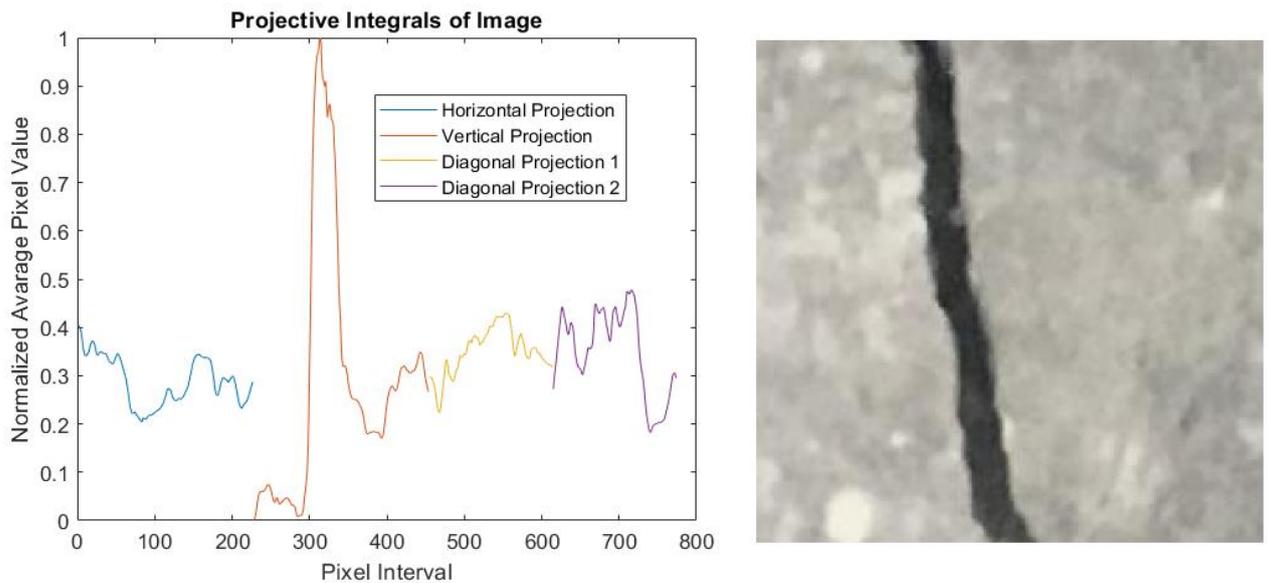


FIGURA 14: Gráfico resultante dos dados de pré-treatmento de uma amostra de imagem de TL.

5.1.2. CART

Inicialmente, busca-se a árvore cujo índice representa o menor erro entre as demais, para isso pode-se visualizar no diagrama da Figura 15 e Figura 16, respectivamente, a evolução do erro conforme variação do tamanho da árvore podada na primeira e segunda etapa, respectivamente.

Conforme descrito em 4.5.1, elaborou-se um processo de validação cruzada K-fold com fins de determinar o tamanho da árvore de decisão ideal em ambas as etapas. As árvores de cada etapa estão ilustradas no diagrama da Figura 17 e Figura 18, respectivamente, em que o critério de decisão a ser tomado será dado conforme a faixa de valores do CP de cada elemento a ser predito, cada ramo ou nó representa a decisão final adotada. Enquanto que na primeira etapa, o tamanho ótimo da árvore de decisão foi de 9 (nós), na segunda foi de 8. O desempenho da análise preditiva individual da segunda etapa pode-se observar no gráfico da Figura 19.

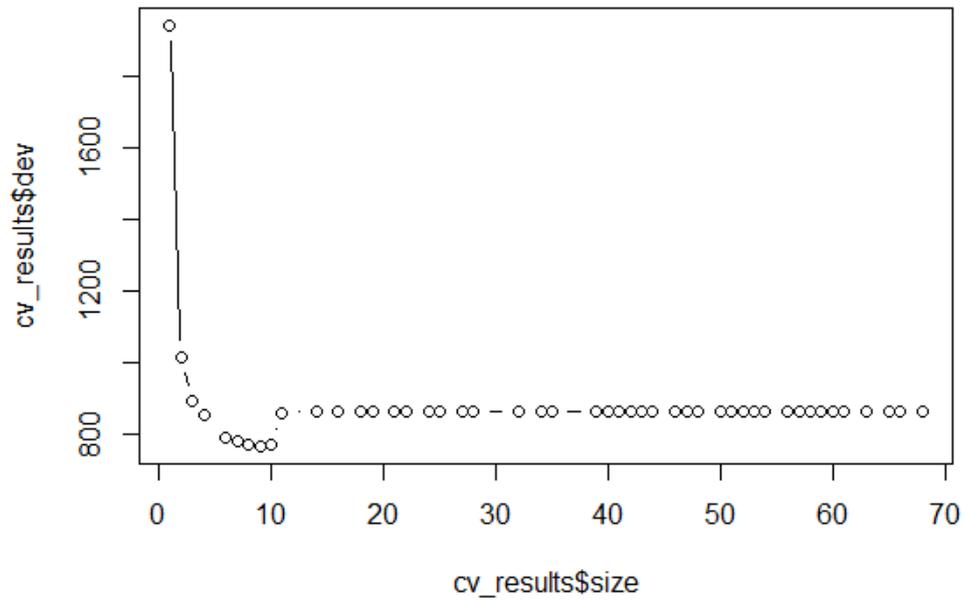


FIGURA 15: Relação de erro de classificação em função do tamanho da árvore de decisão da 1ª etapa.

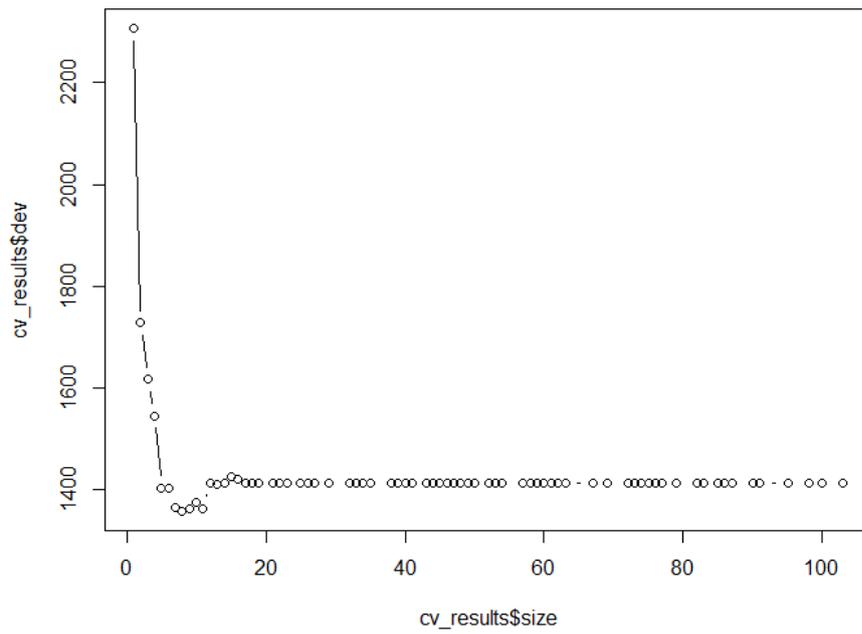


FIGURA 16: Relação de erro de classificação em função do tamanho da árvore de decisão da 2ª etapa.

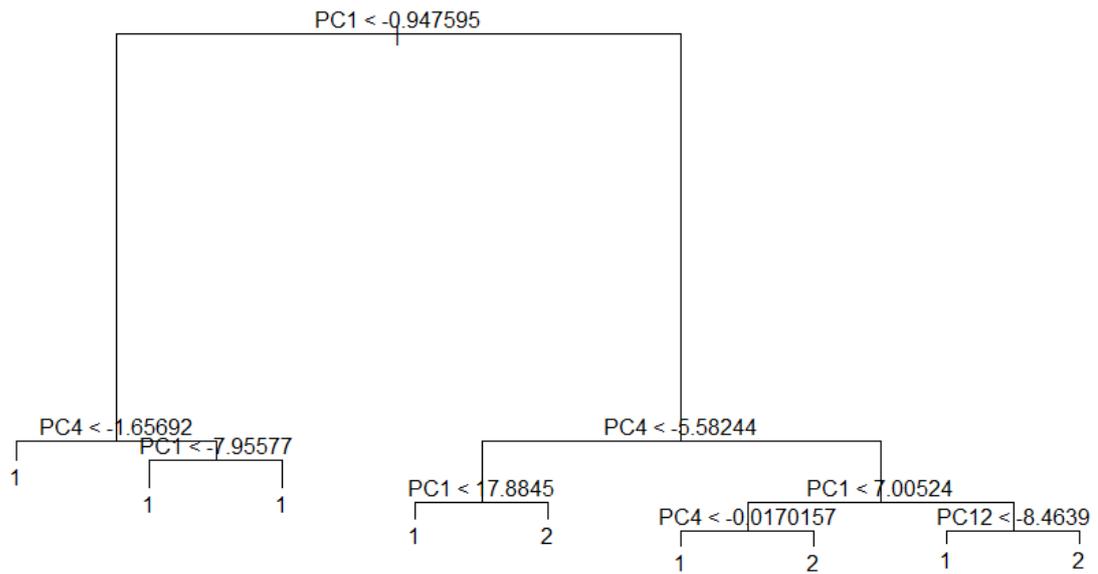


FIGURA 17: Diagrama representativo sequencial de tomada de decisão para classificação da primeira etapa.

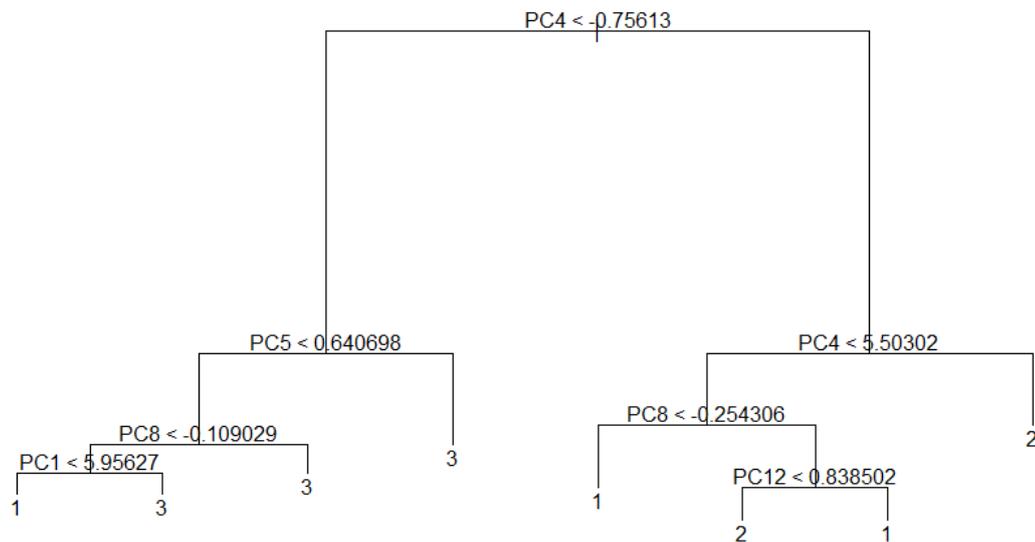


FIGURA 18: Diagrama representativo sequencial de tomada de decisão para classificação da segunda etapa.

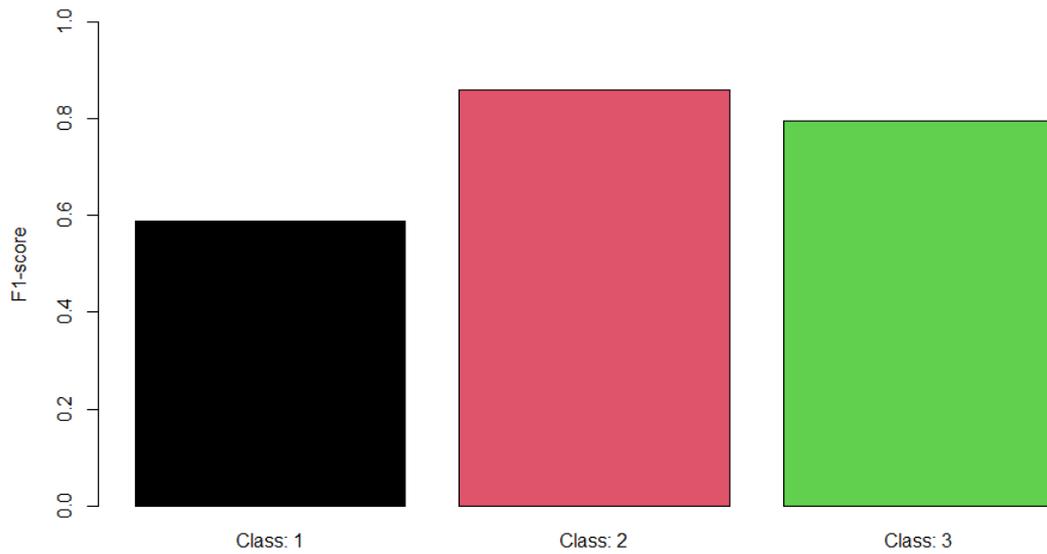


FIGURA 19: Comparativo do desempenho do método de análise preditiva de CART.

5.1.3. SVM

Conforme descrito em 4.5.2, elaborou-se a construção do modelo SVM, o desempenho da análise preditiva individual da segunda etapa pode-se observar no gráfico da Figura 20, a seguir. É válido ressaltar que a classe 2, assim como no modelo de CART teve o melhor desempenho.

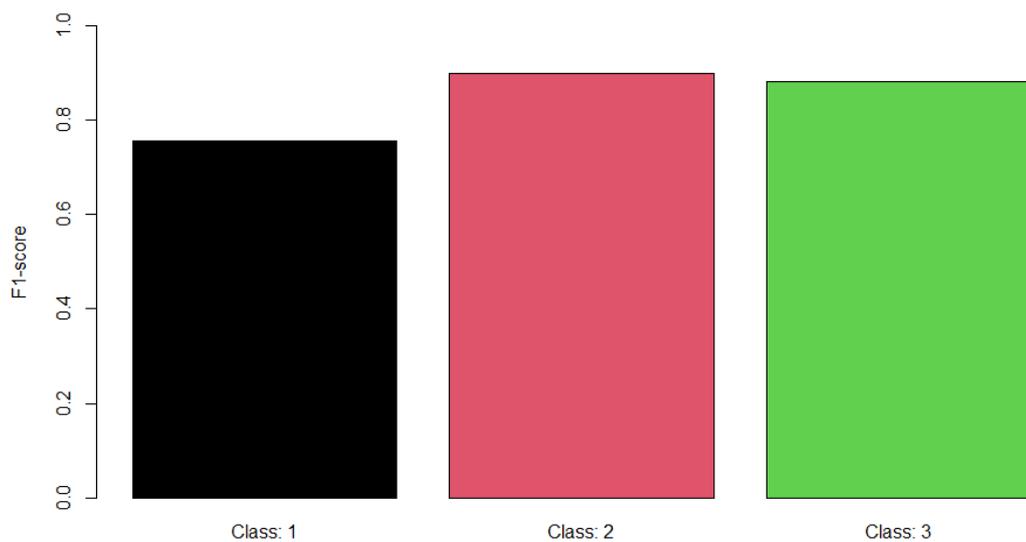


FIGURA 20: Comparativo do desempenho do método de análise preditiva de SVM.

5.1.4. KNN

Conforme descrito em 4.5.3, elaborou-se um processo de validação cruzada K-fold com fins de determinar a quantidade de vizinhos próximos ideal em ambas as etapas. A evolução da acurácia conforme variação do k , de cada etapa estão ilustradas no diagrama da Figura 21 e 22, respectivamente. Enquanto que na primeira etapa, a quantidade ótima de vizinhos próximos foi de 11, na segunda foi de 4. O desempenho da análise preditiva individual da segunda etapa pode-se observar no gráfico da Figura 21.

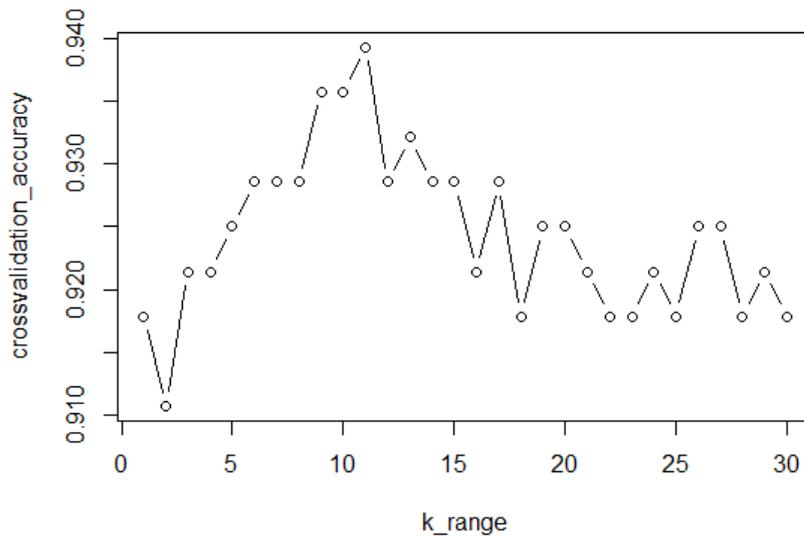


FIGURA 21: Relação da acurácia de classificação em função da quantidade de vizinhos mais próximos, 1ª etapa.

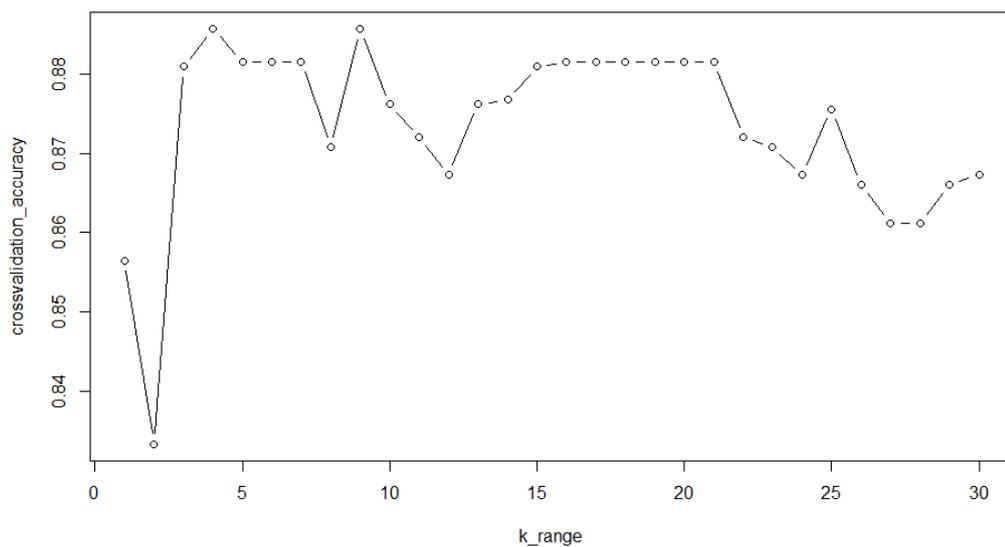


FIGURA 22: Relação da acurácia de classificação em função da quantidade de vizinhos mais próximos, 2ª etapa.

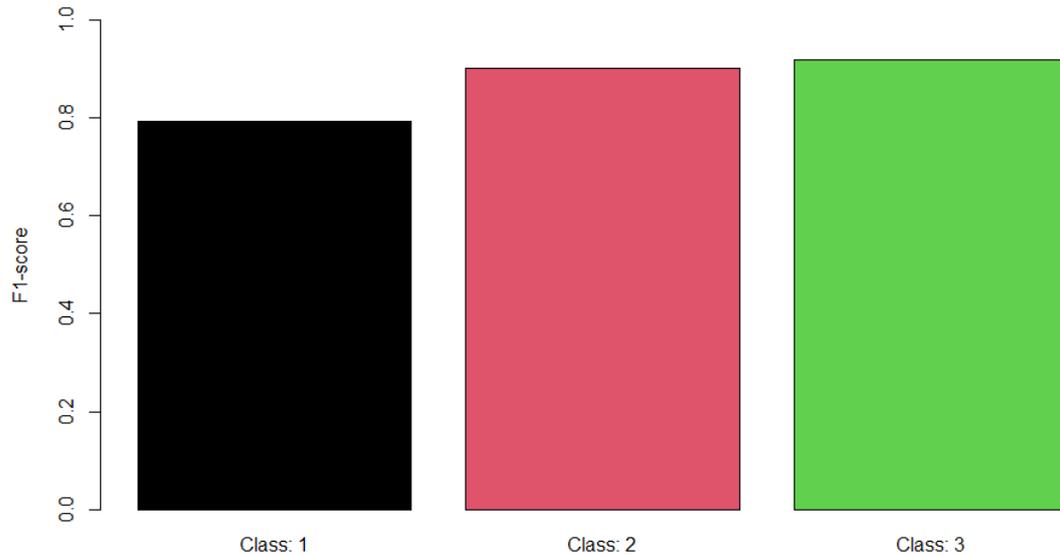


FIGURA 23: Comparativo do desempenho do método de análise preditiva de KNN.

5.1.5. ANN

Conforme descrito em 4.5.4, elaborou-se um processo de validação cruzada K-fold com fins de determinar a quantidade de camadas internas em ambas as etapas. A evolução da acurácia conforme variação do k , de cada etapa estão ilustradas no diagrama da Figura 24 e 25, respectivamente. Enquanto que na primeira etapa, a quantidade ótima de camadas internas foi de 3, na segunda foi de 5. O desempenho da análise preditiva individual da segunda etapa pode-se observar no gráfico da Figura 26.

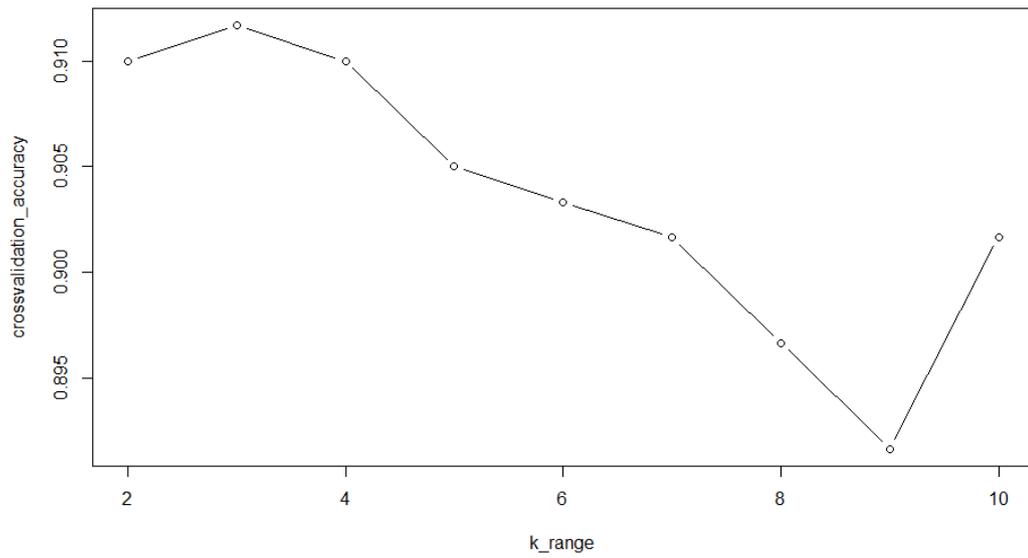


FIGURA 24: Relação da acurácia de classificação em função da quantidade de camadas internas, 1ª etapa.

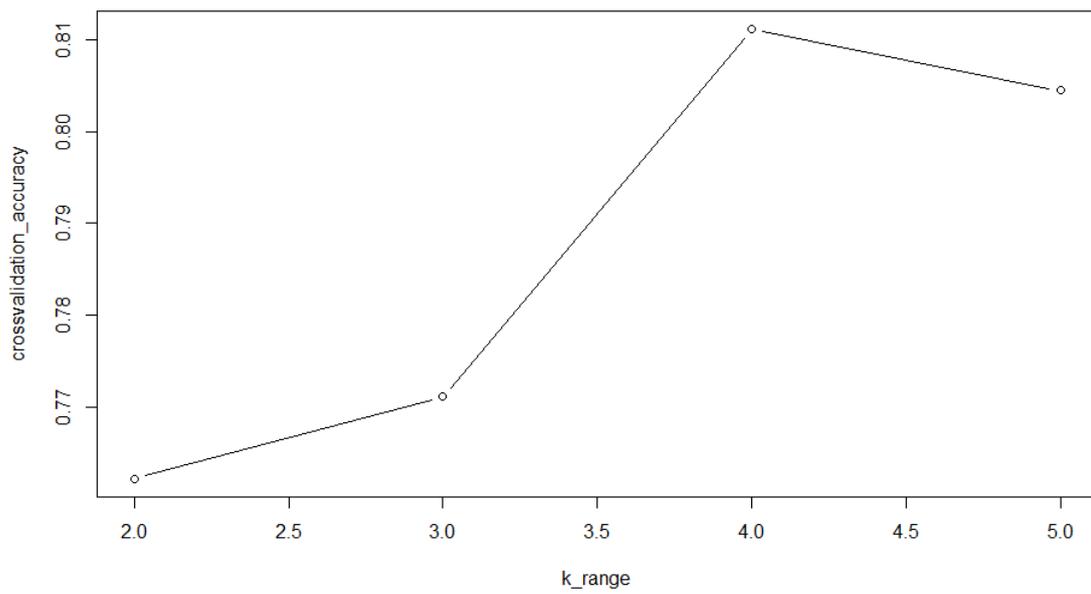


FIGURA 25: Relação da acurácia de classificação em função da quantidade de camadas internas, 2ª etapa.

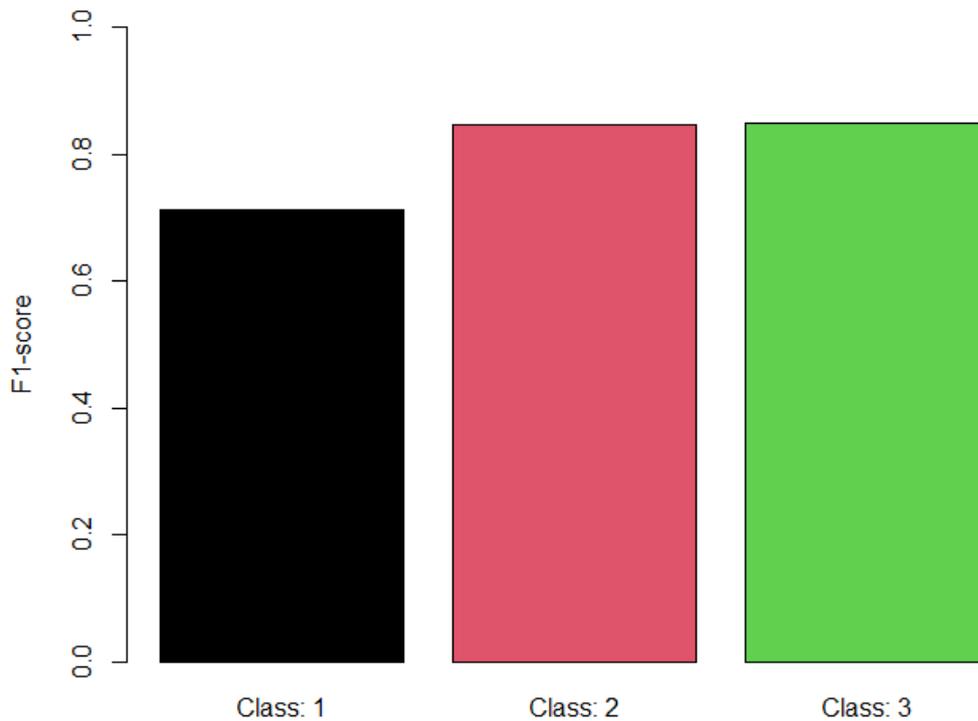


FIGURA 26: Comparativo do desempenho do método de análise preditiva de ANN.

5.2. Comparativo de desempenho

Como se pode observar no gráfico de barras da Figura 27 e 28, a seguir, cada método teve desempenho razoavelmente satisfatório na classificação final de ambas as etapas ao realizar análise comparativa por meio da acurácia total de classificação das classes.

A acurácia da 1ª etapa alcançou 93.5%, 91.83%, 90.83%, 89.67%, enquanto que da 2ª, 87.55%, 85.33%, 83.11%, 76.67%, respectivamente. Destaque, portanto, para o método de KNN, o qual obteve 93,5% e 87,5% de acurácia em ambas as etapas, respectivamente.

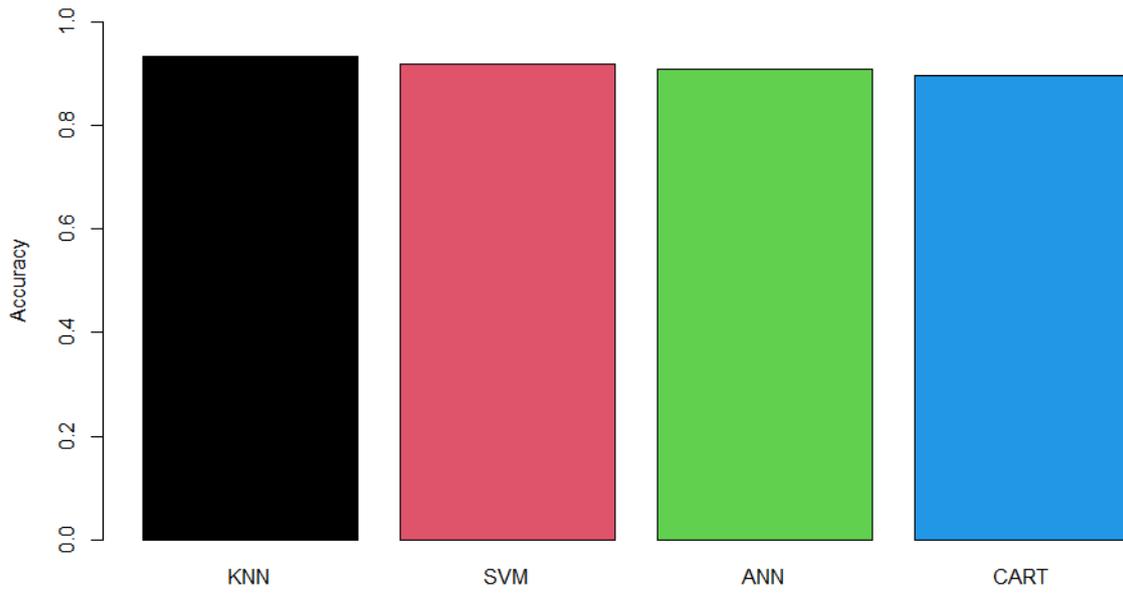


FIGURA 27: Comparativo de acurácia de classificação em função da técnica de AM, 1ª etapa.

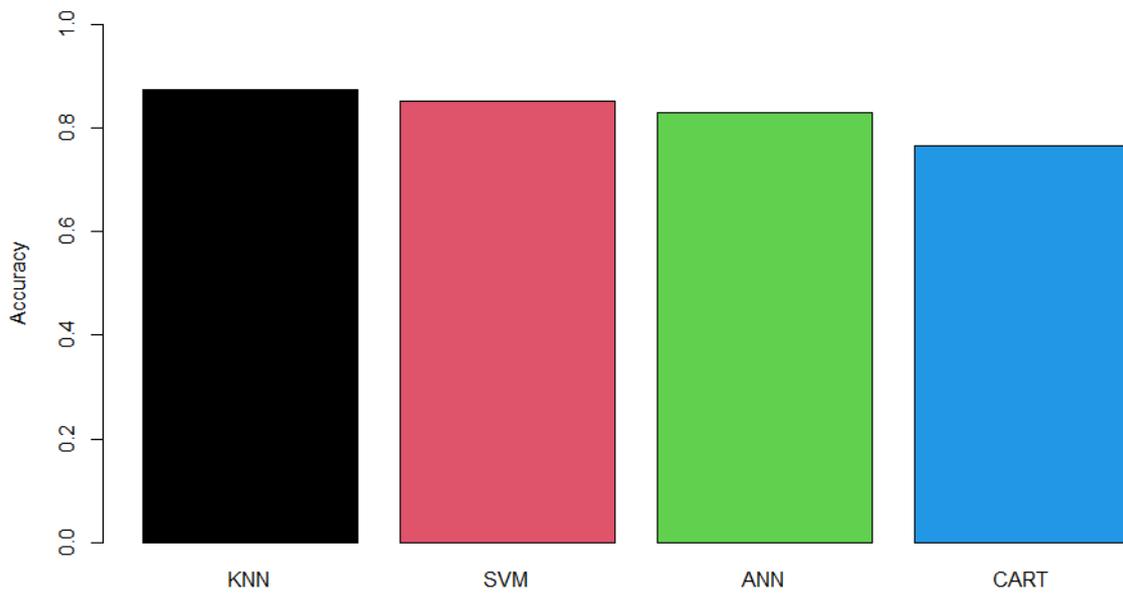


FIGURA 28: Comparativo de acurácia de classificação em função da técnica de AM, 2ª etapa.

5.2.1. Resultados do método KNN

Com os resultados de 4.2 é condizente eleger a técnica de KNN como sendo a melhor a ser utilizada neste estudo, no entanto, é indissimulável a existência de diversos erros de classificação. Verifica-se, a seguir, as Tabelas 1 e 2, as quais contêm os resultados numericamente descritos com fins de análise. Na matriz de confusão, as colunas que do identificador se remete à classe originalmente atribuída, enquanto que nas linhas, à classe predita. Por esse motivo, as classes corretamente classificadas estão presentes na diagonal principal, conforme descrito em 3.2.

TABELA 1: Matriz de confusão da predição realizada pelo método KNN sobre o conjunto de dados de teste na segunda etapa.

Predição	Classe		
	1	2	3
1	88	14	19
2	24	144	3
3	14	11	133

TABELA 2: Conjunto de métricas individualmente descritas para cada classe de predição.

Classe	Precisão	Revocação	F1 score	Acurácia
1	0,727	0,698	0,713	0,798
2	0,842	0,852	0,847	0,878
3	0,842	0,858	0,85	0,887

5.3. Visualização de erros

Esta seção tem como objetivo explorar as imagens que tiveram classes incorretamente atribuídas na segunda etapa de classificação, no intuito de avaliar visualmente o quão errado as previsões necessariamente estão divergindo da sua original atribuição. Na classificação das três classes da segunda etapa, cerca de 60 erros ocorreram (63 no total), imagens oriundas do conjunto de testes. Em cada imagem das Figuras 29, 30 e 31 estão as legendas das classes atribuídas, enquanto que entre parênteses está a classe original do elemento.

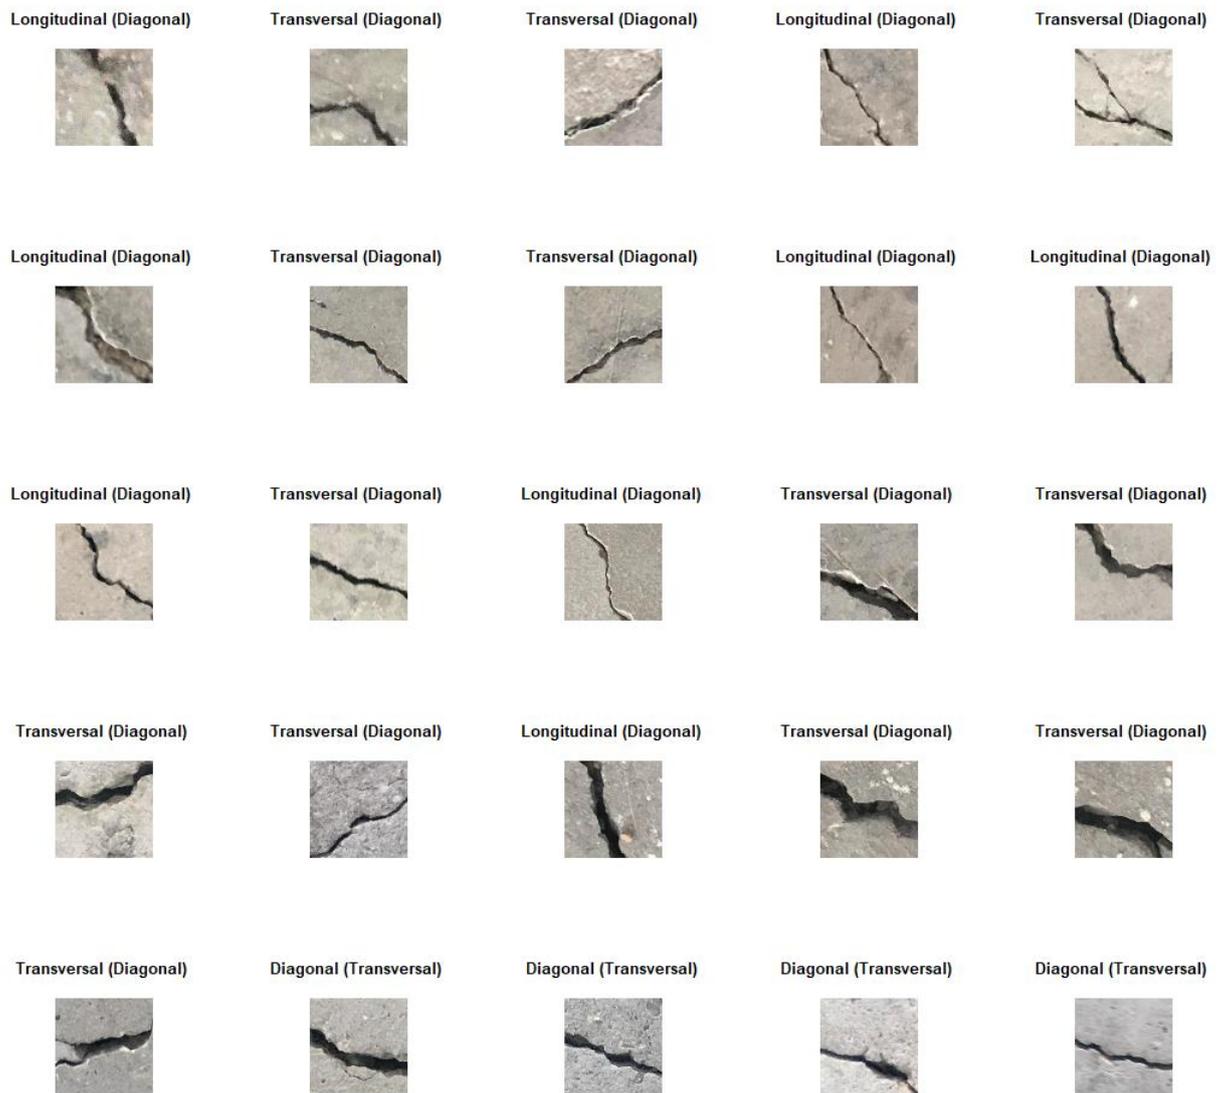


FIGURA 29: Conjunto das 25 primeiras imagens incorretamente classificadas na segunda etapa.

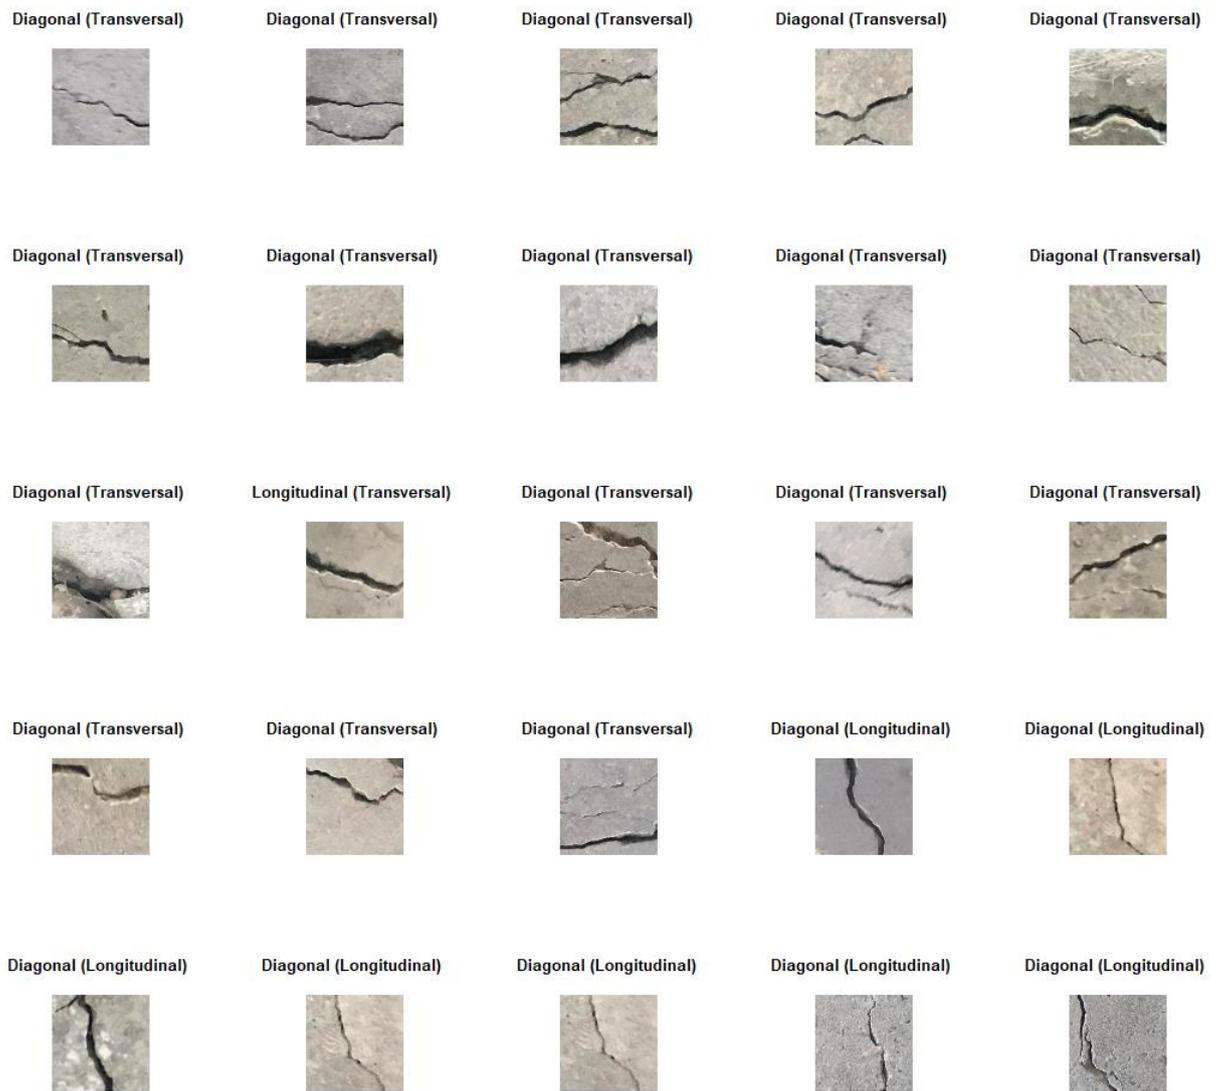


FIGURA 30: Conjunto das 25 imagens seguintes incorretamente classificadas na segunda etapa.

Diagonal (Longitudinal)



Diagonal (Longitudinal)



Diagonal (Longitudinal)



Diagonal (Longitudinal)



Diagonal (Longitudinal)



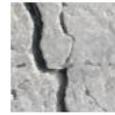
Diagonal (Longitudinal)



Diagonal (Longitudinal)



Diagonal (Longitudinal)



Transversal (Longitudinal)



Diagonal (Longitudinal)



FIGURA 31: Conjunto das 10 imagens seguintes incorretamente classificadas na segunda etapa.

6. Considerações finais

A análise exploratória de dados expôs características interessantes do conjunto de imagens, enquanto que as técnicas de processamento demonstraram que a decomposição dos dados em CP denota regiões razoavelmente distintas por fronteira de decisão, os gráficos de PI para diferentes tipos de imagem também deixaram claro as distinções entre elas no que se refere às projeções em cada eixo.

Ao trabalhar-se com os métodos de AM, cada um apresentou características próprias entre vantagens e desvantagens, enquanto que o método de SVM foi o de mais fácil aplicação por não depender de validação cruzada, o método ANN teve maior custo computacional frente aos demais. Ao processar-se a rotina computacional referente a ele a máquina teve que despende um tempo razoavelmente maior em relação às demais, outrossim no procedimento de validação cruzada ao variar-se a quantidade de camadas internas para além de 5 ocorreu uma divergência de dados no processamento, o que acarretou na impossibilidade do prosseguimento.

As técnicas de AM com fins de classificação desempenharam de modo plausível, com destaque para o KNN otimizado, o qual obteve 93,5% e 87,5% de acurácia em ambas as etapas, respectivamente. Além disso, pode-se afirmar assertivamente que a metodologia de validação cruzada K-fold melhorou significativamente a qualidade dos resultados finais, com exceção do SVM, o qual não foi aplicada.

No que se refere mais especificamente à capacidade individual das técnicas na distinção dos padrões de trincas, as classes 2 e 3 tiveram desempenho geral bastante similar, no entanto a classe 1 (TD), nas quatro técnicas de AM, teve pior desempenho. Esse resultado pode ser explicado pelo fato que as TD se apresentam de maneira mais divergente em relação umas às outras, ou seja, são mais diferentes entre si e acarretam maior dificuldade de predição de padronização, além disso as TD configuram-se em dois subconjuntos, as que são aproximadamente rotacionadas de 45° em relação ao eixo vertical no sentido horário ou anti-horário, essas características podem ser confirmadas ao realizar a análise comparativa das PI das Figuras 11 e 12.

Em suma, classificar imagens esbarra também na dificuldade de rotulação com padrões bem estabelecidos entre as classes. Como se pode observar nas Figuras 29, 30 e 31, apresentadas na seção 5.3, a maioria das classificações erradas deparam-se com situações de difícil enquadramento em padrões específicos, ou seja, mesmo o rótulo “correto” não é amplamente plausível, pois a trinca se manifesta com geometria não bem definida. Uma alternativa para contornar esses desvios é adotar um procedimento de classificação probabilístico em detrimento

da classificação determinística utilizada, em que se atribui uma probabilidade de enquadramento em cada classe de rotulagem e assume-se um percentual de erro inerente. Estudos futuros poderão fazer uso dessa sistemática caso se entenda ser útil para caracterização do conjunto de trincas de um sistema rodoviário.

Por fim, confirma-se a importância dos métodos apresentados neste estudo no âmbito da engenharia de pavimentos, frente a necessidade constante de realização e manutenção preditiva na infraestrutura de pavimentos, seja ele flexível ou não, uma vez que os efeitos de trincamento estão presentes nos diferentes tipos de composição, a maior distinção, portanto, seria no mecanismo de propagação e o método de intervenção, frentes que não foram abordadas devido ao direcionamento restrito a detecção. Outro padrão de trinca, que seria adequado a ser incluído, mas não abordado neste estudo foi o de CJ, visto que o banco de imagens disponível se restringiu apenas às três classes mencionadas, TD, TT e TL.

Essa metodologia, em conclusão, poderia ser estendida a qualquer área da engenharia que estivesse preocupada em abordar, por meio de fotografias, a detecção automatizada de padrões de trincas em superfícies estruturais.

Referências

AASHTO - **The AASHTO Guide for Design of Pavement Structures**. American Association of State Highway and Transportation Officials, Washington, D.C., 1986.

BRANCO, L. H. C. **MANIAC: uma metodologia para o monitoramento automatizado das condições dos pavimentos utilizando VANTs**. 191 p. Tese de Doutorado – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2016.

HOANG, N., NGUYEN, Q. **Automatic Recognition of Asphalt Pavement Cracks Based on Image Processing and Machine Learning Approaches: A Comparative Study on Classifier Performance**. *Mathematical Problems in Engineering*, v. 2018, p. 1–16, 2018.

LANMAN, D. **Steerable Gaussian Filters** - MATLAB CentralFile Exchange, 2006.
Disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/9645-steerable-gaussian-filters>>. Acesso em: 6 nov. 2021.

MURÇA, M. C. R. **Supervised Learning: Artificial Neural Networks**, TRA-48 Inteligência Analítica: Dados, Modelos e Decisões, dez. de 2020 (e). 14 f. Notas de Aula.

MURÇA, M. C. R. **Supervised Learning: Data Exploration & Visualization**, TRA-48 Inteligência Analítica: Dados, Modelos e Decisões, dez. de 2020 (a). 27 f. Notas de Aula.

MURÇA, M. C. R. **Supervised Learning: Decision Trees**, TRA-48 Inteligência Analítica: Dados, Modelos e Decisões, dez. de 2020 (b). 10 f. Notas de Aula.

MURÇA, M. C. R. **Supervised Learning: K-Nearest Neighbors**, TRA-48 Inteligência Analítica: Dados, Modelos e Decisões, dez. de 2020 (d). 5 f. Notas de Aula.

MURÇA, M. C. R. **Supervised Learning: Model Selection & Performance Evaluation**, TRA-48 Inteligência Analítica: Dados, Modelos e Decisões, dez. de 2020 (f). 17 f. Notas de Aula

MURÇA, M. C. R. **Supervised Learning: Support Vector Machines**, TRA-48 Inteligência Analítica: Dados, Modelos e Decisões, dez. de 2020 (c). 28 f. Notas de Aula.

MURPHY, K. P. **Machine learning: a probabilistic perspective**. [S.l.]: MIT press, 2012.

ÖZGENEL, Ç.F., SORGUÇ, A.G. **Performance Comparison of Pretrained Convolutional Neural Networks on Crack Detection in Buildings**, ISARC, Berlin, 2018.

RASCHKA, S. **Python machine learning**. 2015. Packt Publishing, 2015.

RODRIGUES, R. M. **Engenharia de pavimentos**. São José dos Campos: ITA, 2019 - 2020. 2 v.

SHAHIN, M. Y. **Asphalt Surfaced Airfields: Paver Distress Identification Manual**, US. Army Corps of Engineers, 2009.

TUTORIALS POINT. **OpenCV - Bilateral Filter**. Disponível em:
<https://www.tutorialspoint.com/opencv/opencv_bilateral_filter.htm>.
Acesso em: 6 nov. 2021.

VAITKUS, AUDRIUS, et al. **Performance of soft asphalt and double Otta Seal within first three years**. Advances in Materials Science and Engineering, annual 2016. Disponível em:
<link.gale.com/apps/doc/A509161082/AONE?u=anon~e0079d1b&sid=googleScholar&xid=9e8f73c8>. Acesso em: 6 de nov. 2021.

WITTEN, I.; FRANK, E.; HALL, M. **Data mining: practical machine learning tools and techniques**. 3th edition, Morgan Kaufmann. San Francisco, CA, 2011.

ZHANG, L., YANG, F., ZHANG, Y. D., & ZHU, Y. J. **Road Crack Detection Using Deep Convolutional Neural Network**. IEEE International Conference on Image Processing (ICIP), 2016.

FOLHA DE REGISTRO DO DOCUMENTO

1. CLASSIFICAÇÃO/TIPO TC	2. DATA 22 de novembro de 2021	3. REGISTRO N° DCTA/ITA/TC-099/2021	4. N° DE PÁGINAS 60
5. TÍTULO E SUBTÍTULO: Identificação Automatizada de Padrões de Defeitos em Pavimentos			
6. AUTOR(ES): Caio Chacon da Rocha Brasil			
7. INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES): Instituto Tecnológico de Aeronáutica - ITA			
8. PALAVRAS-CHAVE SUGERIDAS PELO AUTOR: 1. Pavimentos. 2. Defeitos. 3. Trincas. 4. Aprendizado de máquina.			
9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO: Pavimentos; Trincas; Aprendizagem (inteligência artificial); Engenharia civil; Engenharia estrutural			
10. APRESENTAÇÃO: <input checked="" type="checkbox"/> Nacional <input type="checkbox"/> Internacional			
ITA, São José dos Campos. Curso de Graduação em Engenharia Civil-Aeronáutica. Orientadora: Profª. Drª. Cláudia Azevedo Pereira. Publicado em 2021.			
11. RESUMO: O gerenciamento ativo de pavimentos preocupa-se, entre outras diretrizes, com as condições de serviço de estradas e pavimentos com o intuito de preservar a segurança e conforto dos usuários. Por esse motivo, a verificação da presença de defeitos é uma necessidade de constante preocupação. No presente estudo, foi proposto uma metodologia para realizar o processo de identificação de defeitos em pavimentos de modo a reduzir custos operacionais, já que a intervenção precoce acarreta melhor aplicação dos recursos, além de auxiliar e agilizar o processo de monitoramento. Partindo-se de um banco de dados de 40.000 imagens de concreto de resolução 227 x 227, realizou-se um procedimento específico com a intenção de obter um algoritmo capaz de classificar cada imagem de maneira autônoma e com alta acurácia. Cada rótulo atribuído, refere-se a presença ou não de defeito, ou tipo de trinca para aqueles apontados com defeito. Neste estudo, as trincas foram classificadas conforme três disposições geométricas: diagonal, longitudinal ou transversal. O pré-processamento das imagens é composto das técnicas de filtro de suavização bilateral, sobreposição orientável em kernel gaussiano e projeção de eixo. Em seguida, os dados do banco de 500 imagens de trincas em cada classe foram submetidos a um processo de Aprendizado de Máquina (AM), em que quatro diferentes técnicas são aplicadas comparativamente. Em geral, a que teve o melhor desempenho foi o algoritmo de K-Nearest Neighbors (KNN), o qual correspondeu a cerca de 93% e 87% em acurácia na classificação quanto à presença de defeitos e identificação do tipo de trinca, respectivamente.			
12. GRAU DE SIGILO: <input checked="" type="checkbox"/> OSTENSIVO <input type="checkbox"/> RESERVADO <input type="checkbox"/> SECRETO			