



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA
PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

RENNER DE ASSIS GARCIA SOBRINHO

**REDES NEURAS PROFUNDAS PARA ANÁLISE DE FISSURAS EM
REVESTIMENTOS ARGAMASSADOS COM DIFERENTES TIPOS DE
ACABAMENTO SUPERFICIAL**

Uberlândia – MG

2023

RENNER DE ASSIS GARCIA SOBRINHO

**REDES NEURAS PROFUNDAS PARA ANÁLISE DE FISSURAS EM
REVESTIMENTOS ARGAMASSADOS COM DIFERENTES TIPOS DE
ACABAMENTO SUPERFICIAL**

Tese apresentada ao programa de Pós-graduação em Engenharia Mecânica da Universidade Federal de Uberlândia como parte dos requisitos para obtenção do grau de **Doutor em Engenharia Mecânica**.

Área de Concentração: Materiais e Processos de Fabricação

Orientador: Prof. Dr. Henrique Fernandes

Uberlândia – MG

2023

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

G216
2023

Garcia Sobrinho, Renner de Assis, 1990-
Redes neurais profundas para análise de fissuras em
revestimentos argamassados com diferentes tipos de
acabamento superficial [recurso eletrônico] / Renner de
Assis Garcia Sobrinho. - 2023.

Orientador: Henrique Coelho Fernandes.
Tese (Doutorado) - Universidade Federal de Uberlândia,
Pós-graduação em Engenharia Mecânica.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.te.2023.260>

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia mecânica. I. Fernandes, Henrique Coelho,
1986-, (Orient.). II. Universidade Federal de
Uberlândia. Pós-graduação em Engenharia Mecânica. III.
Título.

CDU: 621

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Engenharia Mecânica
 Av. João Naves de Ávila, nº 2121, Bloco 1M, Sala 212 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4282 - www.posmecanicaufu.com.br - secposmec@mecanica.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Mecânica				
Defesa de:	Tese de Doutorado Acadêmico, nº 356, PPGEM				
Data:	13/06/2023	Hora de início:	13:30	Hora de encerramento:	16:30
Matrícula do Discente:	12123EMC012				
Nome do Discente:	Renner de Assis Garcia Sobrinho				
Título do Trabalho:	Redes neurais profundas para análise de fissuras em revestimentos argamassados com diferentes tipos de acabamento superficial				
Área de concentração:	Materiais e Processos de Fabricação				
Linha de pesquisa:	Tribologia e Materiais				
Projeto de Pesquisa de vinculação:	"Infrared thermography as non-destructive evaluation tool"				

Reuniu-se por meio de videoconferência a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Mecânica, assim composta: Professores Doutores: Marcus Antonio Viana Duarte - FEMEC/UFU; Márcio Bacci da Silva - FEMEC/UFU; Francisco Dalla Rosa - UPF; André Ricardo Backes - UFSCar/São Carlos; e Henrique Coelho Fernandes - FACOM/UFU, orientador do candidato.

Iniciando os trabalhos, o presidente da mesa, Dr. Henrique Coelho Fernandes, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Marcus Antonio Viana Duarte, Professor(a) do Magistério Superior**, em 13/06/2023, às 16:26, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Henrique Coelho Fernandes, Professor(a) do Magistério Superior**, em 13/06/2023, às 16:31, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **André Ricardo Backes, Usuário Externo**, em 13/06/2023, às 16:34, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Francisco Dalla Rosa, Usuário Externo**, em 13/06/2023, às 16:34, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcio Bacci da Silva, Professor(a) do Magistério Superior**, em 13/06/2023, às 16:48, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4549625** e o código CRC **AA0D1C03**.

RESUMO

A aplicação de tecnologias como a inteligência artificial (IA) em processos produtivos vem otimizando diversas realidades industriais. Na construção civil, a IA pode ser empregada em diferentes abordagens, uma delas é na inspeção predial. Verifica-se a incidência de estudos que aplicaram IA para a classificação de fissuras em materiais homogêneos como concreto e pavimentação asfáltica, porém, a literatura carece de aplicações em materiais como o revestimento argamassado. Os estudos que foram feitos com esse tipo de material são focados no revestimento liso e com pintura, não levando em consideração os diferentes tipos de acabamento superficial existentes. Em vista disso, essa pesquisa teve com objetivo avaliar o desempenho da aplicação de IA, por meio de redes profundas, para a classificação de fissurações em revestimento argamassado com diferentes tipos de acabamento superficial. Para isso, foi elaborado um banco de dados público de imagens de fissuras em revestimento argamassado considerando diferentes tipos de acabamento superficiais, sendo eles: tipo liso, tipo grafiato e tipo chapiscado. Elaborou-se um banco com 33088 imagens que passaram por um processo sistemático de rotulação a partir de classes definidas no estudo. Foram realizados treinamentos de redes por meio de transferência de aprendizagem utilizando a VGG16 em diferentes agrupamentos dos acabamentos. Verificou-se que a acurácia do treinamento varia de acordo com o acabamento superficial e com o balanceamento dados. A partir disso, pontos foram levantados em relação às características do banco de dados elaborado nessa pesquisa e hipóteses verificadas. O banco ficará disponível para pesquisadores implementarem estudos na área. Verificou-se que o acabamento do tipo grafiato foi o que apresentou um menor desempenho nas medidas de assertividade enquanto o liso e o chapiscado tiveram valores próximos.

Palavras-chave: Inteligência artificial; redes profundas; classificação de fissuras, revestimento argamassado; rede neural convolucional; acabamento superficial

ABSTRACT

The application of technologies such as artificial intelligence (AI) in production processes has been optimizing several industrial realities. In civil construction, AI can be used in different approaches, one of them is in building inspection. It is observed studies that applied AI for the classification of cracks in homogeneous materials such as concrete and asphalt paving, however, the literature lacks applications in materials such as mortar coating. The studies that have been carried out with this type of material are focused on the smooth and painted coating, not considering the different types of surface finish that exist. In view of this, this research aimed to evaluate the performance of the application of AI, through deep networks, for the classification of cracks in mortar coating with different types of surface finish. For this, a public database of images of cracks in mortar coating was created considering different types of surface finishes, namely: smooth type, scrapped type and rough type. A bank was created with 33088 images that went through a systematic labeling process based on classes defined in the study. Network training was carried out through learning transfer using the VGG16 in different groupings of finishes. It was found that the training accuracy varies according to surface finish and data balancing. From this, points were raised in relation to the characteristics of the database elaborated in this research and verified hypotheses. The bank will be available for researchers to implement studies in the area. It was found that the graffiti type finish was the one that presented the lowest performance in the assertiveness measures, while the smooth and chapiscado had similar values.

Keywords: Artificial intelligence; deep networks; crack classification, mortar coating; convolutional neural network; surface finish

AGRADECIMENTOS

Agradeço, primeiramente, a Deus por sempre trilhar meu caminho e me fornecer oportunidades de crescimento e de realizar meus sonhos.

Agradeço a minha família por sempre torcer por mim, pelo carinho e pelo reconhecimento.

Agradeço aos meus amigos, por trazerem tantos momentos especiais para minha vida no meio do turbilhão que ela tem sido e por não desistirem de mim mesmo com os sumiços.

Agradeço aos amigos do doutorado pelo compartilhamento do sofrimento e apoio durante as dificuldades do doutorado.

Agradeço aos meus amigos de profissão por ouvirem minhas dificuldades, me acalmarem, diversas vezes, tornando essa fase mais leve. E também por ajudarem, mesmo que com um material, de modo que fosse mais fácil conciliar o trabalho com o doutorado.

Agradeço as minhas irmãs, Reylla e Rayssa, por serem tudo que são na minha vida. Minhas parceiras, minhas melhores amigas, minhas melhores ouvintes, meu melhor suporte, isso porque não dá para descrever com palavras a conexão que a gente tem.

Agradeço aos meus pais, Isaac e Lucimar, por definitivamente tudo. Por tudo que sou, pelo exemplo de trabalho, dedicação e esforço, pelo exemplo de pessoas boas e com um coração enorme. Vocês me deram todo o suporte, força e exemplo para que eu conseguisse conquistar tudo que queria até o momento.

Agradeço aos meus sobrinhos/filhos por ser a alegria da nossa família. Tudo que fazemos é pensando em vocês.

Agradeço a minha outra mamãe, minha Tia La, por cuidar tão bem de mim e se preocupar tanto comigo. Suas orações são muito especiais e com certeza sempre me ajudaram.

Agradeço ao meu orientador Henrique por ter sido um verdadeiro parceiro e amigo nessa jornada, por ter me apoiado e ajudado em tudo.

E, por fim, agradeço especialmente a mim, por toda garra de dedicação nesse projeto, por não ver o difícil como algo impossível, por acreditar no meu potencial e encarar qualquer obstáculo para conseguir alcançar os meus sonhos e objetivos.

Portanto, é isso, obrigado a cada um que, de alguma forma, me ajudou durante a minha vida para eu estar a onde estou hoje. Se você se reconheceu em alguma parte dessa mensagem, pode se sentir abraçado pela minha gratidão e ficar com o seu coração quentinho.

LISTA DE FIGURAS

Figura 1 - Esquema de design de ponte romana	23
Figura 2 - Exemplo de concentração de tensões em materiais	25
Figura 3 - Três modos de deslocamento da superfície de uma trinca	25
Figura 4 - Propriedades da argamassa	27
Figura 5 - Camadas do revestimento de argamassa da vedação vertical: emboço e reboco; massa única	29
Figura 6 - Sarrafeamento da argamassa	30
Figura 7 - Ferramentas para as operações de sarrafeamento, desempenho e camurçamento	31
Figura 8 - Acabamento do tipo chapiscado	31
Figura 9 - Acabamento do tipo grafiato	32
Figura 10 - Comparação entre procedimentos de solução entre a medicina e a engenharia civil	34
Figura 11 - Diferentes tipos de configurações de fissuras	36
Figura 12 - Fissurações por ausência de juntas de dilatação	37
Figura 13 - Exemplos de fissurações por ações hidrotérmicas	38
Figura 14 - Fissurações por recalque de fundações	38
Figura 15 - Fissuração com direção predominante a 45°	39
Figura 16 - Diferentes configurações de fissurações	39
Figura 17 - Fissuração por retração na argamassa	40
Figura 18 - Microfissuras mapeadas	40
Figura 19 - Fissuras devido a fadiga hidrotérmica	41
Figura 20 - Diferentes configurações de fissurações e suas causas	41
Figura 21 - Paralelo entre um neurônio e o perceptron	46
Figura 22 - Diferentes tipos de arquiteturas de redes neurais	47
Figura 23 - Matrix de confusão	49
Figura 24 - Exemplo do processo de aquisição de uma imagem digital	53
Figura 25 - Representação RGB de imagem	53
Figura 26 - Exemplo de filtros de detecção de bordas	54
Figura 27 - Exemplo de estrutura de CNN	55
Figura 28 - Exemplo de funcionamento de transferência de aprendizagem	56
Figura 29 - Esquema das buscas nas bases de dados	58
Figura 30 - Camadas do revestimento de estudo de Guo et al. (2020)	62
Figura 31 - Imagens das fachadas capturadas por meio de VANT	67
Figura 32 - Estruturação da pesquisa	70
Figura 33 - Fluxograma das etapas realizadas	71
Figura 34 - Mapa do Campus Santa Mônica (UFU)	72
Figura 35 - Fachadas com diferentes tipos de materiais constituintes	72
Figura 36 - Exemplo de faces das edificações consideradas ou não no levantamento dos dados	73
Figura 37 - Variações angulares entre a câmera e o revestimento argamassado	74
Figura 38 - Esquema do pré-processamento das imagens	76
Figura 39 - Procedimento de rotulação dos dados	76
Figura 40 - Diferentes tipos de acabamento superficial	77
Figura 41 - Processo de classificação na rotulação dos dados	78
Figura 42 - Exemplo de patches com informações sem relação com revestimento argamassado	86
Figura 43 - Exemplo de patches onde o revestimento argamassado não é a informação principal	87
Figura 44 - Diferentes texturas no acabamento superficial liso	88
Figura 45 - Diferentes cores de pinturas no acabamento superficial liso	89

Figura 46 - Texturas do acabamento superficial grafito	90
Figura 47 - Texturas do acabamento superficial chapiscado	91
Figura 48 - Imagens do revestimento com fundo	91
Figura 49 - Imagens de encontros	92
Figura 50 - Imagens partes de esquadria nos revestimentos	92
Figura 51 - Imagens com partes das instalações prediais	93
Figura 52 - Imagens com vegetação	93
Figura 53 - Imagens de sombra e de luminosidade.....	94
Figura 54 - Desenhos, símbolos ou letras realizadas sobre o revestimento argamassado	94
Figura 55 - Imagens com objetos	95
Figura 56 - Manifestações patológicas	96
Figura 57 - Fissurações por tipo de acabamento.....	97
Figura 58 - Diferentes configurações de fissurações	98
Figura 59 - Diferentes níveis de visibilidade das fissurações	99
Figura 60 - Exemplos de codificação dos patches. A figura é melhor visualizada no formato colorido	100
Figura 61 - Gráficos da função perda e da acurácia nos treinamentos de teste	103
Figura 62 - Gráficos da função perda e da acurácia grupos com o banco todo	104
Figura 63 - Gráficos da função perda e da acurácia grupos contendo somente o revestimento liso....	105
Figura 64 - Gráficos da função perda e da acurácia grupos contendo somente o revestimento do tipo grafiato	106
Figura 65 - Gráficos da função perda e da acurácia grupos contendo somente o revestimento do tipo chapiscado.....	107
Figura 66 - Melhores acurácias de validação de cada grupo.....	108
Figura 67 - Desbalanceamento dos dados dos grupos grafiato e chapiscado	109
Figura 68 - Tempo de treinamento dos agrupamentos A e B.....	109
Figura 69 - Tempo de treinamento por número de imagens grupo A e B	110
Figura 70 - Erro por número de épocas dos agrupamentos desbalanceados (D).....	114
Figura 71 - Acurácia por número de épocas dos agrupamentos desbalanceados (C)	115
Figura 72 - Erro por número de épocas dos agrupamentos balanceados (D)	116
Figura 73 - Acurácia por número de épocas dos agrupamentos balanceados (D)	116
Figura 74 - Tempo de treinamento dos agrupamentos C e D.....	117
Figura 75 - Tempo de treinamento por número de imagens grupo C e D	117
Figura 76 - Acurácias para os grupos de teste de C e D	118
Figura 77 - Tempo de teste dos agrupamentos C e D	119
Figura 78 - Matriz confusão do agrupamento desbalanceado (C).....	119
Figura 79 - Matriz confusão dos agrupamentos balanceados (D)	120
Figura 80 - Curvas do erro e da acurácia por épocas dos grupos D+	122
Figura 81 - Matriz de confusão dos grupos D+	123
Figura 82 - Acurácia do grupo de teste dos agrupamentos D e D+.....	123
Figura 83 - Tempo de teste grupos D e D+	124
Figura 84 - Erro e Acurácia por época para os grupos E	125
Figura 85 - Erro e Acurácia por época para os grupos F	125
Figura 86 – Acurácia do grupo de teste para os agrupamentos D, E e F.....	126
Figura 87 - Matriz de confusão dos grupos E	127
Figura 88 - Matriz de confusão dos grupos F	127
Figura 89 - Gráfico de tempo por número de imagens de todos os grupos	128
Figura 90 - Acurácia dos grupos multi-classe do tipo 1	129

Figura 91 - Acurácia dos grupos multi-classe do tipo 2	131
--	-----

LISTA DE TABELAS

Tabela 1 - Espessuras admissíveis de revestimentos Internos e Externos.....	29
Tabela 2 - Classificação das aberturas de fissuras em alvenarias	35
Tabela 3 - Conjunto de dados de Lee et al. (2020)	61
Tabela 4 – Resultados de Lee et al. (2020).....	62
Tabela 5 - Conjunto de dados de Guo (a) et al. (2020).....	63
Tabela 6 - Resultados de Guo (a) et al. (2020)	64
Tabela 7 – Resultados de precisão de Guo (a) et al. (2020).....	64
Tabela 8 - Banco de dados de Guo (b) et al. (2020)	66
Tabela 9 - Resultados de Guo (b) et al. (2020).....	66
Tabela 10 - Banco de dado de Chen et al. (2021).....	67
Tabela 11 - Resultados de precisão de Chen et al. (2021)	68
Tabela 12 – Quantidade de imagens por acabamento superficial	100
Tabela 13 – Quantidade de imagens em relação ao ruído.....	101
Tabela 14 – Quantidade de imagens em relação ao acabamento superficial e ao ruído	101
Tabela 15 – Quantidade de imagens em relação ao nível de visibilidade das fissuras.....	102
Tabela 16 - Quantidade de imagens após o balanceamento e a divisão entre treinamento e validação de A e B.....	104
Tabela 17 - Quantidade de imagens após o balanceamento e a divisão entre treinamento e validação de D e C	113
Tabela 18 - Valores de precisão das classes para os agrupamentos C e D	121
Tabela 19 - Divisão dos dados para os bancos de dados com o teste expandido	122
Tabela 21 - Precisão por classe para os grupos D+.....	124
Tabela 22 - Divisão dos dados para os bancos de dados E e F	125
Tabela 23 - Precisão por classe para os grupos E e F	128
Tabela 24 - Precisão por classe do Tipo 1	130
Tabela 25 - Precisão por classe do Tipo 2	131

LISTA DE QUADROS

Quadro 1 - Esquema de informações dos artigos levantados	58
Quadro 2 - Número de imagens por agrupamento	75
Quadro 3 – Agrupamentos de dados analisados	81
Quadro 4 - Esquema dos grupos binários	83
Quadro 5 - Classes dos agrupamentos do Tipo 1	84
Quadro 6 - Classes dos agrupamentos do Tipo 2.....	84
Quadro 7 - Agrupamentos dos treinamentos multi-classe	85

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	16
1.1 OBJETIVOS	21
1.2 HIPÓTESE	21
CAPÍTULO 2 - REFERENCIAL TEÓRICO	22
2.1 FUNDAMENTAÇÃO E CARACTERÍSTICAS DO MATERIAL.....	22
2.1.1 <i>Mecânica da Fratura</i>	22
2.1.2 <i>Propriedades da argamassa e sistemas de revestimento argamassados</i>	26
2.1.3 <i>Descontinuidades em revestimentos argamassados</i>	32
2.2 ENSAIOS NÃO DESTRUTIVOS	42
2.2.1 <i>Inspeção visual</i>	43
2.3 INTELIGÊNCIA ARTIFICIAL	44
2.3.1 <i>Métricas de assertividade</i>	49
2.3.2 <i>Processamento Digital de Imagens</i>	52
2.3.3 <i>Redes Neurais Convolucionais – CNN</i>	55
2.4 ESTUDOS RELACIONADOS	57
CAPÍTULO 3 - METODOLOGIA	70
3.1 MONTAGEM E ANÁLISE DO BANCO DE DADOS.....	71
3.1.1 <i>Delimitação do ambiente e do procedimento de coleta</i>	71
3.1.2 <i>Pré-processamento manual das imagens</i>	75
3.1.3 <i>Rotulação dos dados</i>	76
3.1.4 <i>Análise da quantidade de classes e do equilíbrio do banco de dados</i>	78
3.1.5 <i>Treinamento iniciais</i>	79
3.2 ANÁLISE COMPARATIVA A PARTIR DE TREINAMENTOS DE CNN.....	81
3.2.1 <i>Treinamento binários</i>	82
3.2.2 <i>Treinamentos multi-classe</i>	83
CAPÍTULO 4 - RESULTADOS E DISCUSSÃO	86
4.1 MONTAGEM E ANÁLISE DOS BANCOS DE DADOS.....	86
4.1.1 <i>Rotulação dos dados</i>	86
4.1.2 <i>Análise da quantidade de classes e do equilíbrio do banco de dados</i>	100
4.1.3 <i>Treinamentos iniciais</i>	102
4.1.4 <i>Discussão</i>	110
4.2 TREINAMENTOS COMPARATIVOS.....	113
4.1.5 <i>Treinamentos binários</i>	113
4.1.6 <i>Treinamento multi-classe</i>	129
CAPÍTULO 5 - CONCLUSÃO	132

5.1 TRABALHO FUTUROS	133
5.2 PRODUTOS E PUBLICAÇÕES GERADAS	133
REFERÊNCIAS	134
ANEXO A – Visualização de mapas de extração de características	142
ANEXO B – Topologia da rede dos treinamentos iniciais (VGG16)	143
ANEXO C – Topologia da rede dos treinamentos comparativos (VGG16)	144

CAPÍTULO 1 - INTRODUÇÃO

O avanço da tecnologia e sua aplicação nas indústrias trouxe uma nova realidade para as dinâmicas produtivas. Essa otimização vem sendo tão significativa que se criou o conceito da Indústria 4.0. Nele, acredita-se que o setor produtivo está passando pela quarta revolução industrial (SCHWAB, 2018). Dentre as inovações que estão sendo implementadas na indústria, tem-se a internet das coisas (IoT), realidade virtual (RV), manufatura aditiva, robótica, inteligência artificial (IA), dentre outras (OLSEN, 2020; VAIDAY, AMBAD e BHOSLE, 2018).

No caso da IA, essa tecnologia tem como objetivo desenvolver autonomia de máquinas e sistemas computacionais para que esses simulem o raciocínio humano, principalmente na tomada de decisões. Desse modo, é possível otimizar processos e atividades repetitivas de longa escala, que necessitariam de análises humanas (TAULLI, 2019; TAN, 2018). Esse processamento inteligente já vem sendo utilizado em várias aplicações como, por exemplo, para simular a linguagem humana, realizar previsões, agrupar e classificar dados (AHMED, JENOS e PICCIALLI, 2022).

Nos estudos das engenharias, recursos provenientes da IA já são empregados para solução de diversos problemas. Santos (2001) utilizou redes neurais para um procedimento com o propósito de determinar uma relação experimental entre o desgaste e o acabamento superficial de ferramentas de corte. Palomino (2012) aplicou técnicas de redes neurais e análise de *cluster fuzzy* em um método de monitoramento estrutural baseado na impedância eletromecânica. Nascimento (2022) empregou técnicas de inteligência artificial, de correlação de imagens digitais e do conceito de impedância térmica para estimar o tamanho e a localização de tumores mamários. Brito (2022) propôs novas metodologias para o diagnóstico de falhas de máquinas rotativas a partir de inteligência artificial e análise de vibração. Desse modo, observa-se a multiplicidade de aplicação da tecnologia em diversas linhas de pesquisa dentro das engenharias.

Apesar desse cenário de inovação, não são todos os setores que estão absorvendo o que está sendo provido pelos atuais avanços. A indústria de construção civil, apesar da tentativa constante de modernização, ainda está atrás das outras realidades industriais, principalmente quando se observa em escala global. Algumas práticas produtivas desse setor ainda podem ser consideradas quase que artesanais (NEWMAN, EDWARDS, *et al.*, 2021; MASKURITY, SELAMANT, *et al.*, 2019). Sendo assim, é possível observar que a indústria da construção tem demanda de inovações e pesquisa para melhorar o setor.

Dentre as modernizações presentes da indústria 4.0 na construção civil, verifica-se o esforço de estudos para aplicar processamento de IA em todas as etapas de construção, indo desde a elaboração do projeto até a fase de uso e manutenção de edificações (FRANCO, DOMINGUES, *et al.*, 2022; PAN e ZHANG, 2021). Zhang (2021) aplicou a IA para detectar situações de riscos entre a interação de alvos e trabalhadores da construção civil com o objetivo de melhorar a gestão de segurança de obras. Palencia *et al.* (2021) utilizou o *machine learning* para melhorar o processo de decisão para adoção de eficiência energética em projetos de *Building Information Modeling* (BIM) destinados à renovação de edifícios. Tan (2018) combinou o uso de inteligência artificial com manufatura aditiva para melhorar os processos de impressão em 3D de edificações. Pietro *et al.* (2019) geraram cronogramas de execução para um projeto de construção simples a partir de um modelo de linguagem de IA denominado ChatGPT.

Uma das atividades na qual se pode aplicar a IA na realidade da engenharia civil é na inspeção predial. A questão é que as edificações sofrem desgaste e perda de desempenho ao longo de sua vida útil. Desse modo, é necessário realizar monitoramento de seus sistemas e elementos ao longo de seu uso. Uma das maneiras de executar esses procedimentos é por meio de inspeções e vistorias regulares (CHAN, 2019; SILVA e BRITO, 2019). Esses tipos de serviços costumam a gerar um grande número de imagens que devem ser processadas e classificadas de acordo com os defeitos e manifestações patológicas encontrados. Isso ocasiona em uma grande demanda de tempo e dedicação dos especialistas em questão. Garcia Sobrinho *et al.* (2021) realizaram um estudo baseado em inspeção predial. A pesquisa gerou 4481 imagens que tiveram que ser classificadas manualmente, atividade que poderia ter sido feita por uma IA treinada para classificar as categorias da pesquisa.

Visualizando a otimização desse tipo de serviço, é possível treinar um classificador baseado em IA para catalogar os problemas encontrados nas edificações. Um dos tipos de redes mais utilizadas na classificação de imagens são as redes neurais convolucionais (CNN).

A CNN é uma arquitetura de rede neural que é muito aplicada no reconhecimento de imagens. Ela é dividida, basicamente, em camadas convolucionais, camadas de *pooling* e camadas densamente conectada. Nas camadas convolucionais, um grupo de pixel é atribuído a um neurônio, sendo feito isso em todos os pixels da imagem. A partir dessa configuração, são aplicados filtros nesses agrupamentos, com o objetivo de extrair as características mais relevantes da imagem. Dessa maneira, no processo de convolução, são gerados mapas de características em toda imagem pelos quais é possível identificar informações importantes para o processo de classificação, como bordas e geometrias, considerando a dependência e

posicionamento dos pixels. No processo de *pooling*, ocorre a redução da dimensionalidade da imagem. Acontece que, após o processo de extração dos mapas de características na camada de convolução, essas informações podem ser simplificadas, o que diminui a quantidade de pesos no processo e pode evitar o *overfitting*. As últimas camadas são as densamente conectadas, onde ocorre o processo de classificação das imagens a partir das informações da extração de características definidas nas camadas convolucionais e de pooling (WEIDMAN, 2019; ZEILER e FERGUS, 2013).

Um fator relevante para o desempenho da rede é o banco de dados que será utilizado no processo de treinamento. O banco de dados geralmente é dividido em três grupos: treinamento, validação e teste. No grupo de treinamento, estão as imagens que serão utilizadas para ensinar a rede qual classe deve ser atribuída a cada imagem. O grupo de validação serve para verificar se a rede está realmente aprendendo durante a fase de treinamento ou está simplesmente memorizando o grupo de treinamento. Por fim, no grupo de teste estão as imagens que serão utilizadas para verificar a capacidade da rede em obter sucesso, ou seja, verificar se ela é capaz de classificar corretamente um indivíduo nunca antes visto. A montagem do banco de dados é importante para o sucesso de um treinamento. É necessário que o banco seja grande o suficiente para a rede generalizar e abranger ao máximo o aspecto da classificação desejada. Algumas redes atuais como a AlexNet e GoogleNet foram treinadas com milhões de imagens, por exemplo. Outro ponto importante é o equilíbrio entre o banco de dados entre as classes. Isso porque se alguma classe tiver mais imagens que a outra, ela pode gerar uma tendência do ajuste dos pesos (WEIDMAN, 2019; CHOLLET, 2021)

Desse modo, verifica-se a importância de ter um banco de dados representativo e equilibrado para o processo de treinamento de CNN. Um dos bancos de dados mais utilizados para aplicações de reconhecimento de imagens por IA é o ImageNet. Ele contém mais de 14 milhões de imagens divididas em mais de 20.000 categorias, todas de domínio público (IMAGENET, 2023). Porém, para alguns problemas específicos, objetos de investigação científica, as bases de dados públicas atuais não costumam a ter informações em escala ou representatividade suficiente. Tendo em vista essa situação, alguns estudos como Silva et al. (2014), Katija et al. (2022) e Leenhardt (2020) tiveram como foco a montagem de bancos de imagens públicas para investigações, destinados para aplicações de IA. Pesquisas em algumas vertentes da engenharia costumam ter dificuldades de encontrar fontes públicas de dados para estudos de classificação. Além disso, mesmo quando ocorre a montagem de um banco de dados próprio para uma determinada abordagem, eles costumam a ser pequenos quando comparados com os que foram utilizados para treinamento das CNNs atuais.

Para resolver essas questões, utiliza-se a transferência de aprendizagem. Nesse processo, pega-se redes já treinadas, mantém-se as camadas de convolução e de *pooling*, e se altera somente as camadas densamente conectadas. No caso, entende-se que as características extraídas no processo de convolução não costumam a variar muito entre diferentes objetos. Desse modo, uma rede treinada para extrair características de milhões de imagens tem grande capacidade de generalização. Assim, aproveita-se da parte de extração de característica e só se treina a rede para classificar o banco de dados proposto. Esse tipo de abordagem tem sido aplicado em estudos de classificação e obtido bons resultados (GONÇALVES, SOUZA e FERNANDES, 2022; CHAVES, GONÇALVES, *et al.*, 2022).

Verifica-se na bibliografia um esforço de pesquisadores para treinar redes classificadoras em diferentes problemas de construção civil. Porém, maioria destes estudos trabalham com materiais homogêneos como concreto e pavimentação. Nem todos os materiais aplicados na construção civil possuem superfícies de aspecto homogêneo, como é o caso dos revestimentos de fachadas (LI, WANG, *et al.*, 2017; ZHANG, NATEGHINIA, *et al.*, 2022; JIANG, PANG e LI, 2021; DUNG e ANH, 2019).

As fachadas são elementos das edificações que ficam expostas ao ambiente externo, ou seja, sofrem insolação, ciclos de secagem e umedecimento, ação da precipitação de chuvas, variações térmicas do ambiente, dentre outros agentes e tipos de intempéries. Dessa maneira, são necessária inspeções e manutenções periódicas nessas regiões da edificação. As fachadas podem ser constituídas de diferentes materiais, um dos mais utilizados para finalização é o revestimento argamassado. Esse tipo de acabamento pode ser aplicado de várias formas variando a espessura de seus componentes e o seu tipo de textura, o que resulta em diferentes características em relação a seu acabamento superficial (SONNTAG e GRUNEWALD, 2020; TOMAL, 2017; EDIS, COLEN e BRITO, 2014).

O acabamento superficial mais utilizado é o liso. Nele, realiza-se o desempenamento, nivelamento e camuçamento, obtendo-se o aspecto liso no revestimento. Outra textura possível é o grafiato. Para sua execução, é adicionada grafitina na argamassa, o que resulta em um aspecto de ranhuras no acabamento. O chapiscado é outro tipo de finalização do revestimento argamassado. Ele pode ser executado por meio de projeção da argamassa ou um rolo de textura. Seu acabamento visual dá um aspecto rugoso no local no qual é aplicado.

Em relação categorização de defeitos em revestimento argamassado por meio de CNN. Lee et al. (2020) utilizaram uma rede neural convolucional de aprendizado profundo do tipo Faster R-CNN para detectar defeitos multi-classe em fachadas com revestimento argamassado. A acurácia média verificada pelos autores foi de 62,7%. Guo (a) et al. (2020) realizaram a

classificação de defeitos em revestimento argamassado a partir de um conjunto de dados desequilibrado, usando a VGG16. Para lidar com o conjunto de dados desbalanceado, os autores utilizaram meta-aprendizagem. Eles obtiveram uma acurácia de 82,86%. Gui (b) (2020) realizaram um aprendizado semi-supervisionado com o uso da ResNet 101 e de um filtro de incerteza para classificação de defeitos em fachadas. Os autores atingiram a acurácia de 84,36%.

Entretanto, esses estudos abordam somente o revestimento liso com acabamento em pintura. Dessa maneira, não costumam a considerar diferentes tipos de acabamento superficial de revestimento, o que diminui a capacidade, até então, das redes de generalizar.

Um dos problemas mais comuns de serem encontrados em revestimentos argamassados são fissurações. O estudo desses tipos de discontinuidades a partir da sua configuração já algo consolidado na ciência dos materiais, como é o caso da mecânica da fratura. Por meio dessa característica é possível aferir informações como algumas propriedades dos materiais e causas da falha (MECHOLSKY JUNIOR e POWELL JUNIOR, 1982; ABM, 1988). A engenharia diagnóstica de edificações segue a lógica da mecânica da fratura para caracterizar fissurações. Um ponto relevante é a configuração da discontinuidade, se a trinca for vertical, horizontal, inclinada ou distribuída, já é possível descartar diversas possibilidades de causas e encaminhar uma apuração mais precisa (THOMAZ, 2020).

Em relação a esse tipo de defeito, os estudos relacionados à detecção de fissuras em concreto já apresentam bons resultados. Chow (2020) elaboraram uma *pipeline* com inteligência artificial para inspeção baseada em imagens de estrutura de concreto. Os autores obtiveram uma acurácia média no conjunto de teste de 95,60%. Ali et al. (2021) avaliou o desempenho de técnicas de localização e detecção de trincas profundas baseadas em CNNs para estruturas de concreto. No método de detecção proposto pelos autores, eles obtiveram 96,70% de acurácia. Islam (2022) desenvolveram uma abordagem de CNN com base em modelos de transferência de aprendizagem usando aumento e transformação de dados para detecção de trincas no concreto. Os melhores resultados da pesquisa foram utilizando a VGG16 e a AlexNet, ambas com acurácia de 99,90%. Chaiysarn (2022) realizaram a detecção integrada de rachaduras, a partir de CNN-FCN, em nível de pixel via mapeamento fotogramétrico de textura 3D de estruturas de concreto. Os autores obtiveram 99,80% de acurácia.

A superfície de revestimentos argamassados são mais heterogêneas quando comparadas com a do concreto armado, o que não é tão explorado nos estudos atuais. Esses são focados na classificação multi-classe de defeitos e não levam em consideração diferentes tipos de acabamento superficial. Outro ponto é que no caso do concreto, já se tem bancos de dados

públicos sobre problemas neste tipo de estrutura, o que pode justificar a incidência de mais pesquisas sobre esse tema e melhores resultados nas métricas de assertividade quando comparadas com os estudos em revestimento argamassado.

Sendo assim, o presente estudo tem como objetivo verificar se o tipo de acabamento superficial influencia no desempenho em treinamentos de CNNs para a classificação de fissuras em revestimento argamassado. Para isso, foi elaborada um banco de dados de fissuras em revestimento argamassado considerando alguns diferentes tipos de acabamento superficial sendo eles: o liso, o chapiscado e o grafiato. Esse banco ficará disponível para pesquisadores realizarem procedimentos de treinamento de redes neurais com diferentes abordagens. Foram realizados treinamentos de CNNs, a partir de transferência de aprendizagem, com diferentes configurações de agrupamentos das imagens obtidas para o banco de dados. O objetivo é testar o desempenho do banco de dados de acordo com alguns pontos levantados na sua montagem como o desbalanceamento em relação a quantidade de imagens em cada tipo de acabamento superficial definido. A arquitetura de rede utilizada foi a VGG16.

1.1 OBJETIVOS

Verificar se diferentes tipos de acabamentos superficiais de revestimentos argamassado influenciam no desempenho no treinamento de redes neurais convolucionais.

Objetivos secundários:

- Montar um banco de dados públicos de imagens de revestimento argamassado com diferentes tipos de acabamento superficial;
- Verificar fatores que podem influenciar no treinamento de redes profundas de acordo com os acabamentos superficiais.

1.2 HIPÓTESE

Diferentes tipos de acabamento superficiais vão influenciar nas métricas de assertividade de redes neurais convolucionais.

CAPÍTULO 2 - REFERENCIAL TEÓRICO

O referencial teórico tem como objetivo explicar conceitos, ferramentas que foram aplicadas, justificar a relevância da pesquisa e fomentar as discussões. Para isso, ele foi dividido em 3 tópicos principais que são: Fundamentação e características do material; ensaios não destrutivos e inteligência artificial.

2.1 FUNDAMENTAÇÃO E CARACTERÍSTICAS DO MATERIAL

A seção de fundamentação e características dos materiais tem como foco descrever as principais propriedades, os conceitos e as descontinuidades relacionadas com o revestimento argamassado que são relevantes para o estudo. Para isso, ela foi dividida em 3 partes. A primeira trata da Mecânica da Fratura. Nela são abordados alguns conceitos importantes para o estudo explicado como essa vertente da ciência utiliza a configuração da falha para atribuir informações como: As características do material e a causa da descontinuidade. Na segunda parte, são abordadas as propriedades da argamassa e dos sistemas desse tipo de revestimento. Nesse caso, serão explicadas as propriedades do revestimento argamassado, definições, e fundamentações necessárias para compreensão de termos. Por último, tem-se o item Descontinuidades em Revestimento Argamassados. Nele é explicado como a configuração das fissurações pode ser utilizada no diagnóstico dos problemas.

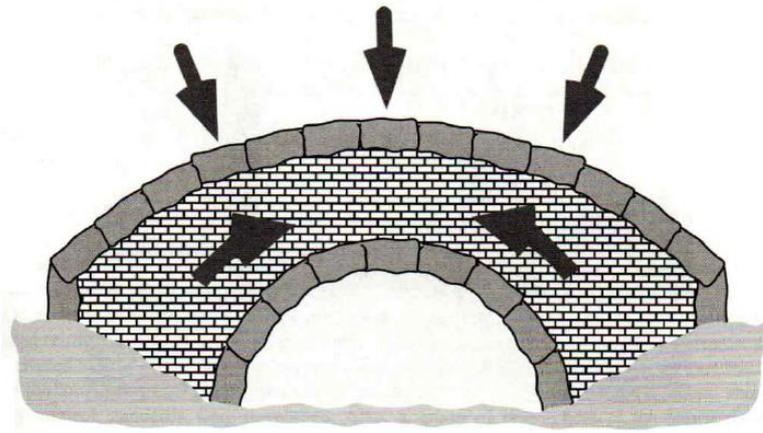
2.1.1 *Mecânica da Fratura*

O uso de metais para aplicações estruturais foi amplificado no século dezenove devido a revolução industrial. Com essa otimização de demanda, teve-se também o aumento de acidentes relacionados com a maneira e com os propósitos nos quais esses materiais foram empregados na época. Apesar de alguns desses problemas estarem associados com a concepção dos projetos das estruturas utilizadas, com o passar do tempo verificou-se que parte dos acidentes eram causados por deficiências pré-existentes nos materiais empregados, como o início de fissuras, que acabavam resultando em falhas. Tendo em vista esse cenário, observou-se a necessidade de elaborar metodologias que reduzissem a incidência desses problemas (JANSSEN, ZUIDEMA e WANHILL, 2002).

A ideia de evitar a fratura não é nova quando se observa um contexto geral de evolução tecnológica das sociedades. A partir de configurações de *design*, engenheiros e arquitetos

elaboraram estruturas encomendadas por Faraós do antigo Egito e Césares da Roma que até hoje estão de pé. Isso é observável, também, em pontes na Europa do período da renascença. Na Figura 1 é possível verificar a configuração de uma ponte romana projetada em arco visualizando a transmissão das cargas da estrutura como tensão de compressão, o que otimiza o potencial dos materiais mais utilizados antigamente nesse tipo de aplicação (ANDERSON, 2005).

Figura 1 - Esquema de design de ponte romana



Fonte: (ANDERSON, 2005)

Com o passar do tempo e evolução de estudos, a tecnologia de analisar as falhas para garantir o desempenho de materiais se tornou uma linha de conhecimento consolidada e desenvolvida. Nesse contexto, surgiu a mecânica da fratura, matéria que analisa o comportamento dos materiais que possuem descontinuidades pequenas ou trincas (BROEK, 1982).

A partir da mecânica da fratura é possível avaliar a integridade estrutural de corpos. Isso pode determinar qual é o emprego mais adequado para um componente ou levantar informações de como melhorar a produção desses. Desse modo, pode-se analisar o comportamento dos materiais e as possíveis causas de fratura decorrentes de seu processo de fabricação ou durante sua operação. Essa abordagem viabiliza intervenções preventivas com o foco de evitar a falha de materiais e otimizar sua vida útil (ASKELAND e WRIGHT, 2016).

Segundo Callister Junior e Rethwisch (2016), “a fratura consiste na separação de um corpo em duas ou mais partes em resposta à imposição de uma tensão estática e em temperaturas que são baixas em relação à temperatura de fusão do material”. Os autores destacam que a

fratura pode ocorrer, também, devido à fluência (resultado da deformação do material) e a fadiga (que ocorre quando são impostas tensões cíclicas).

A falha pode ocorrer em dois modos que são: Fratura dúctil e fratura frágil. O termo frágil e dúctil está relacionado a capacidade do material de deformar mediante a uma sollicitação. No caso dos materiais dúcteis, esses conseguem absorver uma grande parte da energia antes da falha. Desse modo, tem-se uma deformação maior antes do material romper. Já os materiais frágeis apresentam pouca ou nenhuma deformação, o que resulta em falhas mais abruptas, sem aviso prévio (ANDERSON, 2005).

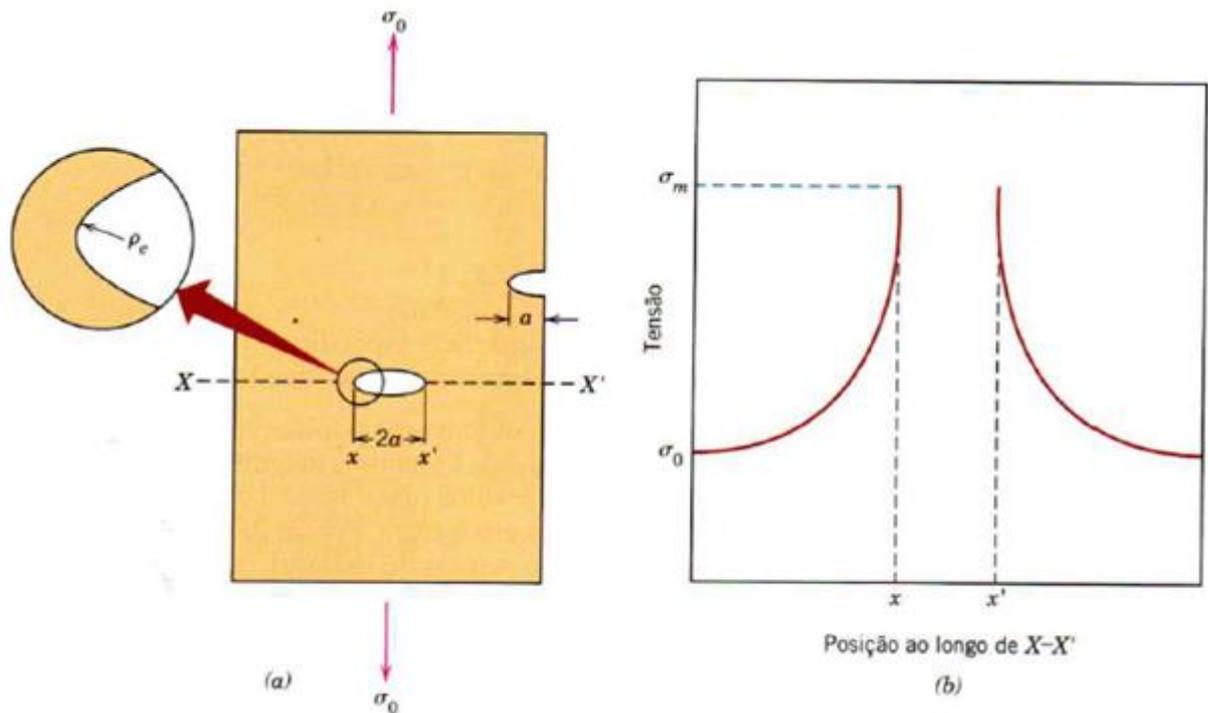
O desenvolvimento de uma fratura pode ser dividido em duas fases. Ao se aplicar uma sollicitação, primeiro tem-se a formação das trincas e depois sua propagação. A maneira na qual a trinca se propaga pelo material influencia, diretamente, na modalidade da sua falha (CALLISTER JUNIOR e RETHWISCH, 2016).

Com a evolução dos estudos da mecânica da fratura, verificou-se a necessidade de compreender melhor os mecanismos de fratura. Um dos fatores que influenciam no surgimento e propagação de trincas é a concentração de tensões. Quando se tem algum defeito em um material, sobre uma força aplicada, ocorre um acúmulo de tensão nas extremidades dessa descontinuidade fazendo com que essas regiões fiquem propícias à nucleação e propagação de trincas (JANSSEN, ZUIDEMA e WANHILL, 2002).

Isso pode ser observado na Figura 2. Na seção X-X' da imagem (a) dessa figura, observa-se um vazio que reduz a seção transversal do material perpendicular ao carregamento σ_0 . Isso faz com que a carga sobre a região desse vazio, que nas outras partes do material estava distribuída em uma seção contínua, se concentre nas extremidades do defeito. O perfil de tensões que demonstra esse acúmulo de tensão pode ser observado na imagem (b). Desse modo, essa concentração de tensões pode ser grande o suficiente para superar a resistência do material à respectiva sollicitação.

A configuração do modo de deslocamento das superfícies no processo de propagação da trinca depende do tipo de sollicitação que foi realizada. Na Figura 3 é possível verificar as 3 modalidades de deslocamento das superfícies de uma trinca. No modo I, tem-se um esforço de tração que divide o material puxando as duas superfícies em direções opostas. Já no modo II, ocorre um esforço de cisalhamento no qual as superfícies deslizam entre si na ruptura. No caso do modo III, as superfícies são deslocadas de forma lateral, o que se assimila a uma sollicitação de torção.

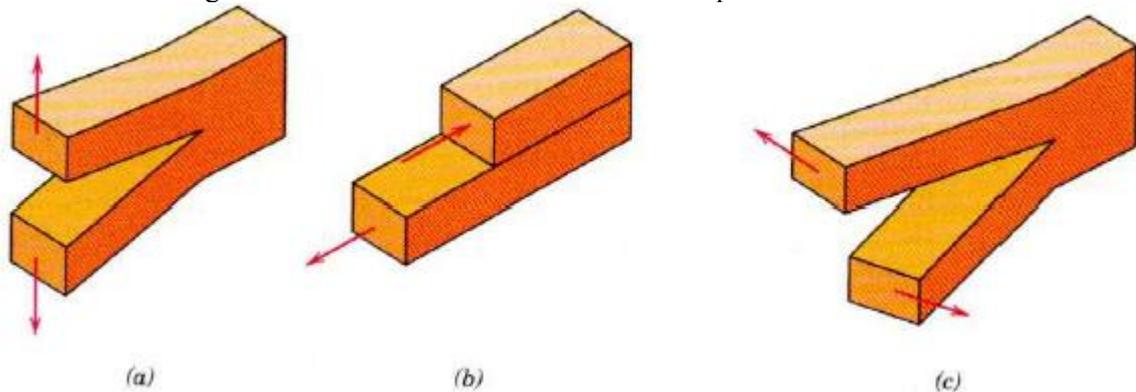
Figura 2 - Exemplo de concentração de tensões em materiais



(a) Geometria de trincas superficiais e internas; (b) Perfil de tensões esquemático ao longo da linha X-X' em (a), demonstrando a amplificação da tensão nas extremidades da trinca.

Fonte: (CALLISTER JUNIOR e RETHWISCH, 2016)

Figura 3 - Três modos de deslocamento da superfície de uma trinca



(a) Modo I, modo de abertura ou de tração; (b) modo II, modo de cisalhamento; (c) modo III, modo de rasgamento.

Fonte: (CALLISTER JUNIOR e RETHWISCH, 2016)

Os materiais podem ser classificados de acordo com características semelhantes baseadas, principalmente, em suas composições químicas e estruturas atômicas. Essas configurações influenciam no seu comportamento a fratura, como o caso da fragilidade e ductilidade. As três categorias básicas são: Metais, cerâmicas e polímeros. Tem-se, também, o material compósito que consiste da união de dois ou mais materiais diferentes. Os metais são compostos por um ou

mais elementos metálicos, são relativamente densos, dúcteis e resistentes a fraturas. Já os materiais cerâmicos são compostos por elementos metálicos e não metálicos, na maioria das vezes, são óxidos, nitretos e carbetos. Eles são rígidos, apresentam resistência a temperaturas elevadas e comportamento frágil. Os polímeros possuem estruturas moleculares grandes com sequência de cadeia, o que lhe dá a característica de fio. Materiais plásticos e borrachas fazem parte do conjunto de matérias poliméricas. Eles não possuem tanta rigidez e resistência quando comparados com os materiais cerâmicos e metálicos. São dúcteis e flexíveis, o que facilita sua moldagem para diversas aplicações (ASHBY e JONES, 2007; ASKELAND e PHULÉ, 2008).

Uma das maneiras de se analisar a fratura é por meio de sua superfície. Acontece que características visíveis como a topografia da superfície de ruptura permitem apurar as condições relacionados ao processo de falha do material. Esse tipo de estudo se chama fractografia, a partir dele é possível inferir a causa da fratura e informações como a direção de propagação, as condições de tensões, o efeito da temperatura e até algumas propriedades do material (ABM, 1988). Segundo Mecholsky Junior e Powell Junior (1982), os estudos de fractografia são mais aplicados em materiais metálicos do que cerâmicos, tendo ainda grande potencial de expansão.

Desse modo, é possível observar que a configuração a fratura é uma característica que pode gerar informações importantes sobre o desempenho dos materiais. A partir dela é possível apurar diferentes aspectos do processo que resultou na falha e possíveis causas. Dessa maneira, pode-se tomar medidas preventivas para evitar que o problema ocorra de novo ou definir qual é a maneira mais eficiente de realizar o tratamento. Essa abordagem de analisar a fratura dos materiais é utilizada nos mais diversos ramos da engenharia, orientando práticas de inspeção e otimizando o desempenho de sistemas em operação.

2.1.2 Propriedades da argamassa e sistemas de revestimento argamassados

A argamassa é o produto resultante da mistura de cimento, água, agregado miúdo (areia) e aditivos. Em alguns casos, mistura-se outros tipos de aglomerantes, como cal e gesso, ou material de enchimento, como o *filler*. A relação da proporção dos materiais que irão compor a argamassa é denominada de traço. Ele indica a quantidade dos insumos, que devem ser adicionados, em relação a uma unidade de cimento, podendo ser dado em massa, volume ou a mistura dos dois, que é denominado de traço misto (BAUER, 2008).

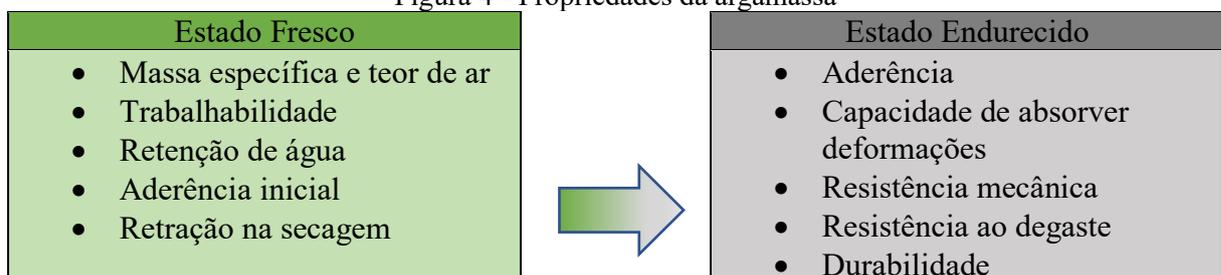
Existem diferentes aplicações de argamassa como: no assentamento de blocos em alvenarias, no assentamento de revestimento cerâmico em pisos e para o revestimento de paredes. Desse modo, tem-se diferentes traços que vão ser dimensionados de acordo com o

desempenho e a função desejada. Um traço com mais quantidade de cimento, denominado de consumo ou teor de cimento, vai ocasionar em uma argamassa com maior resistência mecânica. No caso de uma granulometria de areia com menor distribuição entre os tamanhos dos grãos, denominadas de areia grossa, média e fina, a argamassa pode conter mais vazios, o que vai afetar a sua resistência (FIORITO, 1930).

Essa variação do emprego da argamassa pode ser observada nas aplicações para revestimento em ambientes externos e internos. Na região interna de edificação, a argamassa tem que resistir a possíveis impactos e solicitações como objetos pendurados, por exemplo. Já na área externa, além de resistir aos impactos, deve também suportar as intempéries do ambiente e garantir a estanqueidade da construção em relação a água da chuva (ABNT NBR 15575-4, 2021). Dessa maneira, verifica-se que é importante compreender as propriedades e características da argamassa para escolher o melhor tipo, de acordo com o desempenho desejado.

Segundo a ciência dos materiais, a argamassa endurecida é um material cerâmico com comportamento frágil, ou seja, não sofre deformação plástica, o que ocasiona em uma ruptura mais abrupta quando a tensão aplicada ultrapassa a tensão de resistência. Ela possuiu dois estados relacionados a sua produção e desempenho ao longo da vida útil sendo eles o estado fresco e o endurecido. O estado fresco é aquele em que os insumos foram misturados e a argamassa ainda possui fluidez para sua moldagem e aplicação. O estado endurecido inicia-se quando as reações químicas de hidratação dos componentes do cimento já estão ocorrendo e já propiciaram o endurecimento da argamassa, etapa denominada de início de pega. Um processo relevante para a qualidade do revestimento argamassado é a cura. Trata-se de molhar a superfície do revestimento com água. Isso deve ser feito porque o cimento consome água no seu processo de hidratação e endurecimento, dessa maneira, deve-se garantir que não falte água para as reações químicas necessária acontecerem. As propriedades da argamassa dos dois estados podem ser observadas na Figura 4. (SABBATINI e BAÍA, 2004).

Figura 4 - Propriedades da argamassa



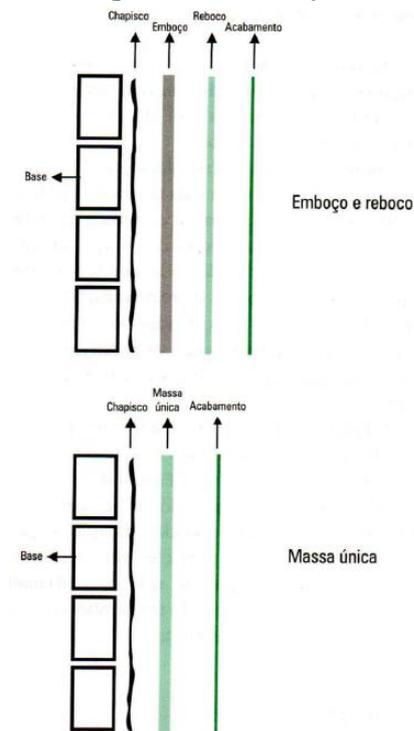
Fonte: (Adaptado de Sabbatini e Baía, 2004)

A argamassa deve ter capacidade de absorver deformações de pequena amplitude, como as que ocorrem em consequência da temperatura e da umidade. Porém, não é função dela resistir a deformações de grande amplitude, como deslocamentos estruturais, que devem ser suportados pela estrutura da edificação. Para garantir o desempenho adequado quanto a movimentação estrutural dos elementos, deve-se realizar justas de dilatações, quando essas são necessárias. A resistência mecânica deve ser o suficiente para suportar ações de diferentes naturezas devido à abrasão superficial, ao impacto e a contração termoigroscópica. Essa propriedade está diretamente ligada ao processo executivo, ao consumo e à natureza dos aglomerantes e agregados empregados. Fatores como fissurações, espessura excessiva, proliferação de microrganismos, afetam diretamente na durabilidade da argamassa (SABBATINI e BAÍA, 2004).

O revestimento argamassado consiste de um conjunto camadas de argamassas. Ele é considerado um subsistema do sistema de vedação vertical. Segundo a ABNT NBR 15575-4 (2021), os sistemas de vedação vertical são as partes que limitam verticalmente a edificação dividindo seus ambientes. São vedações verticais as paredes, as divisórias internas e as fachadas, podendo ser denominadas, também, de fechamentos. Existem vários tipos de vedações, como é o caso do *dry wall*, *steel frame*, parede de concreto, *wood frame*, dentre outros. Todos os sistemas devem atender aos requisitos de desempenho da ABNT NBR 15575 (2021) e suas respectivas partes.

O sistema tradicional de vedação consiste da junção da alvenaria, também denominada de base, com revestimento argamassado. A alvenaria é composta pelo assentamento de componentes de fechamento. O bloco cerâmico de vedação é um exemplo de componente da alvenaria, popularmente conhecido como tijolo furado. Existem diferentes tipos de revestimento argamassado, variando suas camadas de aplicação. Os dois tipos mais utilizados podem ser observados na Figura 5 (BAUER, 2005).

Figura 5 - Camadas do revestimento de argamassa da vedação vertical: emboço e reboco; massa única



Fonte: (SABBATINI e BAÍA, 2004)

No subsistema de emboço e reboco da Figura 5, tem-se a camada de chapisco que é aplicada sobre a alvenaria. Ela tem a função de regularizar a base e melhorar a aderência para as camadas subsequentes. Em seguida, tem-se camada de emboço, com o objetivo de nivelar o chapisco e preparar a superfície para a aplicação do reboco, que é a camada final. No segundo subsistema, o de massa única, tem-se a aplicação do chapisco e o reboco em duas camadas, sem a aplicação do emboço (ABNT NBR 13749, 2013). O intervalo entre as espessuras mínimas e máximas do revestimento finalizado, contando com todas as camadas, pode ser observado na Tabela 1.

Tabela 1 - Espessuras admissíveis de revestimentos Internos e Externos	
Revestimento	Espessura (e) mm
Parede interna	$5 \leq e \leq 20$
Parede externa	$20 \leq e \leq 30$
Tetos internos e externo	$e \leq 20$

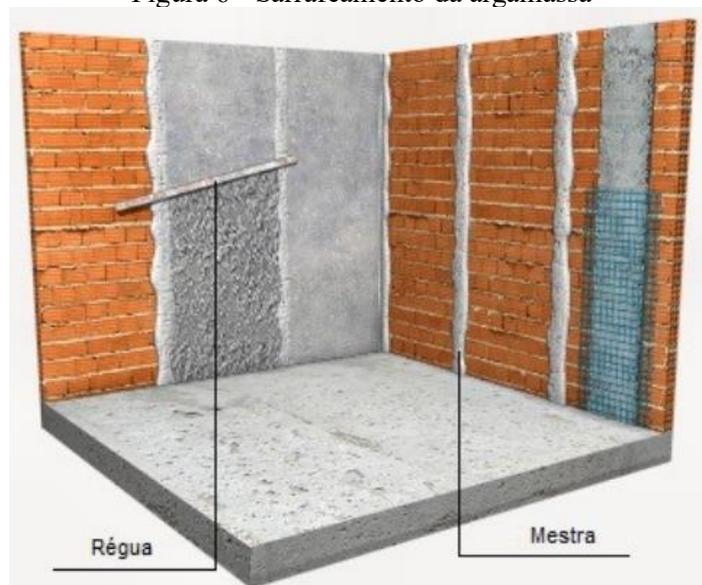
Fonte: (ABNT NBR 13749, 2013)

O acabamento do revestimento argamassado pode ser realizado de diversas maneiras. Pode-se aplicar uma pintura para a finalização ou executar algum procedimento para se obter uma textura com a superfície topográfica desejada. O acabamento é a camada final da vedação

e que vai determinar o seu aspecto estético. Ela está diretamente relacionada com o desempenho do sistema, por exemplo, em uma região com forte precipitação, pode ser interessante utilizar uma pintura impermeabilizante para melhorar a estanqueidade da edificação (AZEVEDO, 2007).

Para o acabamento superficial liso, deve se realizar o sarrafeamento, desempenho e camurçamento. O sarrafeamento consiste do aplainamento da superfície após a aplicação da argamassa, deve ser realizado após o material ter perdido um pouco de água e estar com a trabalhabilidade adequada para o processo. Para isso, utiliza-se uma régua metálica de alumínio apoiada em alinhamentos de referência, denominados de mestras, que devem delimitar a espessura finalizada do revestimento de acordo com o projeto. Um esquema de sarrafeamento utilizando mestras e a régua metálica pode ser observado na Figura 6 (SUDECAP, 2018).

Figura 6 - Sarrafeamento da argamassa

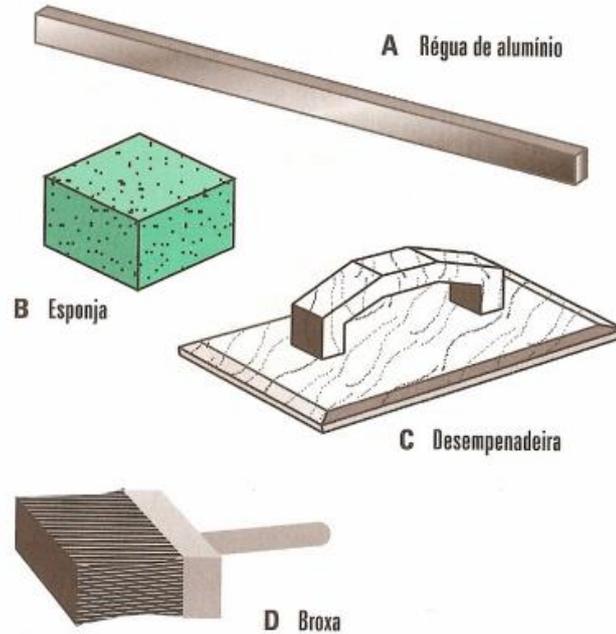


Fonte: (SUDECAP, 2018, adaptado de Planeta Eng, 2015)

O desempenho tem como objetivo regularizar e nivelar a argamassa. Ele é realizado com a ferramenta denominada desempenadeira. Deve-se realizar movimentos circulares sobre a superfície do emboço ou massa única, exercendo determinada pressão. Já no camurçamento, é realizado uma fricção no revestimento com uma esponja ou uma desempenadeira com espuma úmida. Esse processo deve ser feito, também, por meio de movimentos circulares e propicia um acabamento superficial mais liso no revestimento argamassado finalizado. Isso acontece porque as partículas de cimento, que tem granulometria mais fina que os outros compostos, acabam se concentrando na superfície devido a esse procedimento, removendo o aspecto rugoso

(SABBATINI e BAÍA, 2004). Na Figura 7 é possível observar as ferramentas utilizadas no processo de acabamento descrito.

Figura 7 - Ferramentas para as operações de sarrafeamento, desempeno e camurçamento



Fonte: (SABBATINI e BAÍA, 2004)

Além do acabamento liso com ou sem pintura, é possível realizar outras configurações de finalização a superfície do revestimento argamassado. Um desses acabamentos diferentes é o chapiscado. Nele, a superfície fica com aspecto rugoso. Ele pode ser obtido por meio da projeção de argamassa ou com rolo de textura. Na Figura 8 é possível verificar um exemplo de revestimento com acabamento chapiscado.

Figura 8 - Acabamento do tipo chapiscado



Outro tipo de acabamento superficial é grafiato. Ele é obtido a partir da mistura da argamassa com granitina, que são grãos de rochas moídas, derivados de um processo de moagem seletiva por cores e granulometria. Quando se passa a desempenadeira, esses grãos são arrastados, o que resulta um aspecto de ranhuras no revestimento. Um exemplo de acabamento do tipo grafiato pode ser observado na Figura 9.

Figura 9 - Acabamento do tipo grafiato



Tendo em visto o que foi exposto. É possível verificar que existem muitas variáveis que podem influenciar nas características finais estéticas e mecânicas dos revestimentos argamassados.

2.1.3 *Descontinuidades em revestimentos argamassados*

Como pode ser observado no item 2.1.1, avaliar as possíveis causas e implicações de problemas a partir da configuração do defeito já é uma metodologia de investigação consolidada nas engenharias (ABM, 1988). No caso das edificações, a linha de trabalho que avalia os problemas nas construções, propõem intervenções e determina os tipos de serviços prestados nessa área denomina-se de engenharia diagnóstica.

Segundo Gomide et al. (2013) sobre a engenharia diagnóstica:

“Um dos importantes benefícios introduzidos pela engenharia diagnóstica foi a concepção de uma hierarquia lógica, e muito bem fundamentada, dos serviços prestados pelos profissionais especializados, partindo do nível mais simples, qualificado como Vistoria em Edificação, até o nível mais complexo da prestação do serviço, caracterizado pela Consultoria em Edificações. A hierarquização dos serviços os permite que sejam ofertados de forma mais precisa e clara ao mercado, evitando

que um trabalho seja classificado como “imprestável”, por não satisfazer às necessidades do interessado, assim como proporciona relações justas entre os honorários e os serviços desenvolvidos” (GOMIDE, FAGUNDES NETO e GULLO, 2013).

As principais ferramentas de investigação utilizadas na engenharia diagnóstica são as vistorias, inspeções, auditoria, perícia e consultoria. Elas podem ser definidas como:

- Vistoria: É o ato de constatar e catalogar o defeito ou falha;
- Inspeção: A partir do problema levantado, é realizada uma análise técnica considerando as variáveis relacionadas ao problema;
- Auditoria: Nessa parte, a situação avaliada é confrontada com as normas técnicas e legislações vigentes;
- Perícia: É a apuração e conclusão sobre os fatores envolvidos no problema e atribuição das devidas responsabilidades;
- Consultoria: Trata-se do prognóstico do defeito, da determinação de como ele irá evoluir. É nessa etapa que se faz as prescrições técnicas relativas aos problemas, como a gravidade e o que deve ser realizado para mitigação dos danos.

Para o emprego dessas ferramentas, diferentes metodologias são utilizadas como, por exemplo, a catalogação dos defeitos encontrados a partir de relatório fotográfico e a aplicação de ensaios não destrutivos (END). São exemplos de ensaios não destrutivos aplicados em edificações o uso de indução magnética para detectar e medir o diâmetro de barras de aço no concreto armado, o uso de ultrassom para localizar tubulações em paredes e o uso de termografia infravermelha para detectar pontos de vazamento de água em sistemas hidrossanitários (MARIANA, BARRETO, *et al.*, 2014; SANTOS, ROCHA e PÓVOAS, 2019).

Um dos meios mais utilizado para detectar problemas em inspeções é a análise sensorial. Trata-se do uso dos sentidos humanos para identificar quando se tem o desempenho de alguns sistemas e ou de um material abaixo do adequado. É o caso da visão na da inspeção visual e da análise sonora da presença de som clavo em revestimento cerâmico, que ocorre devido a presença de delaminações, quando se aplica o impacto de um martelo padronizado. Esse último procedimento citado é denominado de ensaio de percussão (ABNT NBR ISO 5492, 2017).

Para se atribuir responsabilidades e verificar os riscos de problemas é importante realizar a análise da origem, da causa e do mecanismo de formação. A origem está relacionada a etapa do processo produtivo ou do uso em que o problema foi inserido no material avaliado. A causa é, literalmente, o que causou o defeito. Já o mecanismo de formação está relacionado ao processo químico ou físico que explica a falha ocorrida. Por exemplo, no caso de um eixo de

aço que rompeu por torção devido a presença de bolhas dentro de sua estrutura. A origem seria momento em que essa bolha foi inserida no material em seu processo de fabricação. A causa seria a bolha de ar que gerou uma descontinuidade do eixo de aço e fragilizou o mesmo. O mecanismo de formação seria o esforço a torção que foi aplicado no objeto em questão. A partir dessas delimitações, é possível arbitrar responsabilidades, realizar intervenções, recuperações e retroalimentar o processo produtivo para tentar evitar a incidência da falha identificada (SENA, NASCIMENTO e NETO, 2020).

A ciência que estuda as características dos problemas em edificações é a patologia das construções. Inspirada na medicina, essa abordagem traz conceitos da área da saúde como anamnese e profilaxia, aplicando-os no contexto das construções. Isso pode ser observado na afirmação de França et al. (2011), que compara o funcionamento e os sistemas das edificações com corpo humano.

“É fácil traçar um paralelo e entender que o esqueleto de um ser humano compara-se à estrutura de um edifício, onde a musculatura se assemelharia às alvenarias, a pele poderia ser comparada aos revestimentos, o sistema circulatório seria como as instalações elétricas, de gás, esgoto e água potável enquanto que o aparelho respiratório seria o sistema de ventilação (janelas, ar-condicionado, sistemas de exaustão etc.)” (FRANÇA, MARCONDES, *et al.*, 2011)

O processo de diagnosticar problemas em edifícios é similar as abordagens que são realizadas nas ciências da saúde. O profissional analisa os sintomas e a partir deles são definidos os procedimentos necessários para solução ou investigação da situação em questão. Um paralelo como o exemplificado pode ser verificado na Figura 10.

Figura 10 - Comparação entre procedimentos de solução entre a medicina e a engenharia civil

	MEDICINA	ENGENHARIA CIVIL
Análise inicial	Consulta	Inspeção
	↓	↓
Sondagem do problema	Exames	Ensaio não-destrutivos e destrutivos
	↓	↓
Diagnóstico	Verificação dos exames	Resultados dos ensaios
	↓	↓
Tratamento	Medicação, cirurgia, entre outros	Proposição das soluções construtivas adequadas

Fonte: (GARCIA SOBRINHO, 2020)

No caso das edificações, os problemas e sintomas detectados são denominados de manifestações patológicas. Uma das manifestações mais recorrentes são as fissurações. Elas são descontinuidades que, de modo geral, surgem em materiais frágeis, como o concreto e a cerâmica vermelha, quando algum esforço a tração ultrapassa a resistência do material. Desse modo, são formadas aberturas na estrutura de seus corpos que podem variar de acordo com o seu tamanho, espessura e profundidade (THOMAZ, 2020).

No caso da patologia das construções, as fissurações são classificadas de acordo com o nível de abertura, como pode ser observado na Tabela 2.

Tabela 2 - Classificação das aberturas de fissuras em alvenarias

Classificação	Aberturas (mm)
Fissura	até 0,5
Trinca	de 0,5 até 1,5
Rachadura	de 1,5 até 5,0
Fenda	de 5,0 até 10,0
Brecha	acima de 10,0

Fonte: (OLIVEIRA, 2003)

Para o estudo desenvolvido nesta tese, o nível de abertura não medido. Sendo assim, esses tipos de descontinuidades serão todos denominados como fissuras e fissurações, que são os termos mais genéricos para abordar o tema.

Além do nível de abertura, as fissurações são classificadas em ativas, passivas e sazonais. As fissuras ativas são aquelas que ainda estão em processo de desenvolvimento no qual a fissura ainda está aumentando. Por exemplo, em um recalque pontual na edificação por algum problema na resistência do solo suporte. Enquanto o solo estiver abaixando, a fissura vai continuar a crescer. No caso das passivas, são as fissuras que estão estabilizadas, que não aumentam mais de tamanho. Retomando o exemplo citado, seria a situação das descontinuidades no momento em que o recalque parasse de progredir. As fissurações sazonais são aquelas que variam de tamanho de acordo com as condições ambientais. É o caso quando se tem o encontro de materiais distintos, pois, devido aos coeficientes de dilatação diferentes, eles também irão movimentar de forma diferente de acordo com variação de temperatura, o que pode ocasionar fissurações nas regiões de ligação (THOMAZ, 2020).

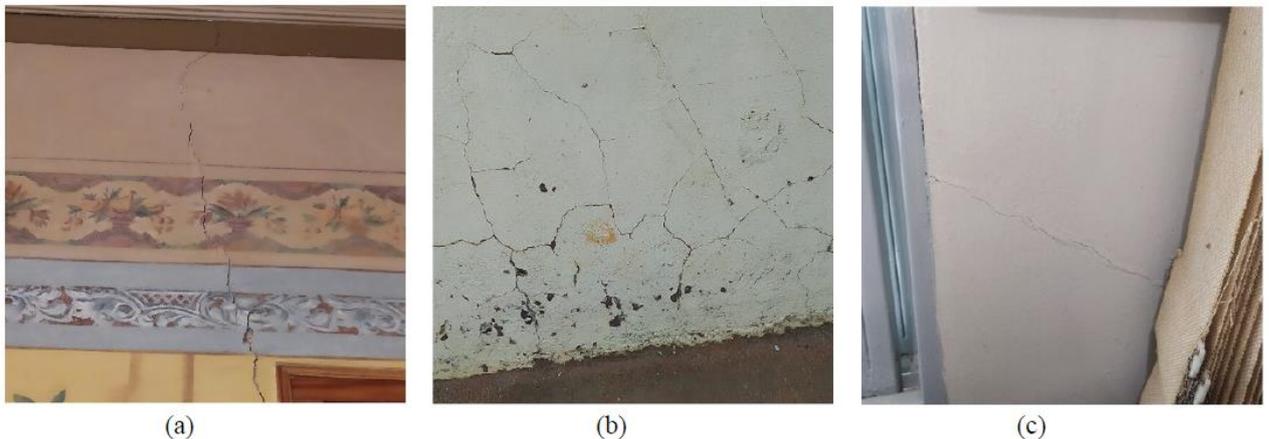
Esses fatores são importantes para escolha do procedimento e técnica adequada para recuperação. É possível realizar um reparo superficial em uma fissura passiva, porém, se ela for

ativa, o problema voltara a incidir. No caso de fissurações sazonais em relação a dilatação devido a variação de temperatura, também não resolve reparar superficialmente o problema. Nesse caso, é necessário enrijecer a ligação de maneira adequada ou realizar uma junta de dilatação com material que consegue deformar junto com a movimentação dos materiais em questão.

Desse modo, é possível verificar que a análise de fissurações em edificações depende de diferentes fatores. Uma das características que é relevante para um diagnóstico é a configuração da fissura. Assim como na mecânica da fratura, é possível atribuir informações a partir da maneira com que a fissura se apresenta.

Quanto a configuração, as fissuras são definidas como geométricas e mapeadas. As geométricas formam delineações que possuem sentidos podendo ser verticais, horizontais ou inclinadas. Uma fissura geométrica pode se ramificar em diferentes caminhamentos ou encontrar com outras descontinuidades desse tipo. Já as fissurações mapeadas são um agrupamento de descontinuidades que formam um aspecto parecido com mapas. Elas costumam a ser mais superficiais. Os diferentes tipos de configurações podem aparecer isolados ou em conjunto, de uma forma mais generalizada. Alguns tipos de disposições de fissuras podem ser observados na Figura 11.

Figura 11 - Diferentes tipos de configurações de fissuras



(a) Fissura geometria inclinada por recalque; (b) Fissuração mapeada; (c) Fissura inclinada em esquadria
Fonte: (GARCIA SOBRINHO, 2020)

As fissurações possuem comportamentos e aspectos característicos de acordo com suas origens e causas. Desse modo, é possível ter uma apuração preliminar ou mais precisa a partir de uma inspeção visual.

Por exemplo, encontros entre a estrutura e os fechamentos, como em pilares e vigas com a alvenaria, costumam a gerar fissuras geométricas na vertical e na horizontal. Isso ocorre devido

à ausência da ligação entre os elementos, que deveria ter sido realizada utilizando tela metálica ou barras de aço, ou pela necessidade de uma junta de dilatação que não foi realizada. Sendo assim, com a dilatação diferentes dos materiais, vai ocorrer a descontinuidade seguindo o alinhamento da ligação entre os diferentes tipos de materiais. Isso pode ser observado na Figura 12.

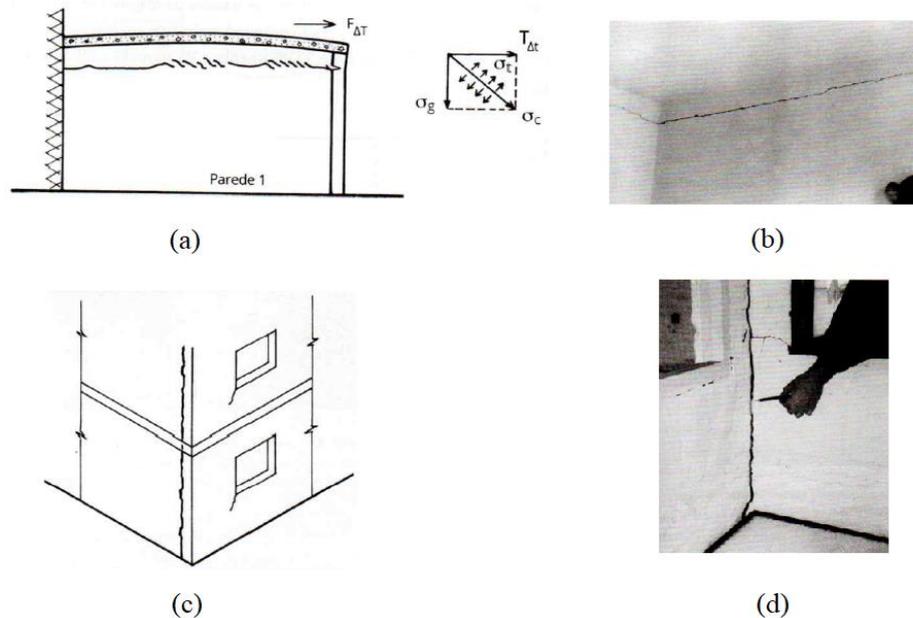
Figura 12 - Fissurações por ausência de juntas de dilatação



Fonte: (GARCIA SOBRINHO, MOTTA e GUTERRES, 2021)

Fissurações geométricas na vertical e na horizontal também são comuns quando ocorre uma variação volumétrica somente de uma parte da edificação por conta de ações hidrotérmicas. Desse modo, a expansão ou retração localizada vai gerar um esforço nos demais elementos da construção causando uma ruptura pelo modo de deslocamento do tipo I, conforme mostrado na imagem (a) da Figura 3. Na Figura 13 segue exemplos da situação explicada.

Figura 13 - Exemplos de fissurações por ações hidrotérmicas

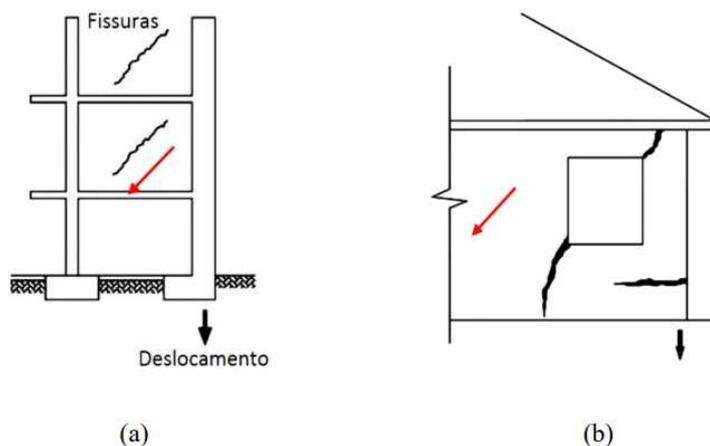


(a) e (b) Fissura no topo da parede devido ao abaulamento da laje de cobertura; (c) e (d) Fissuração no canto de edifício devido à expansão de tijolos devido a absorção de umidade;

Fonte: (Adaptado de THOMAZ, 2020)

Descontinuidades na configuração inclinada estão comumente associadas a problemas estruturais como recalque em edificações. Costumam a ser mais alarmantes e de acordo com o seu grau de abertura e local de incidência, podem indicar risco aos usuários e necessidade de interdição da edificação. Esse tipo de fissura, quando associada a recalques diferenciais, ocorre a 45° no sentido oposto ao ponto de rebaixamento, como apresentado na Figura 14. Na Figura 15, é possível verificar uma fissura com direção predominante a 45° devido a um recalque diferencial. Nesse caso, a estrutura do telhado precisou ser apoiada devido a fragilidade causada na parede.

Figura 14 – Fissurações por recalque de fundações



(a) Fissuras por recalque de fundação de pilar de canto; (b) Fissuras na parede por recalque na extremidade

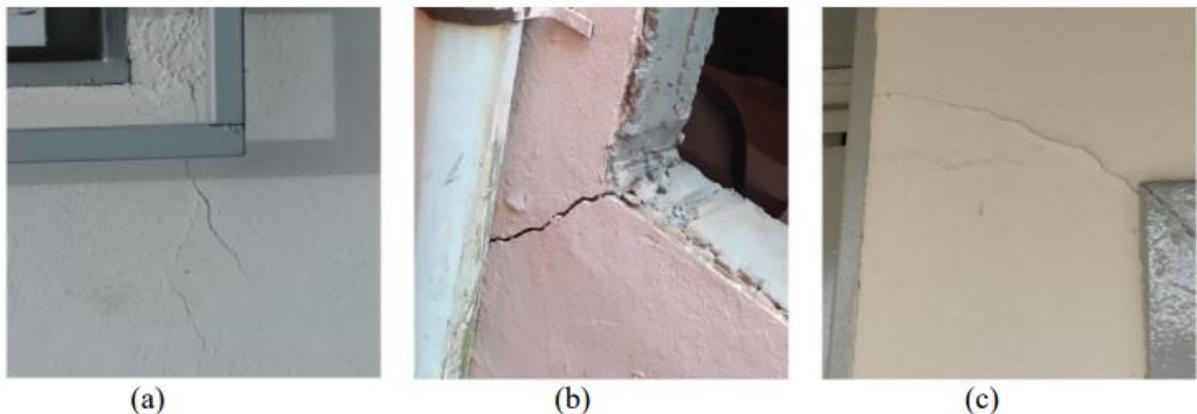
Fonte: (MILITITSKY, CONSOLI e SCHNAID, 2005)

Figura 15 - Fissuração com direção predominante a 45°



Em relação as fissurações a 45°, nem todas indicam a incidência de um recalque. Por exemplo, em cantos de esquadrias, quando não é feito o reforço dos cantos das aberturas a partir de vigas denominadas de verga e contra-verga, pode ocorrer fissurações, geralmente a 45°. Isso porque a abertura que na parede geram concentração de tensões em seus cantos, como é mostrado na Figura 2. Exemplos de ruptura a partir de concentração de tensões em bordas de esquadrias podem ser verificadas na Figura 16.

Figura 16 - Diferentes configurações de fissurações



Fonte: (GARCIA SOBRINHO, MOTTA e GUTERRES, 2021)

As fissurações mapeadas podem possuir diferentes aspectos. A partir de suas características visuais, é possível atribuir suas causas ou origens. Por exemplo, a retração excessiva da argamassa devido à perda de água no seu processo hidratação do cimento e

ausência de uma cura adequada pode gerar fissurações na configuração mapeada. Essas aparecem de forma mais espaçada, como pode ser observado na Figura 17.

Figura 17 - Fissuração por retração na argamassa



Fonte: (SAHADE, 2005)

Já quando ocorrem devido a falhas no processo do camuçamento, as discontinuidades mapeadas são mais agrupadas, denominadas de microfissuras por serem pequenas e superficiais. Esse tipo de problema ocorre pela aplicação excessiva da esponja e dos movimentos circulares na etapa de camuçamento na finalização do revestimento liso, que foi explicado no item 2.1.4. Acontece que, com esse procedimento em excesso, ocorre uma deposição acentuada das partículas do cimento na superfície, que enrijece uma camada fina superficial. Desse modo, a superfície não tem capacidade de absorver deformações devido a secagem da argamassa e as ações do tempo, o que resulta em fissurações. Esse tipo de configuração pode ser visto na figura 18.

Figura 18 – Microfissuras mapeadas



Fonte: (BURKHEAD, 2023)

Outra incidência de fissurações mapeadas ocorre devido a fadiga hidrotérmica. Com o passar do tempo as ações de ciclos de secagem e umedecimento e de aquecimento devido a incidência direta da insolação fragilizam a superfície do revestimento argamassado causando fissurações. Uma maneira de evitar esse problema é realizando a manutenção a partir de pinturas periódicas para proteção da fachada. Esse tipo de descontinuidade pode se observado na Figura 19.

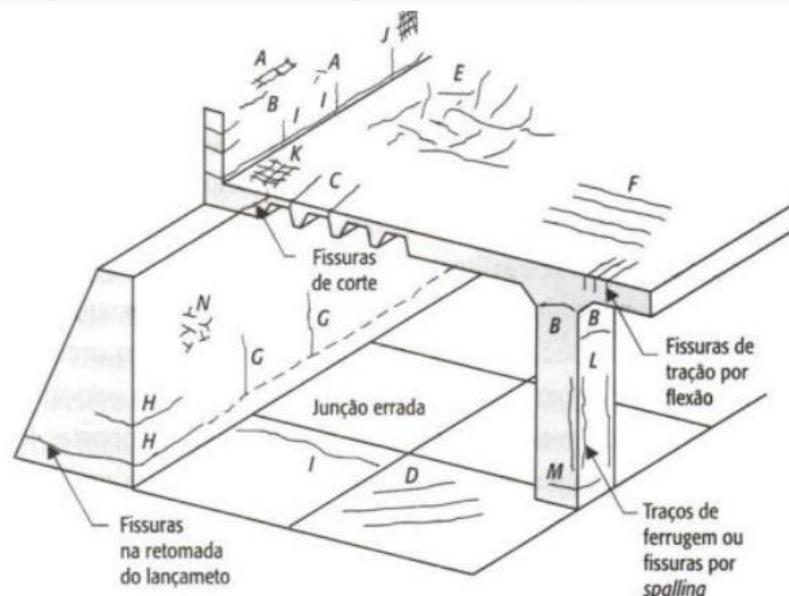
Figura 19 - Fissuras devido a fadiga hidrotérmica



Fonte: (SAHADE, 2005)

Na Figura 20, tem-se diferentes tipos e configurações de fissurações que podem incidir em revestimentos argamassados e estruturas de concreto, agrupadas por principais tipos de causas.

Figura 20 - Diferentes configurações de fissurações e suas causas



(A) (B) e (C) Fissurações devido a assentamento plástico; (D) (E) e (F) Fissurações devido a retração plástica; (G) e (H) Fissurações devido a contrações térmicas prematuras; (I) Fissura por retração hidrotérmica; (J) e (K) Microfissuras; (L) e (M) Fissurações devido a corrosão de armadura; (N) Fissuração devido a reação álcali-agregado

Fonte: (BERTOLINI, 2010)

A análise critério visual é um dos quesitos de desempenho estruturais de sistemas de vedações. De acordo com a ABNT NBR 15575 (2021), as ocorrências de fissuras ou descolamentos são consideradas toleráveis caso atendam às seguintes características, conforme o local do aparecimento:

“a) sistema de vedação vertical interna (*SVVI*) ou faces internas de sistema de vedação vertical externa (*SVVE*) (fachadas):

- Fissuras no corpo dos *SVVI* ou nos seus encontros com elementos estruturais, destacamentos entre placas de revestimento e outros seccionamentos do gênero, desde que não sejam detectáveis a olho nu por um observador posicionado a 1,00 m da superfície do elemento em análise, num cone visual com ângulo igual ou inferior a 60°, sob iluminação igual ou maior que 250 lux, ou desde que a soma das extensões não ultrapasse 0,1 m/m², referente à área total das paredes do ambiente;

b) fachadas ou sistemas de vedação vertical externo (*SVVE*):

- Fissuras no corpo das fachadas, descolamentos entre placas de revestimento e outros seccionamentos do gênero, desde que não sejam detectáveis a olho nu por um observador posicionado a 1,00 m da superfície do elemento em análise, num cone visual com ângulo igual ou inferior a 60°, sob iluminação natural em dia sem nebulosidade;” (ABNT NBR 15575-1, 2021)

Tendo em vista tudo que foi apresentado, é possível verificar a importância das características visuais das fissurações para atribuir possíveis causas, origens e mecanismos de formações bem como iniciar a arbitrar um diagnóstico. Serviços como vistorias e inspeções prediais são embasados, principalmente, em análise sensorial, o que demonstra a relevância do aspecto e configuração das discontinuidades nessa área da engenharia. Observando a relevância da inspeção visual para a situação abordada, a próxima seção irá abordar esse tipo de ensaio a partir do conceito de END.

2.2 ENSAIOS NÃO DESTRUTIVOS

Os ensaios não destrutivos são metodologias para detectar defeitos e discontinuidades em peças e materiais. Desse modo, é possível evitar problemas em suas aplicações que poderiam gerar desde custo de manutenções corretivas até à prejuízos segurança de usuários (ABM, 1981).

Identificar descontinuidades em elementos e materiais por meio de ensaios não destrutivos é uma aplicação já utilizada em diversas vertentes, como já mostrado sobre a mecânica da fratura (ASKELAND e WRIGHT, 2016).

Existem diferentes tipos de ensaios não destrutivos. Eles possuem mecanismos de funcionamento diferentes o que orienta sua aplicação em consonância com o tipo de material e descontinuidade a ser inspecionada.

São exemplos de ensaios não destrutivos: Inspeção visual, emissão acústica, correntes parasitas, radiografia, ultrassom, termografia infravermelha, líquido penetrante, estanqueidade, partículas magnéticas (ABM, 1981). Na próxima subseção, serão tratadas algumas características básicas do ensaio de inspeção visual.

2.2.1 Inspeção visual

O exame visual foi o ensaio não destrutivo pioneiro nesse tipo de análise. Por meio dessa abordagem, engenheiros descartavam peças que eram consideradas defeituosas (ABM, 1981). Além de prevenir falhas, observou-se que o custo para realizar esse tipo de verificação era bem inferior aos decorrentes dos prejuízos de uma falha durante a operação (ACI, 1973).

A inspeção visual é um dos END mais utilizados. Segundo U.S. Department of Transportation (2021), “aproximadamente 80% de todos os procedimentos de END são realizados por métodos visuais diretos”. Esse tipo de ensaio é aplicado com frequência no setor aeronáutico para detectar descontinuidades e falhas estruturais em aeronaves (STASZEWSKI, BOLLER e TOMLINSON, 2004).

No processo de uma inspeção visual, verifica-se a integridade da peça ou do material por meio do que é possível inferir a partir da visão, podendo ser a olho nu, o que caracteriza um ensaio visual direto, ou por meio de equipamentos, denominado de ensaio visual indireto. A partir dessa observação, pode-se verificar defeitos superficiais e, em alguns casos, subsuperficiais. É possível observar diferentes tipos de descontinuidades como trincas, delaminações, corrosão, contaminações, falhas de acabamento superficial, deslocamentos adesivos, dentre outros (U.S. DEPARTMENT OF TRANSPORTATION, 2021).

A observação humana é variável, ou seja, cada pessoa pode ter uma percepção diferente de um mesmo cenário. A visão humana depende da percepção da luz visível, profundidade, cores e distância podendo ser afetada por ilusão de ótica. Fatores como a distância entre o observador e o objeto, o tipo de iluminação, a experiência, treinamento e fadiga do observador em serviços longos, afetam diretamente na percepção e precisão da inspeção. Desse modo, de

acordo com a abordagem, existem padronizações entre esses fatores para ensaios de inspeção visual (ABM, 1981; U.S. DEPARTMENT OF TRANSPORTATION, 2021).

Os ensaios visuais por meio remoto auxiliam em inspeções de difícil acesso ou em ambientes insalubres. Por meio de dispositivos que conseguem capturar imagens ou vídeos é possível realizar inspeções, a partir da visão, em diversas situações nas quais são inviáveis ou não é possível a aproximação de um inspetor. Um dos métodos que vêm sendo utilizado em ambientes industriais, em maquinário e edificações é a inspeção por meio de veículos aéreos não tripulados (VANT), como o caso de drones (JORDAN, MOORE, *et al.*, 2018).

A obtenção de imagens em inspeções visuais ampliou as possibilidades e aplicações deste tipo de END. Um desses processos é a correlação de imagem digital (DIC), no qual deformações na superfície são capturadas em câmeras digitais de alta resolução, em duas ou três dimensões, e a partir delas se faz correlações com as propriedades do material analisado. É possível medir o contorno, a vibração, tensão, deformação em diferentes tipos de componentes (STRAUCH, 1991; FERREIRA, 2012).

Como foi visto no item 2.1.3 do referencial teórico. A inspeção visual é muito aplicada em serviços da engenharia diagnóstica de edificações. No caso de fissurações, é uma ferramenta de avaliação de desempenho estrutural da ABNT NBR 15575-4 (2021). A partir do uso dessa metodologia em atividades como vistorias e inspeções, é gerado um grande número de imagens. Essas, por sua vez, são catalogadas e classificadas, de acordo com o nível de precisão ou profundidade que o serviço executado exige (GARCIA SOBRINHO, 2020). A produção de imagens digitais nesses processos propicia abordagens de visão computacional, como é o caso de IA na classificação de imagens.

Tendo em vista os pontos levantados, serão levantados conceitos e característica da aplicação de inteligência artificial em processamentos de imagens de acordo com as ferramentas que serão utilizadas na pesquisa dessa tese.

2.3 INTELIGÊNCIA ARTIFICIAL

A IA pode ser entendida como a capacidade atribuída a máquinas de realizarem atividades complexas, que são associadas a inteligência e ao raciocínio humano. Explorada após a Segunda Guerra Mundial, essa tecnologia tem sido cada vez mais aplicada e presente em diferentes abordagens tecnológicas e em diversos produtos. Além disso, é uma ferramenta constantemente empregada em estudos para otimizar processos, como no caso das engenharias (RUSSEL e NORVIG, 2013).

De acordo com Coppin (2013), o conceito de IA é relativamente novo, porém, suas bases já existem há milhares de anos. O autor defende que o pensamento e a pesquisa que constituem o que atualmente é denominado de IA são baseados em áreas como na psicologia, biologia, filosofia e linguística, a partir de conhecimentos que são explorados a muito tempo pela humanidade.

Segundo Coelho (1994):

“Os problemas de IA resistem a uma especificação e estão em geral descritos de forma incompleta, referem-se a domínios dinâmicos e estão em geral descritos de forma incompleta através de uma aproximação modular, estão intimamente associados ao contexto do uso, e possuem que costumam a ser adequadas, em vez de corretas. Por isso, o desenvolvimento não é feito da mesma forma que na engenharia de programação.” (COELHO, 1994)

No início do desenvolvimento da IA, as soluções para os problemas eram realizadas a partir do conhecimento de especialistas. Por meio entrevistas, essas informações eram levantadas e sistematizadas a em regras lógicas. Esses sistemas eram denominados de sistemas especialistas, atualmente, por IA simbólica. Esse tipo de procedimento era bem limitado, pois, tinha-se uma grande dependência do especialista para se obter boas soluções, o que nem sempre acontecia. Constantemente, se verificava o receio por parte do profissional de ser substituído pela máquina, o que limitava o levantamento de dados. Devido ao crescimento da complexidade dos problemas que deveriam ser computacionalmente tratados, foi necessário desenvolver metodologias mais sofisticadas, mais independentes da intervenção humana e autônomas. Desse modo, teve o surgimento do Aprendizado de Máquina (AM) (FACELI, LORENA, *et al.*, 2021).

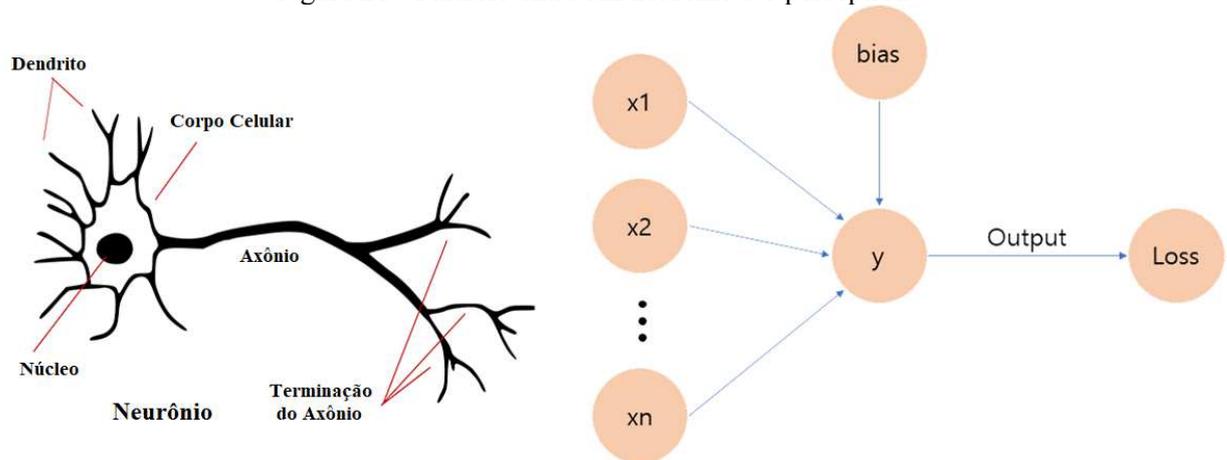
Com o desenvolvimento do AM, foi possível avançar em vários ramos da IA como na robótica, na visão computacional, processamento de linguagem computacional, raciocínio humano e representação do conhecimento (FACELI, LORENA, *et al.*, 2021).

Um dos pontos que otimizaram o desenvolvimento de aplicações de IA foi a evolução da capacidade de processamento e armazenamento de grandes volumes de dados. Dentre as tecnologias desenvolvidas para abordagens de IA, tem-se algorítmicos bioinspirados no funcionamento do cérebro humano denominados de redes neurais (BRAGA, CARVALHO e LUDERMIR, 2000).

Segundo (HAYKIN, 2001) “O Cérebro humano é um computador (sistema de processamento de informação) altamente complexo, não-linear e paralelo.” Um exemplo disso

é a visão humana que pode ser entendida como uma tarefa de processamento de informação. O cérebro por volta de 10^{11} neurônios e cada um deles processa informações e se comunicam uns com os outros continuamente e em paralelo. As redes neurais são inspiradas nessas células, no seu funcionamento e na maneira em que elas interagem. Um exemplo mais tradicional dessa bioinspiração é no perceptron (BRAGA, CARVALHO e LUDERMIR, 2000). Na Figura 21 pode-se verificar um paralelo entre um neurônio e o perceptron.

Figura 21 - Paralelo entre um neurônio e o perceptron



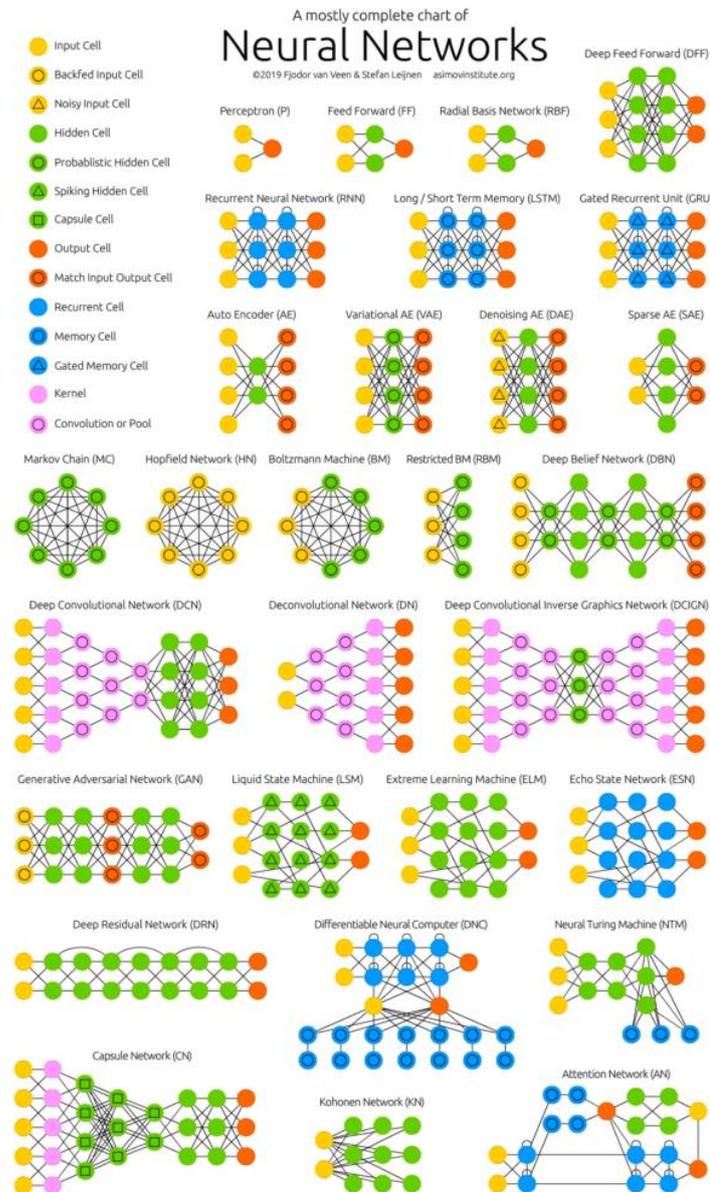
Fonte: (DSML, 2023)

O perceptron é um modelo matemático que pode receber várias entradas e produz uma única saída binária. Em seu processamento, pesos e *bias* são atribuídos para cada entrada. A partir disso, os valores ajustados das entradas são submetidos a uma função de ativação, que vai tentar agrupar os dados de acordo com uma classificação binária. Caso a resposta desse processamento não seja adequada, é realizada a retropropagação do erro, que consiste do ajuste dos pesos e bias a partir do resultado inadequado da saída. Isso é realizado várias vezes, na tentativa do perceptron ajustar a melhor configuração de pesos e bias para que o a rede consiga chegar na melhor condição relacionada a solução desejada. Cada um desses ciclos, considerando a entrada do dado, o ajuste dos pesos e *bias*, a função de ativação e a retropropagação do erro é chamado de épocas (HAYKIN, 2001; BRAGA, CARVALHO e LUDERMIR, 2000).

É possível observar que o perceptron, apesar de didático, é um modelo simples, que não conseguiria abranger problemas muito complexos como os que necessitam de mais saídas do que uma categorização binária. Nenhuma atividade do cérebro humano, por exemplo, não funciona somente com um neurônio, e sim sempre com um conjunto deles. Para isso, utiliza-se

o perceptron multicamadas. Realizando diferentes maneiras de combinações desses neurónios ao longo de implementações desses tipos de algoritmos, obteve-se diferentes arquiteturas de redes, que são empregadas nas mais diversas situações (HAYKIN, 2001). Alguns tipos dessas arquiteturas podem ser observados na Figura 22.

Figura 22 - Diferentes tipos de arquiteturas de redes neurais



Fonte: (DSA, 2023)

O *Deep Learning* (DL) utiliza essas redes profundas. O DL é uma ramificação do AM que tem o foco de trabalhar com um grande volume de dados. Uma das maiores vantagens do DL é que seus processamentos geram automaticamente propriedades que são relevantes para o

problema implementado. Desse modo, reduz grande parte do pré-processamento manual, pois, as redes têm um desempenho mais autônomo na aprendizagem (DSA, 2023).

O processo de treinar uma rede consiste a ensinar ela como trabalhar com o conjunto de dados e com o problema em questão. Esse procedimento pode ser mais manual ou mais autônomo. Para isso, tem-se 3 tipos principais de treinamento sendo eles: O supervisionado, não supervisionado e o semi-supervisionado. No caso do supervisionado, todos os dados já são rotulados e a rede vai ter que aprender a trabalhar com eles conforme as categorias que já foram definidas. No não supervisionado, os dados não estão rotulados e a própria rede vai ter que definir os rótulos. O semi-supervisionado é uma combinação dos dois métodos (RUSSEL e NORVIG, 2013).

Para executar um treinamento de uma rede, é necessário ter um conjunto de dados. No caso de DL, de grande volume. Esse conjunto é dividido em agrupamentos que são denominados grupo de treinamento, de teste e de validação. Por exemplo, em um caso de um treinamento supervisionado de uma classificação binária. O conjunto de treinamento vai ser utilizado para a rede tentar aprender a enquadrar os dados nas classes corretas, conforme os rótulos pré-existente. Sendo assim, toda vez que ela acerta ou erra em uma época, seus pesos e bias são ajustados para tentar chegar em valores que consigam acertar com mais precisão as classes definidas. A validação serve para avaliar se a rede não está somente memorizando o grupo de treinamento, ou seja, se ela está realmente aprendendo. O grupo de teste é um conjunto de dados que não foi utilizado no processo de treinamento da rede, desse modo, é avaliado o desempenho dela a partir de dados que são inéditos. Sendo assim, é possível verificar se a rede consegue manter o desempenho obtido no processo de treinamento em dados que nunca foram vistos por ela (DSA, 2023).

O conjunto de dados empregado nesse processo deve ser, preferencialmente, balanceado. Ou seja, deve ter um número igual de dados em relação as classes. Isso porque, se uma classe tiver mais dados do que a outra, ela pode gerar uma tendência no ajuste dos pesos além de prejudicar as métricas de assertividade. Isso pode ocasionar em *overfitting* e imprecisões quanto aos resultados do treinamento (DSA, 2023). Existem ferramentas que possibilitam trabalhar com conjuntos de dados desbalanceados como o *oversampling* e o *weighted loss* (GUO (A), WANG, *et al.*, 2020).

O *overfitting*, ou sobre ajuste, é algo que tem que ser evitado ao se elaborar uma IA. Uma das situações que pode ocasionar o *overfitting* é o super treinamento. Isso ocorre quando a rede para de aprender e começa a ajustar o próprio erro. Desse jeito, a rede começa a melhorar seu desempenho para o conjunto de dados do treinamento, porém, ela fica cada vez mais

distante de acertar em relação a outros dados, o que não é de forma alguma o cenário desejado. Uma das maneiras de evitar esse problema é utilizando o *early stopping*. Trata-se de uma implementação que finaliza o treinamento a partir do momento que a rede para de aprender, evitando, assim, o *overfitting* por conta desse processo. Uma das ferramentas que também ajuda a reduzir a chance de *overfitting* é a taxa de *dropout*. Por meio dela, neurônios da rede são desligados de forma aleatória, o que proporciona a rede uma aprendizagem mais robusta (DSA, 2023).

Feito o processo de treinamento, é necessário compreender como avaliar se a rede está tendo resultados bons ou ruins, para isso, são utilizadas algumas métricas de assertividades que serão explicadas no próximo item.

2.3.1 Métricas de assertividade

As métricas de assertividade são valores numéricos ou representações gráficas pelos quais é possível interpretar informações relativas ao desempenho da rede. Um indicador relevante para esse processo é a matriz de confusão, a partir dela é possível levantar métricas importantes para avaliar uma abordagem de classificação. Na Figura 23 é possível observar a configuração de matrizes de confusão.

Figura 23 - Matrix de confusão

A		Dado de Referência			
		A	B	C	Total
Dado Classificado	A	VA	FP	FP	\sum_c^A
	B	FN	VB	FP	\sum_c^B
	C	FN	FN	VC	\sum_c^C
	Total	\sum_r^A	\sum_r^B	\sum_r^C	\sum^T

B		Dado de Classificado			
		A	B	C	Total
Dado de Referência	A	VA	FN	FN	\sum_r^A
	B	FP	VB	FN	\sum_r^B
	C	FP	FP	VC	\sum_r^C
	Total	\sum_c^A	\sum_c^B	\sum_c^C	\sum^T

Fonte: (DINIZ, 2021)

A matriz de confusão relaciona a quantidade de erros e acertos para cada classe definida. Por exemplo, pensando em uma classificação binária de positivo e negativo. Toda vez que um dado positivo for classificado corretamente, ele será considerado um verdadeiro positivo. Quando um dado negativo foi classificado como negativo, ele será um verdadeiro negativo. Porém, quando uma informação positiva for classificada como negativa, ela será um falso

negativo. E do mesmo jeito ao contrário, um dado negativo definido como positivo, é um falso negativo.

Na Figura 23 é possível verificar uma matriz de confusão de uma classificação multi-classe. É possível observar que na diagonal principal da matriz estão os valores de verdadeiro positivo para as classes A, B e C, que no caso do exemplo citado acima, seriam as categorias positivo e negativo. Acima e abaixo da diagonal principal estão os falsos positivos e negativos. A variação dos falsos positivos negativos entre as matrizes A e B da Figura 23 é devido a maneira que foi posicionado os eixos das classes de referência, as reais, e do que foi classificado, o que foi predito. No fim, são os mesmos valores dentro da matriz, porém, organizados de maneira diferente. Só é necessário saber qual foi a definição desses eixos na montagem da matriz para a interpretação adequada dos resultados.

A partir dos valores extraídos da matriz de confusão, é possível obter as métricas de assertividade de acurácia, precisão, sensibilidade, especificidade e F-Score. Nas equações 1, 2, 3, 4 e 5 é possível verificar como que se obtém essas métricas.

$$A = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

$$P = \frac{VP}{VP + FP} \quad (2)$$

$$S = \frac{VP}{VP + FN} \quad (3)$$

$$E = \frac{VN}{VN + FP} \quad (4)$$

$$F - score = \frac{2 * (P + S)}{(P + S)} \quad (5)$$

Sendo que:

A = Acurácia;

P = Precisão;

S = Sensibilidade;

E = Especificidade

VP = Verdadeiros positivos

VN = Verdadeiros negativos;

FP = Falsos positivos;

FN = Falsos negativos.

A acuraria é uma das métricas mais importantes para avaliação do desempenho de uma rede. Ela verifica o percentual de acertos do modelo todo. Apesar de ser a mais aplicada, a acurácia sozinha pode acabar não traduzindo o desempenho detalhado do modelo, é o caso quando se tem classes desbalanceadas. Nesse caso, é adequado avaliar, também, a precisão.

A precisão é a relação da quantidade de acertos da classe analisada em relação a todos os dados dessa classe. É possível saber, dentro da classe avaliada, a quantidade que a rede acertou. Desse modo, a partir da precisão individual de cada classe, é possível verificar se a rede está acertando mais uma classe do que a outra.

Já a sensibilidade mede se a rede está detectando com sucesso os resultados que realmente são positivos dentro do que foi definido como positivo. No caso da especificidade, é o contrário. Nessa métrica, se avalia a capacidade de detectar os resultados negativos em relação ao que foi definido como negativo. O F-score é a média harmônica entre a precisão e a sensibilidade.

Essas métricas podem ser obtidas para o conjunto de teste, validação e treinamento. Para avaliar o desempenho de uma rede, o mais usual é utilizar as métricas aplicadas ao teste, pois, assim se verifica o desempenho da aplicação para um conjunto de dados que ela não conhece.

Além das métricas destacadas, é importante verificar a progressão da acurácia e do erro durante o processo de treinamento. No caso, em toda época o erro e a acurácia são avaliados. Plotando o erro e acuraria por épocas, em relação aos conjuntos de treinamento e validação, obtém-se gráficos pelos quais é possível observar se o treinamento teve um comportamento adequado. Acontece que o valor de acurácia deve aumentar na proporção que o erro diminui. Outro ponto é que é possível detectar se ocorreu *overfitting* devido ao super treinamento. Isso é observável quando o erro de treinamento continua a diminuir e o erro da validação começa a aumentar. Isso indica que nesse ponto o treinamento deveria ter sido encerrado. Uma medida que é utilizada para avaliação da rede é a melhor acurácia da validação, isso é realizado quando não se tem o grupo de teste. Porém, é importante ressaltar que, desse modo, o desempenho da rede não está sendo verificado para um conjunto de dados inéditos, e sim para dados que foram utilizados no treinamento.

Qualquer tipo de dado que pode ser lido por um computador pode ser utilizado para elaboração de redes e aplicações de IA. Dentre as possibilidades, tem-se as imagens. Como argumentado anteriormente, serviços de inspeção geram imagens e essas podem ser utilizadas como dados para elaborar redes classificadoras para problemas de engenharia. Tendo em vista isso, o próximo item tratara desse tipo de dado e de sua visão computacional.

2.3.2 *Processamento Digital de Imagens*

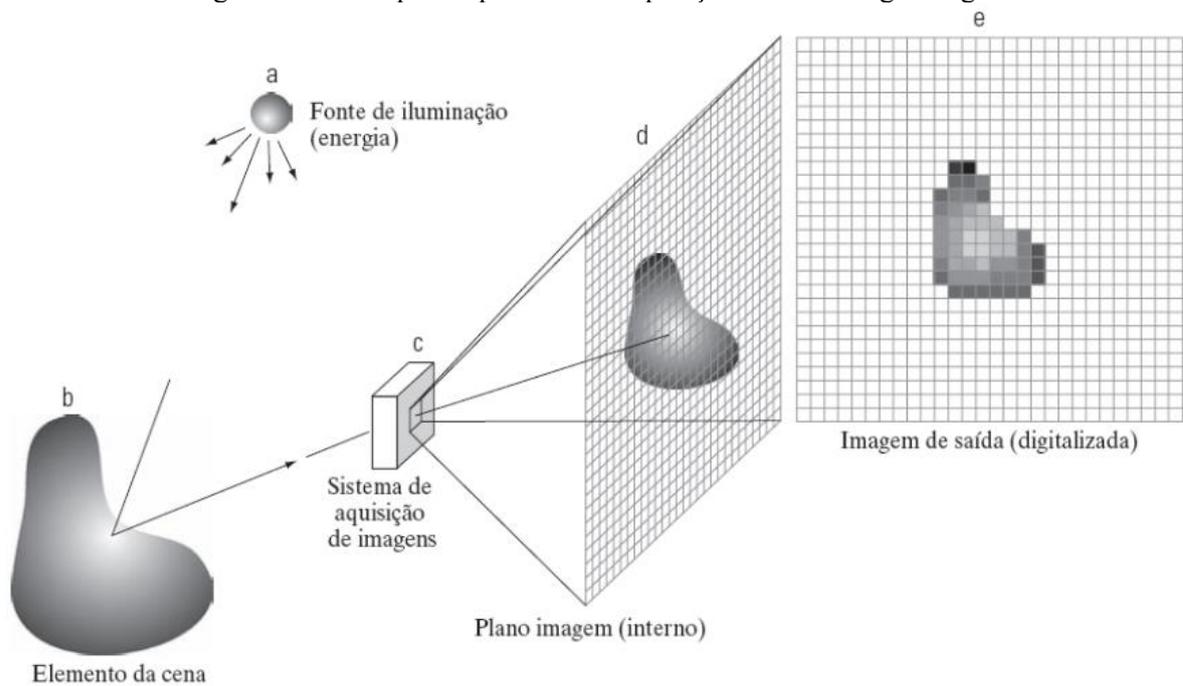
Comunicar e transferir um conhecimento entre pessoas e gerações sempre foi uma necessidade da humanidade. Uma das maneiras mais antigas de executar essa atividade é por meio de recursos visuais. Isso pode ser observado desde de épocas anteriores a 40.000 anos a.C, a partir das pinturas rupestres que até hoje nos transmitem informações relativas aquele período. As representações gráficas de objetos e cenários se tornaram importantes em várias tecnologias, como na arquitetura e nas engenharias, criando linhas de estudo como o desenho técnico (HETEM JUNIOR, 2006). Com a evolução da tecnologia, foram desenvolvidos sensores que eram capazes de detectar sinais da luz e que podiam reproduzir imagens a partir deles (RIBEIRO, 2009). Juntamente com o desenvolvimento da tecnologia da informação, esses sinais foram inseridos e processados em computadores, o que possibilitou um tipo de estudo denominado de Processamento Digital de Imagens (PDI).

Uma imagem, na visão computacional, é entendida como uma matriz com duas dimensões. Cada elemento dessa matriz possui um valor finito atribuído e é denominado de pixel. Essa matriz é obtida por sensores que transformam a energia eletromagnética da luz em voltagem. O tipo de sensor define qual onda ele é capaz de captar e gerar a imagem por meio dela (GONZALEZ e WOODS, 2010).

Cada pixel da imagem possui um valor denominado intensidade. Esse valor vai determinar qual é a cor do respectivo pixel. No caso de uma imagem em tons de cinza de 8 bits, por exemplo, pode-se ter 256 níveis de cinza. A variação da intensidade de cada pixel em relação a matriz 2D da imagem é o que forma as características visuais que está sendo representado (GONÇALVES, SOUZA e FERNANDES, 2022). Um exemplo de aquisição de uma imagem digital pode ser observado na Figura 24.

No caso da imagem colorida, ela é um conjunto de três matrizes sendo cada uma para uma cor primária. Os componentes espectrais utilizados são de vermelho, verde e azul, denominado de modelo RGB. A sobreposição dessas 3 matrizes gera as diferentes cores que são percebidas nas imagens (RUSS, 2006). Na Figura 25 é possível verificar como que funciona as 3 matrizes RGB para formação de uma imagem colorida.

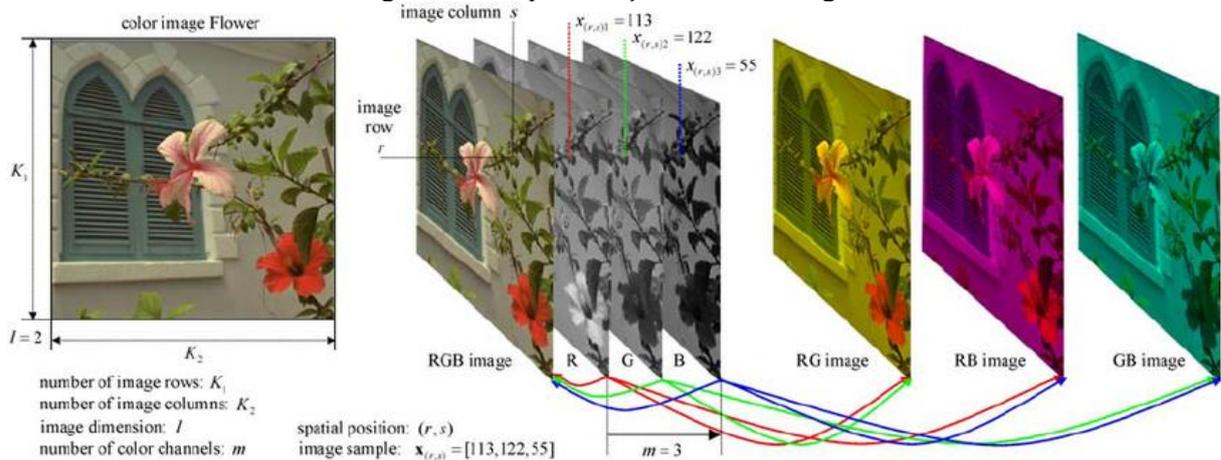
Figura 24 - Exemplo do processo de aquisição de uma imagem digital



(a) Fonte de energia (“iluminação”); (b) Um elemento de uma cena; (c) Sistema de aquisição de imagens; (d) Projeção da cena no plano imagem; (e) Imagem digitalizada.

Fonte: (GONÇALVES, SOUZA e FERNANDES, 2022)

Figura 25 - Representação RGB de imagem



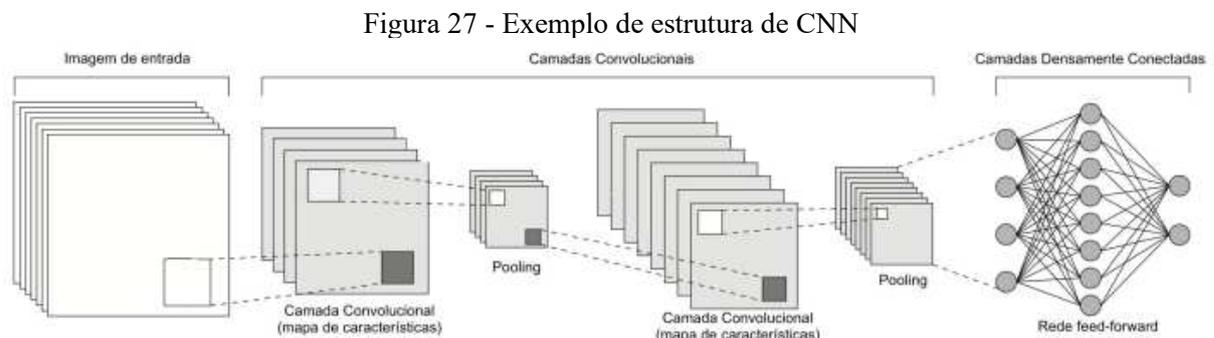
Fonte: (LUKAC e PLATANOTIS, 2006)

O PDI aplica metodologias e equacionamentos matemáticos nos pixels das imagens e em suas intensidades com para melhorar sua apresentação destinada à percepção humana e à visão computacional. Dentre as possibilidades de melhoria tem-se: expansão de contraste; correção de foco, correção de ruídos relacionados ao movimento na aquisição das imagens; correção na iluminação irregular; a eliminação de ruídos diversos, dentre outras implementações. Para isso são aplicados métodos como filtragens espacial, filtragem no

deles, e sim do seu agrupamento, posicionamento e interrelação. Para solucionar melhor a questão da visão computacional das imagens a partir da visão computacional, tem-se as CNN.

2.3.3 Redes Neurais Convolucionais – CNN

Diferentes das redes totalmente conectadas, as CNNs associam um conjunto a um neurônio. Isso permite com que ela analise a interdependência e relação entre os pixels, sendo essa uma abordagem mais próxima do que é realizado na visão humana. Dessa maneira, esse tipo de rede consegue proporcionar bons resultados relacionados a aplicações de visão computacional utilizando vídeos e imagens (DSA, 2023). Um exemplo da estrutura de uma CNN pode ser observado na Figura 27.



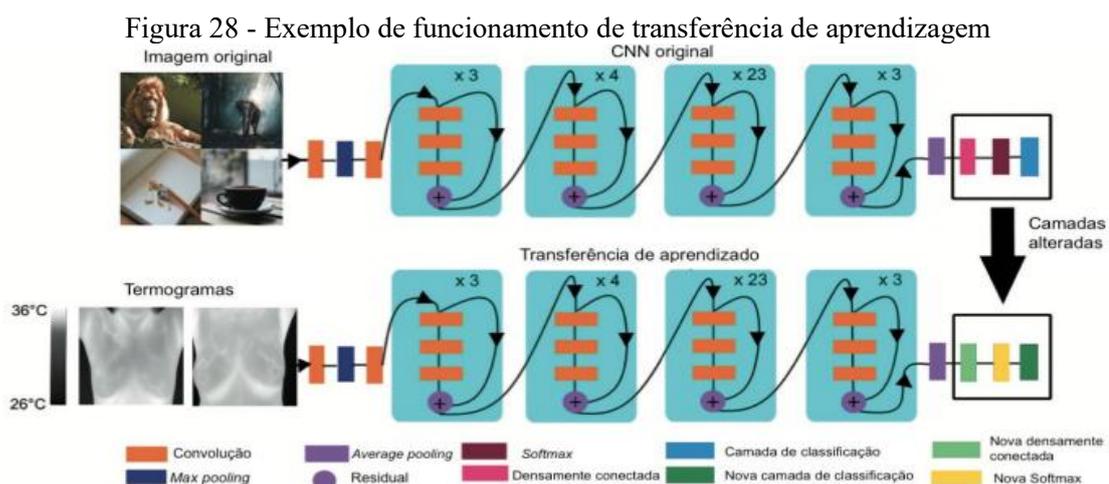
Fonte: (GONÇALVES, 2022)

A estrutura de uma CNN é composta de camadas. A primeira camada é denominada de convolucional. Nela ocorre o processo denominado de extração de características. Nesse processo, um grupo de pixels é atribuído a um neurônio, sendo realizado isso para todos os pixels das imagens. Essa janela de pixels é chamada de campo receptivo local e é aplicada em todos os pixels da imagem. A partir dessas janelas, são aplicados como se fossem filtros inicializados de forma aleatória. Esses filtros vão tentar extrair as características mais relevantes da imagem e seus pesos serão ajustados de acordo com cada época de treinamento. Em uma camada convolucional, existem várias camadas desses processamentos denominados de mapas extratores de características, eles podem ser observados na Figura 27 na parte das camadas convolucionais. Cada um desses mapas atua de forma independente e se especializa em extrair alguma característica da imagem. Após a camada convolucional é comum ter a função ReLU para zerar os valores negativos nos mapas de características (DSA, 2023; ZEILER e FERGUS, 2013). No Anexo A é possível verificar uma Figura que exemplifica alguns desses mapas.

Após essa etapa de convolução, as imagens passam por um processo chamado de *polling*. Trata-se de reduzir a dimensão da imagem. Verifica-se que, após a extração das principais características, as informações obtidas pelos mapas de características podem ser simplificadas sem prejuízo para o desempenho da rede. Isso auxilia, pois, reduz a quantidade de pesos que devem ser aprendidos no processo e ajuda a evitar o overfitting. A função mais utilizada para essa etapa é a Max-Pooling. Para finalizar, é realizada a vetorização das saídas das camadas convolucionais e a tarefa de classificação pela rede totalmente conectada (WEIDMAN, 2019; CHOLLET, 2021).

As CNNs atuais são formadas por diferentes configurações entre as camadas conectadas, camadas de pooling, quantidades de mapas de extração, dentre outras configurações dentro com o uso das estruturas da CNN que foram descritas. Essas diferentes disposições formaram as redes pré-treinadas atuais como a AlexNet, VGG16, GoogleNet, ResNet, DenseNet dentre outras. Essas redes foram treinadas grandes bancos de dados, algumas com mais de milhões de imagens (ZEILER e FERGUS, 2013).

Em problemas da engenharia, os dados disponíveis são limitados. Para ser possível aplicar CNN em classificação situações com quantidades de imagens limitadas utiliza-se a transferência de aprendizagem. Trata-se de aproveitar a parte de extração de características da camada convolucional e modificar somente a parte da classificação da última camada densamente conectada. A questão é que, as informações relevantes que são extraídas, como bordas e formas, não costumam a variar muito entre objetos. Desse modo, uma rede que foi treinada com milhões de imagens tem grande capacidade de generalização na extração de características, podendo essa parte ser aproveitada para classificar outras situações. Na Figura 28 é possível observar como funciona a transferência de aprendizagem.



Fonte: (GONÇALVES, 2022)

As CNNs são aplicadas para três principais abordagens em relação a imagens que são: Classificação, detecção e segmentação. Na classificação, as imagens são rotuladas de acordo com classes e a rede vai tentar agrupar os dados nas classes definidas. Na detecção, a rede vai identificar quais objetos tem nas imagens. Na segmentação, a rede identificar e localizar os objetos. Essas atividades possuem características distintas quanto ao funcionamento das redes.

Dessa maneira, é possível observar o potencial da aplicação de CNN em problemas da engenharia, como é o caso das imagens resultantes de serviços de engenharia diagnóstica para classificar problemas como fissurações no revestimento argamassado. Tendo em vista isso, realizou-se um levantamento dos artigos relacionados com esse tema para verificar como estão os conteúdos publicados em relação a esse cenário.

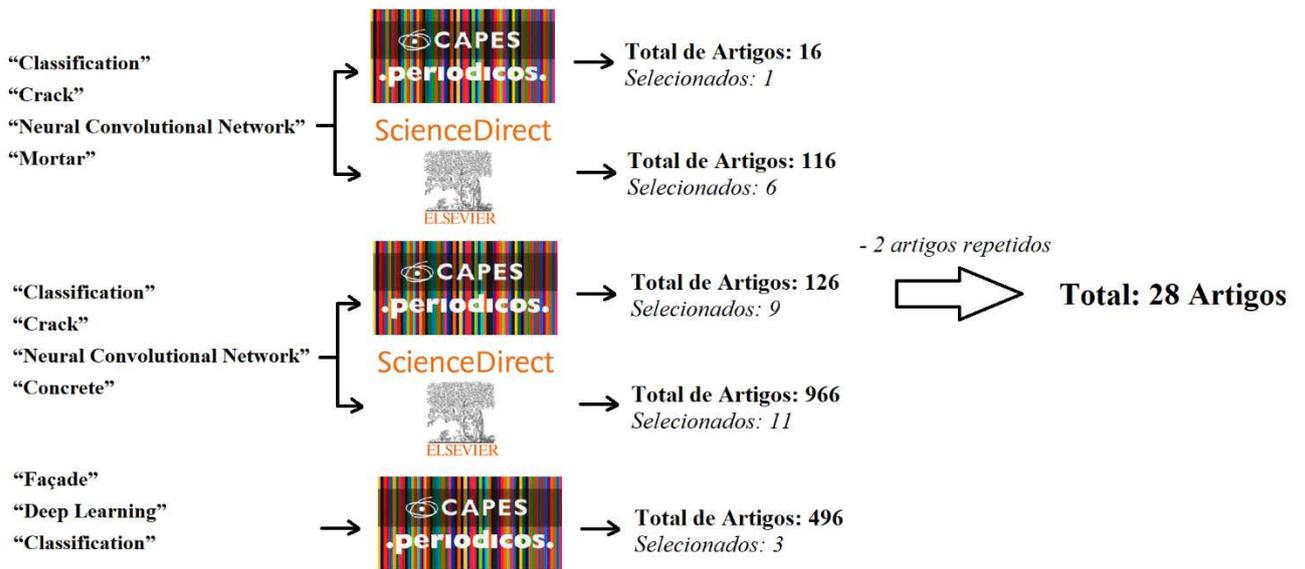
2.4 ESTUDOS RELACIONADOS

Para a investigação do cenário e dos assuntos relacionado que estão sendo publicados, realizou-se uma busca de artigos nas plataformas de pesquisa ScienceDirect e Portal Periódicos. Foram feitas duas combinações dos termos “classification”, “crack”, “convolutional neural network”, “mortar” e “concrete”. Delimitou-se o período como sendo publicas entre 2017 e 2023. A busca resultou em 1224 artigos. Uma seleção foi realizada a partir do nome e do resumo. Os critérios de inclusão e exclusão foram:

- Só artigos de classificação, sendo excluídos os de segmentação e detecção;
- Só artigos que trabalhassem com concreto, argamassa ou fachadas;
- Trabalhos com qualquer abordagem de CNN para problemas em revestimento argamassado em edificações.

Um total de 27 artigos foram selecionados a partir dessa delimitação de busca, sendo que dois deles estavam repetidos. Realizou-se uma busca suplementar com os termos “façade”, “classification” e “deep learning” no Portal Periódicos. Foram considerados, nesse caso, somente os trabalhos que investigassem revestimento argamassado em fachadas. Em um total de 496 artigos, 3 aplicavam CNN para processamento nesse material. No total, foram levantados 28 artigos, como pode ser observado na Figura 29.

Figura 29 - Esquema das buscas nas bases de dados



A partir dos artigos selecionados, realizou-se uma leitura para levantar o material que foi investigado, as redes que foram aplicadas, o melhor resultado da pesquisa e identificar o tema desenvolvido. No caso dos artigos que abordavam de alguma forma o revestimento argamassado em fachadas, ou as informações não estavam fáceis de serem aferidas, foi realizada uma leitura mais detalhada do conteúdo. As principais informações dos artigos podem ser vistas no Quadro 1. Considerou-se como “rede própria” as aplicações em que o treinamento era feito do zero utilizando ou modificando a estruturas das redes atuais.

Quadro 1 - Esquema de informações dos artigos levantados

Autor	Material	Redes	Melhores resultados
(FUTAO, ZHANG e ZHIQIANG, 2019)	Concreto	GoogleLeNet	Precisão: 88,65%
(HUNG, SU e DIEP, 2019)	Concreto	AlexNet	Acurácia: 93,00%
(SHENGYUAN e ZHAO, 2019)	Concreto	AlexNet	Acurácia: 99,06%
(HUTHWOHL, LU e BRILAKIS, 2019)	Pontes de concreto armado	InceptionV3	Acurácia: 85,00%
(FLAH, SULEIMAN e NEHDI, 2020)	Ponte de concreto	Rede própria	Acurácia: 96,17%
(CHOW, SU, <i>et al.</i> , 2020)	Concreto	ResNet	Acurácia: 95,60%
(GUO, LI, <i>et al.</i> , 2020)	Concreto	Não especificado	Acurácia: 86,57%
(WANG, HU, <i>et al.</i> , 2021)	Concreto	Inception-ResNet-v2	Acurácia: 97,41%

(JINSONG e JINB, 2020)	Ponte de concreto	Rede própria; AlexNet; GoogleNet; ResNet	Acurácia: 83,76%
(GUO (A), WANG, <i>et al.</i> , 2020)	Revestimento argamassado em fachadas	VGG16	Acurácia: 82,87%
(GUO (B), WANG e LI, 2020)	Revestimento argamassado em fachadas	ResNet101	Acurácia: 84,36%
(LEE, HONG, <i>et al.</i> , 2020)	Revestimento argamassado em fachadas	Rede baseada em outro estudo do tipo Faster R-CNN	Interseção sobre união (IoU): 62,70%
(CHEN, REICHARD, <i>et al.</i> , 2021)	Fachadas (Diferentes tipos de materiais)	U-Net	Precisão: 94,52%
(BUBRYUR, YUVARAJ, <i>et al.</i> , 2021)	Concreto	Rede própria	Acurácia: 99,80%
(DAIS, BAL, <i>et al.</i> , 2021)	Tijolo maciço aparente	VGG16; MobileNet; MobileNet2; InceptionV3; DenseNet21; DenseNet169; ResNet34; ResNet50	Acurácia: 95,30%
(HSIEH, YUNG-AN, <i>et al.</i> , 2021)	Pavimento de concreto	Rede propria	Precisão: 85,42%
(HALLE, NAPOLITANO, <i>et al.</i> , 2021)	Tijolo maciço aparente (Imagens da internet e imagens de laboratório)	Rede própria e baseada em outro estudo	Acurácia: 81,00% para as imagens da internet e 92,50% para as imagens de laboratório
(ARAFIN, ISSA e BILLAH, 2022)	Concrete	VGG19; ResNet50; InceptionV3; Xception; MobiliNetV2	Acurácia: 91,00%
(YE, DENG, <i>et al.</i> , 2022)	Concreto	VGG16; ResNet50	Acurácia: 96,30%
(HAN, ZHAO, <i>et al.</i> , 2022)	Concreto	AlexNet	Acurácia: 98,26%
(QIAN, LI, <i>et al.</i> , 2022)	Concreto (Micrografia)	Rede própria	Acurácia: 94,00%
(YING, XULEI, <i>et al.</i> , 2022)	Concreto	SCNet	Acurácia: 96,80%

(JIN, HAIDER, <i>et al.</i> , 2023)	Argamassa auto cicatrizante (Laboratório)	U-net	Acurácia: 99,00%
(ABUBAKR, RADY, <i>et al.</i> , 2023)	Ponte de concreto armado	Xception; Vanilla	Acurácia: 94,95%
(CHEN, CHEN, <i>et al.</i> , 2023)	Ponte de concreto armado	AlexNet	Precisão: 86,00%
(BRIEN, OSBORNE, <i>et al.</i> , 2023)	Túnel de concreto	VGG16	Acurácia: 96,60%
(NGUYEN, GHAREHBAGHI, <i>et al.</i> , 2023)	Ponte de concreto	InceptionV3	Acurácia: 94,07%
(ARAFIN, BILLAH e ISSA, 2023)	Concreto	VGG19; ResNet50; InceptionV3	Acurácia: 98,98%

Em um contexto geral, maioria dos estudos levantados trabalharam com a classificação binária em relação a presença de fissuras, ou seja, realizando o treinamento de redes para classificar as imagens entre as que tinham ou nas fissuras. Alguns abordaram classificações multi-classe, nas quais a CNN tinha que classificar, também, outros defeitos ou elementos como janelas e instalações hidráulicas. Temas desenvolvidos foram diversos, teve-se pesquisas que compararam desempenho de redes pré-treinadas, que elaboraram pipeline para melhorar a classificação, que aplicaram de técnicas de PDI junto a CNN, realizaram testes modificando hiperparâmetros, utilizaram de redes classificadoras para otimizar o desempenho de redes de detecção e segmentação, dentre outras. Verificou-se uma grande incidência de artigos de segmentação e detecção de fissurações durante o processo de busca de artigos. Majoritariamente, as pesquisas de CNNs relacionadas a fissurações são aplicadas em concreto e pavimentação asfáltica. Maioria dos estudos de classificação de fissuras em concreto utilizaram bancos de dados públicos.

Dentre todos os artigos levantados, 4 trabalharam diretamente com o revestimento argamassado e um indiretamente. Dentre os 4, o trabalho de Jin et al. (2023) trabalhou com imagens de corpos de prova de laboratório, o que não é interessante para a abordagem desta tese.

Lee et al. (2020) realizaram uma aplicação de CNN para detecção multi-classe de defeitos em fachadas. Segundo os autores, os estudos para detectar fissurações aparecem com frequência em imagens de estruturas e tubulações de esgoto. Eles destacam que existe diferenças em detectar problemas em fachadas em relação aos trabalhos anteriores ao seu estudo. Ressaltam que as fachadas podem ser projetadas de várias maneiras, que os defeitos

nesse tipo de elemento incidem com diferentes aspectos e formatos irregulares e que isso demandava da elaboração de um modelo com capacidade classificar simultaneamente esses problemas.

Para isso, os autores utilizaram uma rede do tipo Faster R-CNN (detectores de dois estágios) proposto por Ren et al. (2015). O banco de dados foi elaborado pelos pesquisadores e contou com 10907 imagens de fachadas. As imagens foram obtidas a partir de uma câmera digital na resolução de 4032 x 1960 pixels. O conjunto de dados foi dividido em 70% das imagens para treinamento, 10% para validação e 20% para teste. Os autores afirmaram que imagens grandes geram mapas de recurso também grandes e que isso aumenta significativamente o número de parâmetros na camada densamente conectada. Dizem que com esse cenário, é possível que o modelo seja sobreajustado. Desse modo, reduziram o tamanho das imagens para 800 x 600 pixels. Isso foi realizado por meio de cortes aleatórios que foram programados para funcionarem também como um aumento de dados. Foi aplicado, também, flipping horizontal. Na Tabela 3, é possível observar o formato final do conjunto de dados e as classes dos defeitos definidas para o estudo. Não foi relatada nenhuma técnica para trabalhar com o desbalanceamento do conjunto de dados.

Tabela 3 - Conjunto de dados de Lee et al. (2020)

	Categoria	Antes do aumento de dados pelo corte	Após o aumento de dados pelo corte	Validação	Teste
	Imagens	7635	157.584	1091	2181
Objetos	Classe 1: Delaminação	5201	104.073	659	1430
	Classe 2: Fissuras	5668	114.852	834	1717
	Classe 3: Descascamento de pintura	1234	25.267	165	348
	Classe 4: Vazamento e água	222	3773	38	47

Fonte: Lee et al. (2020)

Os autores observaram que após 13 interações, o erro da validação começou a aumentar, e definiram que 13 era o número ótimo de épocas. Para avaliar o modelo, utilizaram a interseção sobre união (IoU) e a precisão média (AP). Na Tabela 4 é possível observar os resultados.

O AP para todas as classes foi de 62,717%. No caso das fissurações, elas foram os problemas que a rede teve mais facilidade de detectar com um AP individual de 69,732%. Os autores ressaltaram a necessidade de ter um banco de dados balanceado para melhorar os resultados. Afirmaram que maioria dos estudos que eles levantaram foram aplicados para imagens obtidas em condições de laboratório controladas e estruturas. Eles ressaltam que as

fachadas de um edifício são compostas de várias cores e formas, que possuem muito mais irregularidades de fundo e seus dados e, portanto, que detectar defeitos nesses elementos é muito mais desafiador. O banco de dados desenvolvido não foi disponibilizado.

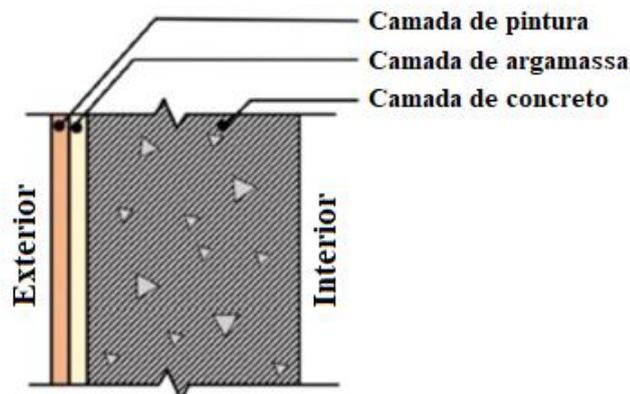
Tabela 4 – Resultados de Lee et al. (2020)

Categoria	AP (IoU = 0.5) (%)
Todas as Classes	62,717%
Classe 1: Delaminação	49,765%
Classe 2: Fissuras	69,732%
Classe 3: Descascamento de pintura	50,140%
Classe 4: Vazamento e água	67,260%

Fonte: Lee et al. (2020)

Guo et al. (a) (2020) utilizaram CNN baseada em meta-aprendizagem para classificar defeitos em fachadas a partir de um conjunto de dados desbalanceado. Para isso, eles montaram um banco de dados seguindo os seguintes passos: Determinar os materiais da fachada, selecionar as partes principais com defeitos, listar a regra de categorização de cada classe de descontinuidade, criar um conjunto de dados de defeitos em fachadas. Os autores argumentaram que no caso de defeitos de fachadas é comum ter um banco de dados desbalanceado e que isso afeta diretamente o desempenho das redes de classificações, pois, o ajuste dos pesos costuma a tender para a classe majoritária. O material mais comum na região para acabamento de fachada é o revestimento argamassado com pintura, sendo esse o escolhido para o estudo conforme mostra a Figura 30.

Figura 30 - Camadas do revestimento de estudo de Guo et al. (2020)



Fonte: (GUO (A), WANG, *et al.*, 2020)

Os defeitos definidos foram: Bolhas na pintura, trincas, delaminações, proliferação biológica, descamação e lascamentos. As imagens foram coletadas na região norte de Cingapura por meio de diferentes dispositivos incluindo três telefones celulares e duas câmeras digitais. O tamanho de captura foi de 2.736 x 3.648 pixels e 3.024 x 4.032 pixels. As imagens foram obtidas a distância de 1 m do alvo variando em diferentes horários e diferentes angulações entre a câmera e as fachadas. Obteve-se nessa coleta o total de 7.794 imagens brutas.

No pré-processamento, as imagens foram divididas em vários patches. Se houvesse mais de um tipo de defeito, a janela de corte era posicionada para focar neles individualmente. Em caso de defeitos sobrepostos, a imagem era rotulada pelo problema mais destacado, no caso de a sobreposição dos defeitos serem de igual dimensão, a imagem era descartada. O tamanho da caixa de corte foi de, no mínimo, 500 x 500 pixels, quando ela era maior do que esse tamanho, a imagem era redimensionada para ficar nessa dimensão padrão. A divisão gerou um total de 21.259 imagens que foram rotuladas de acordo com os defeitos definidos.

Para o aumento de dados, os autores realizaram flip vertical, flip horizontal, transformação de brilho e transformação de contraste. Na definição do grupo de treinamento e de teste, como o banco de dados é desbalanceado, utilizou-se a classificação com menor quantidade de imagens como referência que, no caso, foi a proliferação biológica. Foi definido que a quantidade de imagens de treinamento seria 20% do total do defeito da proliferação biológica, resultando em 50 imagens, esse valor o mesmo para todos os grupos. O banco de imagens pode ser observado na Tabela 5.

Tabela 5 - Conjunto de dados de Guo (a) et al. (2020)

	Total	Treinamento	Validação	Teste	Proporção
Bolhas (B)	762	712	50	50	3%
Trincas (C)	1.955	1.905	50	50	9%
Descamação (D)	3.307	3.257	50	50	16%
Delaminação (D)	1.166	1.116	50	50	5%
Lascamentos (S)	720	670	50	50	3%
Proliferação Biológica (G)	247	197	50	50	1%
Sem Defeitos (N)	13.102	13.052	50	50	63%
Total	21.259	20.909	350	350	100%

Fonte: (GUO (A), WANG, *et al.*, 2020)

Para a classificação, foi utilizada a arquitetura base de CNN da VGG16 em 4 abordagens sendo 3 delas com técnicas de balanceamento de dados. Uma delas utilizando a rede implementações denominada de VGG16, outra utiliza a meta-aprendizagem para balanceamento de dados com o nome de Meta-VGG16, aplicou-se também *oversampling-based* (O-VGG16) e *weighted lossbased* (WL-VGG16). O processo foi realizado utilizando Python e API PyTorch. As épocas de treinamento foram de 50 para todos os modelos com objetivo de garantir uma precisão estável no conjunto de testes. A taxa de aprendizagem e o momento foram de $1e-3$ e 0,9 respectivamente. Os principais resultados podem ser observados na Tabela 6.

Tabela 6 - Resultados de Guo (a) et al. (2020)

	Meta-VGG16	VGG16	O-VGG16	WL-VGG16
Melhor Acurácia	82,86%	71,43%	77,71%	77,14%
Tempo de Treinamento	417 m 43s	135 m 10s	580 m 09s	134 m 51s

Fonte: (GUO (A), WANG, *et al.*, 2020)

Os autores observaram que as acurácias de treinamento da VGG16, O-VGG16 e WL-VGG16 foi de 90%, porém, acurácias de teste tiveram resultados menores que 80%. Eles argumentaram que isso pode ter ocorrido por causa do overfitting das classes majoritárias. A Meta-VGG16 foi o único experimento que as acurácias de teste e treinamento semelhantes. Ela também foi a abordagem que teve melhor resultado atingido uma acurácia de 82,86%, um resultado melhor que a VGG16 que teve 71,43%. A precisão por classe pode ser verificada na Tabela 7.

Tabela 7 – Resultados de precisão de Guo (a) et al. (2020)

	B	C	D	G	N	P	S
Meta-VGG16	0,77	0,84	0,78	0,81	0,83	0,83	0,83
VGG16	0,72	0,78	0,69	0,71	0,70	0,68	0,70
O-VGG16	0,82	0,79	0,73	0,75	0,75	0,77	0,77
WL-VGG16	0,72	0,78	0,72	0,75	0,78	0,77	0,77

Fonte: (GUO (A), WANG, *et al.*, 2020)

É possível observar que as fissurações foram as discontinuidades com maior precisão dentre em todas as redes, com valores entre 79% e 84%. Os autores destacam a importância de criar um banco de dados a partir de parâmetros e que o experimento proposto foi eficiente para

lidar com o desequilíbrio com de conjuntos de imagens de danos em fachadas. Eles reforçaram que conjuntos de dados de defeitos em fachadas são altamente desbalanceados em aplicações quando se trata de aplicações práticas. Os autores não disponibilizaram o banco de dados.

Guo (b) et al. (2020) realizaram um aprendizado semi-supervisionado baseado em CNN e filtro de incerteza para classificação de defeitos em fachadas. A metodologia proposta é baseada no *mean teacher method*. Nesse caso, tem-se dois modelos sendo um o “professor” o outro o “aluno”. Os modelos de professor e aluno são CNN com a mesma arquitetura treinadas previamente pelo ImageNet. Também é desenvolvido um filtro de incerteza para selecionar os dados mais confiáveis.

Para o estruturado, foram coletadas 7.994 imagens por meio de uma câmera portátil. Todas foram de fachadas rebocadas com pintura. Elas foram obtidas entre as resoluções de 2.736 x 3.648 pixels e 3.024 x 4.031 pixels. Cada defeito foi capturado de três ângulos diferentes, nas posições frontal, esquerda e direita, com o objetivo de aumentar a diversidade do banco de dados. As imagens foram cortadas em patches para aumentar o tamanho de dados e reduzir a influência de objetos de fundo irrelevantes. Após cortar as imagens, com foco no defeito com esses apareciam, elas foram redimensionadas para tamanhos de 224 x 224 pixels. Os defeitos classificados foram: Trincas, bolhas, proliferação biológica, lascamento, delaminação e descamação. O conjunto de dados foi refinado, estendido e processado com o método de sub-amostragem para reduzir o nível de desequilíbrio entre o tamanho final e entre as classes. Após esse procedimento, teve-se 6.617 imagens no bando de dados. Os conjuntos de treinamento, teste e validação foram de 70%, 15% e 15%, respectivamente. Realizou-se inversões horizontais e verticais aleatórias, variação de brilho e variação de contraste para o aumento de dados. O conjunto de dados pode ser observado na Tabela 8.

No estudo foram realizados 3 experimentos. Um deles utilizando um modelo de CNN padrão com arquitetura ResNet101, por meio de aprendizagem supervisionada. O segundo utilizando o método *mean teacher* com treinamento semi-supervisionado. O terceiro e último foi realizado por meio de um modelo proposto pelos autores de aprendizagem semi-supervisionada. Todos os 3 experimentos foram treinados em 80 épocas e com uma taxa de aprendizagem para o gradiente descendente de 0,001. O método proposto apresentou melhor resultado de acurácia, com um valor de 84,36%. As acurácias para cada experimento podem ser verificadas na Tabela 9.

Tabela 8 - Banco de dados de Guo (b) et al. (2020)

Classe	Treinamento	Teste	Validação	Total
Bolhas	655	116	116	771
Trincas	905	160	160	1.065
Delaminação	932	165	165	1.097
Proliferação Biológica	558	99	99	657
Descamação	896	159	159	1.055
Lascamento	616	109	109	725
Sem Defeitos	1.059	188	188	1.427
Total	5.621	996	996	6.617

Fonte: (GUO (B), WANG e LI, 2020)

Tabela 9 - Resultados de Guo (b) et al. (2020)

Método	Acurácia
Aprendizagem supervisionada	79,26 %
<i>Mean teacher</i>	83,18%
Método proposto	84,36%

Fonte: (GUO (B), WANG e LI, 2020)

Os autores afirmaram que o método proposto pode reduzir o trabalho manual de rotulagem. O banco de dados elaborado não foi disponibilizado.

Chen et al. (2021) elaboraram um processo para a segmentação automática de fissuras em imagens de inspeções de edificações. Para isso, eles propõem um método de duas etapas sendo a primeira o uso de uma CNN para classificar as imagens entre as que contêm ou não fissuras e a segunda segmentar as discontinuidades dentro das imagens que foram identificadas como contendo trincas.

Os autores afirmam que inspeções prediais costumam gerar centenas ou milhares de fotos que devem ser verificadas manualmente por especialistas. Segundo eles, a maioria dos estudos de aprendizagem profunda para a detecção de trincas foram aplicados para estruturas de concreto, pavimentação asfálticas e metais com fundo uniforme e que isso impede a aplicação generalizada em cenários complicados como é o caso das fachadas. Para os autores, as fachadas são constituídas de diferentes materiais, conter vários elementos e suas imagens são fortemente perturbadas por ruído de fundo.

Para montagem do banco, foram obtidas 222 imagens. Dessas, 126 foram coletadas por meio de um drone a uma distância de 5 m a 3 m das fachadas. As outras 96 foram obtidas na internet por imagens ou quadros de vídeos. Elas foram divididas em *patches* menores de 128 x 128 pixels. *Patches* de objetos como janelas, parapeitos, grades e bordas de fachadas foram excluídos. As imagens foram classificadas manualmente gerando um banco com um total de 26.177 *patches*. Essas imagens foram divididas nas proporções de 80% para o conjunto de treinamento, 10% para validação e 10% para os testes. Os detalhes referentes ao banco de dados podem ser observados na Tabela 10. Alguns exemplos de diferentes tipos de fachadas que o estudo abrangeu pode ser observado na Figura 31.

Tabela 10 - Banco de dado de Chen et al. (2021)

	Com fissuras	Sem fissuras	Total	Tamanho das imagens
Total do nº de imagens online	/	/	96	668 x 500 – 4040 x 1821
Total do nº de imagens preparadas	/	/	126	1920 x 1080 – 5472 x 3078
Total do n de imagens divididas	5318	27.000	32.318	128 x 128
Nº de imagens de treinamento	4310	21.867	26.177	128 x 128
Nº de imagens de validação	461	2448	2909	128 x 128
Nº de imagens de teste	547	2685	3232	128 x 128

Fonte: Chen et al. (2021)

Figura 31 - Imagens das fachadas capturadas por meio de VANT



Fonte: Chen et al. (2021)

O autor não especifica tipo de estrutura da rede ou se empregou transferência de aprendizagem no treinamento, só afirma que utilizou uma CNN. O número de épocas definido foi de 200, a taxa de aprendizagem de 0,001 e foi implementado o early stopping.

Os autores afirmam que a precisão chegou a aproximadamente 95%. Observando os dados da Tabela 10, é possível verificar que a precisão em relação as imagens que tinham fissura foram de 84% e das imagens sem fissura de 96%. Não explicado como foi calculada a média e a média ponderada da precisão.

Tabela 11 - Resultados de precisão de Chen et al. (2021)

	Precisão
Com fissuras	0,84
Sem fissuras	0,96
Média geral	0,90
Média ponderada	0,94

Fonte: Fonte: Chen et al. (2021)

Os autores destacam que o desequilíbrio entre as classes é uma das limitações do estudo. Eles concluíram que utilizar a classificação antes de um procedimento de detecção auxilia na segmentação dos pixels das fissuras entre os padrões complicados existentes nas fachadas. Dentre as imagens de revestimento argamassado exibidas no artigo, todas apresentavam o acabamento superficial do tipo liso. Não foi divulgado o banco de dados da pesquisa.

Sendo assim, foi possível observar que aplicar CNN para problemas em fachadas é uma tarefa mais complexa do que em materiais mais uniformes como concreto e pavimento asfáltico. Na busca realizada, foram encontrados poucos estudos que trabalham com revestimento argamassado em edificações. Foram detectadas 4 pesquisas que abordavam o tema, duas delas de classificação, uma de detecção e uma combinando classificação e segmentação. 3 dos artigos encontrados trabalhavam somente com o revestimento argamassado do tipo liso com acabamento em pintura. Na investigação que trabalhava com fachadas de diferentes materiais, não foram detectadas imagens com acabamentos superficiais diferentes como o grafiato e o chapiscado nas que foram apresentadas no artigo. Desse modo, é possível verificar que a aplicação de processamento inteligente em imagens decorrente de inspeções prediais ainda tem muito potencial a ser explorado. Muitos estudos se preocupam em classificar corretamente a presença de fissura em imagens indo desde abordagens exploratórias ao desenvolvimento de novas implementações. Os estudos dificilmente divulgam seus bancos de dados. Que não se

tem estudos sobre classificação de fissurações considerando diferentes tipos de acabamento superficial se mostrando essa linha uma lacuna de pesquisa nos estudos atuais de classificação. Desse modo, foi possível visualizar o potencial e o caráter de ineditismo da pesquisa desenvolvida nesta tese.

CAPÍTULO 3 - METODOLOGIA

A pesquisa desenvolvida nesta tese é majoritariamente exploratória. A principal ferramenta de investigação são análises comparativas a partir de um banco de dados coletado. Tendo em vista que esses dados foram obtidos da situação em que o objeto de investigação está em operação real, o estudo também é caracterizado como um estudo de campo.

Para a investigação, o banco de dados foi organizado em diferentes agrupamentos. A partir deles, redes foram treinadas e algumas medidas de assertividade, em relação aos grupos definidos, comparadas.

A questão principal investigada é se o acabamento superficial do revestimento argamassado influencia no desempenho do treinamento das redes e em suas medidas de assertividade. Para isso, foi montado um banco de dados inédito e elaborados agrupamentos de dados, de acordo com pontos que foram levantados no decorrer da pesquisa. Por meio dessa organização, realizou-se treinamentos utilizando a rede pré-treinada VGG16 por meio de transferência de aprendizagem. A VGG16 foi escolhida por ser uma rede popular e muito aplicada nesses tipos de estudos. Todos os treinamentos foram do tipo supervisionado. O processo da pesquisa, de modo geral, consistiu em montar, rotular e analisar o banco de dados, realizar treinamentos de teste que foram chamados de treinamentos iniciais, levantar hipóteses e, a partir delas, executar treinamentos com uma abordagem da VGG16 mais robusta.

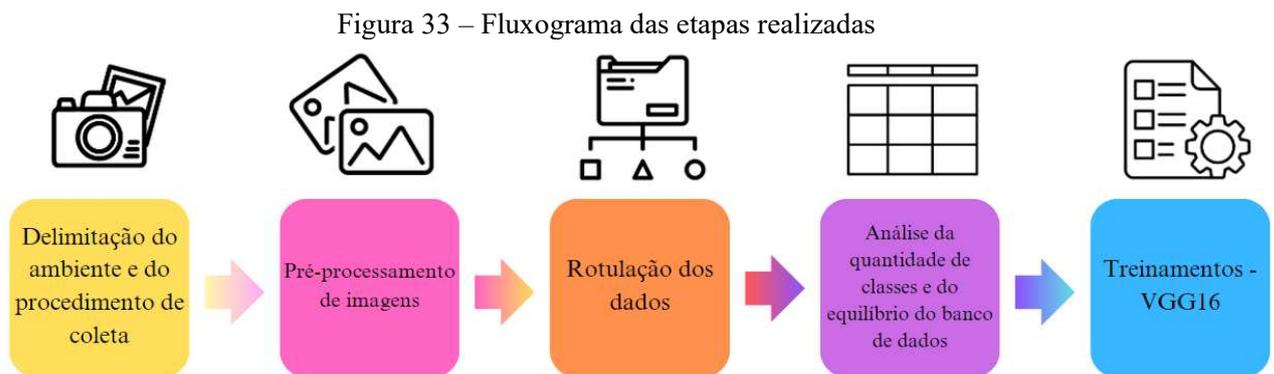
A metodologia e a discussão serão organizadas em dois eixos principais, o primeiro trata da montagem e análise do banco de dados, incluindo os treinamentos iniciais. O segundo está relacionado com os treinamentos com mais implementações, eles são divididos em duas abordagens que é a partir de classificações binárias e de multi-classe. Essa organização pode ser observada na Figura 32.

Figura 32 - Estruturação da pesquisa

EIXO 1	EIXO 2
Montagem e Análise do Banco de dados	Análise comparativa a partir de treinamentos de CNN
<i>Delimitação do ambiente e do procedimento de coleta</i>	<i>Treinamentos binários</i>
<i>Pré-processamento manual das imagens</i>	<i>Treinamentos multi-classe</i>
<i>Rotulação dos dados</i>	
<i>Análise da quantidade de classes e do equilíbrio do banco de dados</i>	
<i>Treinamentos iniciais</i>	

3.1 MONTAGEM E ANÁLISE DO BANCO DE DADOS

A etapa de montagem e análise do banco de dados foi realizada em cinco etapas principais, sendo elas: a delimitação do ambiente e do procedimento de coleta; o pré-processamento das imagens; rotulagem de dados; a análise do número de imagens e o balanceamento do banco de dados e, por fim, o treinamento das redes neurais a partir da transferência do aprendizado utilizando o VGG16. O fluxograma das etapas pode ser visto na Figura 33.



O processo de delimitação do ambiente de coleta das imagens e do pré-processamento será explicado na metodologia. Já os demais processos serão descritos nesta seção, porém, detalhados nos tópicos de resultados e discussão, pois, o processo e as tomadas de decisão na montagem do banco de dados são partes importantes dos objetivos da pesquisa.

3.1.1 Delimitação do ambiente e do procedimento de coleta

O ambiente de coleta de dados, definido para o estudo, foi uma das unidades da Universidade Federal de Uberlândia (UFU), denominado de Campus Santa Mônica. Esse campus se localiza na cidade de Uberlândia – MG, no Brasil. Atualmente, ele possui 73 blocos identificados por letras e números, de acordo com o mapa da Figura 34. Os blocos são classificações administrativas das edificações, ou de um conjunto delas, definidos pela universidade. Eles servem para diversos objetivos como: Sala de aula, laboratórios, centro de convivência, restaurante universitário, galpões de teste, dentre outras funcionalidades.

Figura 34 - Mapa do Campus Santa Mônica (UFU)



Fonte: (UNIVERSIDADE FEDERAL DE UBERLÂNDIA, 2018)

As edificações que compõem o ambiente de coleta são diversas. Elas variam em relação aos seus formatos, tamanhos e materiais constituintes. Na Figura 35 é possível observar quatro edificações com diferentes composições de materiais em suas fachadas.

Figura 35 – Fachadas com diferentes tipos de materiais constituintes



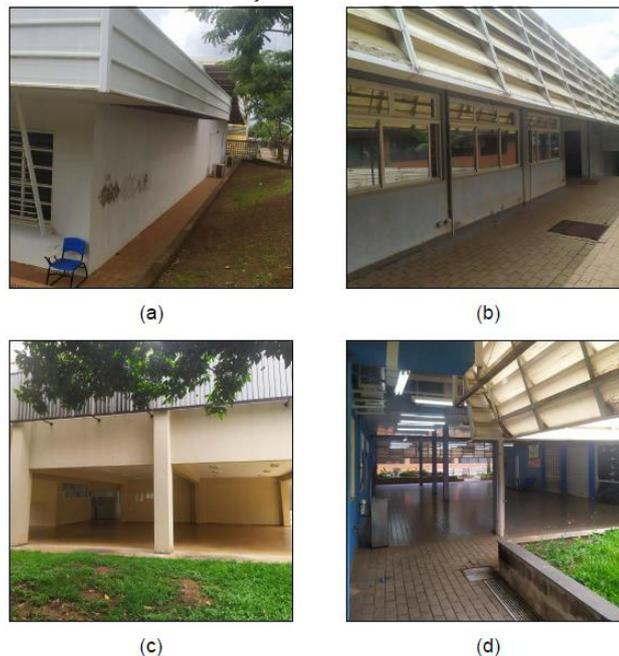
(a) Fachada com revestimento argamassado; (b) Fachada com tijolo maciço aparente; (c) Fachada com esquadrias metálicas e de vidro; (d) Fachada com revestimento cerâmico.

Tendo em vista a variabilidade dos tipos de materiais possíveis de serem encontrados nas construções da UFU, foram realizadas visitas ao campus com o objetivo de identificar quais edificações possuíam revestimento argamassado e que poderiam ser utilizadas para a montagem

do banco de dados. Foram identificadas 43 unidades com suas fachadas finalizadas com argamassa em sua área total ou parcial. Outras estruturas com revestimento argamassados também foram observadas como: Muros de contenção, muros de rampas, muros de escadas e muretas.

Após a catalogação das construções, realizou-se as inspeções para o levantamento do banco de dados. Alguns critérios foram estabelecidos para padronizar, dentro do possível, a obtenção das imagens. O primeiro ponto foram os critérios de inclusão e exclusão das fachadas. Considerou-se somente aquelas que possuíam algum contato direto com as intempéries do ambiente. Desse modo, só foram obtidas imagens dos elementos que estavam expostos diretamente ao sol ou protegidos com lances curtos de toldos ou beirais de coberturas. Não foram consideradas paredes que estavam no centro da edificação, mesmo que posicionadas na sua parte externa, com proteção de lances longos de cobertura ou de pavimentos superiores. Na Figura 3, é possível observar exemplos de fechamentos que fizeram ou não parte do banco de dados.

Figura 36 – Exemplo de faces das edificações consideradas ou não no levantamento dos dados



(a) e (b) Paredes com proteções curtas de cobertura, consideradas na montagem do banco de dados; (c) e (d) Paredes externas protegidas por grandes áreas de coberturas ou pavimentos superiores, não consideradas na montagem do banco de dados.

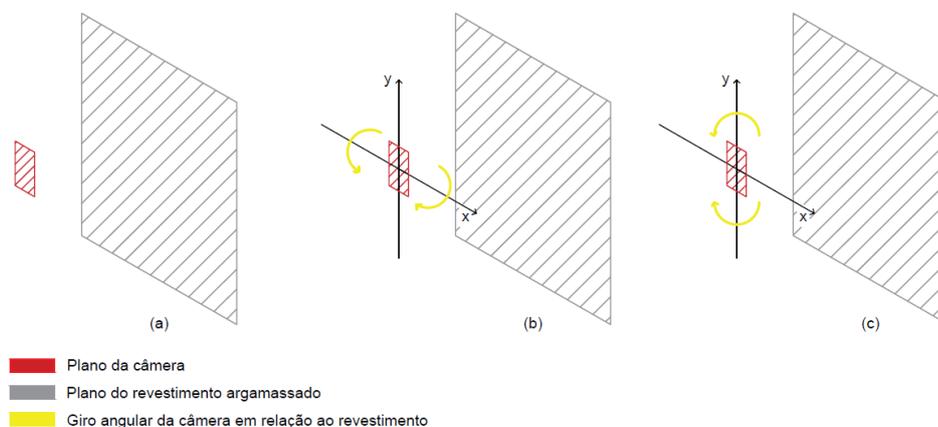
Incluiu-se no banco de dados muros, muretas e qualquer outro tipo de construção que possuía o tipo de revestimento estudado e que estava exposta ao ambiente. No tratamento preliminar dos dados, as imagens das edificações foram associadas à nomenclatura de seus respectivos blocos. As construções consideradas como anexos, quando estavam incluídos no

mesmo bloco com a edificação principal, foram separadas em grupos distintos. As imagens de muros, muretas e outros elementos foram agrupados ao conjunto de dados do bloco mais próximo. Uma rampa de acesso foi classificada como uma região distinta das demais, tendo seu próprio grupo de dados. No fim, obteve-se 44 agrupamentos de imagens, de acordo com as regiões delimitadas. Maioria deles foram identificados com o nome do bloco no qual foram obtidos.

As fotos foram tiradas por meio da câmera de um celular. O dispositivo pode obter imagens de 48 MP ou 5 MP, possui um sensor de $\frac{1}{2}$ " e uma aperture size de F 1.8 + F 2.2 e autofoco. As imagens foram obtidas na resolução de 8000 x 6000 pixels. A distância entre a câmera e os objetos fotografados foi de, aproximadamente, 1 m ($\pm 0,2$ m). Limitou-se essa distância com o objetivo de ter maior padronização das imagens obtidas e para elas ficarem mais próximas dos critérios de desempenho estrutural de vedação da norma brasileira ABNT NBR 15575-4 (2021). Controlou-se a distância entre o operador e os revestimentos argamassados por meio de uma trena laser.

Priorizou-se manter a câmera o mais paralelo possível do plano do objeto inspecionado. Para isso, foram evitadas angulações horizontais entre a câmera e o revestimento e admitida pouca angulação na vertical. Não foi utilizada nenhuma ferramenta para medir os ângulos entre o plano da câmera e do revestimento. O controle em questão foi realizado pela sensibilidade do operador quanto ao posicionamento da câmera. Na Figura 37, é possível verificar o que foi considerado como angulação horizontal e vertical neste estudo.

Figura 37 – Variações angulares entre a câmera e o revestimento argamassado



(a) Plano da câmera paralelo ao plano do revestimento; (b) Giro que gera variação angular horizontal entre a câmera e o revestimento ocorrendo em torno do eixo y; (c) Giro que gera a variação angular vertical entre a câmera e o revestimento ocorrendo em torno do eixo x.

Por fim, foram obtidas 4.092 imagens nos 44 agrupamentos especificados. No Quadro 2, é possível verificar a quantidade de imagens por cada agrupamento. Essas imagens passaram por pré-processamento e foram classificadas.

Quadro 2 - Número de imagens por agrupamento

Agrupamento	Nº de Imagens	Agrupamento	Nº de Imagens	Agrupamento	Nº de Imagens	Agrupamento	Nº de Imagens
1C	4	1V	3	3Z	9	50A	55
1D	15	1X	46	5B	96	50B	183
1E	94	3C	47	5D	26	5P	10
1E Anexo	162	3E	256	5D Anexo	24	5RA	101
1I	49	3J	84	5F	167	5RB	176
1K	38	3K	60	5G	96	5T	91
1M	160	3K Anexo	90	5H	54	5U	46
1N	112	3L	43	5I	88	5V	29
1P	20	3°	92	5J	77	Rampa	186
1Q	99	3P	388	5K	128		
1S	142	3Q	228	5L	92		
Total		4.091					

3.1.2 Pré-processamento manual das imagens

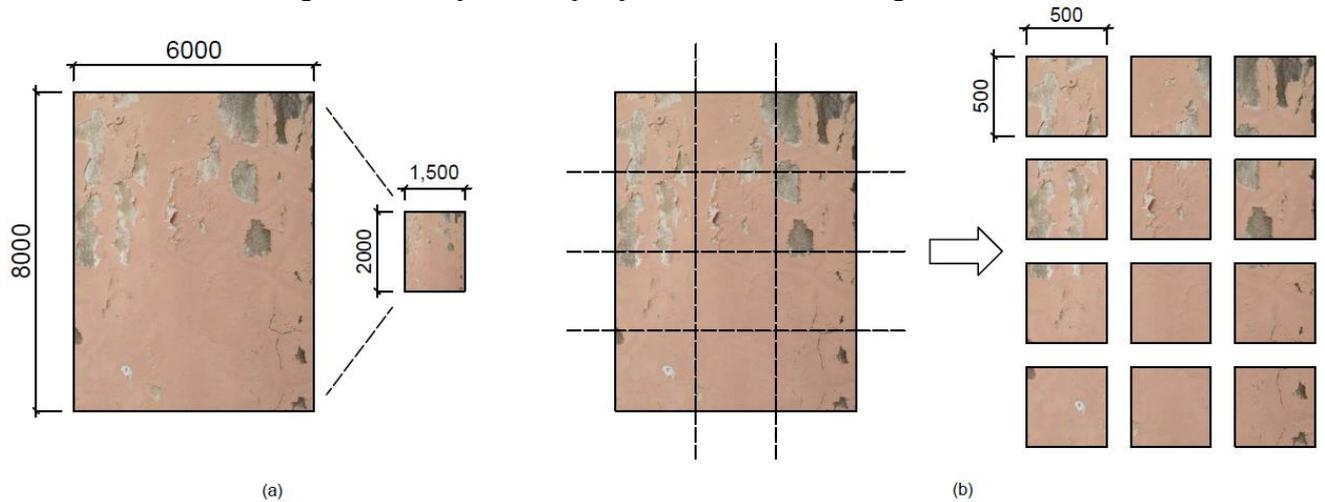
No pré-processamento, as fotos foram redimensionadas e cortadas em *patches* de imagem. O redimensionamento foi realizado com o objetivo de otimizar o treinamento visto que o tamanho original das imagens era muito grande. O tamanho usual dos indivíduos que geralmente são empregadas no treinamento das redes atuais é de 224 x 224 pixels, seguindo as dimensões presentes no banco de dados do ImageNet, muito menor que o tamanho original das imagens obtidas. A divisão não afeta a semântica do que é apresentado na imagem, pelo contrário, até é vantajoso, pois gera um número maior de imagens no banco.

O processo de redimensionamento foi realizado a partir da ferramenta Image Resizer para o Windows. As fotos foram reduzidas do tamanho de 8000 x 6000 pixels para 2000 x 1500 pixels. Essa dimensão foi escolhida para que fosse possível realizar o corte de patches menores de 500 x 500 pixels. Desse modo, cada foto gerou um total de 12 patches de imagens.

O processo de dividir as imagens em patches é comumente empregado em estudos de classificação de problemas em edificações, como em Lee et al. (2020), Guo (a) et all. (2020),

Guo (b) et all. (2020) e Chow et all. (2020). O tamanho de 500 x 500 pixels foi inicialmente escolhido baseado no estudo de Guo (a) et all. (2020). A divisão da imagem foi realizada pelo programa PhotoScape v3.7. Na Figura 38, é possível visualizar os pré-processamentos realizados.

Figura 38 – Esquema do pré-processamento das imagens.



(a) Redimensionamento; (b) Corte em patches de imagens de 500 x 500 pixels.

Após o pré-processamento, o banco de dados ficou com um total de 49.092 patches de imagens de 500 x 500 pixels.

3.1.3 Rotulação dos dados

A rotulação dos dados seguiu seis passos que foram: A eliminação do ruído; a divisão das imagens entre os diferentes tipos de acabamento superficial; a divisão das imagens entre as que tinham ou não ruído, a divisão das imagens entre as que tinham ou não fissuras; a divisão das imagens com fissuras de acordo com o nível de visibilidade do problema e a nomenclatura da imagem de acordo com todas as divisões realizadas. Na Figura 39, é possível verificar o fluxograma do processo de rotulação dos dados realizados.



No processo de eliminação de ruídos, foram removidos do banco os patches que a informação principal não era o revestimento argamassado ou que não tinham o acabamento.

Na divisão em relação ao acabamento superficial, os dados foram agrupados em três tipos textura de revestimento argamassado sendo elas: o revestimento liso, o grafiato e o chapiscado. Na Figura 40, é possível verificar exemplos dos três tipos principais definidos.

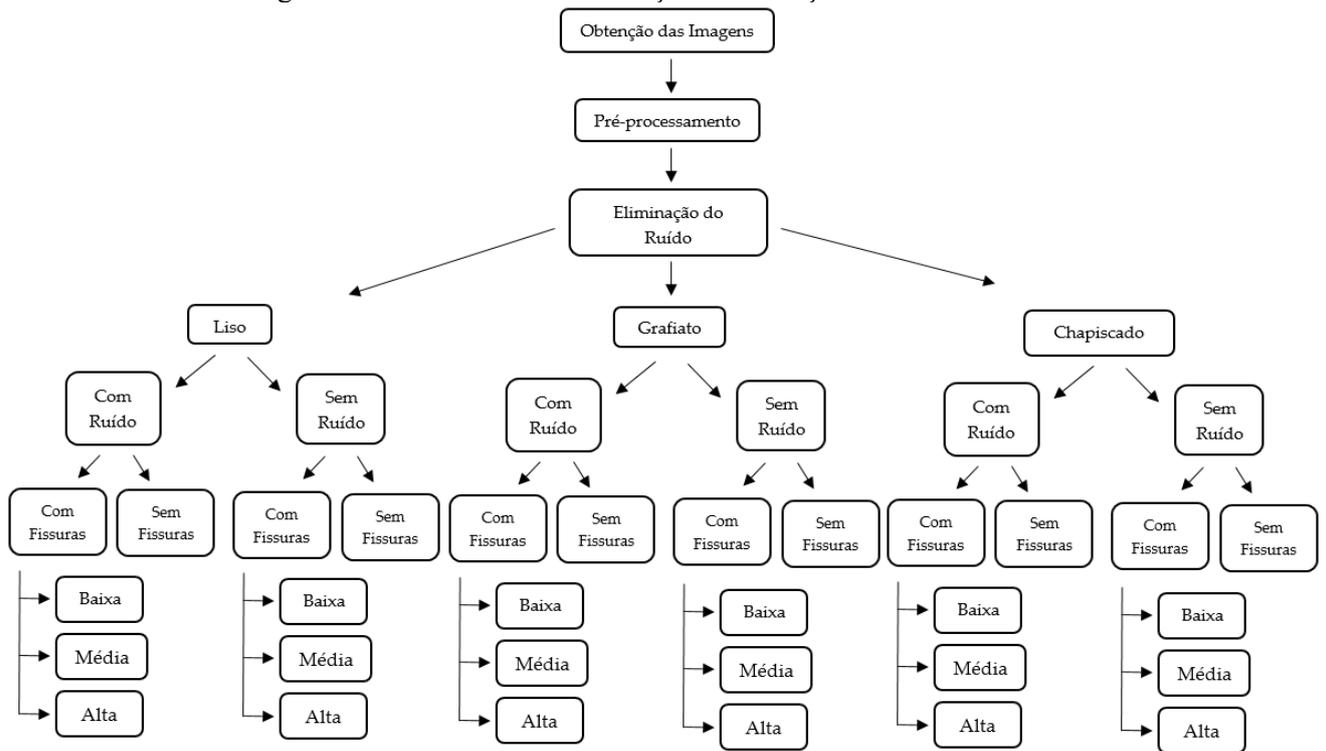
Figura 40 – Diferentes tipos de acabamento superficial



No terceiro passo, os *patches* de imagem foram divididos entre imagens sem ruídos e com ruídos. De maneira geral, toda imagem que possuía alguma informação que não estava relacionado com o revestimento foi considerada como tendo ruído. Em seguida, os dados foram classificados entre os revestimentos que continham ou não fissurações.

O último processo de agrupamento foi entre a visibilidade das fissuras. Observou-se que em algumas imagens as descontinuidades eram mais destacadas enquanto em outras elas eram de difícil identificação. Desse modo, os *patches* divididos em três níveis de visualização em relação as fissuras sendo eles: alto, médio e baixo. Por fim, as imagens foram nomeadas por meio de uma codificação desenvolvida para o banco de dados em questão. O processo detalhado das tomadas de decisão durante a rotulação dos dados vai ser explanada na seção 3.1. Na Figura 41, é possível verificar um fluxograma do procedimento de classificação dos dados.

Figura 41 – Processo de classificação na rotulação dos dados



3.1.4 Análise da quantidade de classes e do equilíbrio do banco de dados

Com o banco de dados dividido e classificado, a quantidade de cada uma das categorias foi tabelada e analisada por meio de planilhas do Excel e a ferramenta de Tabela Dinâmica. Pra verificar o equilíbrio do banco de dados, utilizou-se uma relação entre a quantidade de imagens em cada uma das classes que foram comparadas. A equação da respectiva relação pode ser observada a seguir (equação 6).

$$\text{Relação entre a quantidade de imagem de cada classe } (R_m) = \frac{M^-}{M^+}, \quad (6)$$

No caso, M^- é o número de imagens com menor quantidade entre as duas classes que foram comparadas. Já o M^+ é o inverso, sendo o número de imagens da classe com a maior quantidade de dados. Desse modo, se tem uma relação sempre maior que 0 e menor ou igual a 1. Isso representa que, quando a relação entre as classes em uma comparação for mais próxima ou igual a 1, tem-se um banco bem ou totalmente equilibrado. Em contrapartida, quanto menor for a relação, mais desequilibrado é a situação analisada.

A partir desse parâmetro e do tabelamento dos dados, analisou-se as seguintes relações:

- Entre as imagens contento fissuras ou não do banco total e dos acabamentos superficiais separados;
- Entre as imagens contento fissuras ou não considerando as situações de ter ou não ruídos;
- Entre as imagens contento fissuras ou não considerando os tipos de acabamentos superficiais e a presença do ruído;
- Da quantidade de imagens com fissuras consideradas com visibilidade alta, média ou baixa de acordo em cada tipo de acabamento superficial.

Dessa maneira, levantou-se alguns pontos que podem influenciar nas métricas de assertividade de treinamentos utilizando o banco de dados criado.

3.1.5 *Treinamento iniciais*

A última etapa da investigação teve como objetivo comparar algumas métricas de assertividade de redes treinadas com diferentes agrupamentos de imagens. O foco dessa parte é testar se o tipo de acabamento tem alguma influência na assertividade durante o treinamento na rede e, a partir disso, levantar pontos que possam fomentar pesquisas que utilizem o banco elaborado nesse estudo. Para isso, empregou-se a VGG16, a partir de transferência de aprendizagem.

O processo de transferência de aprendizagem foi realizado removendo a última camada da rede, que tinha 1000 classes, trocando-a por uma com duas classes de saída. Criou-se uma nova camada para substituir a camada oculta da rede para que o modelo pré-treinado da VGG16 classificasse a presença ou não de fissuras no revestimento argamassado. A topologia da respectiva rede pode ser observada no Anexo B. A rede foi treinada em 14 épocas e com uma taxa de aprendizagem de 0,001. Todo o processo foi realizado no ambiente do Google Colab Pro+ por meio da linguagem Python e a biblioteca Pytorch. O Pytorch foi escolhido por ser uma biblioteca popular para aplicações de IA. No ambiente de execução, utilizou-se um GPU do tipo A100 e RAM alta.

No pré-processamento dos dados na entrada da rede, os indivíduos foram redimensionados para o tamanho de 224 x 224 pixels, que corresponde as dimensões das imagens utilizadas para o treinamento da VGG16. As entradas foram transformadas para o tipo dado do pytorch a partir da função `transforms.ToTensor` e normalizadas por meio da função `transforms.Normalize`, que utiliza o desvio padrão e a média dos canais RGB. Os valores dos

desvios padrões e das médias utilizadas na normalização correspondem ao banco de dados do ImageNet sendo, em cada canal RGB, (0,485; 0,456; 0,406) para as médias e (0,229; 0,224; 0,225) para os desvios padrões.

As imagens foram divididas em conjuntos de dados para treinamento e validação. A métrica utilizada para comparação foi a acurácia. Verificou-se, também, as curvas de acurácia e da função perda em relação ao número de épocas. A acurácia é a métrica mais utilizada para avaliar a performance de modelos de treinamento de IA, ela indica o percentual de acertos da rede é obtida a partir da equação 1.

Inicialmente, foram feitos testes com um grupo pequeno de 446 imagens do acabamento superficial do tipo liso, sem ruído, e nas proporções de 50% de imagens contendo fissuras e 50% sem as descontinuidades. Foram realizados dois testes, um deles com a seleção manual das as imagens do grupo de treinamento e o de validação e o outro com essa divisão sendo gerada de forma aleatória a partir da biblioteca splitfolders. Em ambos os testes, os indivíduos foram organizados na proporção de 80% para o conjunto de treinamento e 20% para o de validação.

A partir desses testes, definiu-se o uso da biblioteca splitfolders para dividir os conjuntos de treinamento e validação dos grupos de análise. As proporções foram de 70% para o treinamento e 30% para a validação. Para as comparações, o banco de dados foi dividido em dois grupos principais. Um deles continha todas as imagens, resultando em conjuntos de dados desbalanceados, esse grupo foi identificado com a letra A. No outro agrupamento, os dados foram balanceados a partir da classe minoritária. Ou seja, as classes que possuíam mais imagens foram reduzidas até ficarem com uma quantidade de dados igual da classe com menor valor. Esse processo foi realizado, também, com o auxílio da biblioteca splitfoder de forma aleatória. O grupo equilibrado foi identificado pela letra B.

Dentro dos grupos A e B, foram realizadas 4 abordagens diferentes para cada um deles. Os 4 tipos diferentes de organização dos dados foram:

- Um conjunto de dados contendo todas as imagens, identificado pelo algoritmo 1;
- Um conjunto de dados contendo somente as imagens com acabamento superficial liso, identificado pelo algoritmo 2;
- Um conjunto de dados contendo somente as imagens com acabamento superficial do tipo grafiato, identificado pelo algoritmo 3;
- Um conjunto de dados contendo somente as imagens com acabamento superficial do tipo chapiscado, identificado pelo algoritmo 4;

Dessa maneira, foram realizados 8 treinamentos. Na Quadro 3 é possível verificar os agrupamentos que foram realizados para o estudo.

Quadro 3 – Agrupamentos de dados analisados

Conjunto de imagens de acordo com o tipo de acabamento	Agrupamento de acordo com o balanceamento dos dados	
	Banco desbalanceado (Grupo A)	Banco balanceado (Grupo B)
Todos os tipos – 1	A1	B1
Tipo Liso – 2	A2	B2
Tipo Grafiato – 3	A3	B3
Tipo Chapiscado – 4	A4	B4

Cada um dos grupos possuía duas classes sendo elas: As imagens contendo fissuras e as sem. Desse modo, o objetivo do treinamento foi verificar a capacidade das redes de conseguir classificar a presença ou não da descontinuidade nos agrupamentos realizados. A partir dessa configuração, os conjuntos de dados foram processados e as métricas de assertividade das redes analisadas.

3.2 ANÁLISE COMPARATIVA A PARTIR DE TREINAMENTOS DE CNN

Para os treinamentos da análise comparativa, também foi utilizada a VGG16 a partir de transferência de aprendizagem. Nessa abordagem, congelou-se os pesos das camadas convolucionais e alterou-se a última camada. As novas camadas foram adicionadas foram:

- Camada oculta com 256 neurônios e função de ativação ReLU;
- Camada de dropout com taxa de 20%.
- Camada com o valor de saída de acordo com o número de classes (para as classificações binárias, 2 saídas) e função de ativação Softmax.

A topologia da respectiva rede pode ser observada no Anexo C, no caso, para uma classificação binária. A rede foi treinada em 20 épocas, com o otimizador de Adam e com early stopping. Todo o processo foi realizado no ambiente do Google Colab Pro+ por meio da linguagem Python e a biblioteca Pytorch. No ambiente de execução, utilizou-se um GPU do tipo A100 e RAM alta.

O pré-processamento e a normalização foram realizados da mesma forma que nos treinamentos iniciais.

Não foram aplicados processamentos de aumento de dados. Acontece que esse aumento é feito de forma aleatória e, como o objetivo é realizar uma análise comparativa entre os grupos, optou-se por ter mais controle do processo. Outra questão é que, teoricamente, em alguns desses processamentos as imagens podem perder informações. Por exemplo, em uma imagem que tem uma pequena fissura em um canto, com um corte ou um giro essa informação pode ser perdida e a imagem se torna uma sem defeitos, mesmo tendo o rótulo de com fissura.

As imagens foram divididas em conjuntos de dados para treinamento, validação e teste nas proporções de 70%, 20% e 10%, respectivamente. Os grupos foram separados de maneira aleatória a partir da biblioteca *splitfolders*. Utilizou-se as curvas de acurácia e do erro em relação ao número de épocas para avaliar o desempenho do treinamento.

Nas análises de dados, dessa vez, as métricas de assertividade foram aplicadas no grupo de teste. Dentre as ferramentas utilizadas, teve-se a matriz de confusão. A partir dela obteve-se a acurácia (equação 1) do grupo de teste e a precisão de cada classe (equação 2). Também foi avaliado o tempo de treinamento.

Esse processo foi realizado para o treinamento binário e para o multi-classe em todos os agrupamentos definidos para as comparações. Nas próximas seção, será explicado como foram organizados e nomeados os grupos.

3.2.1 *Treinamento binários*

Os primeiros treinamentos foram realizados nos mesmos agrupamentos dos treinamentos iniciais, Quadro 3. Um deles era desbalanceado e o outro balanceado a partir da classe minoritária. No caso, eles foram denominados com a letra C para o grupo desbalanceado e D para o balanceado. Os Algarismos seguem sendo 1 para o grupo com todo o conjunto de dados, 2 para o conjunto só com o revestimento do tipo liso, 3 só com o grafiato e 4 só com o chapiscado.

Em seguida, foram elaborados outros 3 conjuntos de dados chamados de grupos com testes expandidos. Neles, todas as imagens que foram removidas no balanceamento dos dados pela classe minoritária foram adicionadas no grupo de teste. Manteve-se os grupos de validação e treinamento balanceados. O foco foi verificar se a rede consegue ter o mesmo desempenho no grupo do teste com todos os dados disponíveis. Esses conjuntos foram identificados pela D+ e só foram organizados para os grupos com os revestimentos separados, de Algarismo 2, 3 e 4.

A próxima investigação foi em relação a influência do ruído. Para isso, foram removidas todas as imagens que tinham ruído dos grupos balanceados. Esse conjunto foi identificado pela letra E e também só foi realizado para os grupos com os revestimentos separados.

Por último, nas classificações binárias, foram realizados conjuntos sem as imagens das fissurações com baixa visibilidade e para cada um dos tipos de acabamento superficiais, de forma isolada. Essa abordagem foi identificada com a letra F.

Um esquema dos agrupamentos realizados para as classificações binárias e suas respectivas identificações pode visto no Quadro 4.

Quadro 4 - Esquema dos grupos binários

Agrupamentos de acordo com as delimitações realizadas					
Conjunto de imagens de acordo com o tipo de acabamento	Banco desbalanceado (Grupo C)	Banco balanceado (Grupo D)	Banco balanceado com teste expandido (Grupo D+)	Banco balanceado sem ruído (Grupo E)	Banco Balanceado sem imagens de fissurações com baixa visibilidade (Grupo F)
Todos os tipos – 1	C1	D1
Tipo Liso – 2	C2	D2	D2+	E2	F2
Tipo Grafiato – 3	C3	D3	D3+	E3	F3
Tipo Chapiscado – 4	C4	D4	D4+	E4	F4

3.2.2 Treinamentos multi-classe

Os treinamentos multi-classe tiveram como objetivo verificar como seria o desempenho de uma rede contendo todos os tipos de acabamento superficial, mas, com eles divididos em classes dentro da mesma rede ao invés de agrupados em redes separadas. Para isso, foram realizadas 3 delimitações dos grupos de dados, sendo elas:

- Uma com o banco todo e desbalanceado, identificada com a letra I.
- Uma com o agrupamento balanceado a partir da classe minoritária, identificada com a letra J.
- E, por último, uma com o agrupamento balanceado pela classe minoritária e sem as imagens de fissuras com baixa visibilidade, identificada com a letra K.

Além disso, realizou-se duas maneiras diferentes de dividir as classes. Na primeira, cada um dos acabamentos superficiais em relação a presença ou não de fissura foi definido como uma classe. Desse modo, teve-se 6 classes que podem ser vistas no Quadro 5. Os grupos com essa delimitação foram identificados com o algarismo 1.

Quadro 5 - Classes dos agrupamentos do Tipo 1

Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6
Chapiscado com fissuras	Chapiscado sem fissuras	Grafiato com fissuras	Grafiato sem fissuras	Liso com fissuras	Liso sem fissuras

Na segunda delimitação, as imagens foram divididas por acabamento superficial, pela presença de ruído e pela presença das fissuras, o que totalizou em 12 classes. Essa abordagem foi identificada pelo algarismo 2 e as classes podem ser vistas no Quadro 4.

Quadro 6 - Classes dos agrupamentos do Tipo 2

Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6
Chapiscado com ruído e com fissuras	Chapiscado com ruído e sem fissuras	Chapiscado sem ruído e com fissuras	Chapiscado sem ruído e sem fissuras	Grafiato com ruído e com fissuras	Grafiato com ruído e sem fissuras
Classe 7	Classe 8	Classe 9	Classe 10	Classe 11	Classe 12
Grafiato sem ruído e com fissuras	Grafiato sem ruído e sem fissuras	Liso com ruído e com fissuras	Liso com ruído e sem fissuras	Liso sem ruído e com fissuras	Liso sem ruído e sem fissuras

Os agrupamentos I, J e K foram treinados com as classes do tipo 1 e do tipo 2. No Quadro 7 é possível verificar os grupos, com suas respectivas identificações, que foram elaborados para o treinamento multi-classe.

Quadro 7 - Agrupamentos dos treinamentos multi-classe

Agrupamentos de acordo com as delimitações realizadas

Agrupamento de acordo com as divisões das classes (Quadro 5 e 6)	Banco desbalanceado (Grupo I)	Banco balanceado (Grupo J)	Banco Balanceado sem imagens de fissurações com baixa visibilidade (Grupo K)
Tipo 1 (6 classes)	I1	J1	K1
Tipo 2 (12 classes)	I2	J2	K2

CAPÍTULO 4 - RESULTADOS E DISCUSSÃO

Os resultados são apresentados de acordo com os dois eixos principais definidos na metodologia que são: Montagem e análise do banco de dados; análise comparativa dos treinamentos.

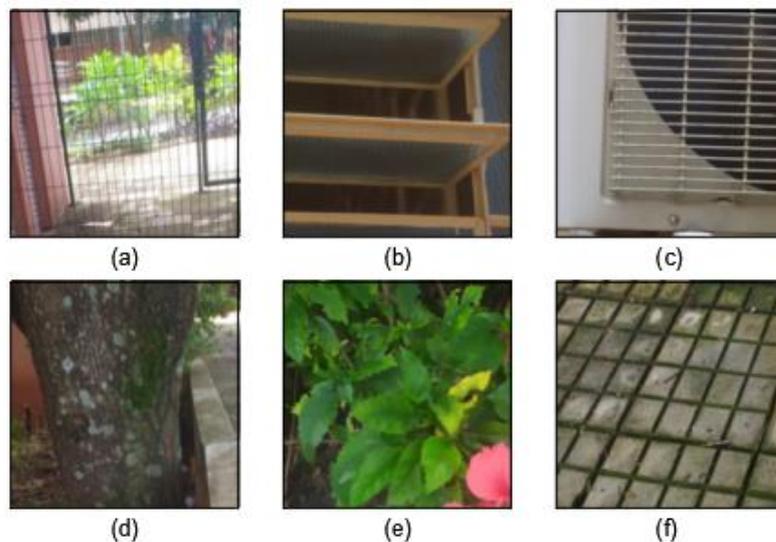
4.1 MONTAGEM E ANÁLISE DOS BANCOS DE DADOS

4.1.1 Rotulação dos dados

A rotulação foi realizada de maneira manual por dois engenheiros civis especialistas no assunto. O primeiro processo efetuado foi a eliminação do ruído. Acontece que as fotografias iniciais tinham regiões que não continham o revestimento estudado. Sendo assim, alguns dos patches ficaram com informações que não eram interessantes para o banco de dados. Dessa maneira, esses *patches* foram excluídos.

Identificou-se dois tipos principais de imagens que foram consideradas como sendo, exclusivamente, ruídos. No primeiro tipo, estavam os patches que não continham nenhuma relação com o revestimento argamassado como: Imagens de fundo, de pisos, de esquadrias, vegetação, e outros objetos. Alguns exemplos desse tipo de ruído podem ser observados na Figura 42.

Figura 42 - Exemplo de patches com informações sem relação com revestimento argamassado



(a) Imagem de fundo; (b) Parte de janela de vidro; (c) Parte de ar condicionado; (d) Tronco de árvore; (e) Vegetação; (f) Piso.

O outro tipo de ruído identificado foram os patches cujo a informação principal da imagem não era o revestimento. Na Figura 43, é possível verificar alguns exemplos desse tipo de ruído. Foram removidos, também, patches de imagens que estavam repetidas.

Figura 43 - Exemplo de patches onde o revestimento argamassado não é a informação principal



(a) Tubulação; (b) Pilar de concreto; (c) Grade; (d) piso e tubulação; (e) Fiação de ar condicionado; (f) Piso e porta; (h) Vegetação; (i) Fundo de imagem.

Após a eliminação do ruído, as imagens restantes foram divididas de acordo com os 3 tipos de acabamento superficial definidos, sendo eles: O acabamento liso, o chapiscado e o grafitado. Dentro de cada uma das categorias dos acabamentos, foi possível observar algumas variabilidades como, por exemplo, na textura superficial. As questões observadas serão discutidas a seguir.

Na execução do revestimento, o processo de finalização pode ser diferente devido a técnicas específicas ou problemas de aplicação. Isso varia, também, de acordo com a finalidade da edificação. Por exemplo, algumas construções possuem necessidade de ter um desempenho estético maior do que outras. Dessa maneira, o processo de finalização do acabamento tende a ser mais cuidadoso. Essas variabilidades podem ser vistas na Figura 44. Nas as imagens (a) e (b) da figura, é possível verificar acabamentos com o aspecto realmente liso. Já nas imagens (c) e (d), observa-se problemas locais na execução do revestimento. No caso dos patches (e) e (f),

tem-se riscos resultantes da passagem da desempenadeira no processo de nivelamento, provavelmente, porque não foi realizada a finalização utilizando uma esponja umedecida. A possível ausência desse último procedimento executivo citado pode ser verificada, também, em (g) e (h). Porém, o resultado nesse caso foi um aspecto áspero. Por último, a textura da imagem (i) pode ter sido executada por técnica específica que não tinha o objetivo de deixar a superfície totalmente lisa.

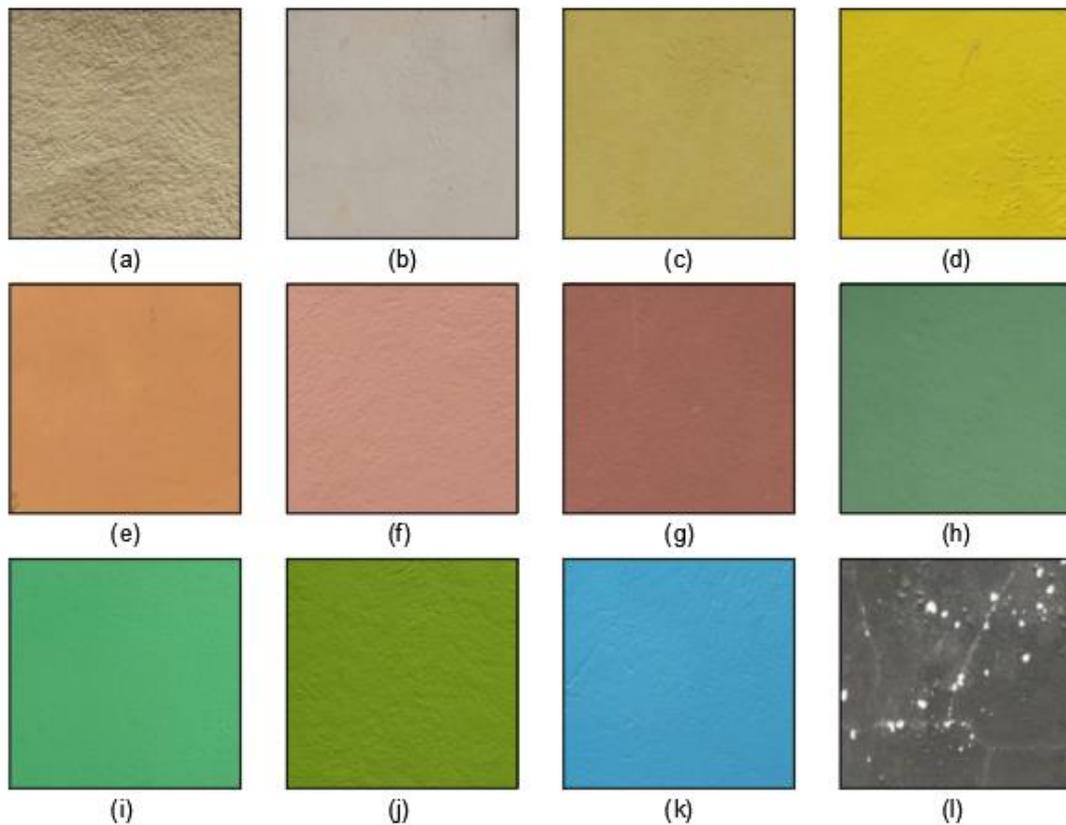
Figura 44 - Diferentes texturas no acabamento superficial liso



(a) e (b) Finalização lisa; (c) e (e) Falhas locais nas texturas; (d) e (f) Textura com riscos pela passagem da desempenadeira e possível ausência do processo de camurçamento; (g) e (h) Textura com áspera pela possível ausência do processo de camurçamento; (i) Acabamento que não tinha o objetivo de ficar totalmente liso.

Outra variabilidade encontrada no acabamento superficial liso foram as cores das pinturas. Na Figura 45, é possível observar algumas dessas diferenças. Um dos pontos verificados visualmente é que as superfícies pintadas costumam ter um aspecto mais homogêneo do que as sem pintura. Isso pode ser justificado porque a tinta sela a porosidade da argamassa, o que diminui o aspecto áspero do revestimento.

Figura 45 - Diferentes cores de pinturas no acabamento superficial liso

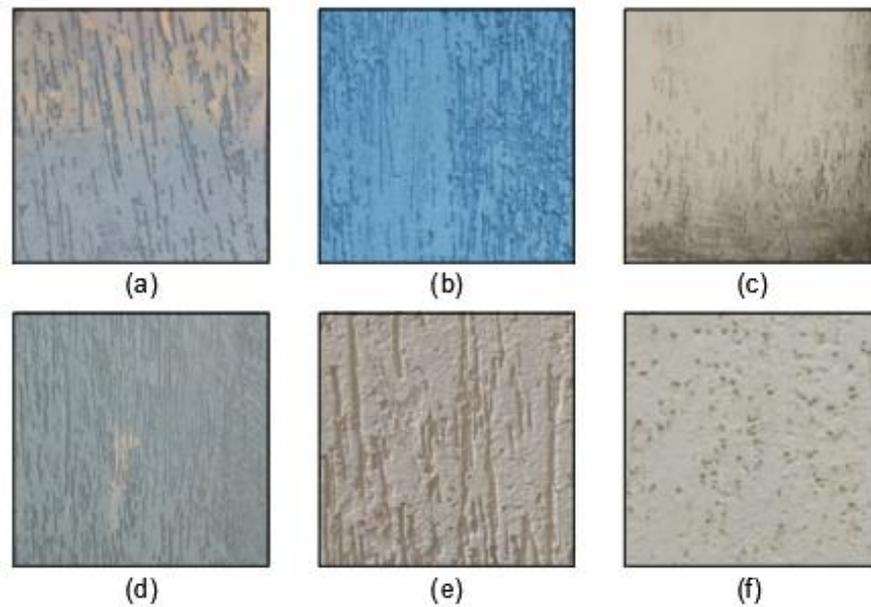


(a) Sem pintura; (b) Branco; (c) Bege; (d) Amarelo; (e) Laranja; (f) Rosa; (g) Vermelho; (h) (i) e (j) Tons de verde; (k) Azul; (l) Preto.

Em relação ao acabamento do tipo grafiato, também foi possível verificar diferentes aspectos da textura superficial. A imagem (a) da Figura 46, tem-se uma distribuição mais uniforme entre as ranhuras. Já na (b) é possível observar uma região lisa entre o grafiato. No patche de imagem (d), o acabamento ficou com um aspecto liso em grande parte da imagem, provavelmente, por algum procedimento inadequado de execução. Na imagem (d), as ranhuras são mais finas e com uma densidade maior. Isso contrasta com a imagem (e), na qual as ranhuras são mais espessas. No caso da (f), o aspecto finalizado ficou mais de próximo de buracos do que ranhuras, o que pode ser resultado de problemas no arraste dos grãos de pedra no processo de execução.

Em relação as cores desse tipo de acabamento, elas ficaram entre branco, tons de cinza, de azul e amarelados, não variando muito em relação as cores apresentadas na Figura 46.

Figura 46 - Texturas do acabamento superficial grafito



(a) Distribuição uniforme; (b) Com região sem ranhuras; (c) Com parte da área lisa; (d) Com ranhuras finas e com maior densidade; (e) Com ranhuras espessas; (f) Sem o arraste adequado dos grãos de pedra dando um aspecto mais de buracos no revestimento.

No caso do acabamento chapiscado, na Figura 47, é possível observar diferenças na rugosidade entre as imagens. No caso da imagem (d), a rugosidade é mais acentuada, possuindo ondulações maiores do que as imagens (a) e (b). Já nos patches (e) e (f), a rugosidade é mais leve, resultado de uma aplicação utilizando rolo com textura. Nas imagens (g) e (h) observa-se uma textura mais áspera, com saliências mais finas. Por fim, a imagem (i) tem uma falha na aplicação do acabamento superficial chapiscado.

Assim como o grafiteado, o chapiscado não teve muita variação quanto as cores de pintura, sendo essas encontradas na cor branca e em tons de cinza e amarelado, similares ao que é apresentado na Figura 47.

Figura 47 - Texturas do acabamento superficial chapiscado

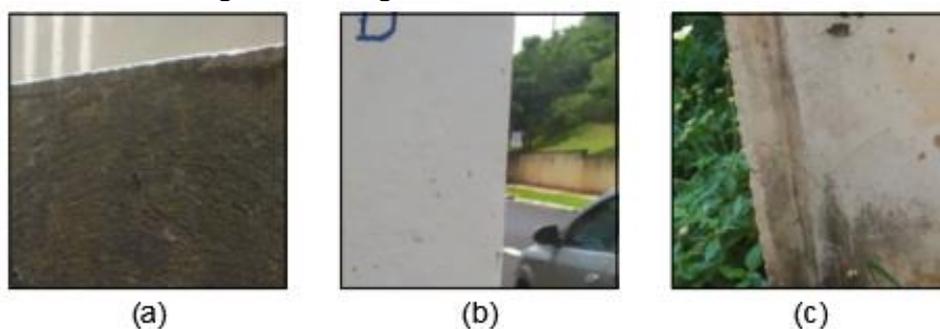


(a) e (b) Com saliências leves; (c) e (d) Com saliências grandes; (e) e (f) Aplicado com rolo de textura; (g) e (h) Com aspecto e saliências finas; (i) Com falha no acabamento.

Após a classificação em relação aos tipos de acabamento superficiais, os patches foram divididos em grupos que tinham ou não ruído. Diferente das imagens que eram ruídos, as que foram definidas como tendo ruído são aquelas que possuíam o revestimento argamassado como informação principal da imagem, porém, também tinham alguma outra que não estava relacionada diretamente com o acabamento.

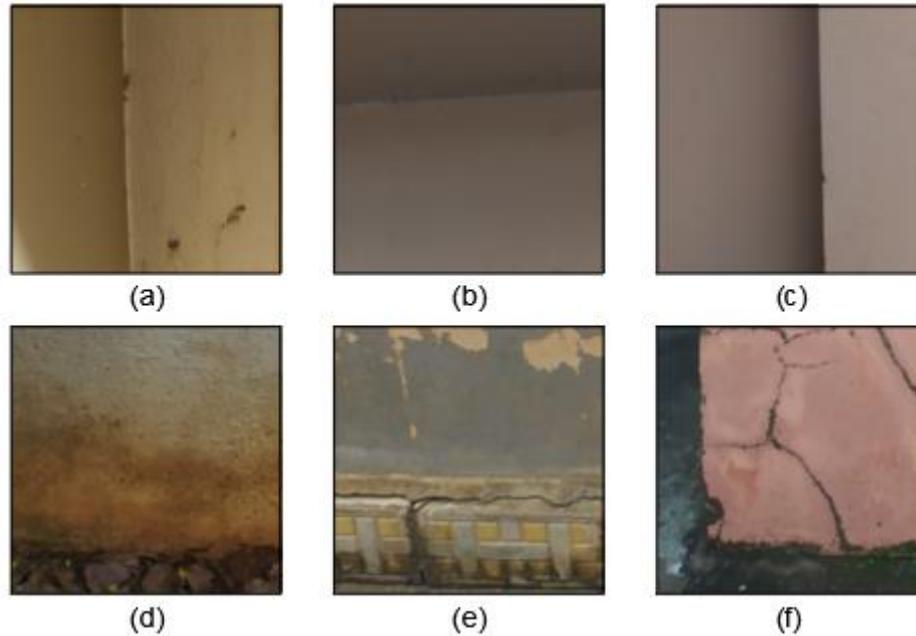
Um exemplo disso são as imagens em que o fundo aparecia nas bordas, como é o caso dos cantos das edificações. Isso pode ser observado na Figura 48.

Figura 48 - Imagens do revestimento com fundo



Outra situação considerada como ruído foi o encontro entre paredes, de parede com a laje, de paredes com o piso e de superfícies que estavam desalinhadas. A questão principal dessa delimitação é que essas configurações geram linhas nas imagens que, teoricamente, podem ser confundidas com fissuras geométricas no treinamento de uma rede, principalmente nas direções vertical e horizontal. Na Figura 49 é possível verificar exemplos dessa situação.

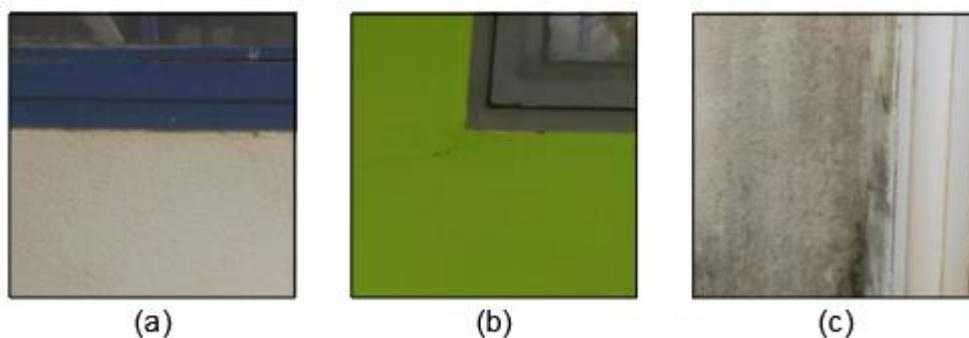
Figura 49 - Imagens de encontros



(a) Encontro entre duas paredes; (b) Encontro entre parede e laje; (c); Encontro entre superfícies desalinhadas; (c) (d) e (e) Encontro entre parede e piso.

Algumas imagens continham cantos e partes de esquadrias como janelas e portas. Esse tipo de ruído aparece na Figura 50.

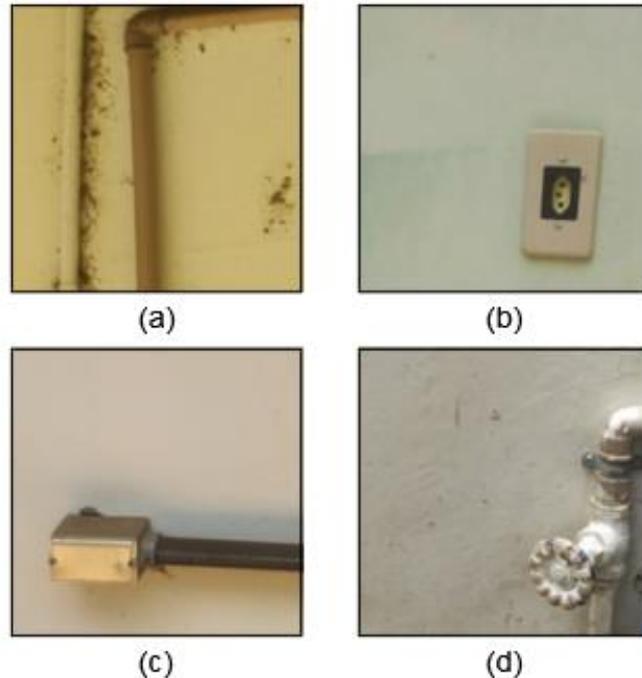
Figura 50 - Imagens partes de esquadria nos revestimentos



(a) Janela na parte superior; (b) Canto de janela; (c); Parte da porta no canto direito.

A presença de dispositivos e elementos das instalações hidráulicas, elétricas, de lógica e de ar condicionado foram outro tipo de ruído encontrado junto aos revestimentos. Exemplos desse tipo podem ser observados na Figura 51.

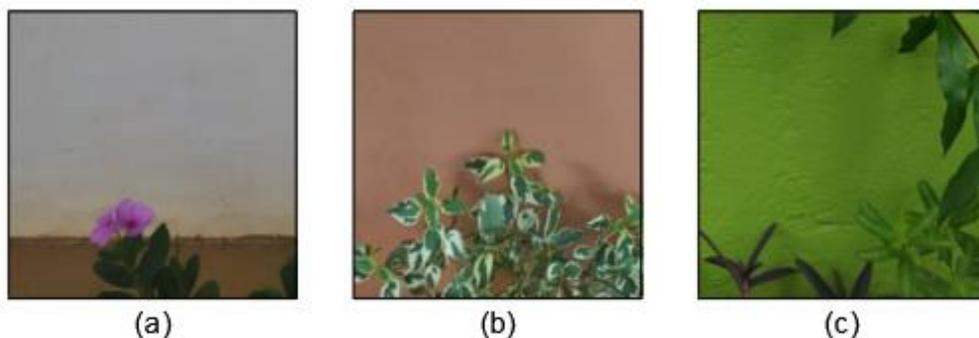
Figura 51 - Imagens com partes das instalações prediais



(a) Tubulação; (b) Tomada de energia; (c); Ponto de energia; (d) Válvula de gaveta.

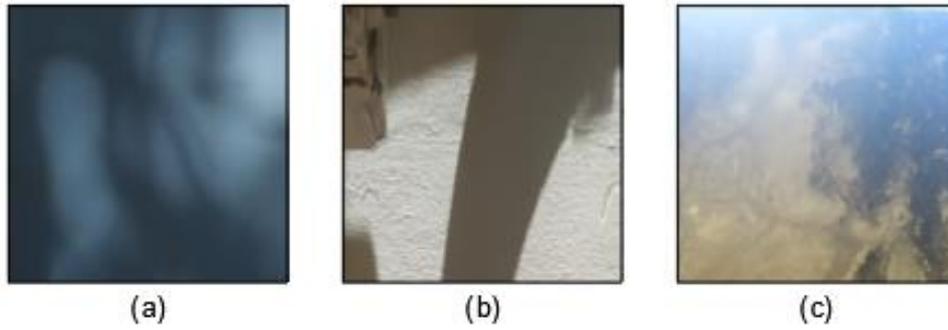
Um ruído que apareceu com frequência foi a incidência de vegetação. Isso pode ser visto nos patches da Figura 52.

Figura 52 - Imagens com vegetação



Considerou-se como ruído sombras que delineavam imagens nas superfícies do revestimento e variações de luminosidade intensas, que prejudicaram a visualização do acabamento. Exemplos desse tipo podem ser observados na Figura 53. Não foi considerado com ruído oscilações de foco nas imagens.

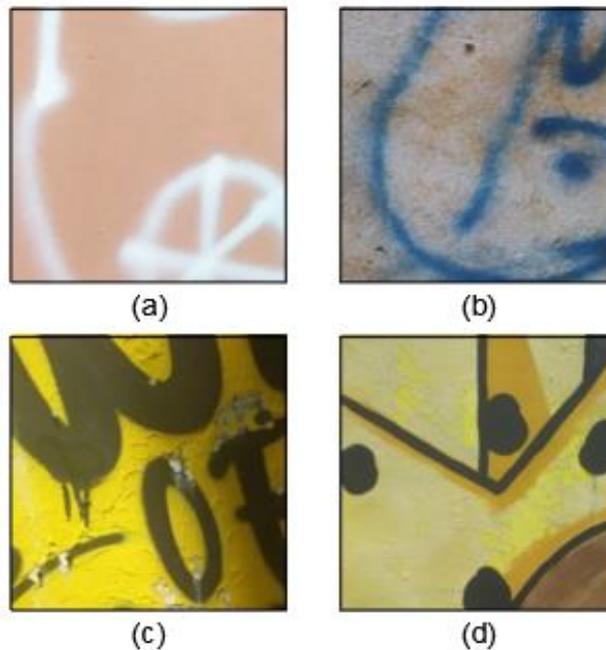
Figura 53 - Imagens de sombra e de luminosidade



(a) e (b) Sombras que delineavam imagens no revestimento; (c) Luminosidade intensa na parte superior.

Desenhos, símbolos ou letras resultado de pintura ou de pichação no revestimento também foram classificados como ruídos. Na Figura 54, segue exemplos das situações citadas.

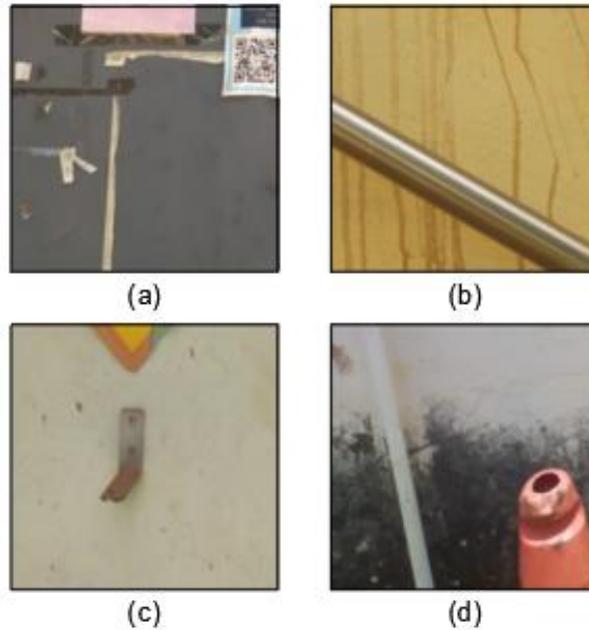
Figura 54 - Desenhos, símbolos ou letras realizadas sobre o revestimento argamassado



(a) e (b) Pichações; (c) Pintura de letras; (d) Pintura de desenho.

Por fim, quaisquer patches com objetos que não era exclusivamente o revestimento foram enquadrados na classe tendo ruído. Na Figura 55, verifica-se alguns tipos de imagens com essas configurações.

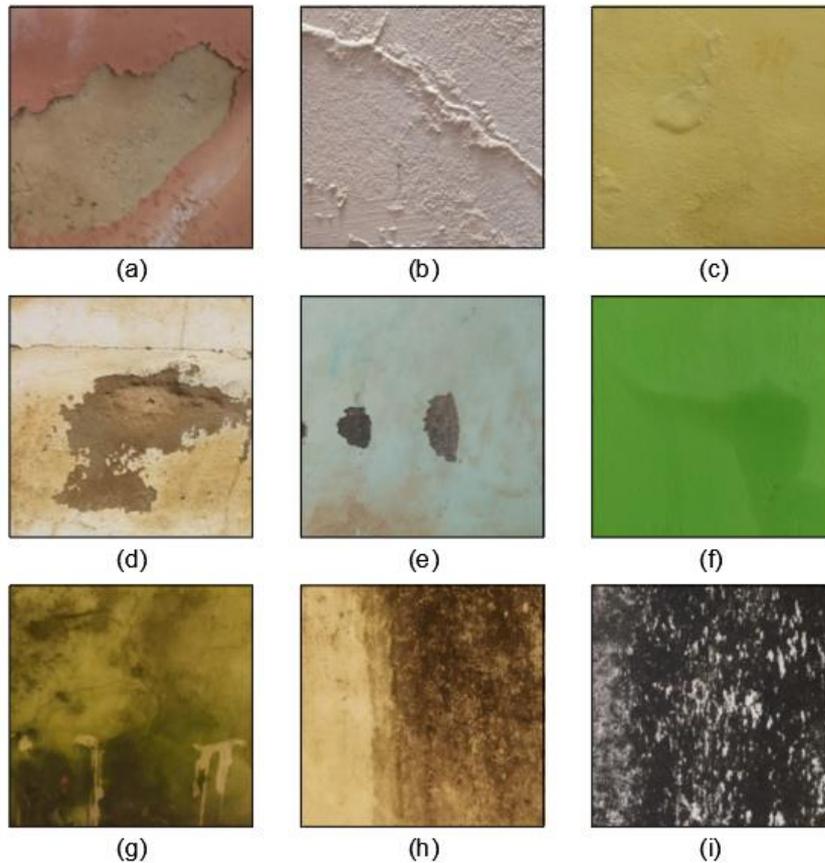
Figura 55 - Imagens com objetos



(a) Papeis e fita adesiva pregados no revestimento; (b) parte de corrimão de uma rampa; (c) cantoneira; (d) objetos diversos.

Não foram considerados como ruídos manifestações patológicas ou defeitos provenientes do desgaste natural ou do uso e operação das edificações. Considerou-se que a rede deveria ter a capacidade de classificar fissuras corretamente mesmo com esses tipos de informações. Algumas manifestações patológicas encontradas podem ser observadas na Figura 56.

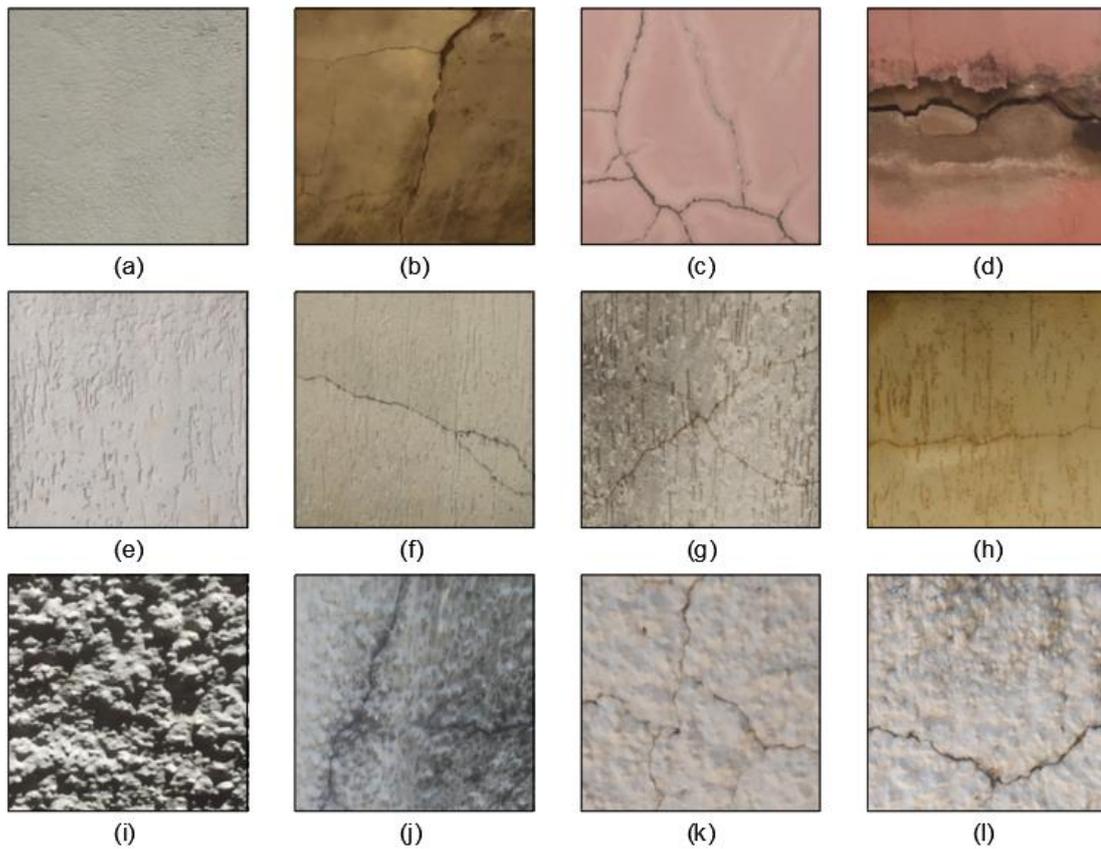
Figura 56 - Manifestações patológicas



(a) Deslocamento de pintura; (b) Empolamento de pintura; (c) Bolhas; (d) Desagregação do revestimento; (e) Danos de impacto; (f) Umidade; (g) Proliferação de musgo; (h) Sujidade por escoamento de água da chuva; Proliferação biológica intensa.

Em seguida a essa etapa da rotulação, as imagens foram separadas entre as que tinham ou não fissuras. Observou-se que em algumas imagens as discontinuidades eram de difícil identificação ou abriam margem para dúvida. Desse modo, estabeleceu-se que, qualquer imagem que sugerisse ter uma fissura seria incluída na classe de com fissura. Exemplos de fissurações por cada tipo de acabamento superficial podem ser verificados na Figura 57.

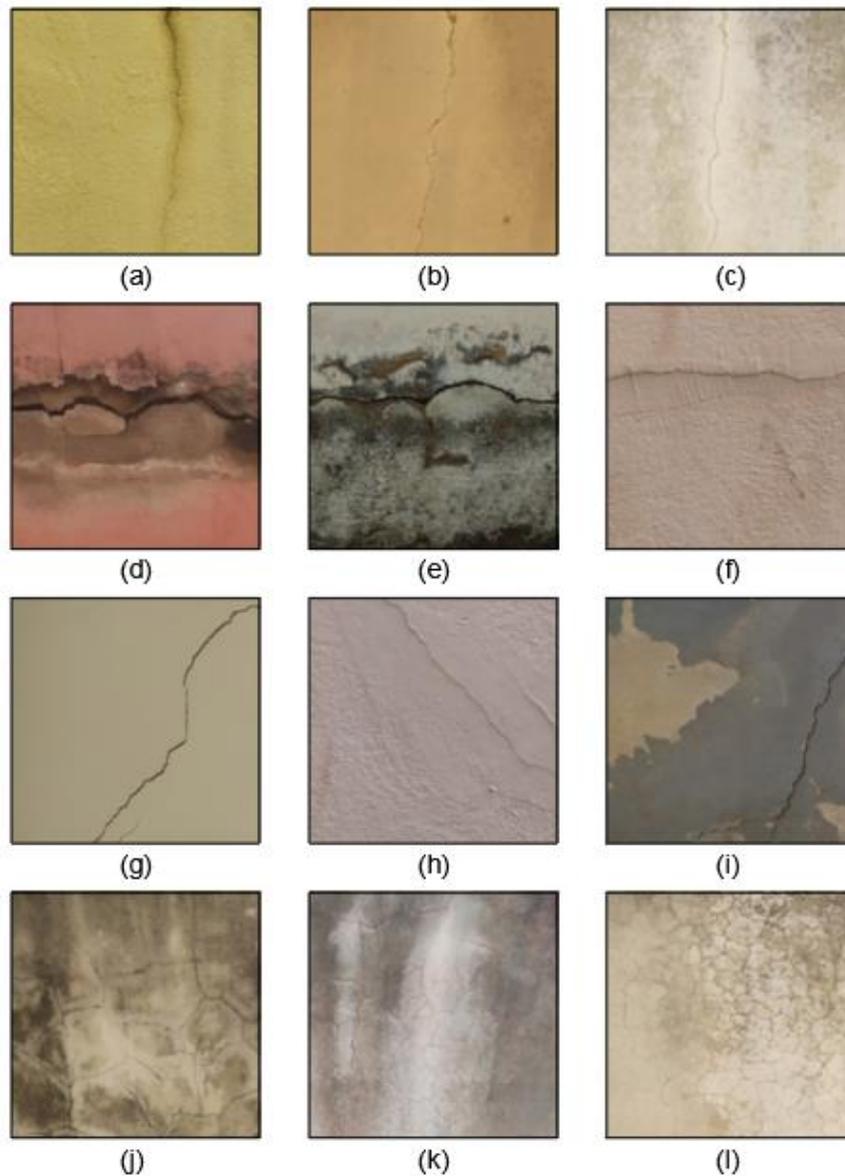
Figura 57 - Fissurações por tipo de acabamento



(a) Acabamento liso saldável; (b) (c) e (d) Acabamento liso com fissuras; (d) Acabamento do tipo grafiato saldável; (e) (f) e (g) Acabamento do tipo grafiato com fissuras; (h) Acabamento do tipo chapiscado saldável; (i) (j) e (k) Acabamento liso com fissuras.

As fissuras variavam também entre configurações. Sabe-se essa característica é importante para a inspeção visual desse tipo de descontinuidade. Na Figura 58, segue exemplos de diferentes configurações de fissuras encontrados.

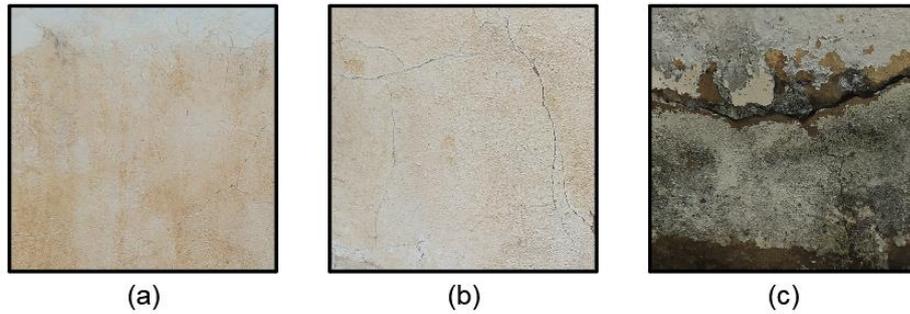
Figura 58 - Diferentes configurações de fissurações



(a) (b) e (c) Fissuras geométricas na direção vertical; (d); (e) (f) Fissuras geométricas na direção horizontal; (g) (h) e (i) Fissuras inclinadas; (j) (k) e (l) Fissurações mapeadas.

Tendo visto o critério de incluir todas as imagens que geravam dúvidas no grupo de patches com fissuras, essa classe foi dividida de acordo com níveis de visibilidade, sendo eles: Alto, médio e baixo. Assim, fica possível realizar agrupamentos do banco de dados de acordo com a visibilidade das fissuras como, por exemplo, remover as imagens com baixa visibilidade para testar um treinamento de uma rede. Essa parte da rotulação pode ser observada na Figura 59.

Figura 59 - Diferentes níveis de visibilidade das fissurações



(a) Baixo; (b) Médio; (c) Alto.

O último procedimento realizado na rotulação foi a nomeação das imagens. Para isso, criou-se uma codificação utilizando letras que foram:

Quanto a presença ou não de fissuras:

- F: Imagens com fissura;
- N: Imagens sem fissura.

Quanto a presença do ruído:

- R: Imagens com ruído;
- S: Imagens sem ruído;

Quanto a visibilidade da fissura, quando essa existia na imagem;

- A: Visibilidade alta;
- M: Visibilidade média;
- B: Visibilidade baixa.

Quanto ao tipo de acabamento superficial:

- L: Imagens com acabamento superficial liso;
- G: Imagens com o acabamento superficial do tipo grafiato;
- C: Imagens com acabamento superficial do tipo chapiscado;

E o nome do agrupamento realizando na obtenção das imagens, conforme a Tabela 1, seguido de um número para diferenciar as imagens com as mesmas classificações.

Desse modo, o nome da imagem foi a sequência dos códigos especificados. Na Figura 60 é possível observar dois exemplos de codificação das imagens:

Figura 60 - Exemplos de codificação dos patches. A figura é melhor visualizada no formato colorido

FRAL1B (1); NSC1E (2)

- **Presença ou não de Fissuras;**
- **Presença ou não de ruído;**
- **Nível de visibilidade das fissuras, se for o caso;**
- **Tipo de acabamento superficial;**
- **Nome do agrupamento de obtenção das imagens (Tabela 1);**
- **Número de identificação.**

Desse modo, finalizou-se o processo de rotulação dos dados.

4.1.2 Análise da quantidade de classes e do equilíbrio do banco de dados

Nessa parte da pesquisa, os dados foram tabelados e a partir disso realizou-se comparações entre a quantidade de imagens das classes e agrupamentos analisados. Para isso, utilizou-se a relação R_m definida na seção 2.1 da metodologia.

Na Tabela 12 tem-se quantidade de imagens, divididas entre as que tem ou não fissuras, para cada tipo de acabamento e para o banco todo.

Tabela 12 – Quantidade de imagens por acabamento superficial

Acabamento Superficial	Com Fissuras	Sem Fissuras	$R_m = \frac{M -}{M +}$
Liso	11648	11147	0,957
Grafiato	985	4739	0,208
Chapiscado	1140	3429	0,332
Total	13773	19315	0,713

É possível verificar na Tabela 12 que o conjunto de dados do acabamento liso é quase totalmente balanceado, possuindo uma relação de 0,957. Já os demais apresentam uma configuração desbalanceada. O grafiato possui a maior diferença entre as quantidades de imagens nas classes comparadas, com uma relação de 0,208. O banco considerando todos os

acabamentos juntos também se apresentou como desbalanceado, porém, com um valor da relação de 0,713, mais alto que os grupos dos revestimentos do tipo grafiato e chapiscado.

Na Tabela 13, tem-se quantidade de imagens contendo ou não ruído, em relação a presença de fissuras, considerando todo o banco de dados.

Tabela 13 – Quantidade de imagens em relação ao ruído

	Com Fissuras	Sem Fissuras	$R_m = \frac{M -}{M +}$
Com Ruído	4867	3779	0,776
Sem Ruído	8906	15536	0,573

Observa-se que as imagens também não são balanceadas quanto a presença de ruído. Tendo em vista essa situação, organizou-se os dados por acabamento superficial, pelo ruído e pela presença ou não de fissurações. Isso pode ser observado na Tabela 14.

Tabela 14 – Quantidade de imagens em relação ao acabamento superficial e ao ruído

Acabamento Superficial	Sem Fissuras			Com Fissuras		
	Sem Ruído	Com Ruído	$R_m = \frac{M -}{M +}$	Sem Ruído	Com Ruído	$R_m = \frac{M -}{M +}$
Liso	8973	2174	0,242	7462	4186	0,561
Grafiato	3887	852	0,219	673	312	0,464
Chapiscado	2676	753	0,281	771	369	0,479

Desse modo, é possível perceber que a quantidade de ruído presente nas imagens varia, também, dentro de cada agrupamento de acabamento superficial. Isso se verificou porque em todas as configurações da Tabela 4 as relações possuem com valores entre 0,6 e 0,2. Supõem-se que, se o ruído for um fator importante para a assertividade da rede, mesmo balanceando o banco em relação a presença ou não de fissuras, o ruído poderá afetar no desempenho do treinamento.

Na Tabela 15, é possível verificar as quantidades de imagens contendo fissuras de acordo com as classes de visibilidade definidas. Ao lado de cada valor, tem-se a porcentagem das imagens em relação ao total de imagens com fissuras de cada acabamento superficial.

Tabela 15 – Quantidade de imagens em relação ao nível de visibilidade das fissuras

	Quantidade de imagens (Porcentagem*)			
	Alto	Médio	Baixo	Total
Liso	1839 (16%)	5668 (49%)	4141 (36%)	11648 (100%)
Grafiato	123 (12%)	309 (31%)	553 (56%)	985 (100%)
Chapiscado	367 (32%)	518 (45%)	255 (22%)	1140 (100%)

* Porcentagem entre a quantidade de imagens em relação ao nível de visibilidade e o total de imagens com fissuras em cada acabamento superficial.

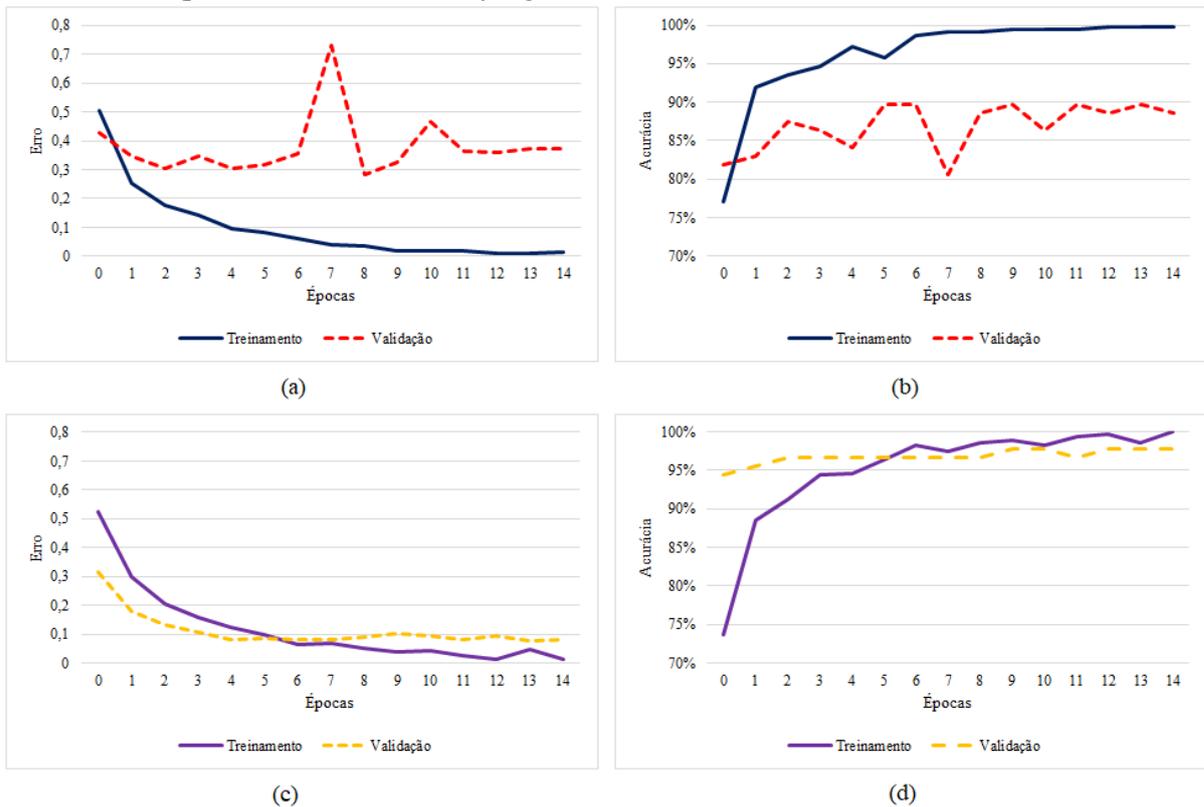
Verifica-se que o acabamento do tipo grafiato é o que possui mais imagens nas quais as fissuras são difíceis de serem detectadas, representando 56% das fissuras desse agrupamento. O liso vem em seguida com 36% de imagens com baixa visibilidade. O chapiscado foi o acabamento com menos tipos dessas imagens.

Observando as relações realizadas, verifica-se que o banco de dados possui uma configuração desbalanceada de modo geral. A situação vai de acordo com Gua (a) et all. (2020) que afirma que a análise de defeitos em fachadas costuma a gerar banco de dados desbalanceados. O banco elaborado nessa pesquisa representa uma situação real de problemas dentro de um universo delimitado. Portanto, conseguir soluções para trabalhar com a configuração dos seus dados e obter resultados de assertividade bons pode resultar em redes com maior capacidade de generalização, em relação ao problema investigado, e mais adequadas para situações reais.

4.1.3 Treinamentos iniciais

Inicialmente, foi feito um treinamento com um grupo selecionado manualmente e equilibrado entre imagens que continham ou não fissuras. A divisão dos patches para treinamento e validação foi realizada de duas formas, uma por meio de seleção manual e a outra de maneira aleatória utilizando a biblioteca splitfolders. Os gráficos do treinamento podem ser vistos na Figura 61.

Figura 61 - Gráficos da função perda e da acurácia nos treinamentos de teste



(a) Função de perda por épocas do grupo com a seleção manual; (b) Acurácia por épocas do grupo com a seleção manual; (c) Função de perda por épocas do grupo com seleção a aleatória; Acurácia por épocas do grupo com a seleção aleatória.

Observa-se que o treinamento utilizando a seleção aleatória foi mais regular que o da seleção manual. Isso pode ser verificado na imagem com erro da validação decaindo junto com o treinamento, que é a situação ideal no processo. A seleção manual pode gerar uma tendência na escolha das imagens, o que prejudicaria o desempenho da rede e a representatividade entre a divisão das categorias. Desse modo, definiu-se que os demais agrupamentos e divisões seriam aleatórias e realizados por meio da biblioteca splitfolders.

A partir disso, as classes majoritárias do grupo B tiveram suas quantidades de imagens reduzidas ao valor da classe minoritária. Em sequência, o grupo A e B foram divididos entre conjuntos de treinamento e validação com as proporções de 70% e 30%, respectivamente. As quantidades de dados utilizados nos treinamentos podem ser observadas na Tabela 16.

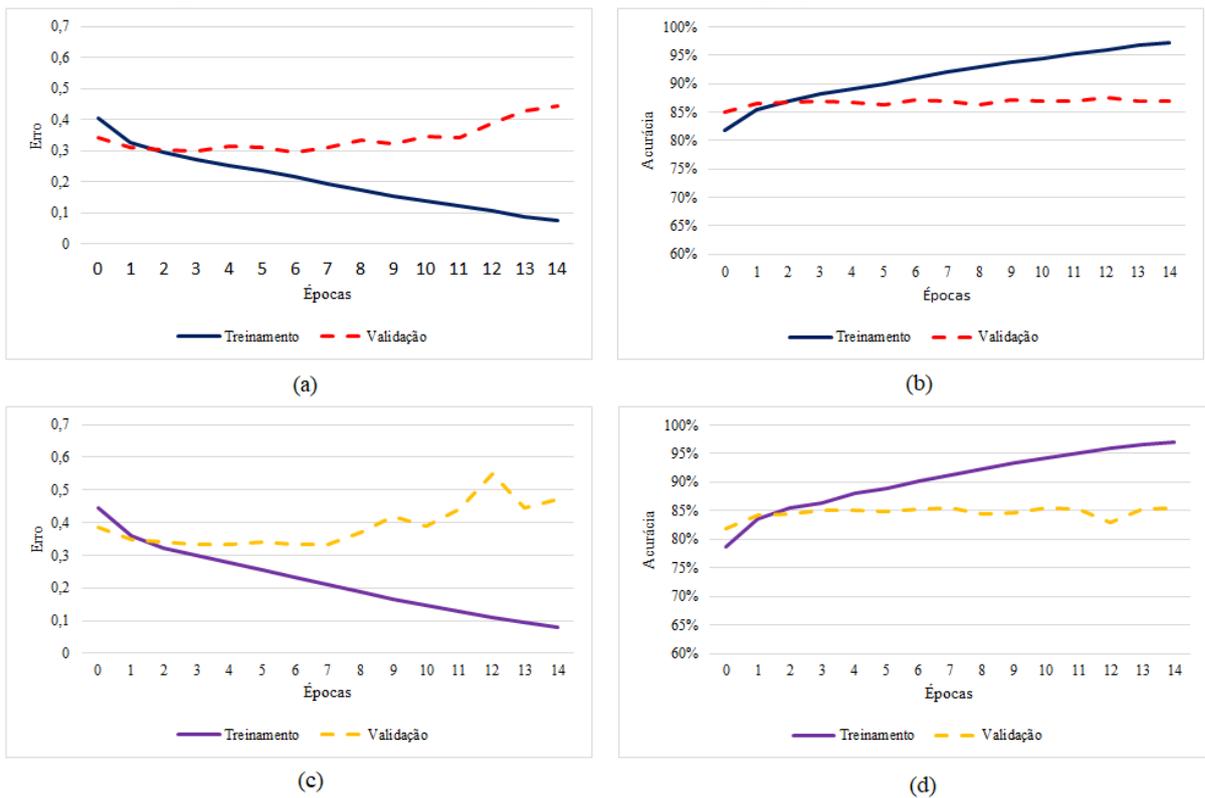
No processo de redução, a biblioteca acabou por diminuir o grupo B1 e B2 abaixo da classe minoritária, porém, conseguindo balancear os dados. Os experimentos prosseguiram com os grupos da Tabela 4.

Tabela 16 - Quantidade de imagens após o balanceamento e a divisão entre treinamento e validação de A e B

Agrupamentos	Com Fissuras	Sem Fissuras	$R_m = \frac{M -}{M +}$	Total	Treinamento (70%)	Validação (30%)
Grupo A1	13773	19315	0,713	33088	23144	9944
Grupo A2	11648	11147	0,957	22795	15938	6857
Grupo A3	985	4739	0,208	5724	4002	1722
Grupo A4	1140	3429	0,332	4569	3194	1375
Grupo B1	11761	11756	1,000	23517	16460	7057
Grupo B2	9636	9621	0,998	19257	13471	5786
Grupo B3	985	990	0,995	1975	1381	594
Grupo B4	1140	1145	0,996	2285	1598	687

Na Figura 62 é possível verificar os treinamentos de A1 e B1. Os gráficos de cada grupo foram plotados com cores diferentes para de facilitar a identificação. Esse procedimento se repetirá nos demais gráficos.

Figura 62 - Gráficos da função perda e da acurácia grupos com o banco todo

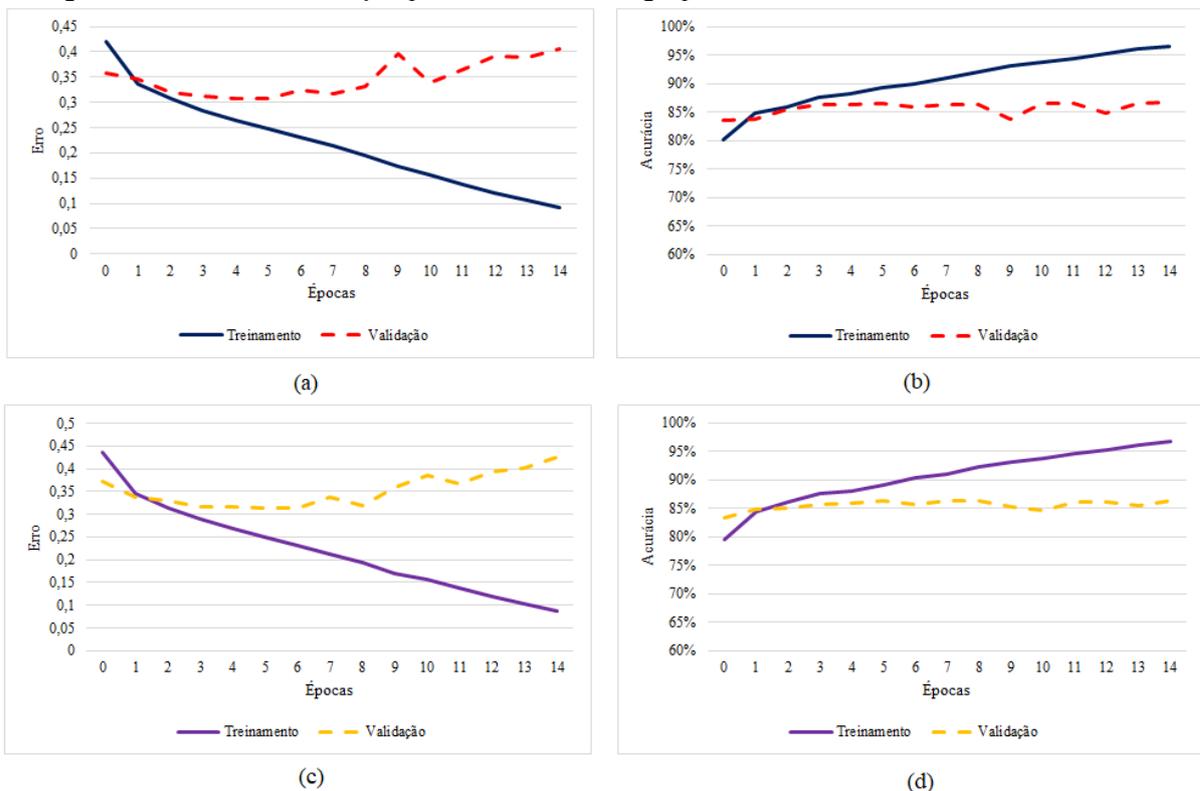


(a) Função de perda por épocas do grupo A1 (desbalanceado); (b) Acurácia por épocas do grupo A1 (desbalanceado); (c) Função de perda por épocas do grupo B1 (balanceado); Acurácia por épocas do grupo B1 (balanceado).

É possível observar que os gráficos relativos ao treinamento dos grupos A1 e B1 quase não variaram. O valor da acurácia do grupo B2 ficou em uma faixa um pouco menor do que a do A1, estando próxima e abaixo de 85%. A acurácia do A1 ficou o treinamento quase todo acima e próximo de 85%. Em relação ao erro, o de validação em ambos os grupos decaiu até certo ponto e depois começa a aumentar. Isso ocorre porque a rede parou de aprender e a partir disso ela começa a ajustar o próprio erro no treinamento, gerando *overfitting*. Uma maneira de evitar isso seria o uso do *early stopping* para realizar a parada do treinamento assim que a rede não estivesse aprendendo mais.

Na Figura 63 estão os gráficos referentes ao treinamento dos grupos contendo somente o revestimento do tipo liso.

Figura 63 - Gráficos da função perda e da acurácia grupos contendo somente o revestimento liso



(a) Função de perda por épocas do grupo A2 (desbalanceado); (b) Acurácia por épocas do grupo A2 (desbalanceado); (c) Função de perda por épocas do grupo B2 (balanceado); Acurácia por épocas do grupo B2 (balanceado).

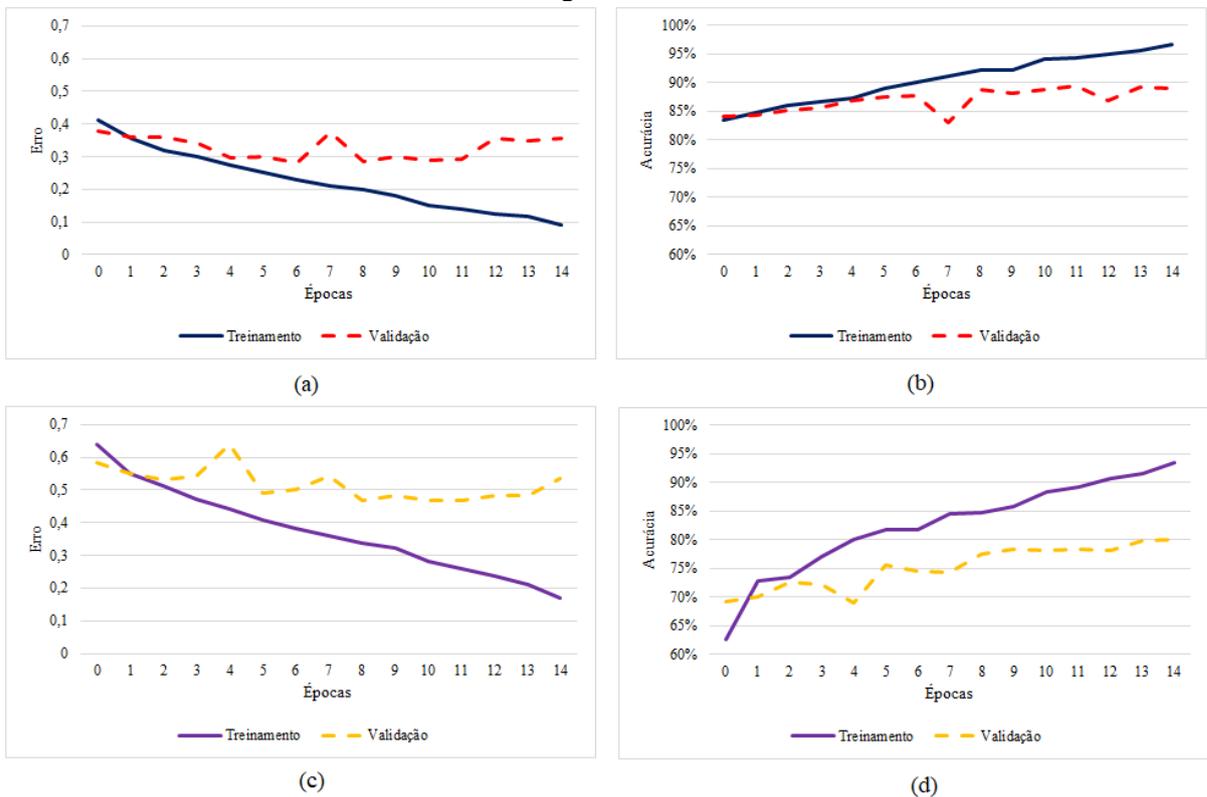
No caso do revestimento do tipo liso, não se teve quase nenhuma variação entre o grupo A2 e B2. Os gráficos do erro e da acurácia apresentam o mesmo comportamento nas duas situações, com acurácia ficando um pouco acima de 85% durante o treinamento. Acontece que

o grupo A1 já estava bem balanceado. A relação R_m dele foi de 0,957, bem próxima de 1. Dessa maneira, o processo de balanceamento pela classe minoritária quase não causou alterações.

Outro ponto foi observado é que os resultados dos grupos A2 e B2 também são semelhantes aos dos grupos A1 e B1. Isso pode ser justificado pelo revestimento do tipo liso ser o acabamento superficial com maior número dados. Ele representa um total de 22.795 imagens em um universo de 33.088. Dessa maneira, é possível que o acabamento liso gere uma tendência dos ajustes nas redes treinadas com o banco todo.

Na Figura 64, verifica-se os dados referentes aos agrupamentos do acabamento do tipo grafiato.

Figura 64 - Gráficos da função perda e da acurácia grupos contendo somente o revestimento do tipo grafiato



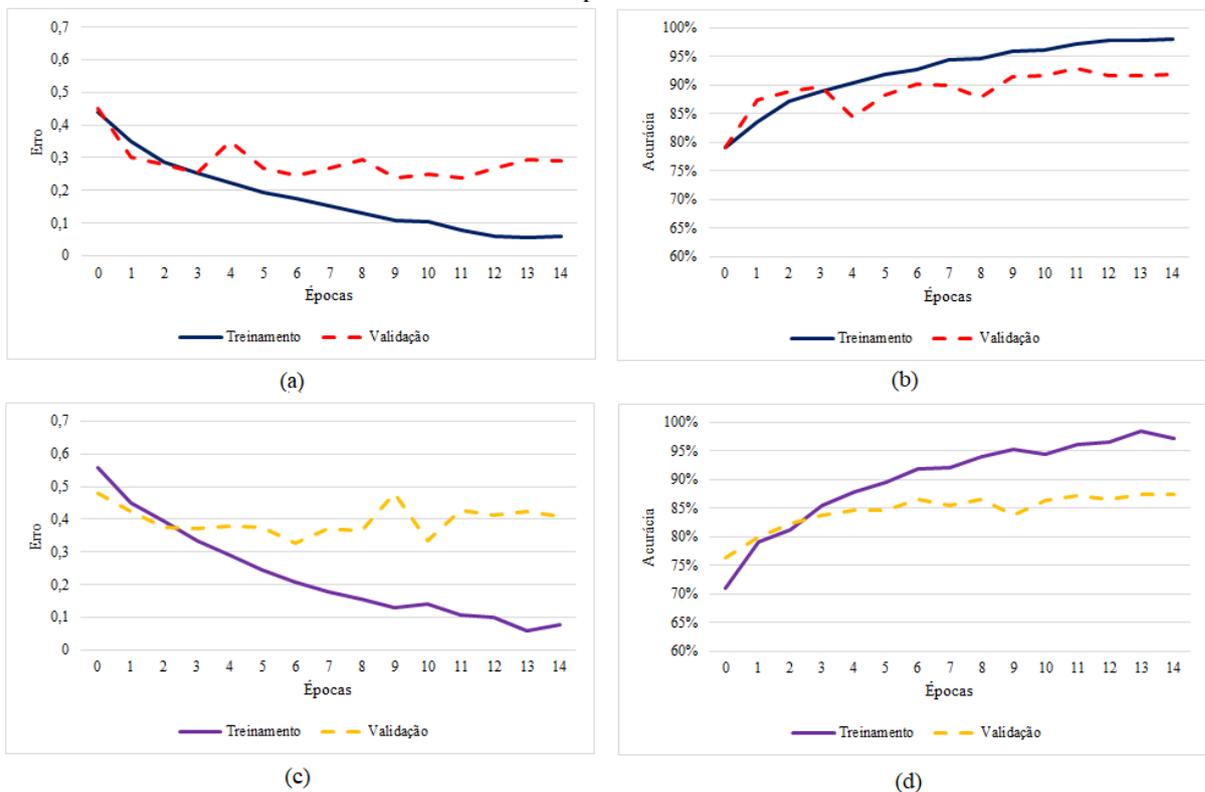
(a) Função de perda por épocas do grupo A3 (desbalanceado); (b) Acurácia por épocas do grupo A3 (desbalanceado); (c) Função de perda por épocas do grupo B3 (balanceado); Acurácia por épocas do grupo B3 (balanceado).

No caso do grafiato, teve-se diferenças entre os grupos A3 e B3. A acurácia do grupo A3 foi maior do que a do B3. Enquanto A3 alcançou resultados próximos de 90% o grupo B3 não chegou 80%. Essa diferença pode ser explicada pelo desbalanceamento dos dados. No caso do A3, seu banco tem 4739 imagens sem fissura contra 985 imagens com fissuras. Dessa maneira, a rede pode se especializar em acertar as imagens que não tem fissura. Assim, ela vai

acabar tendo uma acurácia melhor, pois, o volume de imagens que não tem fissuras é bem maior do que as que tem. Desse modo, a rede vai ter mais acertos, mesmo se não tiver conseguindo classificar adequadamente as imagens com fissuras. Essa situação é problemática, pois, a rede acaba não tendo capacidade de generalização. Dessa maneira, tem-se um modelo de classificação fraco. Um processo adequado para avaliar isso seria ter, também, um grupo de teste com imagens que não foram utilizadas durante o treinamento e analisar a precisão das classes isoladamente.

Outro ponto é que o acabamento do tipo grafiato é o que tem maior número de imagens com baixa visibilidade. Correspondendo a 56% do total das imagens com fissuras do grupo. Os dados referentes ao treinamento do acabamento do tipo chapiscado podem ser observados na Figura 65.

Figura 65 - Gráficos da função perda e da acurácia grupos contendo somente o revestimento do tipo chapiscado

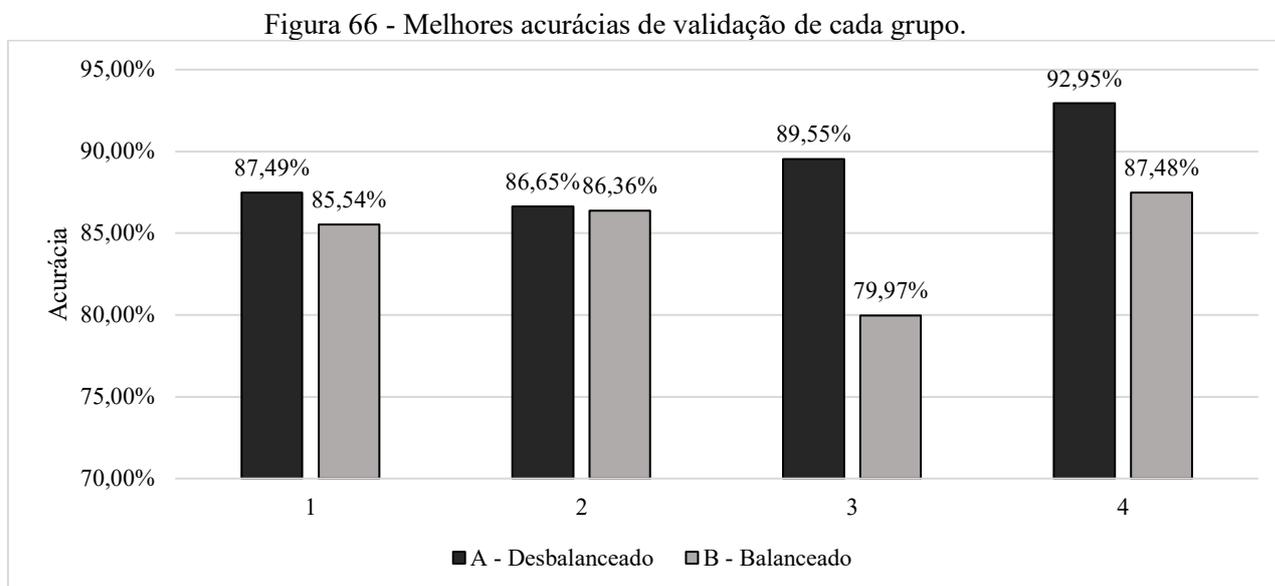


(a) Função de perda por épocas do grupo A4 (desbalanceado); (b) Acurácia por épocas do grupo A4 (desbalanceado); (c) Função de perda por épocas do grupo B4 (balanceado); Acurácia por épocas do grupo B4 (balanceado).

O grupo do tipo chapiscado também teve diferença na acurácia entre os grupos A4 e B4. No caso, a acurácia do grupo A4 ficou acima de 90% enquanto a do B4 ficou abaixo desse valor. Pode ser observado a mesma condição de desbalanceamento de dados do grupo do

grafiato, porém, com uma variação menor da acurácia entre A4 e B4. No caso, o A4 possuía um total de 1140 de imagens com fissuras e de 3429 de sem as descontinuidades.

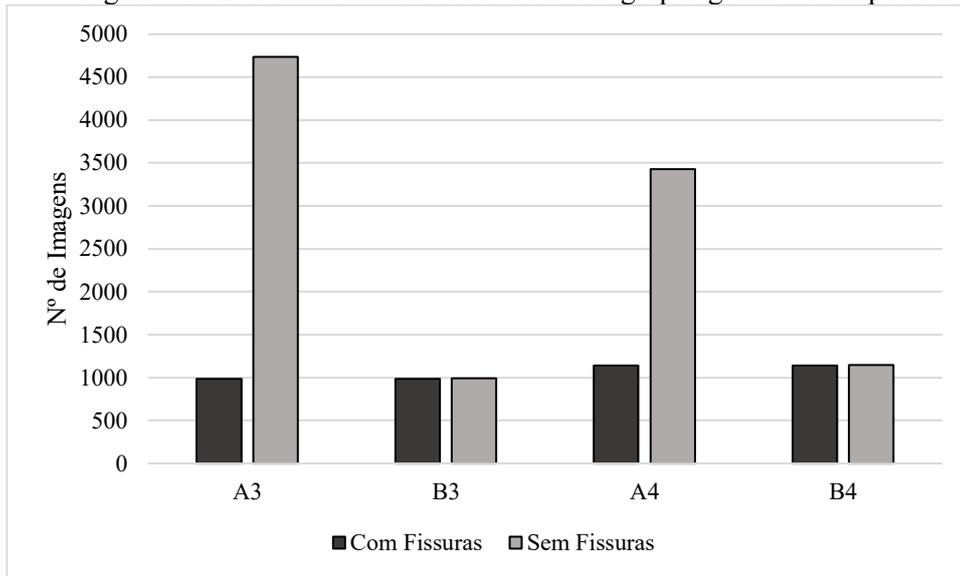
Dessa maneira, observou-se diferenças entre os treinamentos dos diferentes grupos. Na Figura 66, foram plotadas as melhores acurácias de cada grupo.



(1) Banco total; (2) Liso; (3) Grafiato; (4) Chapiscado.

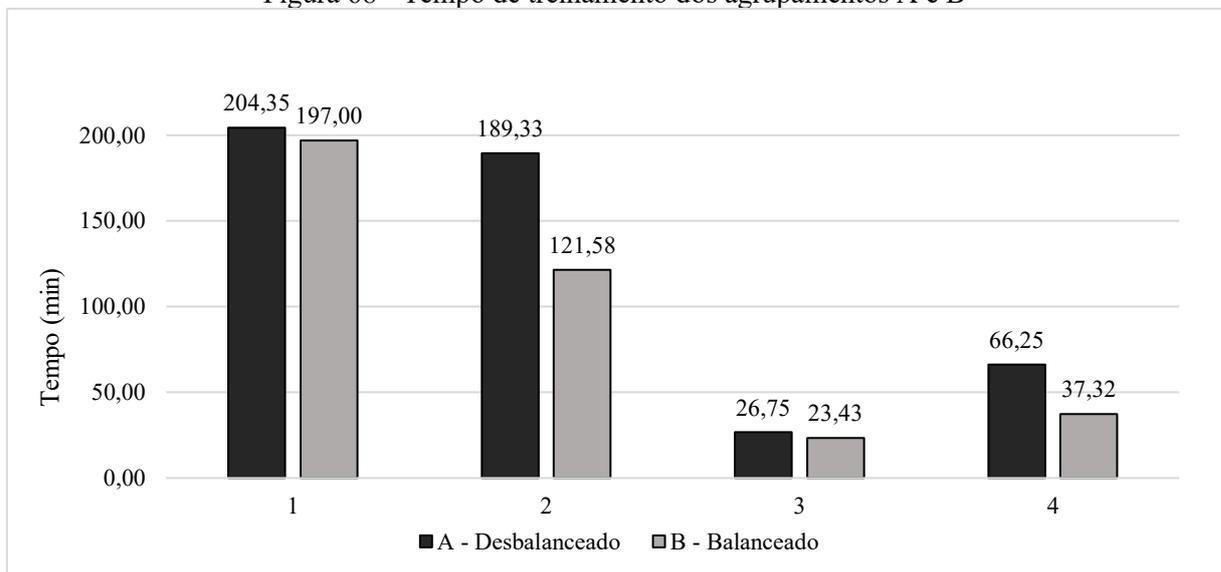
Na Figura 66 é possível avaliar todas as situações levantadas de forma mais clara. O primeiro ponto é que quase todos os grupos balanceados tiveram acurácia menor que os desbalanceados, em menor ou maior escala. Os grupos A2 e B2 quase não tiveram variação quanto a melhor acurácia. Os grupos A1 e B1 tiveram valores próximos dos grupos A2 e B2. Os grupos A3 e B3 foram o que tiveram maior variação de acurácia entre eles sendo que A3 corresponde, também, ao banco de dados mais desbalanceado. O grupo A4 foi o valor de maior acurácia, porém, também era desbalanceado. No caso, a acurácia do grupo B4 foi menor do que o A4, mas, com uma variação menor do que a que ocorreu entre os grupos A3 e B3. A acurácia do grupo B4 foi a melhor entre os grupos balanceados e também foi próxima dos grupos A1, B1, A2 e B2. Isso pode indicar que a capacidade de identificar fissuras em um acabamento superficial chapiscado é próxima da de identificar em um liso. A questão do grafiato e do chapiscado ter tido uma acurácia maior no grupo desbalanceado do que no balanceado pode ser resultado da diferença entre a quantidade de imagens nas classes. Acontece que, a rede pode se especializar em classificar a classe majoritária, desse modo, ela terá mais acertos, o que aumentará o valor da acurácia mesmo se não estiver conseguindo classificar direito a outra classe. O desbalanceamento dos dados pode ser observado na Figura 67.

Figura 67 - Desbalanceamento dos dados dos grupos grafiato e chapiscado



Na Figura 68 estão os tempos de treinamento em relação a cada grupo.

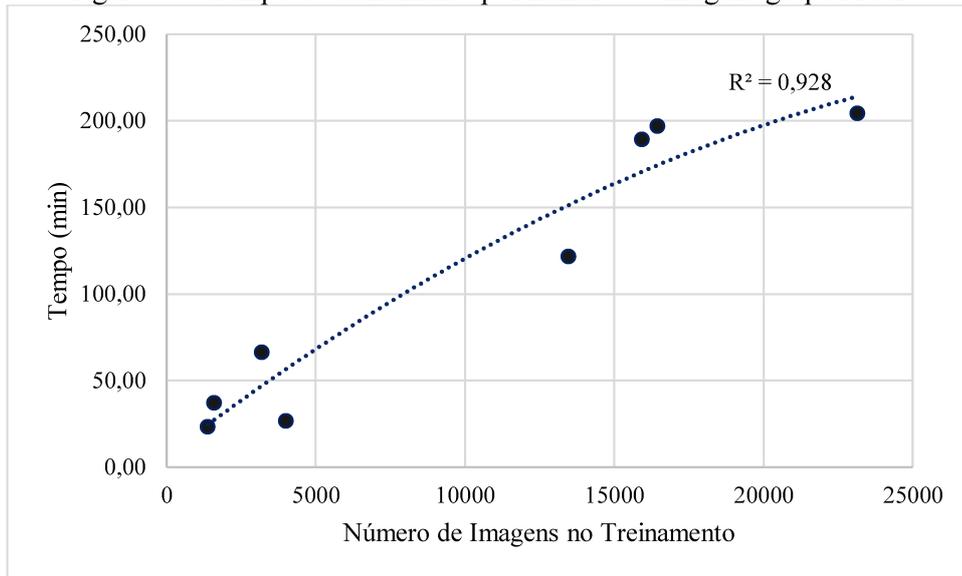
Figura 68 - Tempo de treinamento dos agrupamentos A e B



(1) Banco total; (2) Liso; (3) Grafiato; (4) Chapiscado.

É possível observar que o tempo de treinamento variou entre os grupos. Isso é justificado, pois, os agrupamentos têm quantidade de dados diferentes. Tendo em vista essa situação, o tempo de treinamento foi plotada em relação à quantidade de imagens utilizadas para realizar o processo. Isso pode ser observado na Figura 69.

Figura 69 - Tempo de treinamento por número de imagens grupo A e B



Verifica-se que o tempo de treinamento aumenta conforme o número de imagens. Adicionando uma linha de tendência do tipo polinomial de segundo grau foi possível obter um coeficiente de determinação (R^2) de 0,9279.

Tendo todos os dados levantados, as discussões serão realizadas na próxima seções.

4.1.4 Discussão

Foi possível verificar variabilidades dentro das categorias definidas durante o processo de rotulação. No acabamento superficial, os três tipos apresentaram diferentes texturas em suas imagens, resultando em aspectos topográficos diversos. Em situações que essa característica é importante, essa configuração pode influenciar. Por exemplo, na imagem (c) da Figura 46, na qual o revestimento com acabamento grafiato tem uma grande parte lisa. Ela pode ser confundida por uma rede como pertencendo a uma classificação de revestimento liso.

O banco apresentou vários tipos de ruídos. Alguns deles geraram linhas e formas que nas imagens podem se assemelhar a fissuras no processo de extração de características, como no encontro entre paredes e na incidência de sombras. Outro ponto é que alguns ruídos apareceram com frequência relacionados com fissuras. Isso foi possível de ser observado durante processo de rotulação quando se tinha parte do piso, pois, muitas das imagens com esse tipo de ruído eram acompanhadas de fissurações. Essa situação também foi verificada quando se tinha manifestações patológicas. Alguns tipos de problemas costumavam a vir associados com a incidência de fissuras.

As fissurações apresentaram diferentes tamanhos e configurações. Em algumas imagens, as descontinuidades eram difíceis de detectar, gerando dúvidas até entre os profissionais responsáveis pela rotulação manual.

O banco de dados apresentou desbalanceamento em todas as categorias delimitadas na rotulação, ou seja, em relação ao acabamento superficial, a presença de ruído, a presença de fissuras e a visibilidade das descontinuidades. De maneira geral, teve-se uma quantidade maior de imagens sem a incidência de fissuras do que as que tinham o problema. O banco de dados do tipo chapiscado foi o com menor número de imagens. Já o grafiato teve o maior desequilíbrio na categoria associada a presença ou não de fissuras. O revestimento liso foi o acabamento que teve maior volume de dados e a relação mais equilibrada entre a incidência das descontinuidades. O grafiato foi, também, a finalização com maior índice de imagens nas quais era difícil de detectar os problemas, 56% em relação as suas imagens que continham fissuras do grupo. Já a finalização do tipo liso teve uma incidência de 36%, seguido do chapiscado, com 22%, isso em relação ao total de imagens com problemas dentro entre cada tipo de acabamento. Com o conjunto de dados desenvolvido neste estudo, foi possível verificar as afirmações de Lee et al. (2020), Guo (a) et al. (2020), Guo (b) et al. (2020) e Chen et al. (2021) sobre o revestimento argamassado gerar bancos de dados com muita variabilidade e desbalanceados, principalmente em comparação com o concreto e o pavimento asfáltico. As situações levantadas no processo de rotulação correspondem a cenários que podem ser encontradas em inspeções reais. Portanto, o banco elaborado tem potencial para ser trabalhado em diferentes abordagens de visão computacional, podendo otimizar a capacidade de generalização de redes.

Em relação aos treinamentos, o gráfico do erro apresentou o mesmo comportamento para todos os grupos. O erro decresce até certo ponto e depois começa a aumentar. Isso indica que está ocorrendo *overfitting*. Desse modo, os dados apresentados não podem ser utilizados como critério para avaliar o desempenho da VGG16 para o banco elaborado, porém, servem para o objetivo inicial dessa etapa de comparar os diferentes agrupamentos e levantar pontos que podem ser investigados. O problema de *overfitting* poderia ser minimizado utilizando ferramentas como *early stopping* e a taxa de *dropout*.

O acabamento do tipo grafiato foi o que apresentou maior diferença entre os treinamentos dos grupos A e B. No caso, ele era tipo de acabamento superficial mais desbalanceado, o que pode justificar o de acurácia de 89,55% no grupo A3. Isso porque a rede pode estar acertando mais as imagens da classe que não contem fissura, o que iria aumentar a acurácia da rede tendo em vista que o volume de imagens nesta categoria é bem maior do que

a outra. Uma ferramenta que poderia ajudar a avaliar esse cenário seria a matriz de confusão e a verificação da precisão de acerto em cada uma das classes.

A acurácia do grupo B3 foi a menor entre todos os treinamentos, 79,97%. Essa questão pode ser justificada pela complexidade de identificar as fissuras no acabamento grafiato. As ranhuras desse tipo de finalização são praticamente traços, o que pode se assemelhar à alguns tipos de fissuras. Isso pode ser observado na rotulação dos dados, tendo em vista o grande número de imagens de baixa visibilidade dentro do grupo.

O grupo A4 da classe chapiscado teve o maior valor entre as acurácias, 92,95%. Porém, ele também era desbalanceado, portanto, as mesmas observações realizadas para o acabamento superficial do tipo grafiato também podem ser aplicadas para o chapiscado, nesse caso. O grupo B4 teve a melhor acurácia em relação aos agrupamentos balanceados, com 87,48%. Esse valor foi próximo dos obtidos no acabamento do tipo liso, o que pode indicar que a dificuldade de identificar fissuras é próxima entre esses dois tipos de acabamentos. Em teoria, a superfície do chapiscado tem um aspecto bem mais rugoso que o do liso, porém, não tem muitas informações que podem ser confundidas com fissuras, como é o caso do tipo grafiato. Outro ponto é que na finalização do tipo liso, é possível verificar que algumas texturas também tem um aspecto menos uniforme, como visto na Figura 44.

O acabamento do tipo liso teve resultados semelhantes entre a acurácia dos grupos A1 e B1. Isso pode ser explicado pelo fato que o grupo A1 já era bem balanceado, tendo uma variação de 501 imagens entre as classes em um universo de 22795. A superfície do tipo liso seria a que mais se assemelharia à superfície do concreto, porém, os resultados de acurácia de A1 e B1 foram de 86,65% e 86,36%, respectivamente, o que é abaixo de estudos de concreto como Chow et al. (2020), Ali et al. (2021), Islam et al. (2022) e Chaiysarn (2022). Isso pode indicar que a aplicação de visão computacional em imagens do revestimento argamasso é mais complexa que no caso do concreto.

Os agrupamentos que continham todos os acabamentos superficiais tiveram valores próximos entre o desbalanceado e o balanceado. A1 teve uma acurácia de 87,49% e B2 de 85,54%. Esses valores ficaram próximos dos agrupamentos A2 e B2. Como maioria das imagens do banco de dados eram do revestimento do tipo liso, é possível que a rede tenha tido uma tendência de acertar esse tipo de revestimento. Isso poderia ser avaliado utilizando a matriz de confusão.

Desse modo, foi possível observar diversos pontos relevantes para serem investigados utilizando o banco de dados proposto a partir de abordagens de IA.

4.2 TREINAMENTOS COMPARATIVOS

4.1.5 Treinamentos binários

Os primeiros treinamentos seguiram o mesmo padrão em relação a organização dos grupos que os treinamentos iniciais. Nesse caso, os grupos desbalanceados foram identificados com a letra C e os balanceados a partir da classe minoritária com a letra D. Os agrupamentos quanto ao acabamento superficial mantiveram os mesmos índices sendo 1 para o conjunto com todos os dados, 2 para o só com o acabamento do tipo liso, 3 para o acabamento do tipo grafiato e 4 para o chapiscado.

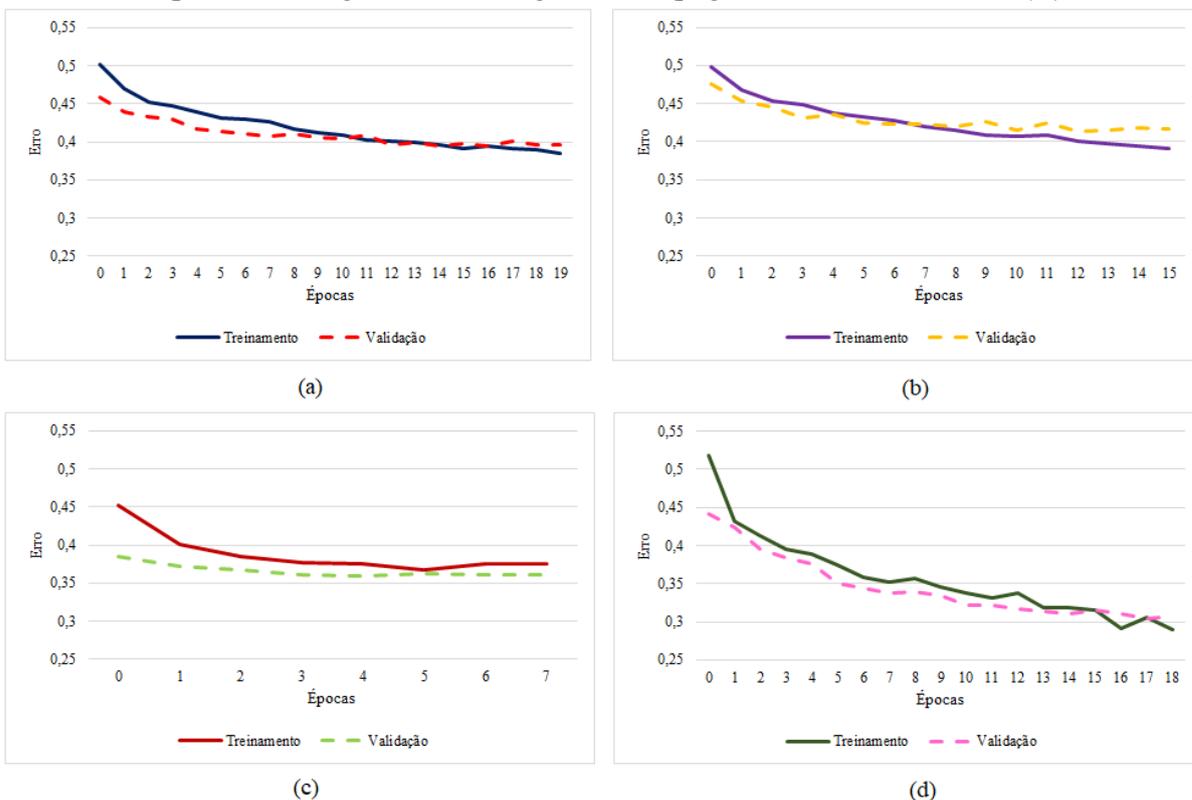
Os 30% que eram do grupo de validação nos treinamentos iniciais foram divididos em 20% para o novo conjunto de validação e 10% para o conjunto de teste. As quantidades de imagens em cada grupo podem ser observadas na Tabela 17.

Tabela 17 - Quantidade de imagens após o balanceamento e a divisão entre treinamento e validação de D e C

Agrupamentos	Com Fissuras	Sem Fissuras	$R_m = \frac{M -}{M +}$	Total	Treinamento (70%)	Validação (20%)	Teste (10%)
Grupo C1	13773	19315	0,713	33088	23144	6598	3346
Grupo C2	11648	11147	0,957	22795	15938	4543	2314
Grupo C3	985	4739	0,208	5724	4002	1145	577
Grupo C4	1140	3429	0,332	4569	3194	910	465
Grupo D1	11761	11756	1,000	23517	16460	4684	2373
Grupo D2	9636	9621	0,998	19257	13471	3836	1950
Grupo D3	985	990	0,995	1975	1381	393	201
Grupo D4	1140	1145	0,996	2285	1598	455	232

Os gráficos do erro em relação ao número de épocas referentes aos agrupamentos desbalanceados (C) podem ser observados na Figura 70.

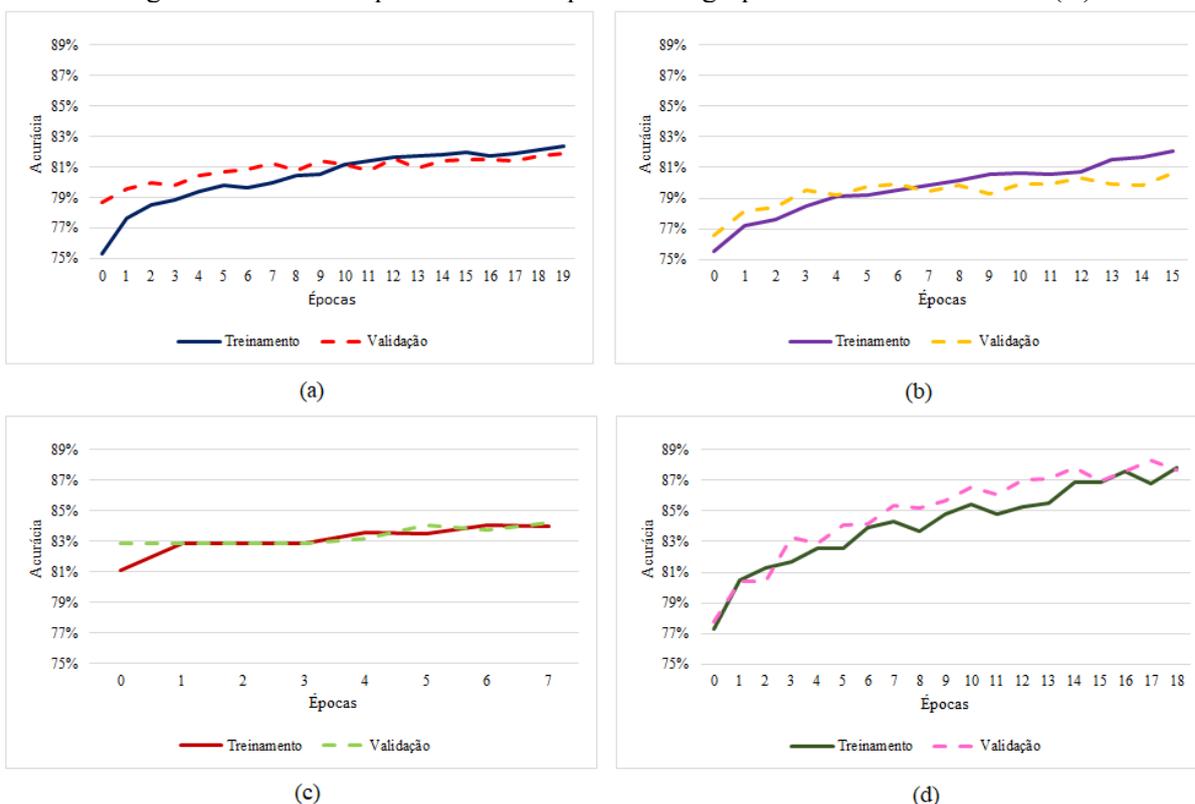
Figura 70 - Erro por número de épocas dos agrupamentos desbalanceados (D)



(a) Erro por épocas do grupo C1 (Banco de dados todo); (b) Erro por épocas do grupo C2 (Liso); Erro por épocas do grupo C3 (Grafiafo); Erro por épocas do grupo C4 (Chapiscado)

Verifica-se uma melhora dos treinamentos em relação aos grupos A e B. Em todos os gráficos o erro da validação desce junto com o do treinamento, o que mostra que não ocorreu superandizagem. No caso, o early stopping parou todos os treinamentos antes das 20 épocas, no caso do C3, em 7 épocas. Isso demonstra a importância dessa implementação e como ela auxilia na obtenção de treinamentos de redes mais confiáveis. Na Figura 71 é possível visualizar as curvas de acurácia por épocas.

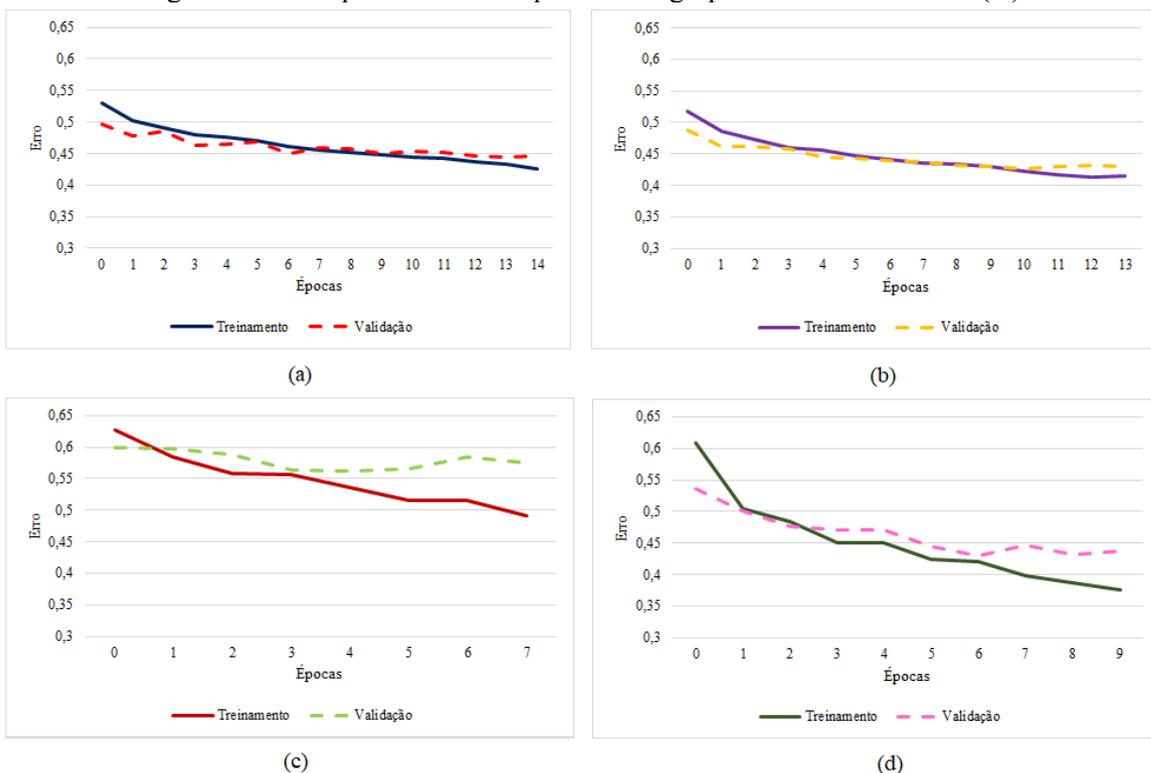
Figura 71 - Acurácia por número de épocas dos agrupamentos desbalanceados (C)



(a) Acurácia por épocas do grupo C1 (Banco de dados todo); (b) Acurácia por épocas do grupo C2 (Liso); Acurácia por épocas do grupo C3 (Grafiato); Acurácia por épocas do grupo C4 (Chapiscado)

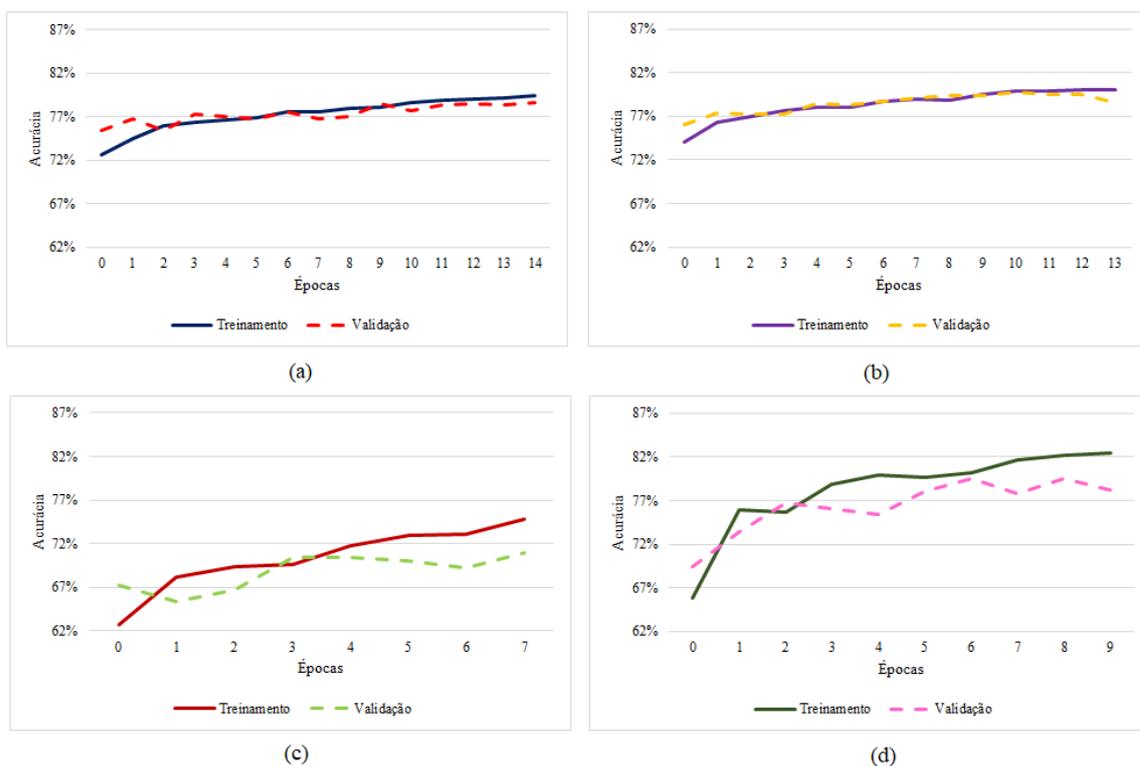
Observou-se que a acurácia também teve um comportamento adequado, crescendo na medida que o erro diminuía para todos os agrupamentos. Nessa etapa da pesquisa, o desempenho das redes será avaliado a partir das métricas de assertividade do grupo de teste e não da melhor acurácia do treinamento, como foi nos testes iniciais. Em relação as curvas de erro e acurácia para os grupos balanceados (D), elas também apresentaram o comportamento adequado, como pode ser observado nas Figuras 72 e 73.

Figura 72 - Erro por número de épocas dos agrupamentos balanceados (D)



(a) Erro por épocas do grupo D1 (Banco de dados todo); (b) Erro por épocas do grupo D2 (Liso); Erro por épocas do grupo D3 (Grafiato); Erro por épocas do grupo D4 (Chapiscado)

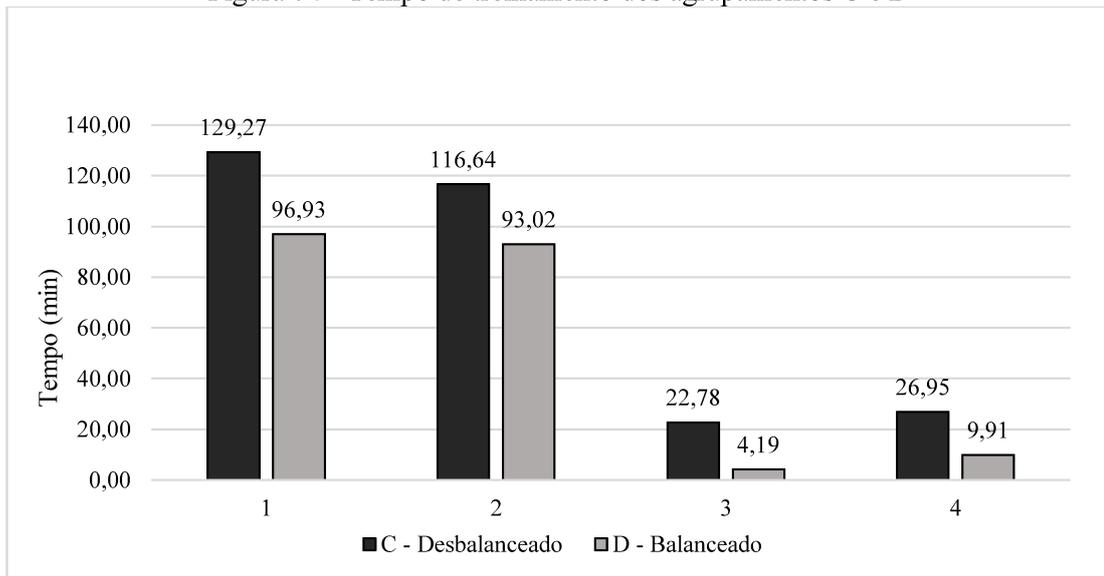
Figura 73 - Acurácia por número de épocas dos agrupamentos balanceados (D)



(a) Acurácia por épocas do grupo D1 (Banco de dados todo); (b) Acurácia por épocas do grupo D2 (Liso); Acurácia por épocas do grupo D3 (Grafiato); Acurácia por épocas do grupo D4 (Chapiscado)

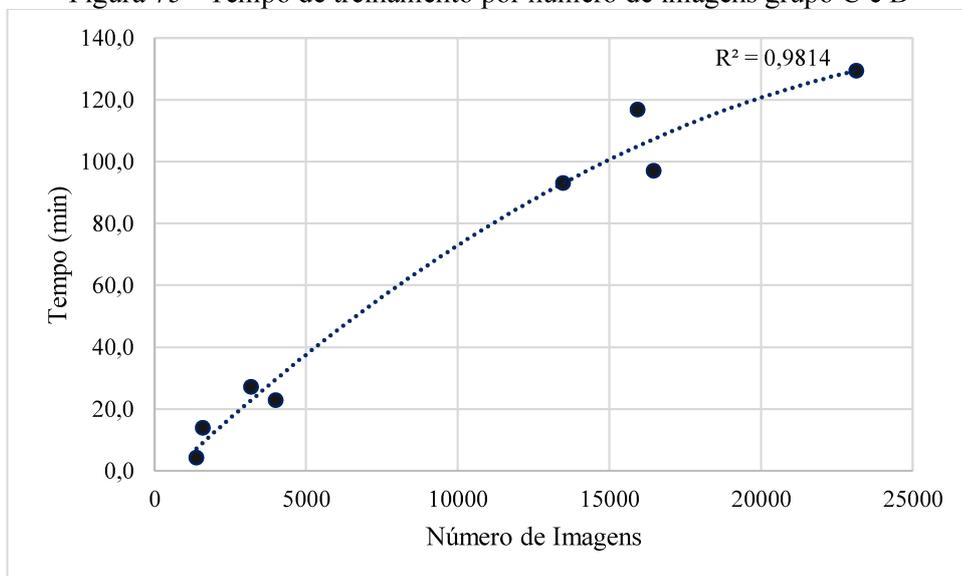
Assim como nos treinamentos iniciais, o tempo de treinamento variou de acordo com a quantidade de dados, isso pode ser observado na Figura 74. Nesse conjunto de dados também foi possível obter ajuste de linha de tendência do tipo polinomial do segundo grau na relação entre tempo de treinamento e número de imagens, com um R^2 de 0,9814 dessa vez. Isso pode ser verificado na Figura 75. Observou-se que os tempos de treinamento dos grupos C e D foram menores do que os do A e B, mesmo que maioria das redes de C e D tenham tido mais que 14 épocas, que foi o padrão aplicado em A e B.

Figura 74 - Tempo de treinamento dos agrupamentos C e D



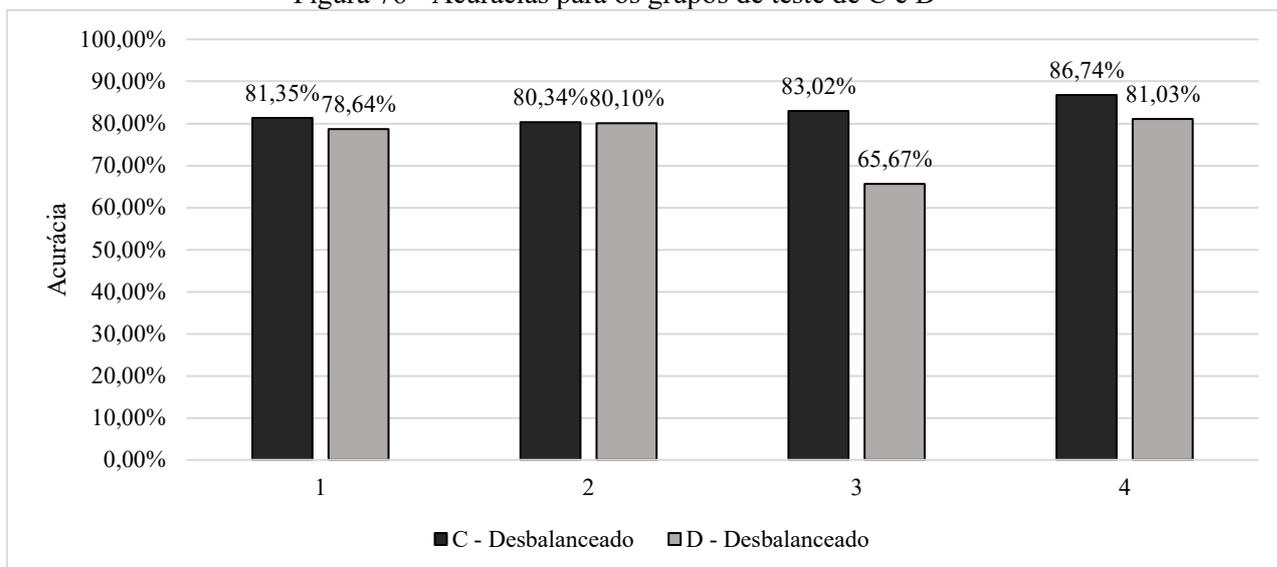
(1) Banco total; (2) Liso; (3) Grafiato; (4) Chapiscado.

Figura 75 - Tempo de treinamento por número de imagens grupo C e D



Na Figura 76 é possível observar a acurácia do grupo de teste para os agrupamentos de C e D.

Figura 76 - Acurácias para os grupos de teste de C e D



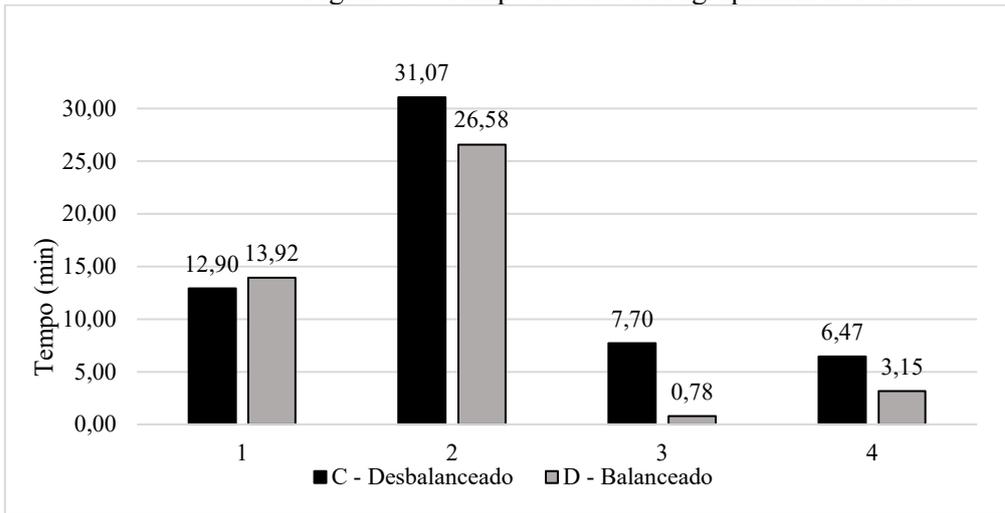
(1) Banco total; (2) Liso; (3) Grafiato; (4) Chapiscado.

Os valores de acurácia para os grupos de teste de C e D foram menores do que os valores da melhor acurácia de validação de A e B. Isso era de se esperar porque nos testes iniciais, com A e B, ocorreu superaprendizagem. Porém, verificou-se que as relações entre os grupos dentro de cada uma das aplicações se mantiveram. As acurácias dos grupos C e D tiveram uma diferença de, aproximadamente 6% para menos em relação a A e B, em quase todos os grupos, com exceção dos grupos B3 e C3 que tiveram uma variação de 14,3% entre eles. Isso mostra que as análises realizadas nos treinamentos iniciais a partir da acurácia de treinamento foram adequadas.

Os grupos C2 e D2 tiveram, praticamente, a mesma acurácia pelo fato do grupo C2 já ser bem balanceado. As acurácias dos grupos C1 e D1 foram próximas dos grupos C2 e D2, provavelmente, pelo revestimento do tipo liso der o com maior quantidade de dados no banco total. O grupo D4 teve o maior valor entre os grupos balanceados. Os grupos dos revestimentos do tipo grafiato (3) e chapiscado (4) tiveram dados diferentes entre os grupos C e D por causa do desbalanceamento de dados do C. O grupo D3 foi o mais desbalanceado.

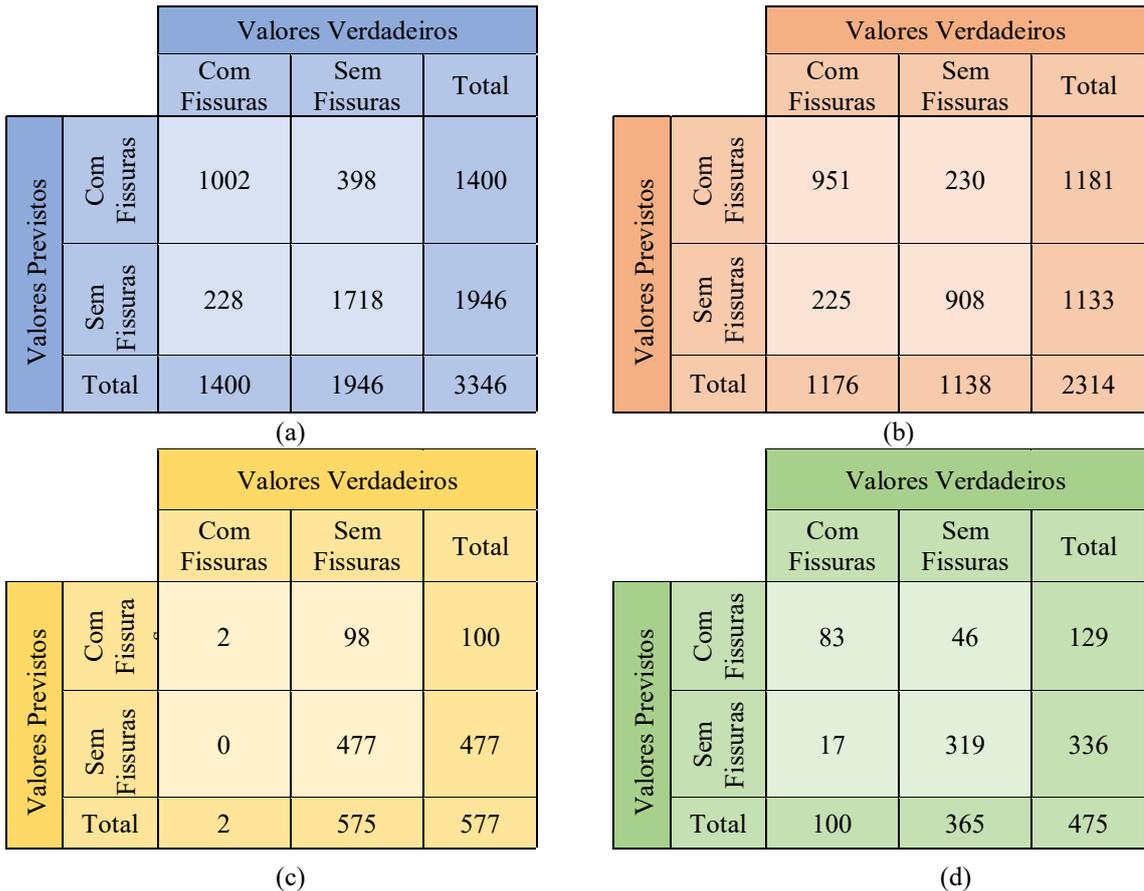
O tempo do processamento grupo de testes não apresentou um padrão, variando muito entre os grupos e não acompanhando o número de dados como aconteceu no tempo de treinamento. Isso pode ser visto na Figura 77.

Figura 77 - Tempo de teste dos agrupamentos C e D



A partir dos dados obtidos até agora, não se teve nada de novo quanto ao que foi identificado nos treinamentos iniciais. Para uma investigação mais detalhada, obteve-se a matriz de confusão do grupo de teste. As matrizes dos agrupamentos desbalanceados (C) podem ser verificadas na Figura 78.

Figura 78 - Matriz confusão do agrupamento desbalanceado (C)



(a) Banco total - 1; (b) Liso - 2; (c) Grafiato - 3; (d) Chapiscado - 4.

Com a matriz de confusão a partir de bancos de dados desbalanceados é mais difícil de verificar se o comportamento entre erros e acertos, isso porque a entre o número de imagens de cada grupo é grande. Porém, foi possível observar que no grupo C3 a rede só conseguiu acertar 2 classificações de fissuras e todas da classe sem fissura. Isso mostra a questão que foi levantada sobre o grupo com classe majoritária interferir na acurácia do treinamento.

Na Figura 79 pode-se observar a matriz de confusão para os grupos balanceados (D).

Figura 79 - Matriz confusão dos agrupamentos balanceados (D)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	944	237	1181
	Sem Fissuras	272	920	1192
	Total	1216	1157	2373

(a)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	789	186	975
	Sem Fissuras	202	773	975
	Total	991	959	1950

(b)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	59	41	100
	Sem Fissura	28	73	101
	Total	87	114	201

(c)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	95	21	116
	Sem Fissuras	23	93	116
	Total	118	114	232

(d)

(a) Banco total - 1; (b) Liso - 2; (c) Grafiato - 3; (d) Chapiscado - 4.

Com os grupos balanceados é possível ter uma sensibilidade maior sobre o desempenho do treinamento, pois, as duas classes estão a mesma escala de dados. Já foi possível perceber que o número de acertos para a classe de fissuras do grupo grafiato melhorou com o balanceamento dos dados. Para realizar uma comparação com maior confiabilidade, obteve-se,

a partir da matriz de confusão, a precisão de cada grupo de dados de acordo com as duas classes analisadas. Os valores das precisões podem ser observados na Tabela 18.

Tabela 18 - Valores de precisão das classes para os agrupamentos C e D

Agrupamentos	Precisão	
	Com Fissuras	Sem Fissuras
C1	71,57%	88,34%
C2	80,05%	80,01%
C3	02,00%	100,00%
C4	64,34%	95,09%
D1	80,01%	77,18%
D2	80,92%	79,28%
D3	59,00%	72,28%
D4	81,90%	80,17%

Verificou-se diferenças entre as precisões das classes nos grupos desbalanceados. O caso do grafiato (C3) foi o mais crítico, com uma precisão de 2% para a classe com fissuras e de 100% para a com fissuras. No caso de C4, a diferença entre as precisões também foi grande, sendo de 30,75% entre as duas classes. Nesse caso, a rede também aceitou majoritariamente a categoria sem fissuras. Os valores de precisão confirmaram as hipóteses levantadas sobre os bons desempenhos de acurácia dos grupos C3 e C4 em relação aos D3 e D4 serem por conta do desbalanceamento dos dados. O grupo C1 também teve variação entre a precisão das categorias, porém, em quantidade menor do que C4 e C3, valor de 16,77%. O grupo C2 teve o mesmo resultado de precisão entre as duas classes, de 80%. Isso confirma o fato de que o banco já estava bem balanceado e pode indicar que relações entre as quantidades de imagens das classes com R_m acima de 0,95 são bons indicadores quanto a esse fator.

Nos grupos balanceados (D), os resultados foram bem melhores. Todos apresentaram precisões próximas, com exceção do grupo D3. Porém, ainda assim o grupo relacionado com o grafiato teve um melhor desempenho tendo uma precisão de 59% para a classe com fissuras. Valores próximos de 50% ainda não são adequados para garantir que a rede está conseguindo classificar, mas já é um resultado mais adequado que 2%.

Tendo em vista os resultados obtidos, os próximos treinamentos só foram realizados para os grupos balanceados. Devido à similaridade dos resultados entre os grupos com o banco de dados total (1) e só o acabamento liso (2), não foram realizados mais experimentos utilizando o banco todo. Isso porque não é possível controlar o equilíbrio interno no banco todo em relação aos tipos de acabamento superficial e, também, os treinamentos utilizando o banco todo resultavam em um custo computacional alto.

A próxima etapa foram os treinamentos com os bancos que foram denominados de bancos de dados expandidos. Nessa parte, todas as imagens que foram removidas no processo de

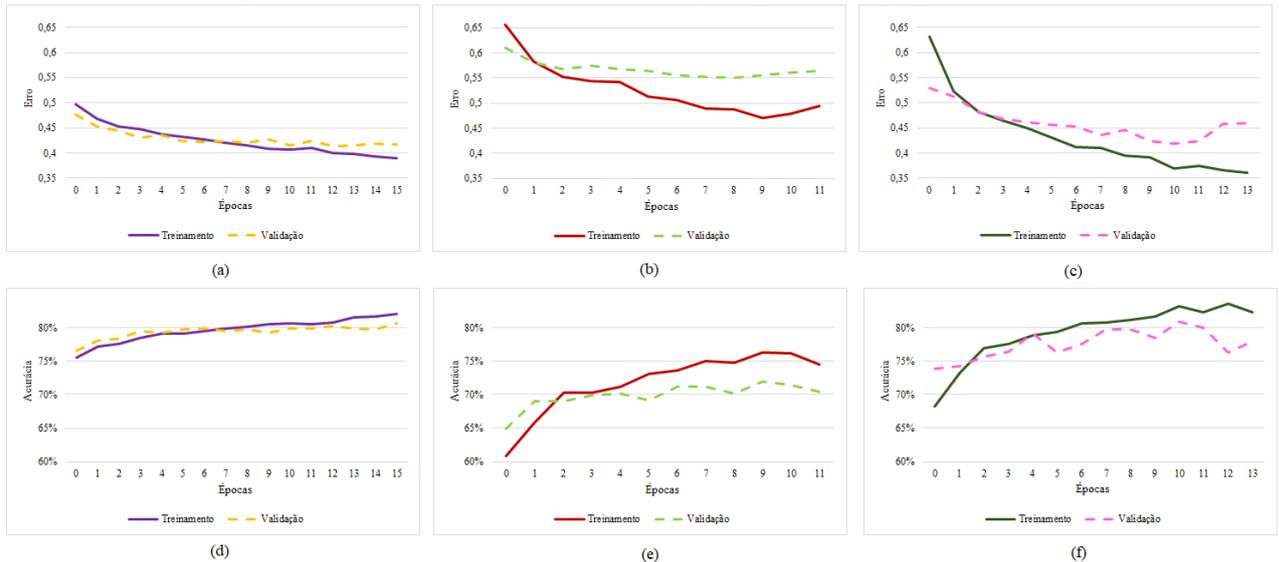
balanceamento a partir da classe minoritária foram adicionadas no grupo de teste. O foco foi verificar se a rede, mesmo treinada com o banco de dados reduzida, consegue manter os resultados para o banco todo. Na Tabela 19 é possível verificar a distribuição das imagens nessa abordagem. Os bancos de dados com teste expandido foram identificados com a letra D+.

Tabela 19 - Divisão dos dados para os bancos de dados com o teste expandido

Agrupamentos	Com Fissuras	Sem Fissuras	$R_m = \frac{M -}{M +}$	Total	Treinamento (70%)	Validação (20%)	Teste +
Grupo D2+	9636	9621	0,998	19257	13471	3836	3538
Grupo D3+	985	990	0,995	1975	1381	393	3749
Grupo D4+	1140	1145	0,996	2285	1598	455	2284

As curvas do erro e da acurácia foram próximas das dos bancos do agrupamento D, o que é o ideal tendo em vista que grupos de treinamento e validação entre o D e o D+ foram os mesmos. Na Figura 80 é possível observar as curvas de treinamento.

Figura 80 - Curvas do erro e da acurácia por épocas dos grupos D+



(a) Erro por épocas do grupo D2+; (b) Erro por época do grupo D3+; (c) Erro por época do grupo D4+; (d) Acurácia por época do grupo D2+; (e) Acurácia por época do grupo D3+; (f) acurácia por época do grupo D4+

Na Figura 81 é possível observar a matriz de confusão para os agrupamentos D+ e na Figura 82 os valores de acurácia para os grupos D e D+.

Figura 81 - Matriz de confusão dos grupos D+

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	128	35	163
	Sem Fissuras	610	2765	3375
	Total	738	2800	3538

(a)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	60	35	95
	Sem Fissuras	991	2663	3654
	Total	1051	2698	3749

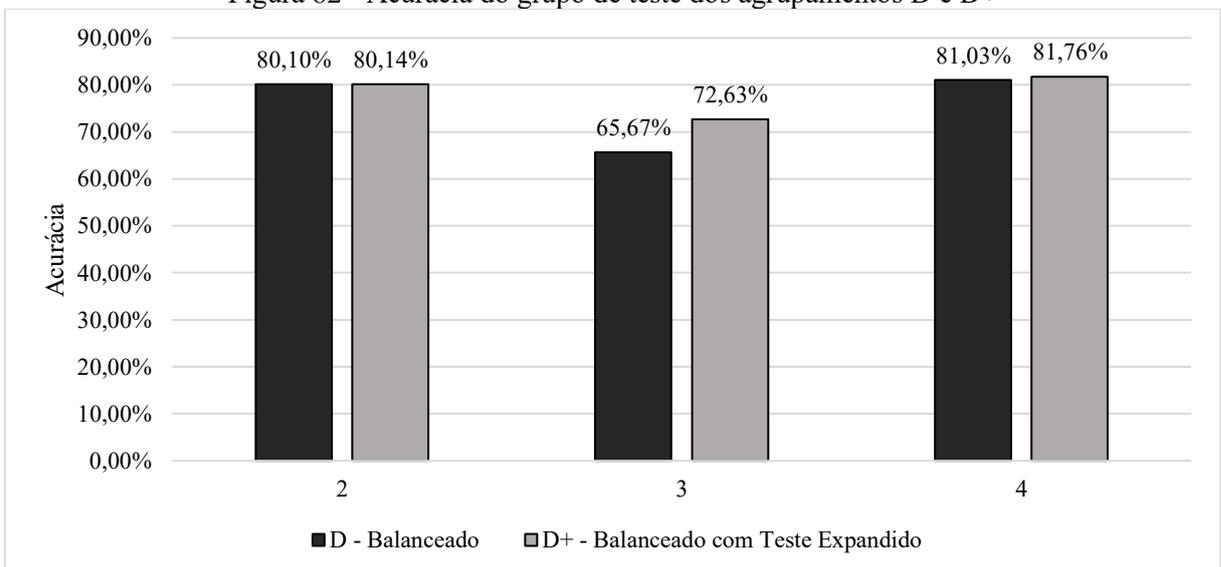
(b)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	83	23	106
	Sem Fissuras	394	1785	2179
	Total	477	1808	2285

(c)

(a) Liso - 2; (b) Grafiato - 3; (c) Chapiscado - 4.

Figura 82 - Acurácia do grupo de teste dos agrupamentos D e D+



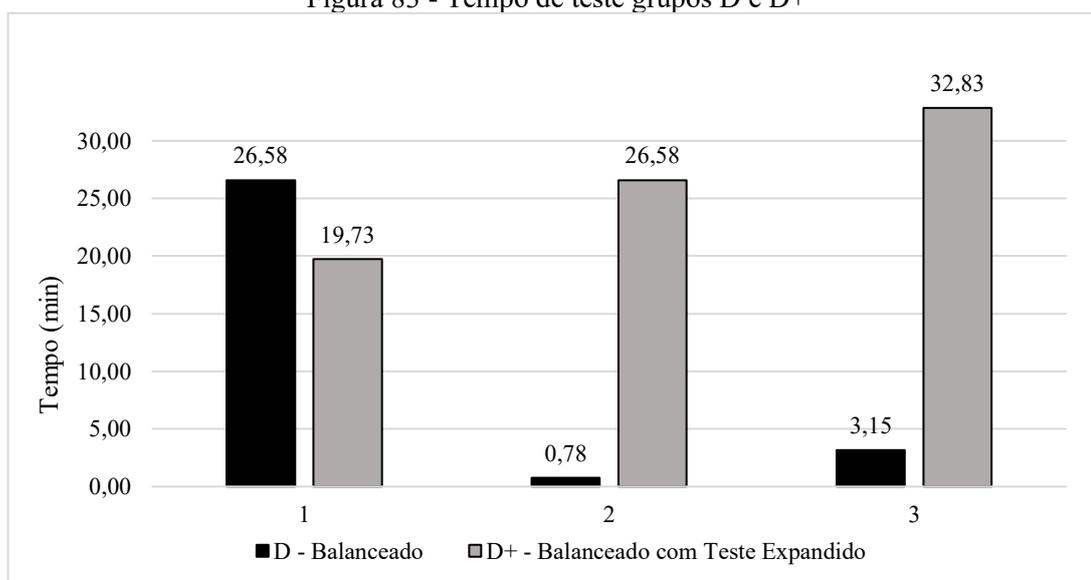
As acurácias entre os agrupamentos D e D+ foram praticamente as mesmas, com exceção do grupo do grafiato (3) que teve um aumento de 6,96% para o grupo D3+ em relação ao D3. Os resultados de precisão por classe dos grupos com testes expandidos podem ser verificados na Tabela 21.

Tabela 20 - Precisão por classe para os grupos D+

Agrupamentos	Precisão	
	Com Fissuras	Sem Fissuras
D2+	80,88%	79,18%
D3+	63,00%	72,88%
D4+	78,84%	81,92%

Verificou-se que os valores de precisão não variaram muito entre as abordagens D e D+. Desse modo, o treinamento com o grupo de teste de 10% representou com eficiência os dados que aviam sido removidos no processo de balanceamento. Na Figura 83 pode-se ver o tempo de execução do teste. Tendo em vista o consumo computacional e o esforço que demandou para organizar os grupos de teste expandido, verificou-se que não compensa utilizar essa abordagem e que é mais vantajoso, operacionalmente, utilizar os 10%.

Figura 83 - Tempo de teste grupos D e D+



Os últimos agrupamentos realizados na classificação binária foram removendo o ruído e as imagens de fissurações com baixa visibilidades. Eles foram identificados, respectivamente, com as letras E e F. Os treinamentos para esses experimentos foram aplicados somente para os acabamentos superficiais agrupados separadamente. Na Tabela 22 é possível observar a quantidade de dados de cada grupo.

Tabela 21 - Divisão dos dados para os bancos de dados E e F

Agrupamentos	Com Fissuras	Sem Fissuras	$R_m = \frac{M -}{M +}$	Total	Treinamento (70%)	Validação (20%)	Teste (30%)
Grupo E2	7447	7462	0,998	14909	10429	2968	1512
Grupo E3	675	679	0,994	1354	945	272	137
Grupo E4	771	776	0,993	1547	1082	309	156
Grupo F2	6110	6255	0,9768	12365	8616	2496	1253
Grupo F3	430	432	0,995	862	601	171	90
Grupo F4	885	895	0,989	1780	1238	362	180

Em todos os grupos, a relação ficou acima de 0,95. Na Figura 84 e 85 segue as curvas do erro e da acurácia por épocas para os grupos E e F, respectivamente. Na Figura 86 tem-se os valores das acurácias do grupo de teste para os conjunto D, E e F.

Figura 84 - Erro e Acurácia por época para os grupos E

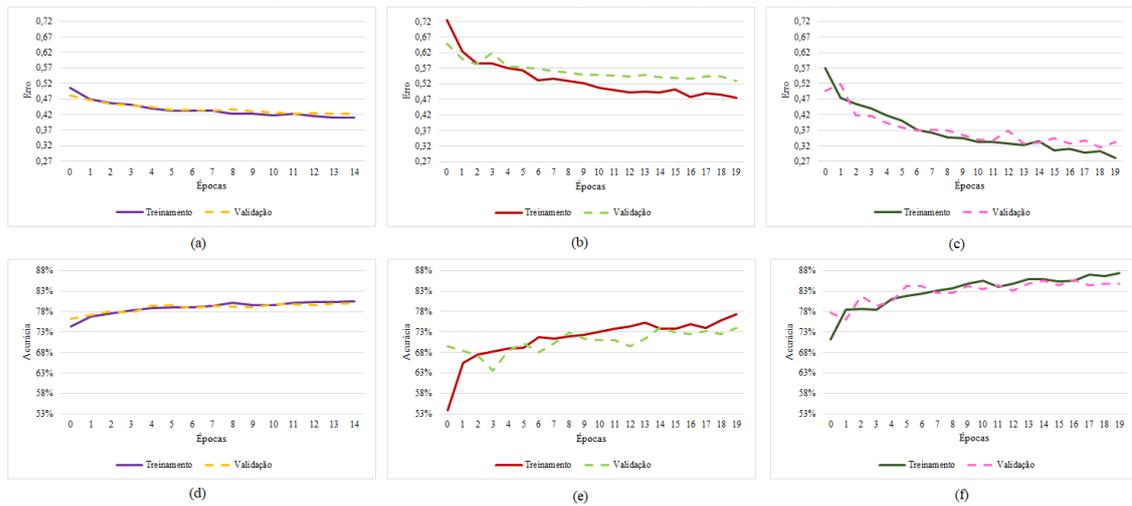


Figura 85 - Erro e Acurácia por época para os grupos F

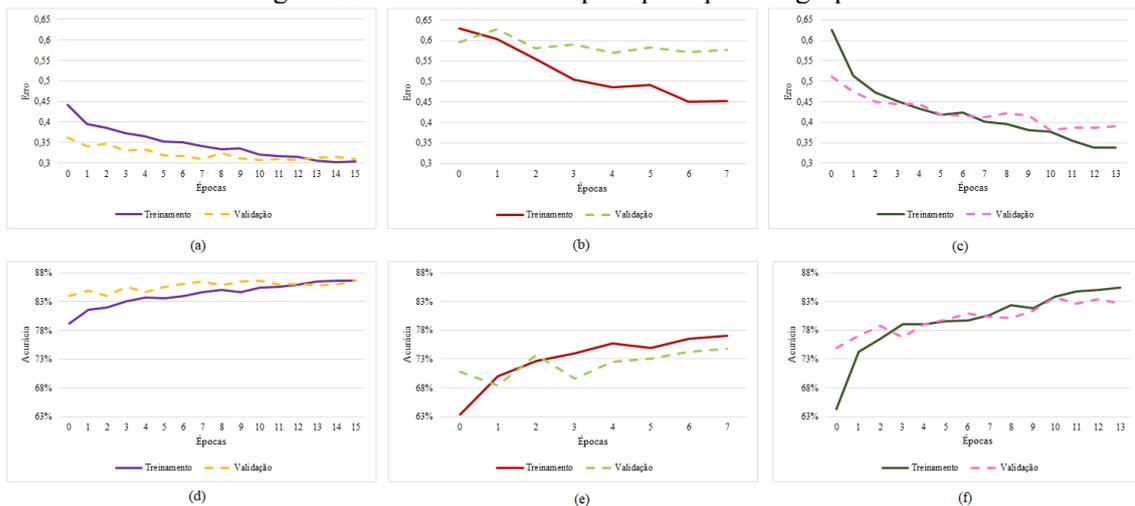
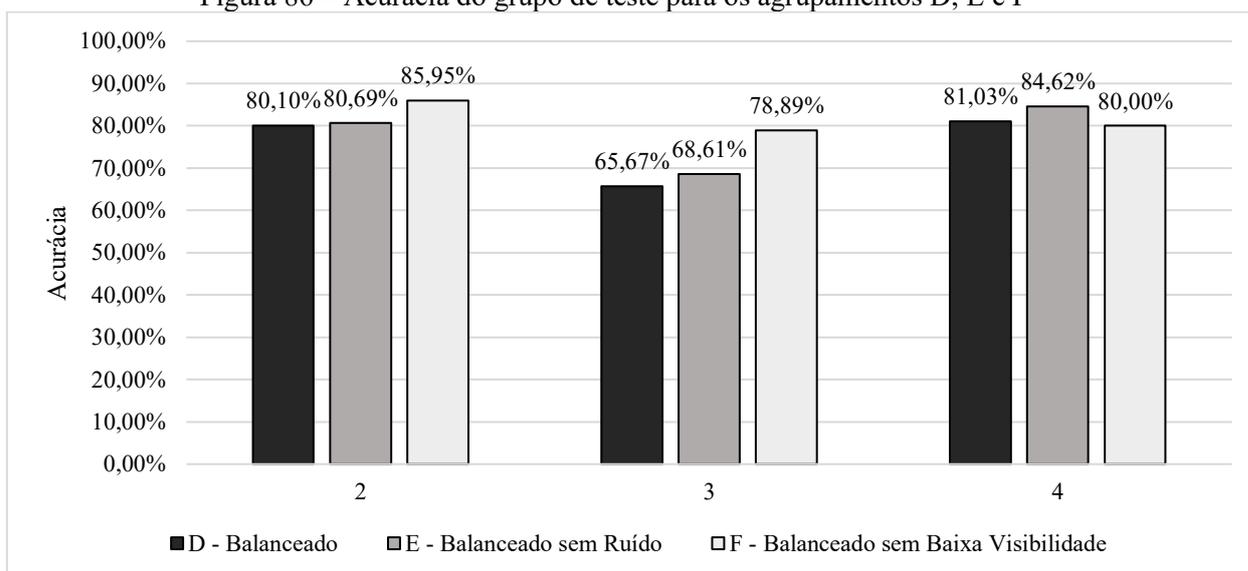


Figura 86 – Acurácia do grupo de teste para os agrupamentos D, E e F



Foi possível observar uma melhora geral com a remoção do ruído e das imagens com baixa viabilidade. Nos grupos com o acabamento do tipo liso, remover o ruído não fez muita diferença. No caso das imagens de baixa visibilidade de fissuras, retirá-las do banco aumentou a acurácia em 5,85%.

A remoção das imagens com baixa visibilidade no chapiscado não teve tanta influência. A acurácia do F4 foi um pouco menor do que a do D4. Com a remoção do ruído, melhorou o desempenho em 3,59% no acabamento do tipo chapiscado.

O grafiato foi que teve uma mudança mais significativa. O acabamento teve uma melhora de 2,94% entre os grupos D3 e F3. No caso do D3 para o F3 a melhora foi de 13,22%. Com a remoção das imagens com baixa visibilidade o grupo contendo só o grafiato conseguiu atingir uma acurácia de 78,89%, o melhor resultado para esse tipo de acabamento e um valor bem próximo dos resultados para o revestimento do tipo liso e chapiscado.

No caso, foi possível verificar que as imagens que foram rotuladas como tendo baixa visibilidade na visualização das fissurações foram as que mais influenciaram no desempenho da classificação do acabamento do tipo grafiato. Nas Figuras 87 e 88 é possível verificar as matrizes para os agrupamentos E e F, respectivamente. Na Tabela 23 a precisão para os grupos E e F.

Figura 87 - Matriz de confusão dos grupos E

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	584	172	756
	Sem Fissuras	120	636	756
	Total	704	808	1512

(a)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	44	24	68
	Sem Fissuras	19	50	69
	Total	63	74	137

(b)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	65	13	76
	Sem Fissuras	11	67	78
	Total	76	80	156

(c)

Figura 88 - Matriz de confusão dos grupos F

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	535	90	625
	Sem Fissuras	86	542	628
	Total	621	632	1253

(a)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	33	12	45
	Sem Fissuras	7	38	45
	Total	40	50	90

(b)

		Valores Verdadeiros		
		Com Fissuras	Sem Fissuras	Total
Valores Previstos	Com Fissuras	78	12	90
	Sem Fissuras	24	66	90
	Total	102	78	180

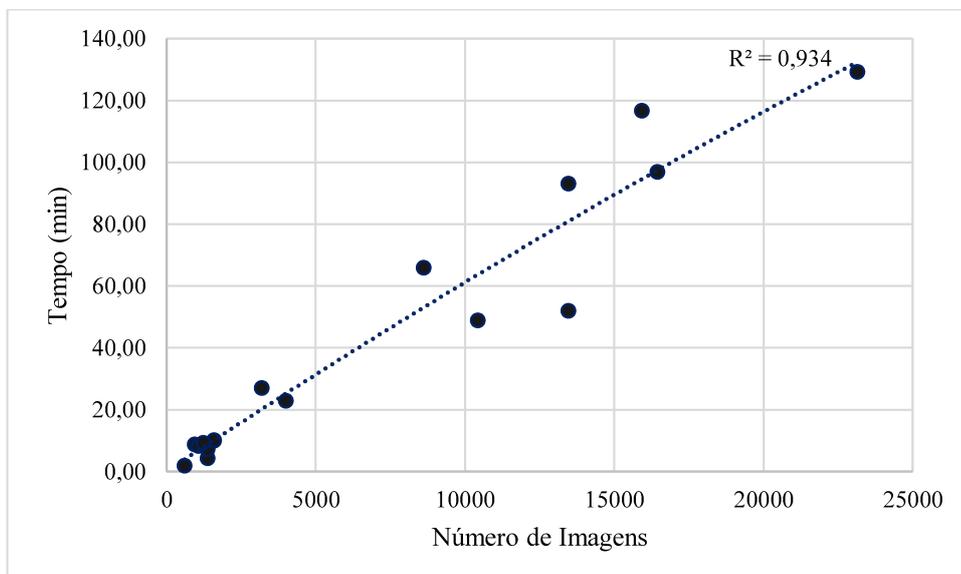
(c)

Tabela 22 - Precisão por classe para os grupos E e F

Agrupamentos	Precisão	
	Com Fissuras	Sem Fissuras
D2	80,92%	79,28%
D3	59,00%	72,28%
D4	81,90%	80,17%
E2	77,25%	84,13%
E3	64,71%	72,46%
E4	83,33%	85,90%
F2	85,60%	86,31%
F3	73,33%	84,44%
F4	86,67%	73,33%

O principal ponto de melhora é no grupo do grafiato. A precisão da classe com fissuras vai de 59% de D3 para 73,33% F3. Foi possível observar em tudo que foi levantado que o tipo de acabamento influencia sim na assertividade da rede. No caso, o revestimento com menor desempenho na classificação foi o grafiato. O revestimento liso e o chapiscado apresentaram valores próximos entre eles ao longo dos experimentos. Sendo assim, trabalhar com a melhora do grafiato já indicaria uma otimização geral em aplicações considerando os tipos de acabamento superficiais empregados. Plotando todos os tempos de treinamento de todos as abordagens realizadas, considerando dos grupos C ao F, foi possível de se obter o gráfico da Figura 89.

Figura 89 - Gráfico de tempo por número de imagens de todos os grupos



4.1.6 Treinamento multi-classe

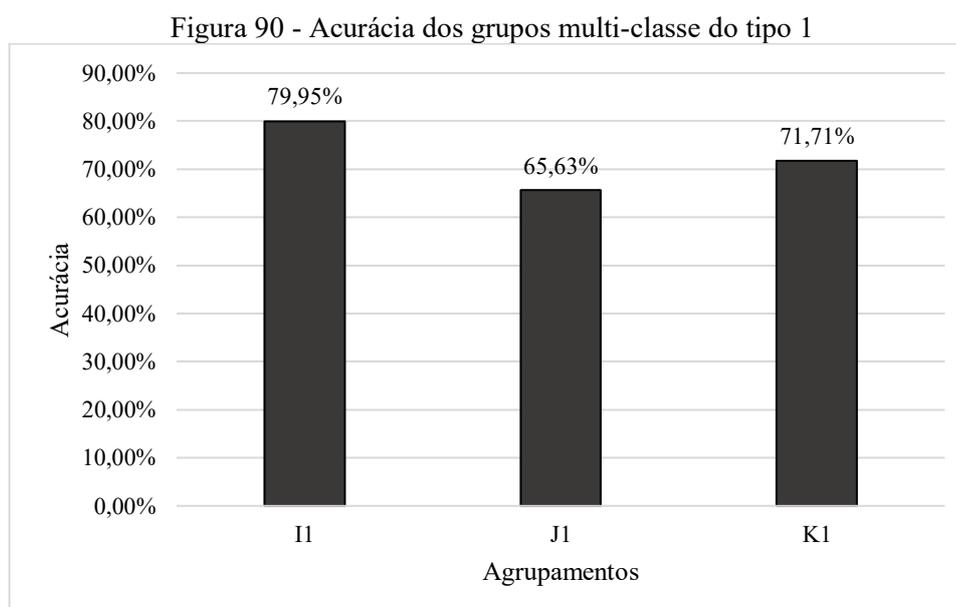
As curvas de acurácia e erro por épocas para todos os grupos da classificação multi-classe apresentaram o comportamento adequado com a acurácia de treinamento e validação aumentando na medida que o erro diminui o que indica que não teve overfitting nesse processo.

Na primeira configuração da classificação multi-classe, as categorias foram definidas dividindo por tipo de acabamento superficial e pela presença ou não de fissurações totalizando 6 classes, conforme o Quadro 5.

O primeiro grupo foi utilizando o banco de dados todo que resulto em um banco de dados desbalanceado entre as classes. Ele foi identificado como I1.

No segundo grupo, as classes foram balanceadas de acordo com classe minoritária. No caso, essa classe era de grafiato com fissuras com 624 imagens. Sendo assim, todas as outras classes foram reduzidas para esse valor. Esse agrupamento foi identificado como J1.

No terceiro, foi realizado o mesmo procedimento, porém, com o banco de dados sem as imagens rotuladas como de baixa visibilidade. Nesse caso, todas as classes foram reduzidas para 390 imagens. Os resultados das acurácias obtidas pela abordagem multi-classe podem ser verificados na Figura 90.



(I) Desbalanceado; (J) Balanceado; (K) Balanceado sem as imagens com baixa visibilidade de fissuras

Verificou-se que o grupo desbalanceado, I1, foi o de maior acurácia. O J1 foi o com menor valor. Para observar como a rede está classificando classe individualmente, verificou-se a precisão individual por classe conforme pode ser observado na

Tabela 23 - Precisão por classe do Tipo 1

	Chapiscado com fissuras	Chapiscado sem fissuras	Grafiato com fissuras	Grafiato sem fissuras	Liso com fissuras	Liso sem fissuras
Grupos	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6
I1	70,59%	87,28%	19,00%	96,02%	81,71%	75,46%
J1	64,06%	73,44%	60,94%	67,19%	62,50%	65,62%
K1	70,00%	77,50%	62,50%	80,00%	67,50%	70,00%

Observa-se que, no grupo I1 o maior problema continua sendo classificar as imagens com fissuras no grafiato. Os valores das precisões das classes são condizentes com as obtidas nas classificações binárias com os acabamentos superficiais separados que podem ser vistas na Tabela 18.

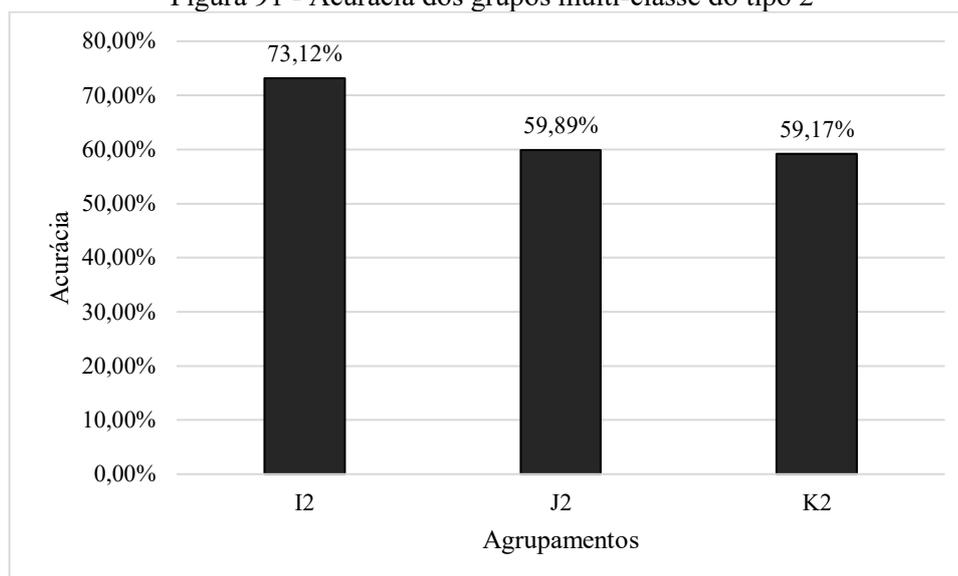
No grupo J1 tem-se a melhora da precisão da Classe 3, porém, uma redução significativa na maioria das outras classes. No caso do K1, a precisão da classe 3 teve o mesmo rendimento que o grupo J1, mas com melhores resultando também nas outras classes.

Tendo em vistos bons resultados do grupo I1 e a perda de precisão em comparação ao J1 e o K1, pode ser interessante realizar uma abordagem de multi-classe com o banco desbalanceado, porém, com ferramentas para esse tipo de configuração de dados. Essa abordagem é realizada por (GUO (A), WANG, *et al.*, 2020) em uma classificação multi-classe de defeito em fachadas.

A segunda abordagem de multi-classe abordada seguiu a mesma estrutura da primeira, porém, as classes foram divididas entre os acabamentos superficiais, a presença do ruído e a presença de fissura. No total, teve-se 12 classes que foram identificadas conforme o Quadro 6.

O agrupamento desbalanceado foi identificado por I2. O grupo balanceado ficou com 312 imagens em cada classe e foi identificado como J2. No grupo balanceado sem imagens de baixa visibilidades, cada classe teve 195 imagens. Ele foi nomeado de K2. Na Figura 91 pode-se observar os resultados de acurácia dos grupos.

Figura 91 - Acurácia dos grupos multi-classe do tipo 2



(I) Desbalanceado; (J) Balanceado; (K) Balanceado sem as imagens com baixa visibilidade de fissuras

Observou-se uma queda grande da acurácia. Os grupos J2 e K2 não chegaram nem a 60%. Na Tabela 25 é possível verifica a precisão por classe nos grupos.

Tabela 24 - Precisão por classe do Tipo 2

	Classes											
	1	2	3	4	5	6	7	8	9	10	11	12
I2	39,47	57,89	79,01	83,33	34,38	54,65	17,65	94,12	73,65	44,20	81,35	70,52
J2	59,38	71,88	75,00	75,00	59,38	28,12	84,38	43,75	62,50	50,00	65,62	43,75
K2	55,00	45,00	70,00	85,00	65,00	60,00	95,00	25,00	50,00	35,00	55,00	75,00

Foi possível verificar que a abordagem adotada no tipo 2 não é adequada. O fato é que a presença de ruído na imagem não causa diferenças significativas para a divisão de classes. Outro ponto é que, bala o balanceamento a partir da classe minoritária, o banco de dados foi muito reduzido.

CAPÍTULO 5 - CONCLUSÃO

Com o estudo desenvolvido, foi possível verificar questões que ainda não haviam sido abordadas na literatura, como a influência do acabamento superficial do revestimento argamassado na classificação de imagens com fissuras. Utilizou-se a aplicação de transferência de aprendizagem por meio da VGG16 para isso.

Um banco de dados inédito foi montado e será disponibilizado para realização de novas pesquisas. Por meio da codificação, é possível realizar diferentes agrupamentos das imagens em relação a presença de ruído, aos tipos de acabamento superficial, a presença de fissuras e ao nível de visibilidade das descontinuidades.

Além disso, o banco pode passar por outros processos de rotulações como em relação as manifestações patológicas encontradas ou a configuração das trincas.

A hipótese da tese foi confirmada como verdadeira, ou seja, o tipo de acabamento superficial influencia sim no desempenho de treinamento de redes neurais convolucionais.

O acabamento mais problemático foi o do tipo grafiato. Foi possível verificar uma dificuldade em classificar corretamente a presença de fissurações nesse tipo de acabamento. A acurácia nos treinamentos binários foi de 65,67% no grupo balanceado. Seu melhor resultado foi com a remoção das imagens de baixa visibilidade, na qual a acurácia chegou a 78,98%. Porém, não é plausível utilizar como critério essa abordagem, pois, a rede é o mesmo que eliminar parte dos problemas reais que podem surgir em um processo de classificação.

Tendo em visto as informações que foram detectadas nesse estudo, um dos passos de avanço seria estabelecer métodos que conseguissem extrair essas fissuras das imagens com baixa visibilidade, de modo geral, ou utilizar ferramentas de solucionam as dúvidas nesse tipo de imagem. Pode ser possível, por exemplo, aplicar técnicas de PDI.

Os acabamentos do tipo chapiscado e liso tiveram valores próximos, dessa maneira, verifica-se que melhorar a acurácia e a precisão do grafiato já ajudaria a otimizar a abordagem de classificar imagens com e sem fissurações em diferentes tipos de acabamentos de revestimento argamassados. A acurácia do revestimento do tipo liso foi de 80,10% e do chapiscado de 81,03%, no caso dos grupos balanceados.

A classificação multi-classe desbalanceada teve resultados das precisões das classes só teve problemas com classificação das fissuras no acabamento do tipo grafiato. Desse modo, é uma abordagem interessante se for solucionada essa questão. Um ponto pode ser a aplicação de implementações para treinamentos com bancos desbalanceados. Outro ponto importante dessa abordagem é que, em uma classificação real, a ideia de ter que separar imagens por tipo de

acabamento não parece atender a ideia de inovação que é trazida pela IA aplicada na engenharia civil.

Sendo assim, a pesquisa teve um resultado importantes para a comunidade científica podendo ser aplicada no desenvolvimento da visão computacional sobre defeitos em revestimento argamassado.

Em relação aos outros estudos de redes profundas em problemas de classificação em revestimento argamassado, essa tese se destaca por analisar os diferentes acabamentos superficiais de maneira separada e conjunto, o que não tinha sido abordado ainda na bibliografia.

Dessa maneira, tem-se um avanço a mais para melhoria da aplicação de IA na indústria da construção civil, o que é necessário para otimizar processos no setor em vista da Indústria 4.0.

Com o presente trabalho espera-se motivar os pesquisadores de visão computacional e IA aplicada a imagens a divulgarem os bancos de dados elaborados em seus estudos. Desse modo, é possível que a comunidade científica tenha acesso a problemas mais específicos, que não são encontrados nos bancos de dados públicos atuais.

5.1 TRABALHO FUTUROS

A partir do que foi investigado, recomenda-se os seguintes temas para trabalhos futuros:

- Investigar as melhores técnicas de PDI para extrair fissurações de revestimento de fachadas para aplicações de IA com imagens;
- Utilizar técnicas de treinamento com bancos de dados desbalanceados considerando a presença das fissurações e os tipos de acabamentos superficiais como um problema multi-classe;
- Utilizar o banco elaborado para aplicações de aprendizagem não-supervisionada e comparar com a rotulação realizada;
- Realizar treinamentos com diferentes redes pré-treinadas a partir do bando de dados proposto e investigar de maneira qualitativa e utilizando técnicas de PDI as imagens classificadas como falso positivo e negativo com o banco de dados proposto.

5.2 PRODUTOS E PUBLICAÇÕES GERADAS

- Artigo aceito para publicação na revista *Buildings*: “Elaboration of a new public database of cracks images in mortar coating with different types of surface finishes.”
- Banco de dados disponível no artigo acima.

REFERÊNCIAS

- ABM, Associação Brasileira de Metais. Ensaios não Destrutivos. São Paulo: ABM, 1981.
- ABM, Associação Brasileira de Metais. Análise de Fratura. São Paulo: Édile, 1988.
- ABNT NBR 13749, Associação Brasileira de Normas Técnicas. **Revestimento de paredes e tetos de argamassas inorgânicas - Especificação**. Rio de Janeiro. 2013.
- ABNT NBR 15575-1, Associação Brasileira de Normas Técnicas. **Edificações Habitacionais - Desempenho - Parte 1: Requisitos Gerais**. Rio de Janeiro. 2021.
- ABNT NBR 15575-4, Associação B. D. N. T. **ABNT NBR 15571-4: Edificações habitacionais - Desempenho - Parte 4: Requisitos para os sistemas de vedações verticais internas e externas - SVVIE**. Rio de Janeiro. 2021.
- ABNT NBR ISO 5492, Associação B. D. N. T. **ABNT NBR ISO 5492: Análise Sensorial - Vocabulário**. [S.I.]. 2017.
- ABUBAKR, M. et al. Application of deep learning in damage classification of reinforced concrete bridges. **Ain Shams Engineering Journal**, May 2023.
- ACI, American Concrete Institute. ACEI Manual of Concrete Inspection. 5ª. ed. Detroit: ACI Publication SP-2, 1973.
- AHMED, I.; JENOS, G.; PICCIALI, F. From artificial intelligence to explainable artificial intelligence in Industry 4.0: A survey on what, how, and where. **IEEE Transactions on Industrial Informatics**, v. 18, p. 5031-5042, aug. 2022. <https://doi.org/10.1109/TII.2022.3146552>
- ALI, L. et al. Performance evaluation on deep CNN-Based crack detection and localization techniques of concrete structures. **Sensors**, v. 21, 2021. <https://doi.org/10.3390/s21051688>
- ANDERSON, T. L. Fracture Mechanics. 3ª. ed. Boca Raton: CRC Press, 2005.
- ARAFIN, P.; BILLAH, A. M.; ISSA, A. Deep learning-based concrete defects classification and detection using semantic segmentation. **Structural Health Monitoring**, may 2023. <https://doi.org/10.1177/14759217231168212>
- ARAFIN, P.; ISSA, A.; BILLAH, A. H. M. M. Performance Comparison of Multiple Convolutional Neural Networks for Concrete Defects Classification. **Sensors**, v. 22, 2022. <https://doi.org/10.3390/s22228714>
- ASHBY, M. F.; JONES, D. R. H. Engenharia de Materiais. Rio de Janeiro: Elsevier, v. 2, 2007. Cap. 2ª.
- ASKELAND, D. R.; PHULÉ, P. P. Ciência e Engenharia dos Materiais. 1ª. ed. São Paulo: Cengage Learning, 2008.
- ASKELAND, D. R.; WRIGHT, W. J. Ciência e engenharia dos materiais. 3ª. ed. São Paulo: Cengage Learning, 2016.
- AZEVEDO, H. A. In: _____ **O Edifício e seu Acabamento: Prática de Construção Civil**. 5ª. ed. Boca Raton: CRC Press, 2007.
- BAUER, E. Revestimentos de Argamassa: Características e Peculiaridades. Brasília: LEM-UnB, 2005.
- BAUER, L. A. F. Materiais de Construção Civil. 5ª. ed. Rio de Janeiro: LTC, 2008.

BERTOLINI, L. *Materiais de construção: patologia, reabilitação, prevenção*. São Paulo: Oficina de Texto, 2010.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. *Redes Neurais Artificiais: Teoria e aplicações*. Rio de Janeiro: LTC, 2000.

BRIEN, D. O. et al. Automated crack classification for the CERN underground tunnel infrastructure using deep learning. **Tunnelling and Underground Space Technology**, v. 131, Jan. 2023. <https://doi.org/10.1016/j.tust.2022.104668>

BRITO, L. C. **Explainable artificial intelligence approaches for fault diagnosis in rotating machinery**. Tese (Doutorado em Engenharia Mecânica), Pós-Graduação em Engenharia Mecânica, Universidade de Uberlândia. Uberlândia, p. 177. 2022.

BROEK, D. *Elementary engineering fracture mechanics*. 4ª. ed. Norwell: Springer, 1982. <https://doi.org/10.1007/978-94-009-4333-9>

BUBRYUR, K. et al. Surface crack detection using deep learning with shallow CNN architecture for enhanced computation. **Neural computing & applications**, v. 33, 2021. <https://doi.org/10.1007/s00521-021-05690-8>

BURKHEAD, V. **Unsplash**, 2023. Disponível em: <<https://unsplash.com/pt-br/fotografias/LhlxYMfnTF0>>. Acesso em: 02 maio 2023.

CALLISTER JUNIOR, W. D.; RETHWISCH, D. G. *Ciência e engenharia de materiais: uma introdução*. 8ª. ed. Rio de Janeiro: LTC, 2016.

CHAIYSARN, K. et al. Integrate pixel-level CNN-FCN crack detection via photogrammetric 3D texture mapping of concrete structures. **Automation in Construction**, v. 140, 2022. <https://doi.org/10.1016/j.autcon.2022.104388>

CHAN, D. W. M. Sustainable building maintenance for safer and healthier cities: Effectives strategies for implementing the Mandatory Building Inspection Scheme (MBIS) in Hong Kong. **Journal of Building Engineering**, v. 24, jul. 2019. <https://doi.org/10.1016/j.jobe.2019.100737>

CHAVES, E, et al. Evaluaton of transfer learning of pre-trained CNNs applied to drest detection on infrared images. **Applied Optics**, v. 142, 2022.

CHEN, K. et al. Automated crack segmentation in close-range building façade inspection images using deep learning techniques. **Journal of Building Engineering**, v. 43, Nov. 2021. <https://doi.org/10.1016/j.jobe.2021.102913>

CHEN, L. et al. Convolutional neural networks (CNNs)-based multi-category damage detection and recognition of high-speed rail (HSR) reinforced concrete (RC) bridges using test images. **Engineering Structures**, v. 276, Feb. 2023. <https://doi.org/10.1016/j.engstruct.2022.115306>

CHOLLET, F. *Deep Learning with Python*. 2ª. ed. New York: Manning, 2021.

CHOW, J. K. et al. Artificial intelligence-empowered pipeline for image-based inspection of concrete structures. **Automation in Construction**, v. 21, 2020. <https://doi.org/10.1016/j.autcon.2020.103372>

COELHO, H. *Inteligência Artificial em 25 Lições*. Lisboa: Fundação Calouste Gulouste, 1994.

COPPIN, B. *Inteligência Artificial*. Rio de Janeiro: [s.n.], 2013.

DAIS, D. et al. Automatic crack classification and segmentation on masonry surfaces using convolutional neural networks and transfer learning. **Automation in Construction**, v. 125, may 2021. <https://doi.org/10.1016/j.autcon.2021.103606>

DINIZ, C. **Três Décadas de Mudanças na Planície Costeira Brasileira: O Status Dos Manguezais, da Aquicultura e Salicultura a Partir de Séries Temporais Landsat e Técnicas de Aprendizado de Máquina**. Tese (Doutorado em Geologia), Programa de Pós-graduação em Geologia e Geoquímica, Universidade Federal do Pará. Belém. 2021.

DSA. Deep Learning Book, 2023. Disponível em: <<https://www.deeplearningbook.com.br/>>. Acesso em: 26 mai 2023.

DSML, Data Science & Machine Learning. Perceptron, 2023. Disponível em: <<https://ttr.gitbook.io/data-science/neural-network/perceptron>>. Acesso em: 06 mai 2021.

DUNG, C. V.; ANH, L. D. Autonomous concrete crack detection using deep fully convolutional neural network. **Automation in Construction**, v. 99, 2019. <https://doi.org/10.1016/j.autcon.2018.11.028>

EDIS, E.; COLEN, I. F.; BRITO, J. Passive thermographic of moisture problems in façades with adhered ceramic cladding. **Construction and Building Materials**, v. 51, n. 31, 2014. <https://doi.org/10.1016/j.conbuildmat.2013.10.085>

FACELI, K. et al. Inteligência Artificial: Uma abordagem de aprendizado de máquina. 2ª. ed. Rio de Janeiro: LTC, 2021.

FERREIRA, M. D. C. **Análise inversa utilizando o método dos elementos de contorno e correlação de imagens**. Tese (Doutorado em Engenharia de Estruturas), Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, p. 171. 2012.

FIORITO, A. J. S. Manual de Argamassa e Revestimentos: Estudos e procedimento de execução. São Paulo: Pini, 1930.

FLAH, M.; SULEIMAN, A. R.; NEHDI, M. L. Classification and quantification of cracks in concrete structures using deep learning image-based techniques, v. 114, Nov. 2020. <https://doi.org/10.1016/j.cemconcomp.2020.103781>

FRANÇA, A. A. V. et al. Patologia das construções: Uma especialidade da construção civil. **Pini**, n. 174, set. 2011.

FRANCO, J. A. B. et al. Sustainability in the civil construction sector supported by industry 4.0 technologies: Challenges and opportunities. **infrastructures**, v. 7, n. 43, mar. 2022. <https://doi.org/10.3390/infrastructures7030043>

FUTAO, N.; ZHANG, J.; ZHIQIANG, C. Pixel-level crack delineation in images with convolutional feature fusion. **Structural control and health monitoring**, v. 26, 2019. <https://doi.org/10.1002/stc.2286>

GARCIA SOBRINHO, R. A. **Estudo da eficiência de processos de reabilitação em obras públicas**. Dissertação (Mestrado em Engenharia Civil), Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Uberlândia. Uberlândia, p. 169. 2020.

GARCIA SOBRINHO, R. A.; MOTTA, L. A.; GUTERRES, P. R. C. **Análise da incidência de manifestações patológicas em edificações públicas**. Congresso Latinoamericano de Patología de Construcción, 2021. Congreso Latino-Americano de Patología de Construcción. [S.l.]: [s.n.]. 2021. p. 1757-1771. <https://doi.org/10.4322/conpat2021.626>

GOMIDE, T. L. F.; FAGUNDES NETO, J. C. P.; GULLO, M. A. Normas Técnicas para Engenharia Diagnóstica em Edificações. São Paulo: Pini, 2013.

GONÇALVES, C. B. **Algoritmos bioinspirados para otimização de CNNs aplicados na detecção de câncer de mama utilizando imagens termográficas**. Dissertação (Mestrado em Ciências da Computação). Pós-graduação da Faculdade de Computação. Universidade Federal de Uberlândia. Uberlândia. 2022.

GONÇALVES, C. B.; SOUZA, J. R.; FERNANDES, H. CNN architecture optimization using bio-inspired algorithms for breast cancer detection in infrared images. **Computers in Biology and Medicine**, v. 142, 2022. <https://doi.org/10.1016/j.combiomed.2021.105205>

GONZALEZ, R. C.; WOODS, R. E. Processamento Digital de Imagens. 3ª. ed. São Paulo: Pearson Prentice Hall, 2010.

GUO (A), J. et al. Façade defects classification from imbalanced dataset using meta learning-based convolutional neural network. **Computer-Aided Civil and Infrastructure Engineering**, 2020. <https://doi.org/10.1111/mice.12578>

GUO (B), J.; WANG, Q.; LI, Y. Semi-supervised learning based on convolutional neural network and uncertainty filter for façade defects classification. **Computer-Aided Civil and Infrastructure Engineering**, v. 17, 2020. <https://doi.org/10.1111/mice.12632>

GUO, L. et al. Automatic crack distress classification from concrete surface images using a novel deep-width network architecture. **Neurocomputing**, v. 397, Jul. 2020. <https://doi.org/10.1016/j.neucom.2019.08.107>

HALLE, M. J. et al. Crack Detection in Images of Masonry Using CNNs. **Sensors**, v. 21, 2021. <https://doi.org/10.3390/s21144929>

HAN, X. et al. Structural damage-causing concrete cracking detection based on a deep-learning method. **Construction and Building Materials**, v. 337, Jun. 2022. <https://doi.org/10.1016/j.conbuildmat.2022.127562>

HAYKIN, S. Redes Neurais: Princípios e prática. 2ª. ed. Porto Alegre: Bookman, 2001.

HETEM JUNIOR. Computação Gráfica. Rio de Janeiro: LTC, 2006.

HSIEH, Y. et al. Convolutional neural network for automated classification of jointed plain concrete pavement conditions. **Computer-aided civil and infrastructure engineering**, v. 36, 2021. <https://doi.org/10.1111/mice.12640>

HUNG, P. D.; SU, N. T.; DIEP, V. T. Surface Classification of Damaged Concrete Using Deep Convolutional Neural Network. **Pattern recognition and image analysis**, v. 29, 2019. <https://doi.org/10.1134/S1054661819040047>

HUTHWOHL, P.; LU, R.; BRILAKIS, I. Multi-classifier for reinforced concrete bridge defects. **Automation in Construction**, v. 105, Sep. 2019. <https://doi.org/10.1016/j.autcon.2019.04.019>

IMAGENET, 2023. Disponível em: <<https://www.image-net.org/>>. Acesso em: 02 Fev. 2023.

ISLAM, M. M. et al. CNN based on transfer learning models using data argumentation and transformation for detection of concrete crack. **Sensors**, v. 287, 2022. <https://doi.org/10.3390/a15080287>

JANSSEN, M.; ZUIDEMA, J.; WANHILL, R. Fracture Mechanics. 2ª. ed. New York: Spon Press, 2002.

- JIANG, Y.; PANG, D.; LI, C. A deep learning approach for fast detection and classification of concrete damage. **Automation in Construction**, v. 128, 2021. <https://doi.org/10.1016/j.autcon.2021.103785>
- JIN, X. et al. Development of nanomodified self-healing mortar and a U-Net model based on semantic segmentation for crack detection and evaluation. **Construction and Building Materials**, v. 365, Feb. 2023. <https://doi.org/10.1016/j.conbuildmat.2022.129985>
- JINSONG, Z.; JINB, S. An Intelligent Classification Model for Surface Defects on Cement Concrete Bridges. **Applied sciences**, v. 10, 2020. <https://doi.org/10.3390/app10030972>
- JORDAN, S. et al. State-of-art technologies for UAV inspections. **IET Radar Sonar Naving**, v. 12, n. 2, p. 151-164, 2018. <https://doi.org/10.1049/iet-rsn.2017.0251>
- KATIJA, K. et al. FathomNet: A global image database for enabling artificial intelligence in the ocean. **Sci Rep**, v. 3, 2022. <https://doi.org/10.1038/s41598-022-19939-2>
- LEE, K. et al. MultiDefectNet: Multi-Class defects detection of building façade based on deep convolutional neural network. **Sustainability**, v. 12, Nov. 2020. <https://doi.org/10.3390/su12229785>
- LEENHARDT, R. et al. CAD-CAP: a 25,000-image data-set serving the development os artificial intelligence for capsule endoscopy. **Endosc Int Open**, v. 8, 2020. <https://doi.org/10.1055/a-1035-9088>
- LI, B. et al. Automatic classification of pavement crack using deep convolutional neural network. **International Journal and Transportation Science and Technology**, v. 21, 2017. <https://doi.org/10.1080/10298436.2018.1485917>
- LOCH, C.; LAPOLLI, É. M. Elementos básicos da fotogrametria e sua utilização prática. 2ª. ed. Florianópolis: Ed. da UFSC, 1989.
- LUKAC, R.; PLATANIOTIS, K. N. Single-Sensor Camera Image Processing, 2006. Disponível em: <DOI:10.1201/9781420009781.ch16>. Acesso em: 20 maio 2023. <https://doi.org/10.1201/9781420009781>
- MAILLARD, P. Introdução ao processamento de imagens. **UFMG**, 2001. Disponível em: <<http://www.csr.ufmg.br/geoprocessamento/publicacoes/cursopdi.pdf>>. Acesso em: 25 mai. 2023.
- MARCHETTI, D. A. B.; GARCIA, G. J. Princípios de fotogrametria e fotointerpretação. 1ª. ed. São Paulo: Câmara Brasileira do Livro, 1977.
- MARIANA, A. P. et al. **Análise da espessura de cobrimento de armadura em uma laje com diferentes distanciamentos entre espaçadores**. ANAIS DO 56º CONGRESSO BRASILEIRO DO CONCRETO - CBC2014 – 56CBC. [S.l.]: [s.n.]. 2014.
- MASKURITY, R. et al. Industry 4.0 for the construction industry: Review of management perspective. **Economies**, v. 6, n. 68, jul. 2019. <https://doi.org/10.3390/economies7030068>
- MECHOLSKY JUNIOR, J. J.; POWELL JUNIOR, S. R. **Fractography of Ceramic and Metal Failures**. A symposium sponsored by ASTM Committee E-24 on Fracture Testing. Philadelphia: ASTM STP 827. 1982. p. 416.
- MILITITSKY, J.; CONSOLI, N. C.; SCHNAID, F. Patologia das fundações. São Paulo: Oficina de Textos, 2005.

NASCIMENTO, J. G. **Uso de técnicas de inteligência artificial, correlação de imagens e do conceito de impedância visado a estimativa da localização e do tamanho de tumores mamários**. Tese (Doutorado em Engenharia Mecânica), Pós-Graduação em Engenharia Mecânica, Universidade de Uberlândia. Uberlândia. 2022.

NEWMAN, C. et al. Industry 4.0 deployment in the construction industry: a bibliometric literature review and UK-based case study". **Smart and Sustainable Built Environment**, v. 10, n. 4, p. 557-580, 2021. <https://doi.org/10.1108/SASBE-02-2020-0016>

NGUYEN, A. et al. ASR crack identification in bridges using deep learning and texture analysis. **Structures**, v. 50, Apr. 2023. <https://doi.org/10.1016/j.istruc.2023.02.042>

OLIVEIRA, R. A. F. **Análise de práticas de conservação e reabilitação de edifícios com valor patrimonial**. Dissertação (Mestrado em Engenharia Civil), Faculdade de Engenharia da Universidade do Porto. [S.l.], p. 349. 2003.

OLSEN, T. L. Tomlin, B. Industry 4.0: Opportunities and challenges for operations management. **Manufacturing & Service Operations Management**, v. 22, p. 113-122, jan/feb 2020. <https://doi.org/10.1287/msom.2019.0796>

PALENCIA, S. M.; DÍAZ, S. Á.; CHICOTE, M. A. M. A. Machine learning for the improvement of deep renovation buildings projects using As-Built BIM models. **Sustainability**, v. 13, 2021. <https://doi.org/10.3390/su13126576>

PALOMINO, L. V. **Técnicas de inteligência artificial aplicadas ao método de monitoramento de integridade estrutural baseado na impedância eletromecânica para monitoramento de danos em estruturas aeronáuticas**. Tese (Doutorado em Engenharia Mecânica), Pós-Graduação em Engenharia Mecânica, Universidade de Uberlândia. Uberlândia, p. 183. 2012.

PAN, Y.; ZHANG, L. Roles of artificial intelligence in construction engineering and management: A critical review and future trends. **Automation Construction**, v. 122, p. 233-238, feb. 2021. <https://doi.org/10.1016/j.autcon.2020.103517>

PIETRO, A.; MENGISTE, E. T.; SOTO, B. G. Investigation the use of ChatGPT for schdulin of construction projects. **Buildings**, v. 24, 2019.

QIAN, H. et al. Image-based microstructure classification of mortar and paste using convolutional neural networks and transfer learning. **Cement and Concrete Composites**, v. 129, maiy 2022. <https://doi.org/10.1016/j.cemconcomp.2022.104496>

REN, S. et al. **Faster R-CNN**: Towards real-time object detection with region proposal. Advances in Neural Information Processing Systems 28, Proceedings of the 29th Annual Conference on. Montreal: [s.n.]. 2015.

RIBEIRO, J. A. J. **Comunicações Ópticas**. 4ª. ed. São Paulo: Érica, 2009.

RUSS, J. C. **The Image Prosessing Handbook**. 5ª. ed. Boca Raton: CRC Press, 2006.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3ª. ed. Rio de Janeiro: Elsevier, 2013.

SABBATINI, F. H.; BAÍA, L. M. **Projeto e Execução de Revestimento de Argamassa1948**. 3ª. ed. [S.l.]: O Nome da Rosa, 2004.

- SAHADE, R. F. **Avaliação de sistemas de recuperação de fissuras em alvenaria de vedação**. Dissertação (Mestrado em Habitação) - Instituto de Pesquisas Tecnológicas do Estado de São Paulo. São Paulo, p. 169. 2005.
- SANTOS, A. L. B. **Metodologia via redes neurais para a estimativa da rugosidade e do desgaste de ferramentas de corte no processo de fresamento frontal**. Tese (Doutorado em Engenharia Mecânica), Pós-Graduação em Engenharia Mecânica, Universidade de Uberlândia. Uberlândia, p. 187. 2001.
- SANTOS, C. F.; ROCHA, J. H. A.; PÓVOAS, Y. V. Utilização da termografia infravermelha para detecção de focos de umidade em paredes internas de edificações. **Ambiente Construído**, Porto Alegre, v. 19, n. 1, 2019. <https://doi.org/10.1590/s1678-86212019000100296>
- SCHWAB, K. A quarta revolução industrial. 1. ed. São Paulo: Edipro, 2018.
- SENA, G. O.; NASCIMENTO, M. L. M.; NETO, A. C. N. Patologia das construções. [S.l.]: 2B Educação, 2020.
- SHENGYUAN, L.; ZHAO, X. Image-Based Concrete Crack Detection Using Convolutional Neural Network and Exhaustive Search Technique. **Advances in civil engineering**, 2019. <https://doi.org/10.1155/2019/6520620>
- SILVA, A.; BRITO, J. Do we need a buildings' inspection, diagnosis and service life prediction software? **Journal of Building Engineering**, v. 22, p. 335-348, mar. 2019. <https://doi.org/10.1016/j.jobe.2018.12.019>
- SILVA, L. F. et al. A. A new database for breast research with infrared images. **Computer methods and programs in biomedicine**, v. 168, 2014.
- SONNTAG, H.; GRUNEWALD, J. Methodology for praxis-oriented development of a building refurbishment concept including consideration of potentially existing moisture related problems and façade restoration measures. **E3S Web of Conferences**, v. 172, jul. 2020. <https://doi.org/10.1051/e3sconf/202017223008>
- STASZEWSKI, W.; BOLLER, C.; TOMLINSON, G. Health Monitoring of Aerospace Structures: Smart Sensor Technologies and Signal Processing. Munich: John Wiley & Sons, 2004. <https://doi.org/10.1002/0470092866>
- STRAUCH, J. C. M. **Correlação de Imagens Digitais**. Dissertação (Mestrado em Ciências), Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná. Curitiba, p. 77. 1991.
- SUDECAP, Superintendência de Desenvolvimento da Capital. **Caderno de Encargos SUDECAP: Revestimentos**. Belo Horizonte. 2018.
- TAN, K. The framework combining artificial intelligence and construction 3D printing in civil engineering. [S.l.]: MATEC Web of Conferences, v. 206, 2018. <https://doi.org/10.1051/mateconf/201820601008>
- TAN, K. The framework of combining artificial intelligence and construction 3D printing in civil engineering. **MATEC Web of Conferences**, v. 206, 2018. <https://doi.org/10.1051/mateconf/201820601008>
- TAULLI, T. Artificial intelligence basics: A Non-Technical Introduction. Monrvia: Apress, 2019. <https://doi.org/10.1007/978-1-4842-5028-0>

THOMAZ, E. Trincas em edifícios: Causas, prevenção e recuperação. 2ª. ed. São Paulo: Oficina de Textos, 2020.

THOMAZ, E. Trincas em edifícios: Causas, prevenção e recuperação. 2ª. ed. São Paulo: [s.n.], 2020.

TOMAL, E. S. The problem of biological destruction of façades of insulated buildings – Causes and effects. **IOP Conf. Series: Materials Science and Engineering**, v. 245, 2017.

<https://doi.org/10.1088/1757-899X/245/3/032012>

U.S. DEPARTMENT OF TRANSPORTATION, Federal Aviation Administration. Acceptable Methods, Techniques, and Practices - Aircraft Inspection and Repair. [S.l.]: ASA, 2021.

UNIVERSIDADE FEDERAL DE UBERLÂNDIA. Mapa Campus Santa Mônica. **Portal UFU**, 2018. Disponível em: <<https://ufu.br/central-de-conteudos/documentos/2018/10/mapa-campus-santa-monica-2018>>. Acesso em: 28 dez. 2022.

VAIDAY, S.; AMBAD, P.; BHOSLE, S. Industry 4.0 – A glimpse. **Procedia Manufacturing**, v. 20, p. 233-238, 2018. <https://doi.org/10.1016/j.promfg.2018.02.034>

WANG, W. et al. Automated crack severity level detection and classification for ballastless track slab using deep convolutional neural network. **Automation in Construction**, v. 124, Apr. 2021.

<https://doi.org/10.1016/j.autcon.2020.103484>

WEIDMAN, S. Deep Learning from Scratch: Buildin with Python from First Principles. Sebastopol: O'Reilly Media, 2019.

YE, W. et al. Deep learning-based fast detection of apparent concrete crack in slab tracks with dilated convolution. **Construction and Building Materials**, v. 329, Apr. 2022.

<https://doi.org/10.1016/j.conbuildmat.2022.127157>

YING, X. et al. Identification of Corroded Cracks in Reinforced Concrete Based on Deep Learning SCNet Model. **Research in nondestructive evaluation**, 2022.

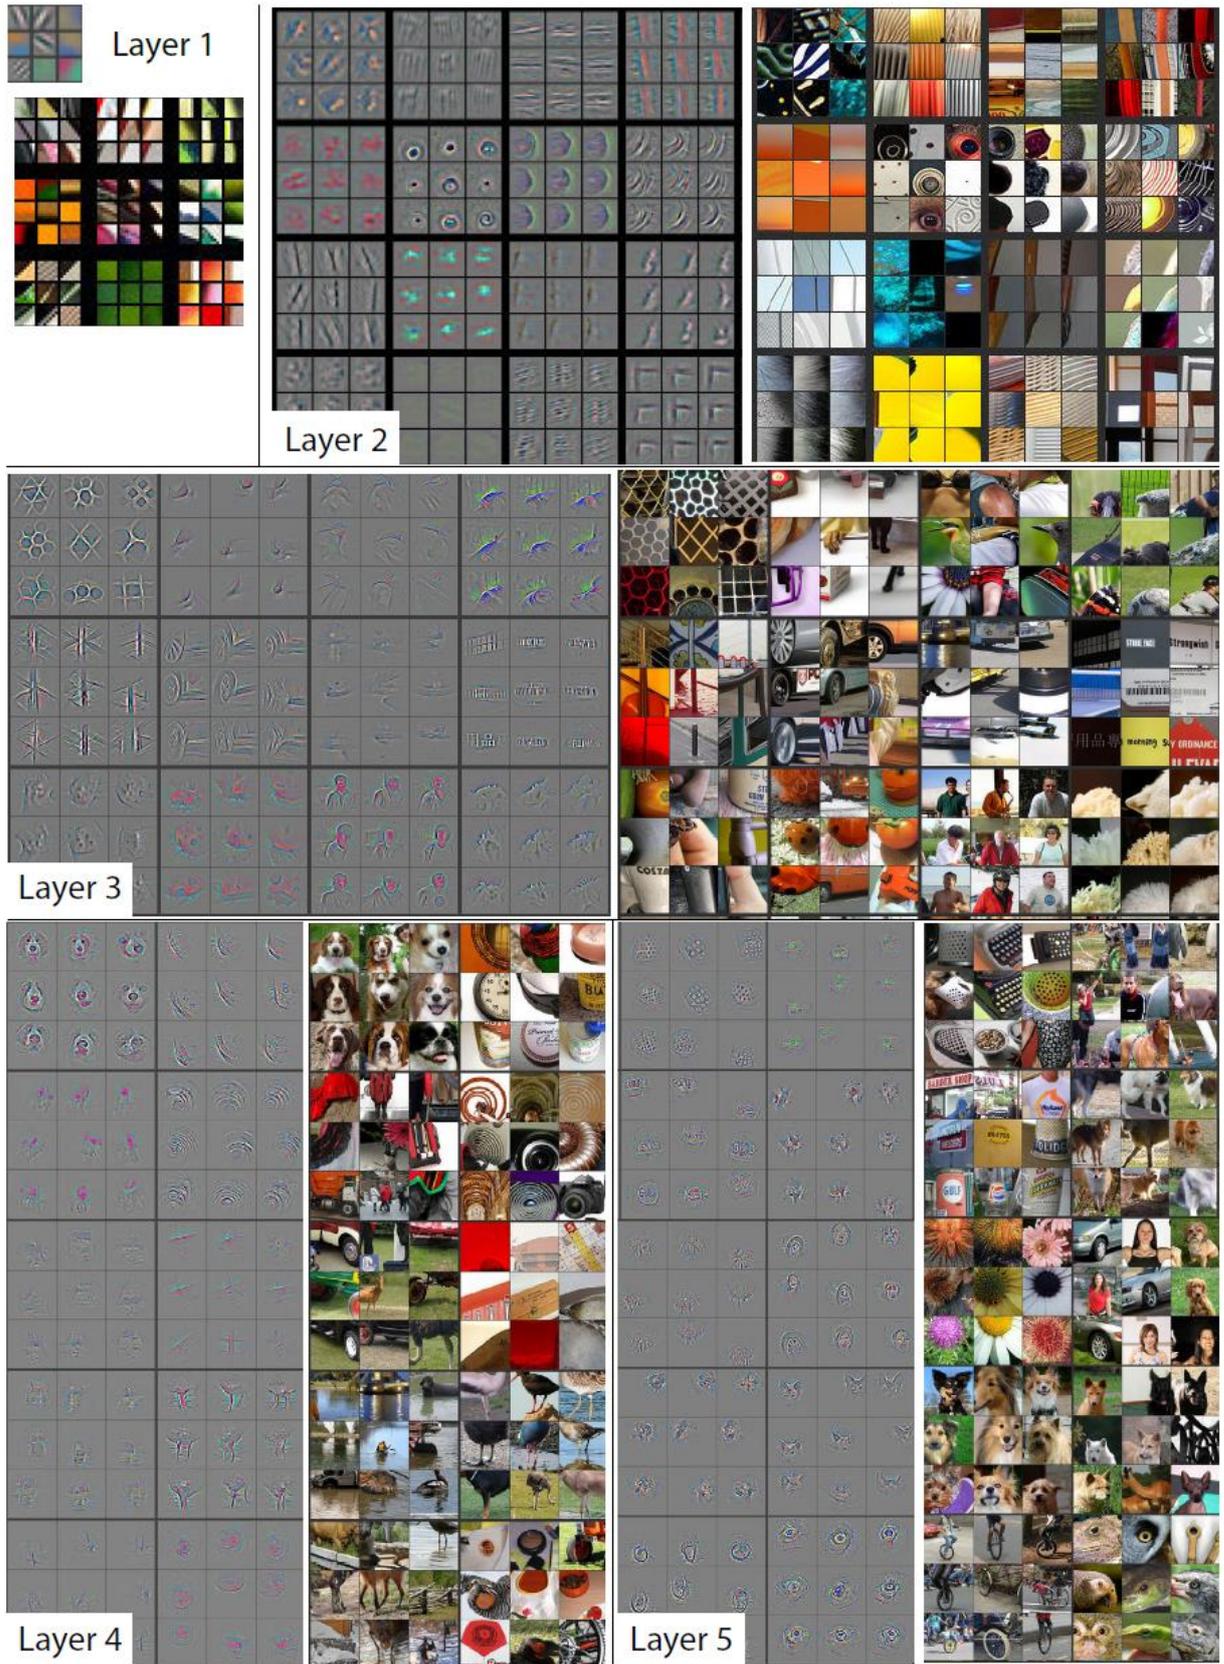
ZEILER, M. D.; FERGUS, R. Visualizing and Understanding Convolutional Networks. **Arxiv**, v. 3, 2013.

ZHANG, C. et al. Pavement distress detection using convolutional neural network (CNN): A study in Montreal, Canada. **International Journal and Transportation Science and Technology**, v. 11, 2022.

<https://doi.org/10.1016/j.ijtst.2021.04.008>

ZHANG, Y. Safety management of civil engineering construction based on artificial intelligence and machine vision technology. **Hindawi**, dec. 2021. <https://doi.org/10.1155/2021/3769634>

ANEXO A – Visualização de mapas de extração de características



Fonte: (ZEILER e FERGUS, 2013)

ANEXO B – Topologia da rede dos treinamentos iniciais (VGG16)

```

VGG(
(features): Sequential(
  (0): Conv2d(3, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (1): ReLU(inplace=True)
  (2): Conv2d(64, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (3): ReLU(inplace=True)
  (4): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
  (5): Conv2d(64, 128, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (6): ReLU(inplace=True)
  (7): Conv2d(128, 128, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (8): ReLU(inplace=True)
  (9): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
  (10): Conv2d(128, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (11): ReLU(inplace=True)
  (12): Conv2d(256, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (13): ReLU(inplace=True)
  (14): Conv2d(256, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (15): ReLU(inplace=True)
  (16): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
  (17): Conv2d(256, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (18): ReLU(inplace=True)
  (19): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (20): ReLU(inplace=True)
  (21): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (22): ReLU(inplace=True)
  (23): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
  (24): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (25): ReLU(inplace=True)
  (26): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (27): ReLU(inplace=True)
  (28): Conv2d(512, 512, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
  (29): ReLU(inplace=True)
  (30): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
)
(avgpool): AdaptiveAvgPool2d(output_size=(7, 7))
(classifier): Sequential(
  (0): Linear(in_features=25088, out_features=4096, bias=True)
  (1): ReLU(inplace=True)
  (2): Dropout(p=0.5, inplace=False)
  (3): Linear(in_features=4096, out_features=4096, bias=True)
  (4): ReLU(inplace=True)
  (5): Dropout(p=0.5, inplace=False)
  (6): Linear(in_features=4096, out_features=2, bias=True)
)
)
)

```

ANEXO C – Topologia da rede dos treinamentos comparativos (VGG16)

Layer (type)	Output Shape	Param #
Conv2d-1	[128, 64, 224, 224]	1,792
ReLU-2	[128, 64, 224, 224]	0
Conv2d-3	[128, 64, 224, 224]	36,928
ReLU-4	[128, 64, 224, 224]	0
MaxPool2d-5	[128, 64, 112, 112]	0
Conv2d-6	[128, 128, 112, 112]	73,856
ReLU-7	[128, 128, 112, 112]	0
Conv2d-8	[128, 128, 112, 112]	147,584
ReLU-9	[128, 128, 112, 112]	0
MaxPool2d-10	[128, 128, 56, 56]	0
Conv2d-11	[128, 256, 56, 56]	295,168
ReLU-12	[128, 256, 56, 56]	0
Conv2d-13	[128, 256, 56, 56]	590,080
ReLU-14	[128, 256, 56, 56]	0
Conv2d-15	[128, 256, 56, 56]	590,080
ReLU-16	[128, 256, 56, 56]	0
MaxPool2d-17	[128, 256, 28, 28]	0
Conv2d-18	[128, 512, 28, 28]	1,180,160
ReLU-19	[128, 512, 28, 28]	0
Conv2d-20	[128, 512, 28, 28]	2,359,808
ReLU-21	[128, 512, 28, 28]	0
Conv2d-22	[128, 512, 28, 28]	2,359,808
ReLU-23	[128, 512, 28, 28]	0
MaxPool2d-24	[128, 512, 14, 14]	0
Conv2d-25	[128, 512, 14, 14]	2,359,808
ReLU-26	[128, 512, 14, 14]	0
Conv2d-27	[128, 512, 14, 14]	2,359,808
ReLU-28	[128, 512, 14, 14]	0
Conv2d-29	[128, 512, 14, 14]	2,359,808
ReLU-30	[128, 512, 14, 14]	0
MaxPool2d-31	[128, 512, 7, 7]	0
AdaptiveAvgPool2d-32	[128, 512, 7, 7]	0
Linear-33	[128, 4096]	102,764,544
ReLU-34	[128, 4096]	0
Dropout-35	[128, 4096]	0
Linear-36	[128, 4096]	16,781,312
ReLU-37	[128, 4096]	0
Dropout-38	[128, 4096]	0
Linear-39	[128, 256]	1,048,832
ReLU-40	[128, 256]	0
Dropout-41	[128, 256]	0
Linear-42	[128, 2]	514
LogSoftmax-43	[128, 2]	0

Total params: 135,309,890

Trainable params: 1,049,346
Non-trainable params: 134,260,544

Input size (MB): 73.50
Forward/backward pass size (MB): 28003.75
Params size (MB): 516.17
Estimated Total Size (MB): 28593.42
