



Aplicação de Redes Neurais Artificiais na Classificação de Manifestações Patológicas por Meio de Imagens Capturadas por Aeronave Remotamente Pilotada

Application of Artificial Neural Networks in the Classification of Pathological Manifestations Using Images Captured by a Remotely Piloted Aircraft

Aplicación de redes neuronales artificiales en la clasificación de manifestaciones patológicas mediante imágenes capturadas por una aeronave pilotada remotamente

Jair Henrique dos Passos Velozo

Pós-Graduando em Engenharia Civil, UNICAP, Brasil
jairhenri.765@hotmail.com

Everson Silva De Albuquerque

Graduando em Engenharia Civil, UNICAP, Brasil.
everson15.silva@hotmail.com

Glauber Carvalho Costa

Professor Doutor, UNICAP, Brasil.
glauber.carvalho@unicap.br

Eliana Cristina Barreto Monteiro

Professora Doutora, POLI/UPE e UNICAP, Brasil.
eliana.monteiro@unicap.br



RESUMO

Com os avanços tecnológicos da atualidade, muitas áreas têm realizado grandes saltos por atribuírem e aderirem sistemas de automação em suas rotinas, e o grande campo da arquitetura moderna e da construção civil têm buscado o mesmo caminho. A programação está se tornando um destaque no mundo inteiro e com ela conhecemos as redes neurais artificiais, conjuntos de algoritmos que ao serem treinados, conseguem identificar e classificar diversos elementos. Tem-se por objetivo utilizar Aeronave Remotamente Pilotada (ARP), extrair as imagens para fazer processamentos de imagens por meio de software e treinar redes neurais a fim de diagnosticar as manifestações patológicas nas arquiteturas modernas das edificações. Por sua vez, as manifestações patológicas, por se tratar de elementos pós-obra, são identificadas e classificadas por profissionais de engenharia civil, que cada vez mais tem aderido o uso de ferramentas tecnológicas para facilitar suas rotinas. Com a utilização das imagens retiradas por meio de câmeras fotográficas e drones para identificação das manifestações patológicas, as redes neurais passaram a ter um papel fundamental quando se trata de identificação, classificação desses elementos e inclusive, eficiência nas atividades. O uso da rede neural elaborada, serviu para identificar onde se localizava e quais eram essas manifestações patológicas, com apenas imagens reais da edificação danificada e assim pôde ser comparada com um mapa de danos, tendo por finalmente uma acurácia aceitável em relação aos seus acertos.

PALAVRAS-CHAVE: Manifestações Patológicas. Tecnologias. Redes Neurais. Arquitetura Moderna.

SUMMARY

With today's technological advances, many areas have made great leaps forward by incorporating and incorporating automation systems into their routines, and the broad field of modern architecture and civil construction have followed the same path. Programming is becoming a highlight around the world and with it we know artificial neural networks, sets of algorithms that, when trained, can identify and classify different elements. The objective is to use Remotely Piloted Aircraft (ARP), extract images to perform image processing using software and train neural networks in order to diagnose pathological manifestations in modern building architecture. In turn, pathological manifestations, as they are post-construction elements, are identified and classified by civil engineering professionals, who have increasingly adopted the use of technological tools to facilitate their routines. With the use of images taken through cameras and drones to identify pathological manifestations, neural networks began to play a fundamental role when it comes to identification, classification of these elements and even efficiency in activities. The use of the elaborate neural network served to identify where these pathological manifestations were located and what they were, with only real images of the damaged building and thus could be compared with a damage map, finally having an acceptable accuracy in relation to its results.

KEYWORDS: Pathological Manifestations. Technologies. Neural networks. Modern architecture.

RESUMEN

Con los avances tecnológicos actuales, muchas áreas han dado grandes pasos incorporando e incorporando sistemas de automatización a sus rutinas, y el amplio campo de la arquitectura moderna y la construcción civil han seguido el mismo camino. La programación se está volviendo un tema destacado en todo el mundo y con ella conocemos las redes neuronales artificiales, conjuntos de algoritmos que, entrenados, pueden identificar y clasificar diferentes elementos. El objetivo es utilizar aeronaves pilotadas a distancia (ARP), extraer imágenes para realizar su procesamiento mediante software y entrenar redes neuronales para diagnosticar manifestaciones patológicas en la arquitectura de edificios modernos. A su vez, las manifestaciones patológicas, al ser elementos post-construcción, son identificadas y clasificadas por los profesionales de la ingeniería civil, quienes han adoptado cada vez más el uso de herramientas tecnológicas para facilitar sus rutinas. Con el uso de imágenes tomadas a través de cámaras y drones para identificar manifestaciones patológicas, las redes neuronales comenzaron a jugar un papel fundamental a la hora de identificar, clasificar estos elementos e incluso eficiencia en las actividades. El uso de la elaborada red neuronal sirvió para identificar dónde se localizaban estas manifestaciones patológicas y cuáles eran, contando únicamente con imágenes reales del edificio dañado y así poder compararlas con un mapa de daños, teniendo finalmente una precisión aceptable en relación a sus resultados.

PALABRAS CLAVE: Manifestaciones patológicas. Tecnologías. Redes neuronales. Arquitectura moderna.



1. INTRODUÇÃO

Segundo Borges et al (2021), várias pesquisas foram conduzidas em relação ao estudo das manifestações patológicas, do qual agrega ao campo da engenharia das construções e da arquitetura moderna, tem por finalidade preservação histórica urbana das cidades, que é atrelada no estudo das origens, formas de manifestações, consequências e mecanismos de ocorrência das falhas e dos sistemas de degradação das fachadas das edificações. Sendo assim é mais sustentável, evitar desperdício de materiais de construção civil, além disso, são os principais problemas que comprometem a vida útil das construções.

Para a NBR 15575-1 (ABNT, 2021) no item 3.42, entende-se por vida útil o período em que um edifício e/ou seus sistemas se prestam às atividades para as quais foram projetados e construídos, considerando a periodicidade e a correta execução dos processos de manutenção especificados no respectivo manual de uso, operação e manutenção. Nesse caso, sabe-se que poucos processos de tecnologias como Inteligência Artificial (IA), são usados na engenharia diagnóstica, mas esse artigo será direcionado e focado em tecnologias para identificação das manifestações patológicas em fachadas de prédios.

O objetivo deste artigo é fazer processamento de imagens a partir de extração de imagens por meio de Aeronave Remotamente Pilotada (ARP) e treinar redes neurais para a detecção automática de manifestações patológicas em edificações, a partir de imagens de alta resolução. A pesquisa buscou desenvolver um modelo de rede neural capaz de identificar e classificar diferentes tipos de manifestações patológicas, como fissuras, umidades, bolor, corrosão na armadura e vegetação, com alta precisão e eficiência. A análise inclui a integração de dados obtidos por ARP e a sua aplicação em um ambiente urbano, visando a otimização dos processos de inspeção e a melhoria da segurança e durabilidade nas construções.

1.1 Manifestações patológica

Conforme Borges et al (2021) termo “patologia” é derivado do grego (*pathos* – doença, e *logia* – ciência, estudo) que significa “estudo da doença”. Na construção civil pode-se atribuir patologia aos estudos dos danos ocorridos em edificações e podem se manifestar de diversas formas: trincas, fissuras, rachaduras, entre outras e por ser encontrada em diversos aspectos, recebe o nome de manifestações patológicas.

A NBR 16747 (ABNT, 2020) determina que as irregularidades constatadas devem ser classificadas em falhas ou anomalias. A norma distingue essa classificação da seguinte forma: a) anomalias se caracterizam pela perda de desempenho de um elemento, sistema ou subsistema construtivo. Podem ser endógenas (quando a perda de desempenho se origina da etapa de projeto e/ou execução); exógenas (quando a perda de desempenho está relacionada a fatores externos a edificação); funcionais (quando a perda de desempenho decorre da degradação natural através da ação do tempo).

1.2 Inspeção técnica



Para Souza e Ripper (2009) as inspeções técnicas e a estratégia de manutenção visam definir como e a que razão uma determinada estrutura está a degradar-se, de forma a estabelecer a necessidade dos eventuais reparos, e quando estes devem suplantar o desempenho inicialmente esperado para a estrutura, e, por fim, para que se mantenha ou até se estenda a vida útil dela.

1.3 ARP

De acordo com o regulamento da Agência Nacional de Aviação Civil (ANAC), Aeronave Remotamente Pilotada (*Remotely-Piloted Aircraft – RPA*) significa a aeronave não tripulada pilotada a partir de uma estação de pilotagem remota com finalidade diversa de recreação (RBAC-E nº 94, 2023).

1.4 Processamento de imagens

Os ortomosaicos das amostras de fachada são obtidos por processamento digital de imagens, utilizado o *software Agisoft Metashape*, cujo princípio de funcionamento se baseia na correspondência estéreo densa (*Dense Stereo Matching – DSM*), que consiste na correlação automática de conjuntos de pixels homólogos em fotos distintas. A sequência de ferramentas do *software* utilizadas e os produtos gerados até a obtenção dos ortomosaicos (Lopes et al, 2023).

1.5 Redes neurais artificial


Uma plataforma baseada em aprendizado de máquina foi utilizada para treinar redes neurais, com o intuito de automatizar os processos e facilitar os diagnósticos. Assim é possível fazer uma recuperação, tratando cada manifestação patológica corretamente, aumentando a vida útil das fachadas das edificações, estendendo o tempo para fazer uma nova manutenção.

2 METODOLOGIA

2.1 Inspeção com uso de ARP

Para realizar a inspeção de fachadas, devem ser tomados alguns cuidados para a obtenção de imagens de boa qualidade e que permitam a construção de modelos tridimensionais e ortomosaicos. Uma característica importante é o posicionamento para as tomadas fotográficas, que devem manter um paralelismo entre si como mostra na Figura 1, com uma tolerância de até 10°, e uma perpendicularidade ao plano da fachada do objeto de interesse. Nos vértices da edificação, as posições para tomadas fotográficas podem ter uma inclinação de até 45° em relação ao plano da fachada, para que não haja problemas no processamento das fotografias, devendo ser mantida uma projeção de raio igual à distância determinada para a posição da câmera em relação ao edifício (Lopes et al., 2022).

A Figura 1 mostra o posicionamento correto da aeronave.



Fonte: Lopes et al., 2022.

Para viabilizar a ortorretificação das aeroimagens coletadas por meio de ARP, foi necessário respeitar alguns parâmetros (Figura 2), visando a elaboração das ortoimagens das fachadas levantadas, sendo esse o principal produto a ser gerado com base nos aerolevantamentos realizados e que servirão de subsídio aos estudos de inspeção e identificação as manifestações patológicas em edificações.

Tabela 1 – Parâmetros para captura de imagens com ARP.

Parâmetros	Descrição	Parâmetro adotado
Posicionamento entre tomadas fotográficas	Paralelismo entre tomadas fotográficas e perpendicularidade ao plano da fachada.	Paralelismo e perpendicularidade
Sobreposição (longitudinal e transversal) (p)	Acima de 60%, o que facilita a correção de erros no processamento das imagens.	70%
Distância até a fachada (L).	A menor possível, com o mínimo de 3 metros para a segurança do voo.	5 metros
Distância entre tomadas fotográficas (B).	$p^{\{\alpha\}} \cdot L \cdot (1 - B = 2 \tan)$, em que: α é o ângulo da abertura da 2 100 Lente da câmera.	B = 2,25 metros
Relação entre distâncias (B/L).	$\{B\} < 0,5$, para melhor processamento das imagens. $0,1 < L$.	B/L = 0,45
Sequência de captura.	Direção paralela à maior dimensão da fachada.	Sequência vertical

Fonte: adaptado de Lopes et al., 2023.

As operações aéreas foram realizadas de forma manual, onde o piloto em operação executou as manobras utilizando o controle remoto da aeronave, sem o emprego de aplicativos para voos automáticos, e adotando uma metodologia onde respeitou-se parâmetros de vôo pré-definidos quanto a proximidade da ARP a face da estrutura (não superior a 6m) e posição da tomada das filmagens aéreas, sendo as tomadas executadas com sensor RGB (câmera digital) acoplado a aeronave (ARP) modelo DJI Mini 3, dos quais esse modelo adotado nos levantamentos atendeu algumas especificações previamente avaliadas, sendo os mesmas elencadas abaixo:

- O modelo DJI Mini 3 contempla a detecção de obstáculos durante o voo, munido de 2 sensores posicionados na parte superior da aeronave, 2 sensores frontais e 2 sensores

inferiores, isso viabiliza um voo mais seguro no entorno de estruturas, e possibilita o controle das distâncias a face da estrutura, visto que o sistema informa ao piloto em operação as distâncias de proximidade da aeronave em tempo real.

- O modelo DJI Mini 3 tem suporte de voo por meio de sistema de posicionamento por satélite (GPS, GLONASS e Galileo), viabilizando voos estabilizados e controlados, e o recurso de RTH (*Return To Home*) em caso de algum sinistro de perda de sinal ou uma repentina interrupção do voo, motivados por mudanças repentinas de condições climática (chuva e vento) ou pelo descarregamento da bateria.
- O sensor RGB (câmera digital) da ARP DJI Mini 3, está acoplado a um estabilizador mecânico triaxial (inclinação, rotação, giro), gerando imagens estabilizadas em rotações e vibrações, que poderiam gerar problema no foco e o efeito de arrasto nas tomadas as imagens. Outro aspecto é que o sensor tem 48 megapixels, e pode gravar filmes em 4K: 3840×2160 a 24/25/30 fps, 2,7K: 2688×1512 a 24/25/30/48/50/60 fps ou FHD: 1920×1080 a 24/25/30/48/50/60 fps

Para o presente estudo, visando agilizar os processos de coleta de aeroimagens em fachadas de edificações verticais, optou-se pela adoção da tomada de aeroimagens tendo como fonte primária filmagens realizadas com a ARP modelo DJI Mini 3, portanto para as edificações analisadas, foram realizadas filmagens em formato 4K (UHD - *Ultra-high Definition*), com resolução de 3840x2160 pixels, gerados em 30 fps (frame per second), em português, 30 quadros por segundo. De posse das filmagens, a partir do programa VLC media player, utilizando uma taxa de exportação de 2 fotos a cada segundo, foram exportadas as aeroimagens do vídeo do levantamento (Figura 2).

Figura 2 – Vista da Janela do programa VLC media player mostrando trecho da filmagem realizado na fachada (a) e exemplo das aeroimagens extraídas (b).



(a)

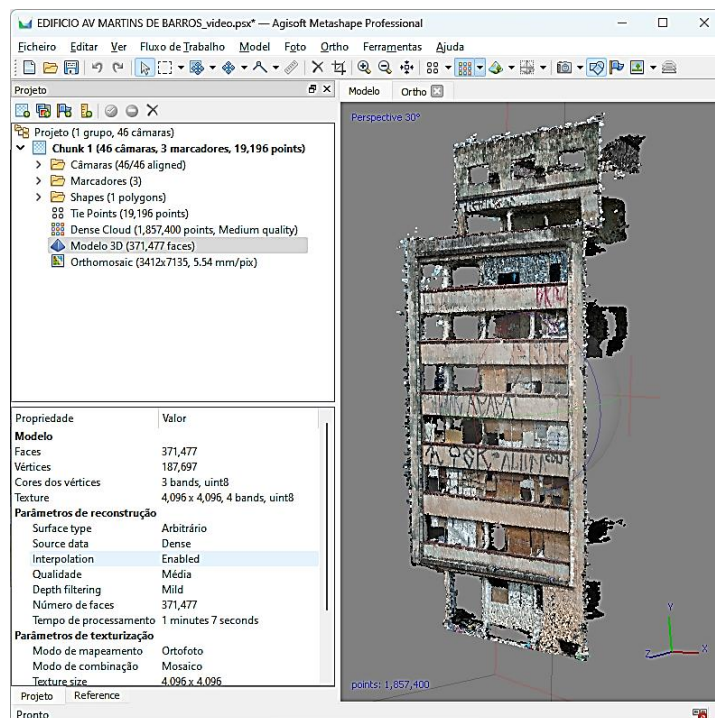


(b)

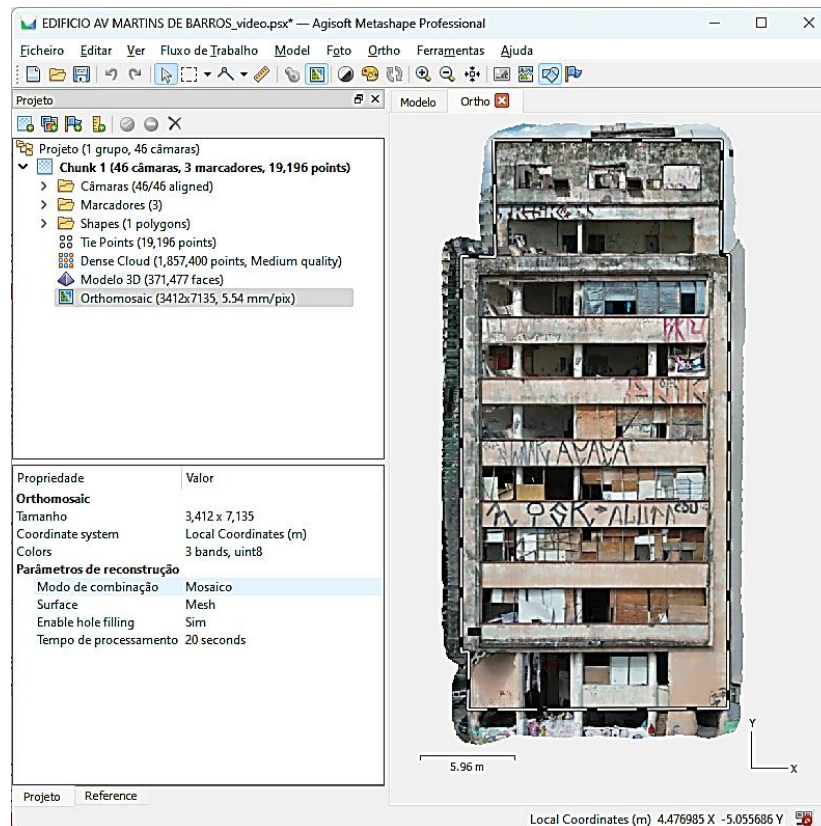
Fonte: Autor, 2024.

Após a coleta das filmagens com a câmera na posição frontal a superfície da fachada, e respeitando os parâmetros de voo pré-estabelecidos, os dados foram processados no programa Agisoft Metashape (Figura 3), gerando as ortoimagens das fachadas levantadas da edificação, seguindo o fluxograma de processamento indicado abaixo:

Figura 3 – Vista da Janela do programa Metashape mostrando o Modelo 3D gerado a partir do processamento (a) e a direita a Ortoimagem (b) da fachada da edificação estudada.



(a)

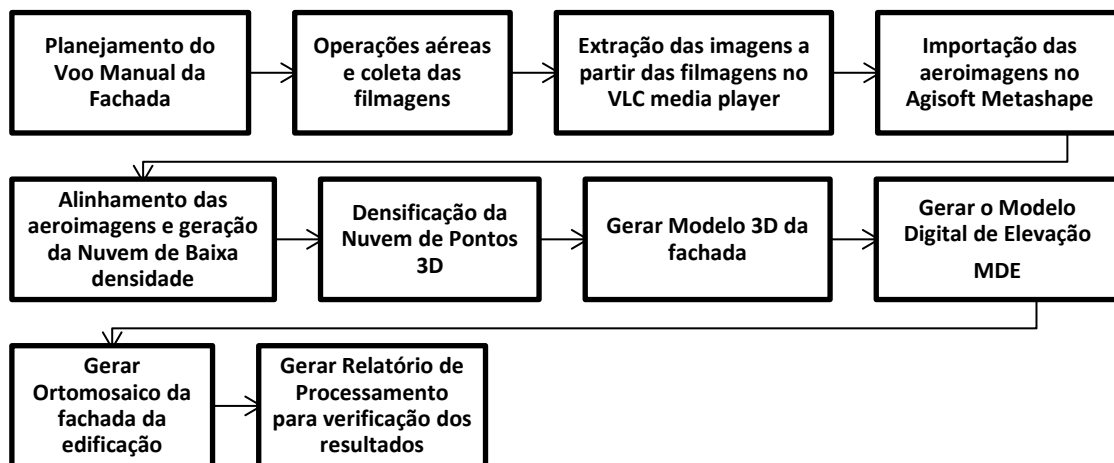


(b)

Fonte: Autor, 2024.

Como resultado dos processados no programa Agisoft Metashape, obteve-se uma ortomagem de resolução espacial (GSD - Ground sample distance) de 5.53mm, seguindo o fluxograma de processamento indicado na Figura 4.

Figura 4 – Fluxograma do processamento das ortomagens geradas.



Fonte: Autor, 2024.



2.2 Software para processamento de dados de imagens

Com as informações das ortoimagens processadas, teve-se início as análises das informações referentes a identificação e mapeamento das manifestações patológicas a partir dos dados processados no programa *Agisoft Metashape*, para isso foram utilizadas metodologias que adotaram técnicas de Machine Learning e de Redes Neurais, associadas ao emprego de sistemas computacionais disponíveis, sendo detalhado abaixo as técnicas que foram adotadas nos estudos.


Machine Learning (aprendizado de máquina) procura otimizar um critério de desempenho usando dados de exemplo ou experiências anteriores. Temos um modelo definido até alguns parâmetros, e aprendizagem é a execução de um *software* para otimizar os parâmetros do modelo usando os dados de treinamento ou experiência. O modelo pode ser preditivo para fazer previsões no futuro, ou descritivo para obter conhecimento dos dados, ou ambos. O aprendizado de máquina usa a teoria da estatística na construção de modelos matemáticos, porque a tarefa principal é fazer inferências a partir de uma amostra. O papel da ciência da computação é duplo: primeiro, no treinamento, é preciso possuir algoritmos eficientes para resolver o problema de otimização, bem como para armazenar e processar a grande quantidade de dados que geralmente se possui. Em segundo lugar, uma vez que um modelo é aprendido, sua representação e solução algorítmica para inferência também precisam ser eficientes. Em certas aplicações, a eficiência do algoritmo de aprendizagem ou inferência, nomeadamente, a sua complexidade no espaço e no tempo, pode ser tão importante quanto a sua precisão preditiva (Cimirro, 2022).

2.3 Redes Neurais Convolucionais (CNNs)

São um tipo especializado de rede neural para processamento de dados com uma topologia conhecida, como uma grade. Os exemplos incluem dados de série temporal, que podem ser considerados como uma grade 1D que coleta amostras em intervalos de tempo regulares, e dados de imagem, que podem ser considerados como uma grade 2D de pixels. As redes convolucionais têm sido extremamente bem-sucedidas em aplicações práticas. O nome “rede neural convolucional” indica que a rede emprega uma operação matemática chamada convolução. A convolução é um tipo especializado de operação linear. As redes convolucionais são simplesmente redes neurais que usam convolução no lugar da multiplicação geral da matriz em pelo menos uma de suas camadas, no contexto de imagens, esse processo pode ser associado como um filtro (também chamado de kernel nesse caso), que transforma uma imagem de entrada, onde esses filtros são representados por uma matriz a qual é utilizada numa operação entre as matrizes, como visto na Figura 5 de modo que é feita uma multiplicação dos pixels da imagem com o pixel do filtro e após essas multiplicações feitas, sua soma é armazenada em um mapa de características. Esta operação é aplicada diversas vezes em diferentes regiões da imagem. A cada aplicação, a região é alterada por um parâmetro conhecido como *stride*. *Stride* é um parâmetro do filtro da rede neural que modifica a quantidade de movimento sobre

a imagem ou vídeo. Por exemplo, se o passo de uma rede neural for definido como 1, o filtro moverá um pixel, ou unidade, por vez, o que significa que a transformação será aplicada em todos os pixels da imagem (Cimirro, 2022).

Figura 5 – Convolução.



Fonte: Cimirro, 2022.

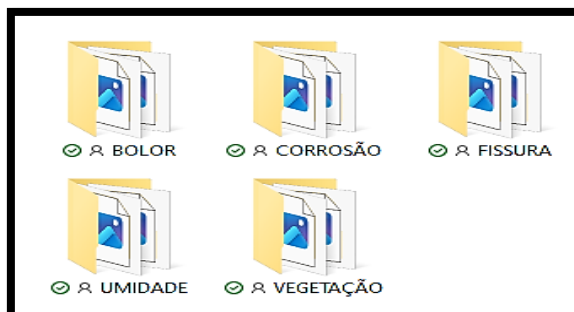
2.4 Montando o Dataset

Para realizar o treinamento de uma rede neural, é preciso ter um banco de dados elaborado ou na maioria dos casos buscar da internet, porém, não existem *dataset's* com imagens específicas, que em nosso caso são de manifestações patológicas.

“Um *dataset*, literalmente, é um conjunto (set) de dados (data). Dados são elementos que, organizados (ou distribuídos) de uma(s) certa(s) maneira(s), isto é, tratados, produzem informação (Freitas, 2023, p. 1).”

O conjunto de dados desse trabalho possui imagens que não foi possível encontrar prontas na internet e, portanto, foi montado do zero. Após a reunião dessas imagens, foi realizado e separado as classes, que são as manifestações patológicas. Na Figura 6, mostram cada classe separadas por pastas para um futuro treinamento da rede neural.

Figura 6 – Dataset



Fonte: Autor, 2024.

As imagens que se encontram em cada pasta, foi utilizada exclusivamente para o treinamento do modelo e em nenhum momento elas foram usadas para o teste real. Um cuidado foi tomado quanto às imagens obtidas e adicionadas às pastas, além de realizados um

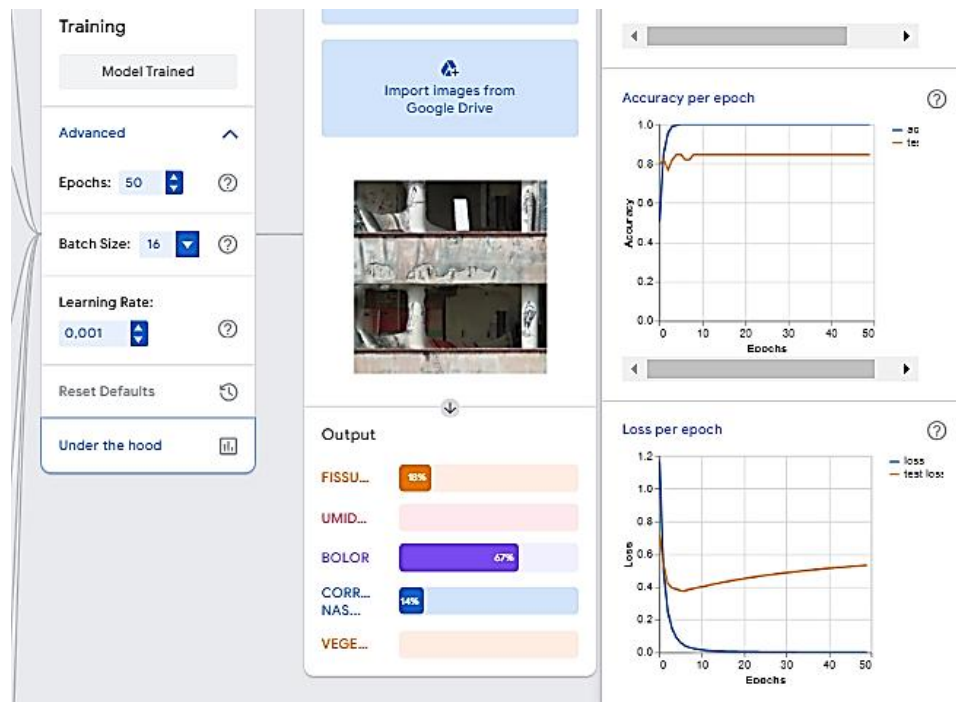
filtro para que as imagens não tivessem outros tipos de manifestações patológicas na classe errada ou objetos como peças e/ou até pessoas que poderiam gerar uma futura confusão na identificação dentro do modelo.

2.5 Treinamento do modelo

A Figura 7 mostra o treinamento das classes, do qual, pode-se observar nos gráficos de acurácia x época, que mostra o comportamento dos acertos realizado pelo modelo. No gráfico de perdas podemos reparar que a acurácia se manteve em 100% (linha azul), comparado ao de teste acima de 80% (linha laranja), do qual o modelo separa e utiliza uma quantidade das imagens em treinamento para pré-validar sem nenhuma interferência externa.

Um outro gráfico também é apresentado, perdas x época, e nesse gráfico, o modelo apresenta um comportamento durante seu treinamento, em que as perdas (linha laranja) ficaram entre 38% e 70%, o que mostra que elas aumentaram gradativamente a cada época (linha azul).

Figura 7 – Treinamento do modelo.

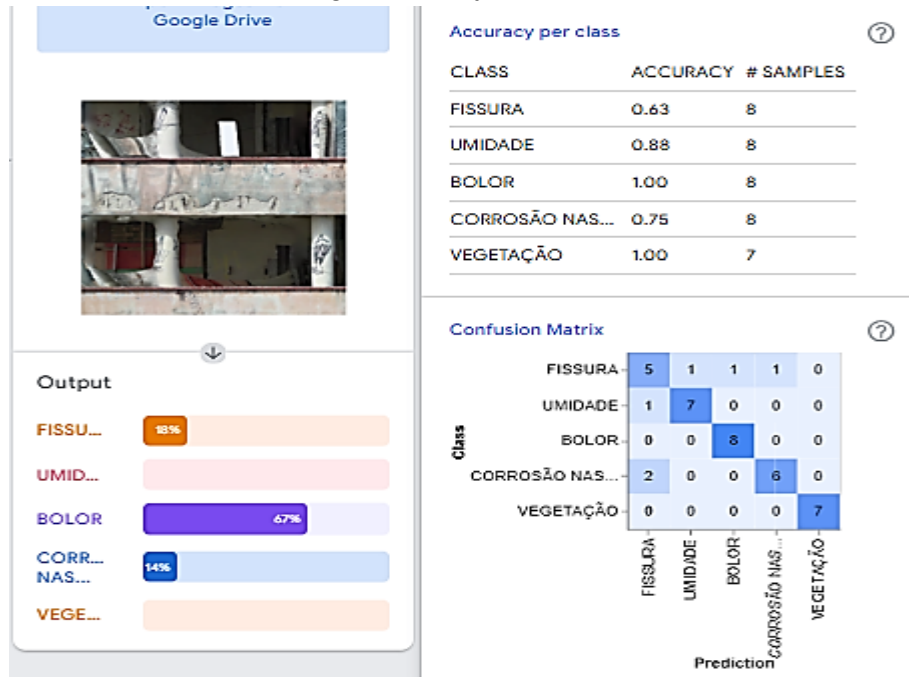


Fonte: Autor, 2024.

2.6 Validando o modelo

Na Figura 8, o modelo apresenta sua resposta ao ser inserido uma imagem externa ao *dataset* e que serviu como validação do modelo.

Figura 8 – validação do modelo



Fonte: Autor, 2024.

A leitura realizada pelo modelo identificou e classificou mais de uma manifestação patológica na imagem utilizada para validação, destas, 14% apresentaram corrosão na armadura, 67% bolor e 18% de fissuras. A Figura 9 mostra a imagem retirado por ARP e processada por um software e a matriz de confusão gerado pelos resultados da imagem.

Figura 9 – a) Imagem retirada por uma ARP e processada por *software*; b) Resultado obtido na leitura da imagem

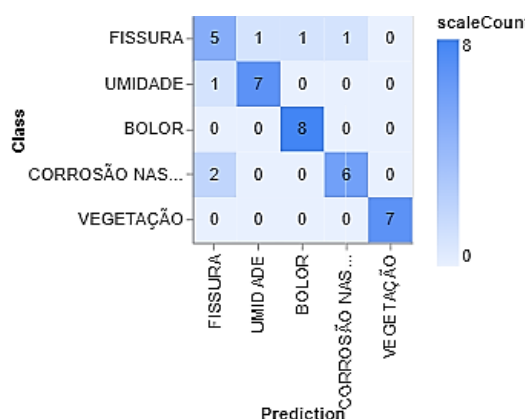


Fonte: Autor, 2024.

3 RESULTADOS

Para ser possível identificar se o modelo treinando obteve bons resultados ou não é necessário ler a matriz de confusão, nela mostra se houve trocas de dados. Na Figura 10, observa-se que houve imagens que foram confundidas entre as classes, como por exemplo, a classe de fissuras, do qual das 8 imagens separadas pelo modelo para predição, todas não foram acertadas sendo 1 confundidas com umidade, 1 confundida com bolor e 1 com corrosão nas armaduras.

Figura 10 – Matriz de confusão.



Fonte: Autor, 2024.

Após o treino realizado e os testes seguidos da validação, obteve-se dados de como se comportou o modelo treinado e a Tabela 2 nos apresenta a acurácia de cada classe com relação ao teste utilizando imagens de predição no próprio modelo.

Tabela 2 – Acurácia x classe.

CLASSE	ACURACIA (%)	AMOSTRA
Fissura	63	8
Umidade	88	8
Bolor	100	8
Corrosão na armadura	75	8
Vegetação	100	7

Fonte: Autor, 2024.

4 CONCLUSÃO

O mapa de danos é uma solução que determina as manifestações patológicas, que são responsáveis pela deterioração das fachadas das edificações. Diante dessa pesquisa foram vistas soluções inovadoras que evita riscos de acidentes graves e reduz pessoas nas inspeções. Por outro lado, a rede de programação, pode dar estímulos ao mercado e as pessoas para cuidarem de suas edificações, assim, aumenta a vida útil das fachadas e estruturas, tornando mais sustentáveis.



O estudo sobre o uso de redes neurais para detecção de manifestações patológicas utilizando imagens capturadas por ARP e por processamento de imagens em um software, revela o potencial promissor dessa abordagem na área de inspeção e monitoramento das fachadas das edificações. A utilização de redes neurais permite a análise automatizada de imagens de alta resolução, fornecendo uma visão abrangente e detalhada das condições das edificações. Além disso, o uso de ARP para a captura das imagens proporciona vantagens significativas, como acesso a áreas de difícil alcance, redução de custos operacionais e aumento da segurança dos inspetores preservando os detalhes arquitetônicos.

Com os resultados obtidos, foi possível concluir que o modelo consegue identificar adequadamente as manifestações patológicas pela imagem, porém, está passivo a erros e confusões como visto nos dados dos gráficos, matriz e tabela. Esse modelo tem a capacidade de ser melhorado em termos gerais e principalmente a sua acurácia através de novos treinamentos e uma padronização dos dados das classes para que o modelo possa separar a mesma quantidade de imagens para testes de predição.

No entanto, é importante ressaltar que o sucesso da detecção de manifestações patológicas por meio de redes neurais depende da qualidade e quantidade dos dados de treinamento, bem como da calibração adequada dos algoritmos. Além disso, a interpretação humana ainda é necessária para validar e interpretar os resultados obtidos pelas redes neurais.

5 REFERÊNCIAS BIBLIOGRÁFICAS

ABNT. **Associação Brasileira de Normas Técnicas**. NBR 15575-1:2021: Desempenho de edificações habitacionais - Parte 1: Requisitos gerais. Rio de Janeiro: ABNT, 2021.

ABNT. **Associação Brasileira de Normas Técnicas**. NBR 16747:2020: Inspeção predial – Diretrizes, conceitos, terminologia e procedimento. Rio de Janeiro: ABNT, 2020.

BORGES, K. L. F. F.; SANTOS, M. E.; TRIGUEIRO, T. N. S.; ARAÚJO, L. L. F. **Manifestações patológicas no concreto armado**. Revista Mangaio Acadêmico, João Pessoa, v. 6, n. 2. 105-120 (2021), dezembro/2021.

CAVALCANTI, W. X. **Identificação das manifestações patológicas em fachadas utilizando o veículo aéreo não tripulado – vant**. Orientador. Prof. MsC. Professor Diogo; Prof. MsC professor Glauber Carvalho, 2022. Trabalho de Conclusão de Curso (Graduação em engenharia civil) – Universidade Católica de Pernambuco, Recife, 2022.

CIMIRRO, J. L. Da S. **Reconhecimento de imagens: uso do método yolo no reconhecimento de placas de trânsito**. Orientador: Gerson Alberto Leiria Nunes, 2022. Trabalho de Conclusão de Curso (Graduação em engenharia da computação) - Universidade Federal do Pampa, Bagé, 2022.

FREITAS, C. **Dataset e corpus**. *Processamento de Linguagem Natural, Conceitos, Técnicas e Aplicações em português*. In. CASELI, H. M. (Org); NUNES, M. G. V (Org.). 1ª edição. Brasil, 2023. Cap. 14, p. 228.

LOPES. M. F. L; SOUZA, A. L. R.; SOUZA, M.; SILVA, L. S.; BAUER, E. **Estudo da degradação de fachadas revestidas de argamassa utilizando aeronave remotamente pilotada (rpa)**. XIV SBTA (Simpósio Brasileiro de Tecnologia das Argamassas), João Pessoa, Out/2023.



LOPES, M. L. F.; BAUER, E.; SILVA, L. S. **Utilização de aeronave remotamente pilotada (rpa) para a inspeção e o mapeamento de danos.** Congresso de construção civil, Nov/2022. Disponível em: <<https://www.scielo.br/j/ac/a/YZKpYMZ5nVMSXDnXf6RFWnR/?format=pdf&lang=pt>>. Acesso em: 06/04/2024.

Regulamento brasileiro da aviação civil rbac-e nº 94 emenda nº 03. ANAC, 2023. Disponível em: <<https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94>>. Acesso em: 06/04/2024.

SOUZA, V. C.; RIPPER, T. **Patologia, recuperação e reforço de estruturas de concreto.** 1ª edição, São Paulo: Pini, 1998.