



17ª Edição do Prêmio ABRAFAC

Melhores do Ano

São Paulo - Brasil

Reconhecimento e classificação de oxidações em estruturas metálicas de telhados industriais com utilização de inteligência artificial

João Claudio NOGUEIRA^{1,2,a}

¹ Universidade Federal do Paraná – UFPR, Curitiba, Paraná, Brasil

² Robert Bosch Ltda., Curitiba, Paraná, Brasil

^a Autor correspondente, e-mail: joaoclaudio.nogueira@br.bosch.com

RESUMO

O custo médio anual mundial investido em manutenção de infraestruturas devido a oxidações é estimado como sendo na ordem de trilhões de dólares. Quando ocorrem em indústrias, falhas devido à oxidação podem trazer inúmeros prejuízos à produção industrial, interrompendo processos por conta de infiltração de água, danos à telhados e o colapso de estruturas, gerando até mesmo acidentes graves colocando em risco a saúde e segurança de colaboradores. Neste trabalho, será detalhado o desenvolvimento de uma inteligência artificial para o reconhecimento e classificação de oxidações em telhados industriais através de imagens obtidas automaticamente por veículo aéreo não tripulado (drone) e um estudo de caso aplicado a falhas de oxidação em coberturas metálicas em uma unidade fabril. O objetivo do desenvolvimento desta IA é ser mais assertivo e eficiente no direcionamento dos esforços para a manutenção de oxidações em telhados industriais, uma vez que a mão de obra especializada para a inspeção e realização deste serviço tem alto custo e demanda bastante tempo, além de ser uma atividade que inerentemente têm diversos riscos atrelados, devidos por exemplo, à realização de trabalhos em altura. Análise de fatores de voo como altura e velocidade foram realizadas com auxílio do experimento Taguchi, diferentes tipos de processamento dos dados de entrada (imagens) são avaliados. A principal contribuição deste trabalho é fornecer uma alternativa eficiente e inteligente para a inspeção preventiva de estruturas que compõem a cobertura de prédios industriais, elevando a confiabilidade destas estruturas, promovendo maior continuidade de linhas de produção e elevando a segurança à saúde dos colaboradores neles inseridos.

Palavras-chave: Manutenção, Corrosão, Inteligência Artificial, Facility Management, Indústria 4.0

1. INTRODUÇÃO

Nos dias de hoje, devido aos grandes avanços tecnológicos, modernização de processos e aos componentes elétricos e eletrônicos, os recursos digitais disponíveis para solução de problemas são cada vez mais acessíveis e práticos. Os ganhos com a utilização de equipamentos modernos, sensores e equipamentos eletrônicos são enormes e possibilitam criar soluções inovadoras para problemas que vão desde os mais simples até os mais complexos.

A corrosão é um problema estrutural causado pelo processo destrutivo natural e não intencional de um metal (Callister, William D., 2018). Este problema está presente em todo o globo terrestre e estima-se que só nos Estados Unidos os custos anuais relacionados à corrosão sejam de mais de 1 trilhão de dólares (G2MT Labs, 2015). O uso de técnicas adequadas de controle e prevenção podem reduzir por volta de 15 a 35% os custos provenientes de falhas causadas por corrosão (Koch et al, 2016). Devido à ampla presença de metais em máquinas e instalações no ambiente industrial, a corrosão é um problema muito presente nas fábricas, e os custos atrelados a estes tipos de falhas neste cenário causam prejuízos materiais, risco à segurança de pessoas e prejuízos financeiros enormes devidos à interrupção de processos produtivos. Entre as diversas infraestruturas metálicas presentes na indústria, a cobertura é um dos componentes chave para a continuidade dos processos, pois protege pessoas e maquinários das intempéries e agentes naturais externos.

Os avanços da capacidade de processamento dos computadores hoje nos permitem realizar a automatização de processos, não só de maneira repetitiva, mas os computadores podem lidar também com situações adversas e tomar decisões por conta própria. Grandes cases atuais observáveis são, por exemplo, a automação da condução de veículos, tendo estes sistemas com capacidade de tomada de decisão por diversas vezes até mesmo superior à dos seres humanos. A capacidade de um computador ou sistema de tomar decisões por conta própria e realizar tarefas adversas sem a necessidade de intervenção humana é chamada de Inteligência Artificial (Howard, 2019), e é utilizada na automatização de processos que normalmente seria performada por uma pessoa.

No trabalho a seguir, será detalhado o desenvolvimento de uma inteligência artificial destinada ao reconhecimento e classificação de oxidações em coberturas de duas plantas industriais Robert Bosch, a primeira localizada na Cidade Industrial de Curitiba, Paraná, e a segunda localizada na cidade de Campinas, São Paulo. Alguns dos métodos serão temas discussão, como a análise do grau de impacto total dos componentes e falhas do telhado, a análise dos parâmetros de voo para captação das imagens e a performance da IA desenvolvida.

2. MATERIAIS E MÉTODOS

2.1 Aquisição de Dados

As imagens utilizadas neste trabalho foram capturadas com o auxílio de diferentes drones. O primeiro, um Matrice 200 da DJI®, aeronave de aproximadamente 4,5 kg, com alcance de comunicação de até 7 km e velocidade máxima de 55 km/h, equipado com uma câmera DJI® Zenmuse x4S de 20 MP, sensor de 1 polegada, lentes de 24 mm e campo de visão de 84°. O segundo, um DJI® Mavic 2 Enterprise Advanced, aeronave de aproximadamente 1,1 kg, com alcance de comunicação de até 10 km, velocidade máxima de 72 km/h, equipado com uma câmera DJI® de 48MP, sensor de ½ polegada, lentes de 24 mm e campo de visão de 84°.

As imagens capturadas são de duas plantas industriais Robert Bosch, a primeira delas com 86.691 m² de área construída ao longo de 31 prédios, localizada na cidade de Curitiba, Paraná, Brasil. A segunda planta industrial localiza-se na cidade de Campinas, São Paulo, Brasil, com um total de 163.066 m² de área construída ao longo de 20 prédios, totalizando 249.757 m² de área de construções capturada em imagens. Além disso, as imagens foram capturadas mantendo-se o ângulo das câmeras equipadas nos drones a todo momento perpendiculares às coberturas, à uma velocidade de 25 km/h, a 37 metros de altura e sempre durante o dia, por conta da presença de maior luminosidade e clareza de imagens.

2.2 Formulação do problema

A realização deste trabalho foi motivada pela constatação do aumento de número de ocorrências e falhas relacionadas à infiltração de água através de estruturas da cobertura de prédios fabris. Para determinar quais são os componentes da cobertura e as falhas que estes podem sofrer, foi utilizada uma técnica chamada de Manutenção das Condições Básicas (MDCB), técnica amplamente utilizada no processo de Manutenção Preventiva Total (TPM). A MDCB relaciona os componentes do equipamento com suas falhas, bem como os respectivos problemas devido à falha, as causas, e o Grau de Impacto Total (GIT). Na tabela a seguir está relacionada a MDCB com o GIT, indicando quanto a função do equipamento é comprometida devido às falhas funcionais:

Tabela 1: MDCB das coberturas

MODO DE FALHA			APARENTE/FUNCIONAL	PRODUÇÃO	PROPAGAÇÃO	QUALIDADE	SEGURANÇA	CUSTO	FREQUÊNCIA	GRAU TOTAL
COMPONENTE	PROBLEMA	CAUSA								
Viga calha	Obstruído	Acúmulo de sujeidade	A							0
	Transbordo	Acúmulo de sujeidade	A							0
	Quebrada	Sobreuso	F	0	3	0	0	2	1	6
	Oxidação	Sobreuso	F	0	3	0	0	2	1	6
	Infiltração	Agentes externos	A							0
	Infiltração	Sobreuso	F	3	3	1	2	2	1	12
Dreno vertical	Vedação deteriorada	Sobreuso	F	0	3	0	0	2	1	6
	Rachado	Sobreuso	F	0	0	3	0	2	1	6
	Rachado	Agentes externos	A							0
	Obstruído	Acúmulo de sujeidade	A							0
	Vedação deteriorada	Agentes externos	A							0
	Obstruído	Falta de componentes	F	0	3	0	0	2	1	6
Flanges do dreno	Vazamento	Sobreuso	F	0	3	0	0	2	1	6
Grade do dreno	Transbordo	Acúmulo de sujeidade	A							0
Terminais de ventilação	Infiltração	Colarinho corroído	F	3	3	2	1	2	1	12
	Infiltração	Má vedação	F	3	3	2	1	1	1	11
	Solto	Má fixação	F	0	3	0	3	0	1	7
	Solto	Oxidação	F	0	3	0	3	0	1	7
	Oxidação	Sobreuso	F	3	3	1	3	2	1	13
	Vazamento de óleo	Excesso de exaustão	F	1	0	1	0	0	1	3

	Vazamento de óleo	Filtro saturado	F	1	0	1	0	1	1	4
	Cabos soltos	Fixação solta	F	0	1	0	0	0	1	2
Rufo	Quebrado	Chapada deteriorada	F	0	3	0	3	2	1	9
	Oxidação	Sobreuso	F	2	3	0	0	2	2	9
Telha	Trincada	Agentes externos	A							0
	Quebrada	Agentes externos	A							0
	Quebrada	Sobreuso	F	3	2	0	1	0	1	7
	Solta	Má fixação	F	3	2	0	1	0	1	7
	Solta	Oxidação	F	3	2	0	1	0	1	7
Clarabóia	Trincada	Sobreuso	F	3	2	0	1	0	1	7
	Solta	Má fixação	F	3	2	0	1	0	1	7
	Solta	Má instalação	A							0
	Quebrada	Agentes externos	A							0
	Solta	Oxidação	F	3	2	0	1	0	1	7
Fixação	Oxidação	Sobreuso	F	0	0	0	0	0	1	1
	Malha solta	Oxidação	F	0	0	0	0	0	1	1
	Malha solta	Fixação quebrada	F	0	0	0	0	0	1	1
	Malha solta	Fixação quebrada	A							0
	Malha solta	Fixação solta	F	0	0	0	0	0	0	1
	Malha solta	Fixação solta	A							0
	Solta	Oxidação	F	0	3	0	3	0	1	7
	Solta	Má instalação	A							0
Eletrodos	Alta impedância	Barras mal enterradas	A							0
	Alta impedância	Oxidação	F	0	1	0	1	1	1	4
Conexões	Alta impedância	Solda ruim	A							0
	Alta impedância	Oxidação	F	0	0	0	2	0	1	3
Malha de aterramento	Alta impedância	Oxidação	F	0	3	0	3	1	1	8
	Alta impedância	Condutores rompidos	F	0	3	0	3	1	1	8
	Alta impedância	Solo seco	A							0
	Não equipotencializada	Má conexão de partes metálicas	A							0
	Não equipotencializada	Má conexão de partes metálicas	F	0	2	0	2	0	1	5
	Não equipotencializada	Condutores rompidos	F	0	2	0	2	1	1	6
	Não equipotencializada	Condutores rompidos	A							0
Pára-raios	Caído	Agentes externos	A							0
	Caído	Fixação solta	F	0	3	0	3	0	1	7
	Caído	Fixação solta	A							0
Cabo de aço	Malha violada	Sobreuso	F	0	3	0	3	0	1	7
	Malha violada	Excesso de aperto	A							0

O GIT é elaborado com uma somatória de pontuações dos aspectos relevantes para o planejamento e gestão das infraestruturas, os critérios e pontuações estão relacionados na tabela a seguir:

Tabela 2: Critérios de pontuação do GIT

CRITÉRIOS DE PRIORIZAÇÃO
PRODUÇÃO

GRAU	0	Nenhum efeito ou consequência
	1	Parada do processo \leq 2 horas
	2	2 horas < Parada do processo \leq 8 horas
	3	Parada do processo > 8 horas
PROPAGAÇÃO		
GRAU	0	Nenhum efeito ou consequência - Baixo custo (\leq R\$500,00)
	1	Parada do processo \leq 3 horas - Médio custo (R\$500 < Custo \leq R\$5000,00)
	2	3 horas < Parada do processo \leq 8 horas - Alto custo (R\$5000 < Custo \leq R\$40.000)
	3	Parada do processo > 8 horas - Altíssimo custo (> R\$ 40.000)
QUALIDADE		
GRAU	0	Nenhum efeito ou consequência
	1	Quantidade de produtos defeituosos \leq 5%
	2	Quantidade de produtos defeituosos > 5%
	3	Defeito percebido pelo cliente final
SEGURANÇA E MEIO AMBIENTE		
GRAU	0	Nenhum efeito ou consequência
	1	Danos leves \leq R\$20.000
	2	R\$20.000 < Danos graves \leq R\$60.000
	3	Danos gravíssimos > R\$60.000
CUSTO DE REPARO		
GRAU	0	Baixo custo (\leq R\$400)
	1	Médio custo (R\$400 < Custo \leq R\$4.000)
	2	Alto custo (R\$4000 < Custo \leq R\$40.000)
	3	Altíssimo custo (>R\$40.000)
FREQUÊNCIA DA OCORRÊNCIA		
GRAU	1	Ocasional (1 < Falhas por ano \leq 4)
	2	Provável (4 < Falhas por ano \leq 12)
	3	Frequente (> 12 Falhas por ano)

Como pode-se observar, uma grande parcela das falhas funcionais é causada pela oxidação dos componentes metálicos que compõem a cobertura, como vigas calha, terminais de ventilação e rufos. Além disso, constata-se que a falha que obteve maior pontuação no GIT é causada por oxidação. Na figura a seguir, é possível observar exemplos de componentes do sistema (cobertura) sujeitas a oxidação, bem como consequências e problemas oriundos de falhas funcionais causadas por oxidação.

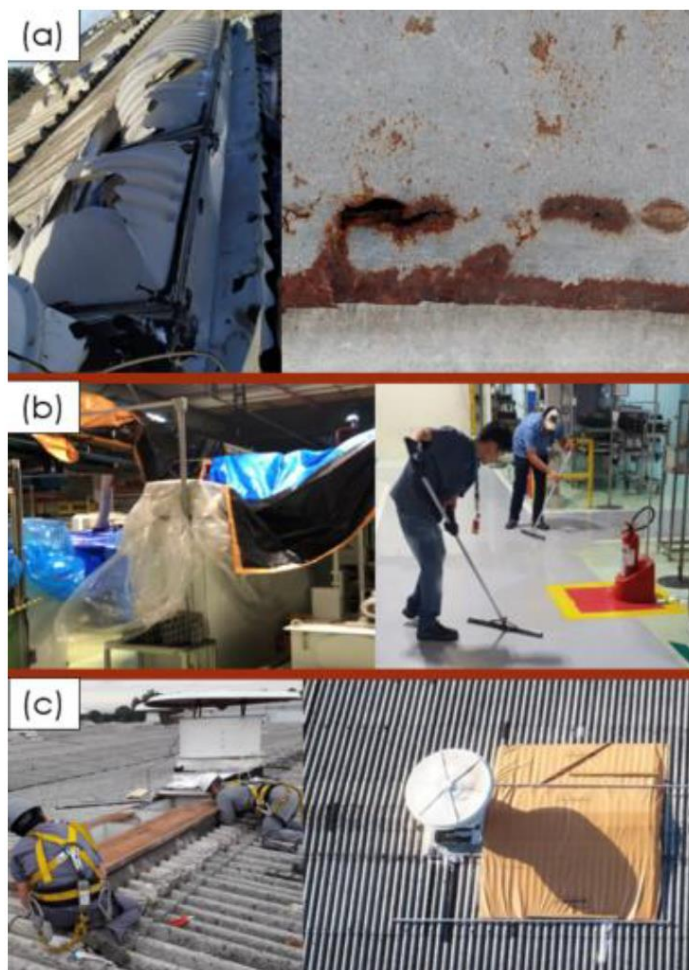


Figura 1: (a) Componentes da cobertura que estão sujeitas à oxidação. (b) Ações de contenção necessárias para lidar com infiltração de água em áreas fabris. (c) Ações corretivas necessárias

As principais consequências devidas a este tipo de falha são perdas enormes no faturamento, devido à necessidade da interrupção de processos fabris para ações corretivas, como a interdição do local, objetivando a segurança das pessoas e a integridade de equipamentos. Levando em consideração todos estes fatos, faz-se necessária ações de manutenção preventiva eficientes que evitem o acontecimento destas falhas.

Devido à magnitude de área construída (249.757 m²), a manutenção preventiva de coberturas pode-se mostrar dispendiosa por conta da necessidade de mão de obra especializada e tempo necessário para a realização de inspeções, bem como os riscos envolvidos neste tipo de atividade, pois estes serviços envolvem trabalhos em altura (altura de trabalho > 2 m). Apenas para a manutenção preventiva da unidade fabril de Curitiba por exemplo, estima-se uma necessidade anual de recursos de aproximadamente R\$ 148.800,00 investidos em inspeção. A tabela a seguir exhibe a comparação entre os custos do estado atual e o estado futuro, após desenvolvimento e implementação deste trabalho:

Tabela 3: Comparativo entre os custos anuais investidos em inspeção de coberturas fabris da unidade de Curitiba, e estado futuro após implementação deste trabalho

Dados relacionados	Estado atual	Estado futuro
Quantidade de prédios	31	31
Tempo médio necessário para realizar inspeção [hh:mm]	02:00	00:02

Quantidade total de horas necessárias à inspeção de todos os prédios [hh:mm]	62:00	01:02
Quantidade de inspeções anuais	48	365
Custo por hora de inspeção [H/H]	50,00	0
Gastos anuais com inspeção [R\$]	148.000,00	15.000,00
Custo da análise do planejador de manutenção [R\$]	4.464,00	0
Custo análise/inspeção drone + IA [R\$/h]	101,00	41,09

Ressalta-se ainda que os valores são relacionados ao ano de 2021, ou seja, não considerando correções monetárias para a situação atual (podendo ser ainda maiores).

Por isto, este projeto foi desenvolvido como uma solução inteligente para a área de Facilities, onde a proposta é o desenvolvimento de uma Inteligência Artificial que através de uma rede neural convolucional detecta e classifica falhas de oxidação em coberturas de prédios fabris. As imagens para análise da IA são captadas por meio de veículos aéreos não-tripulados (popularmente conhecidos como drones), oferecendo maior agilidade e menores custos ao processo de inspeção. As imagens, após serem processadas e analisadas pela IA, serão materiais para a elaboração de um relatório de levantamento, contendo os pontos críticos e o grau de cada ocorrência de oxidação. Os objetivos são uma redução expressiva dos custos anuais investidos nas manutenções preventivas de inspeção, como mostrado anteriormente, além dos ganhos de segurança, uma vez que não é necessário que pessoas se exponham aos riscos de subir em telhados.

2.3 Arquitetura da inteligência artificial

A inteligência artificial é a capacidade de computadores e sistemas realizarem tarefas e tomar decisões de forma autônoma sem necessitar a intervenção humana, e seu funcionamento multidisciplinar envolve, por exemplo, lógica, estatística, neurociência, sensoriamento e engenharia de computação (Howard, 2019). A visão computacional é uma subárea dentro da IA que executa o processamento de imagens e vídeos. Essa tecnologia permite ao computador identificar objetos e suas características, reconhecendo padrões, assim como os seres humanos. Neste processo, a rede neural convolucional é uma técnica de visão computacional que extrai características visuais fundamentais dos objetos e permite o reconhecimento de imagens, sendo utilizada em uma série de aplicações como detecção de pessoas ou objetos, reconhecimento facial e comparação de características (Deshpande, 2016). Como exemplo, para nós seres humanos é fácil identificar um automóvel por conta de suas características visuais. Uma inteligência artificial precisa ser treinada para reconhecer padrões visuais, e entender que um objeto que se move e tem quatro rodas muito provavelmente é um carro. Mas, para uma inteligência artificial treinada para reconhecer carros convencionais, se este tiver por exemplo mais um eixo de rodas, a IA poderá não saber identificar o que ela está visualizando. Estes exemplos foram trazidos para evidenciar o quão complexo pode ser para uma IA reconhecer uma oxidação, pois é algo que não tem características bem definidas como tamanho, cor, localização ou formato.

Dentro de todo este contexto, está inserido o aprendizado de máquinas, onde sistemas aprendem a partir de dados coletados a identificar padrões e tomar decisões, ramificando-se também para o Deep Learning, um dos tipos de aprendizado de máquinas baseado em representações de grupos de dados, onde cada nível deste segmento transforma os dados recebidos em modelos com abstrações de alto nível. Para este trabalho, duas redes neurais

convolucionais U-net foram desenvolvidas, as quais aplicam filtros convolucionais e desconstrução de imagem em diversos níveis para aprender padrões.

A figura 2 ilustra o fluxograma do que é executado pela rede neural convolucional. A primeira camada age como um extrator de recursos, removendo áreas de não interesse (que não sejam coberturas de prédios), reduzindo o custo computacional para análise das imagens. As imagens capturadas originalmente em resolução 5472x3078 ou superior são então subdivididas em múltiplas imagens de 640x640 pixels processadas pela segunda camada. A IA então extrai a informação da imagem, identificando as oxidações, e ao final a imagem é reconstruída com os pontos de oxidação reconhecidos.

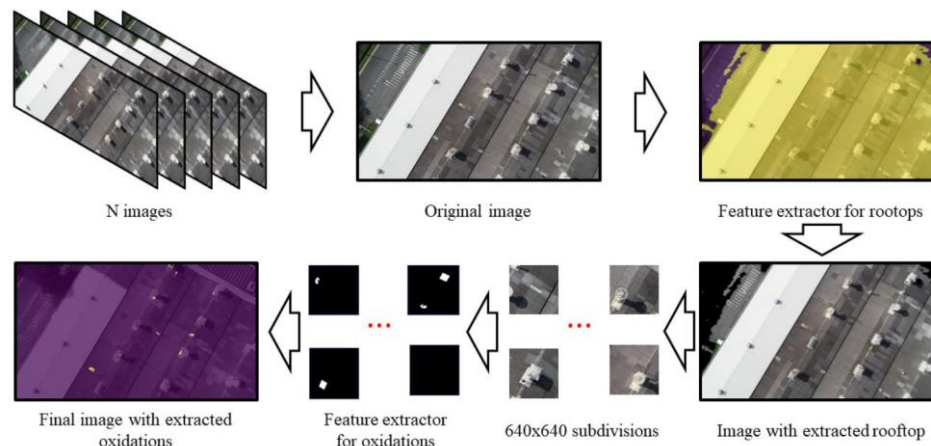


Figura 2: Fluxograma ilustrando o processamento realizado pela IA

3. PARÂMETROS DE VOO

3.1 Velocidade de voo

A velocidade de voo é um importante fator que influencia diretamente as imagens capturadas. Em grandes velocidades, as imagens capturadas podem ficar borradas, gerando dados indesejados e de baixa qualidade. Imagens borradas podem ainda dificultar a delimitação das bordas das oxidações pela IA.

Para determinar a velocidade de voo ótima, foi utilizada a segunda derivada da Laplaciana (equação 1). Esta técnica consiste em encontrar em uma imagem de entrada valores nulos de pixels, onde, tais valores indicam fronteiras entre objetos.

$$\text{Laplace}(f) = \frac{d^2f}{dx^2} + \frac{d^2f}{dy^2} \quad (1)$$

A aplicação desta técnica foi feita objetivando-se conhecer a velocidade máxima que a aeronave pode deslocar-se sem causar distorções e variações na definição das imagens. Na primeira derivada da imagem, as variações de intensidade de pixels tornam-se pontos de máximo local. A segunda derivada aplicada faz com que os pontos que anteriormente eram de máximos locais tornem-se nulos. Desta forma, é possível analisar a variância dos valores de pixels e determinar de maneira concretamente quais velocidades geram imagens com melhores nitidez. A figura 3 ilustra a variância média da Laplaciana obtida em diferentes velocidades.

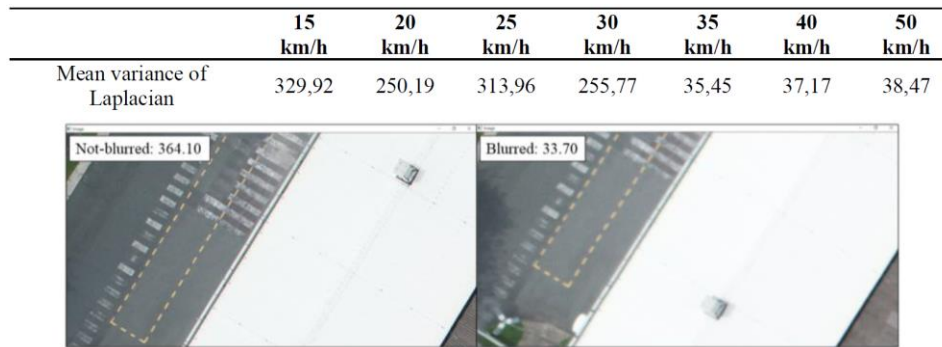


Figura 3: Variâncias médias das Laplaciana em diferentes velocidades e a comparação entre uma imagem não borrada e outra borrada

Um total de 7 diferentes velocidades foram testadas e cada uma gerou 32 imagens para comparação da variância da Laplaciana. É possível observar que até 30 km/h não houve variações consideráveis, e as bordas e formatos ficaram bem definidos. Os valores médios caíram para 35,45 para velocidades de 35 km/h, indicando uma grande redução da qualidade das imagens obtidas.

3.2 Período de voo

Outro fator importante a ser analisado é a iluminação ambiente em que as imagens são capturadas. A diminuição do valor total de luz disponível causa diminuição no contraste e imagens com qualidade inferior, por conta da dificuldade da em câmera focar em ambientes mais escuros.

Para avaliar a dependência da qualidade das imagens com o período do voo, foi elaborado um histograma. A figura 4 ilustra as imagens capturadas em diferentes períodos do dia. Além disso a figura 5 mostra a análise da distribuição de pixels após conversão das imagens para escala de cinza.



Figura 4: Imagens capturadas em diferentes períodos do dia




Figura 5: histograma contendo a análise da escala de cinza das imagens capturadas em diferentes períodos do dia. A linha azul indica os valores acima de 110.000 lux, a laranja mostra os valores para 40.000 lux e a verde ilustra valores para imagens capturadas com 100 lux

3.3 Altura de voo

A fim de analisar a influência da altura na qualidade das imagens, outro histograma contendo diferentes densidade de pixels foi elaborado. A mesma área das imagens foi analisada para diferentes alturas, sendo: 30, 35, 40, 45, 50 e 55 m.

A figura 6 ilustra a comparação das curvas obtidas para estas alturas. É possível observar um deslocamento do espectro de 130 a 160. Enquanto um achatamento é observado também entre 110 e 125, quando a altura de voo foi aumentada. Esta mudança indica uma redução na distinção dos pixels, o que dificulta a identificação de bordas em alturas mais altas.




Figura 6: Comparação entre uma imagem capturada à 30 m, em azul, e outra capturada à 55 m, em laranja

3.3 Análise Taguchi

Após realizados os testes de velocidade, período e altura, a análise Taguchi foi utilizada para avaliar o impacto total de cada parâmetro sob o conjunto de dados obtidos. Para isso, estas variáveis foram analisadas com auxílio do software Minitab®, onde foram permutados os valores de altura de 30, 50 e 80m, a velocidades de 15, 25 e 45 km/h e luminosidades de 140.000, 40.000 e 100 lux. A figura 7 ilustra os resultados obtidos com a análise.

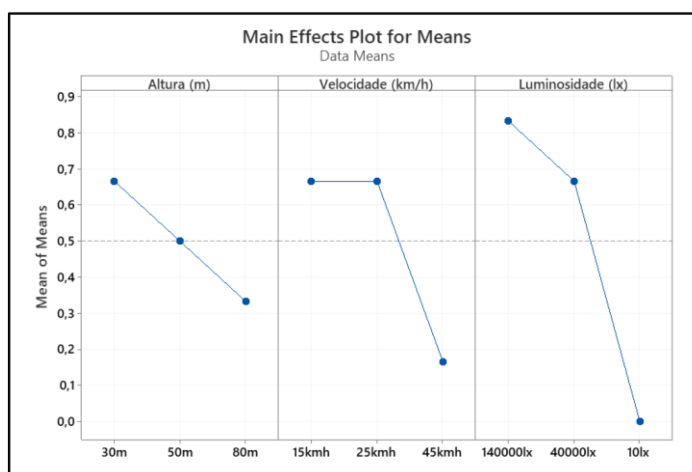


Figura 7: resultados obtidos com a análise Taguchi

A partir dos resultados obtidos, pode-se observar que a altura de voo exibe um perfil linear e a altura de 30 m retornou melhores valores médios. Nenhuma variância significativa foi observada quando a velocidade de voo foi alterada de 15 a 25 km/h, mas para velocidades superiores a 45 km/h observa-se uma grande diminuição da qualidade dos dados coletados. Além disso, os melhores resultados retornaram em iluminâncias de 110.000 lux, indicando que a qualidade de imagem sofre grande influência pela iluminância do ambiente no

momento das capturas. Pode-se ainda observar que para valores abaixo de 40.000 lux há uma diminuição acentuada da qualidade das imagens capturadas pela aeronave.

4. RESULTADOS E DISCUSSÕES

4.1 Performance da IA

A inteligência artificial desenvolvida neste trabalho é composta por duas redes neurais convolucionais U-net distintas, uma para detectar e identificar telhados e outra para a detecção das oxidações. A IA foi então treinada com quatro diferentes arranjos, e submetida à duas baterias de testes distintas. Essa mudança de arranjos e cenários é necessária para avaliar a performance individual de cada parâmetro e as influências destes na IA como um todo.

Na figura 8 é possível observar os resultados de predição obtidos pelo treinamento da IA com os quatro diferentes arranjos, sendo os testes de predição realizados no cenário de Curitiba (Ctp). Uma pequena redução dos valores de Q1 e Q3 é observável quando o treinamento para detecção dos telhados realizado com o dataset de Campinas (Cap) é adicionado à IA. Na figura 9 é possível observar que as maiores alterações na predição acontecem quando quando a fase de treinamento de detecção de telhados e oxidações é realizada em Curitiba e testada em Campinas, onde a mediana das predições sofreu uma redução de 0.55 para 0.51. Esta redução pode indicar um possível “vício” da IA no cenário de Curitiba, fazendo com que seu desempenho seja menor quando submetida à um cenário onde não foi treinada, mas por conta da complexidade do problema e dos valores de desvio obtidos, maiores evidências são necessárias.

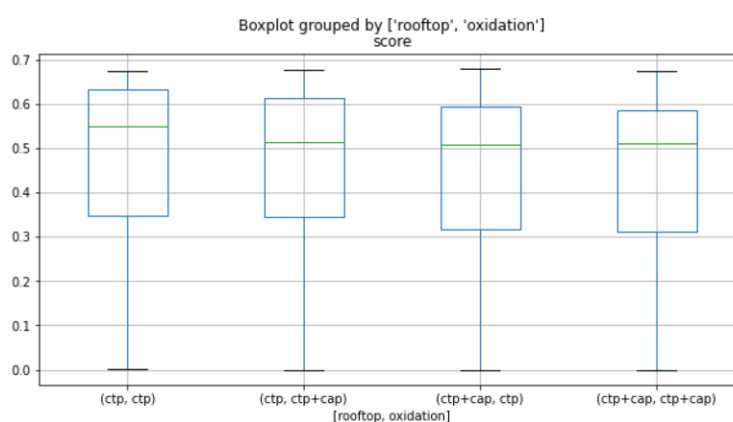


Figura 8: Boxplot dos arranjos do processo de validação da IA utilizando imagens da planta de Curitiba. O eixo x mostra quais dados foram utilizados no processo de treinamento no formato (telhado, oxidações). O eixo y representa a pontuação obtida pela IA

Arrangement	Rooftop	Oxidation	Mean	Median	Std. deviation
1A	Ctp	Ctp	0.458	0.549	0.230
2A	Ctp	Ctp + Cap	0.442	0.512	0.230
3A	Ctp + Cap	Ctp	0.429	0.509	0.232
4A	Ctp + Cap	Ctp + Cap	0.433	0.510	0.219

Figura 9: Média, mediana e desvio padrão das pontuações obtidas pela IA quando treinada com os dados de Curitiba

Então a segunda rodada de testes foi realizada, onde a IA validada com o dataset de Campinas, permutando os dados de treinamentos com ambos os datasets. A figura 10 ilustra os resultados obtidos. Devido às diferentes arquiteturas presentes entre as localidades, a IA tem uma menor performance quando treinada apenas com dados de Curitiba, observável na

figura 11. Esta menor performance é devida à incapacidade da IA de generalizar os dados e identificar os padrões quando submetida a diferentes arquiteturas de construção. Quando os dados de Campinas são inseridos ao treinamento, é possível observar um aumento da performance da IA.

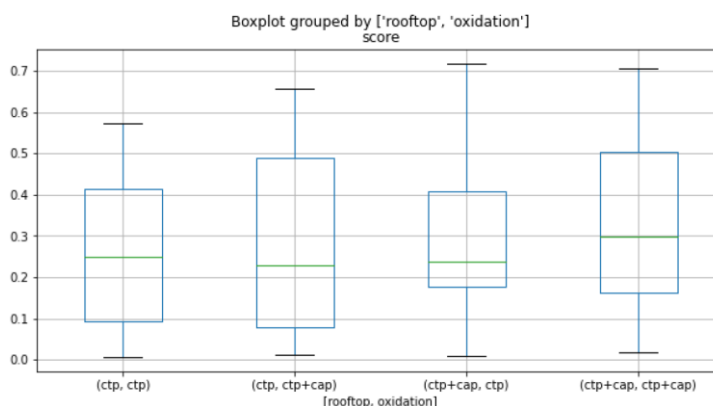


Figura 10: Boxplot dos arranjos do processo de validação da IA utilizando imagens da planta de Campinas. O eixo x mostra quais dados foram utilizados no processo de treinamento no formato (telhado, oxidações). O eixo y representa a pontuação obtida pela IA

Arrangement	Rooftop	Oxidation	Mean	Median	Std. deviation
1B	Ctp	Ctp	0.257	0.249	0.185
2B	Ctp	Ctp + Cap	0.284	0.229	0.223
3B	Ctp + Cap	Ctp	0.295	0.238	0.221
4B	Ctp + Cap	Ctp + Cap	0.331	0.298	0.222

Figura 11: Média, mediana e desvio padrão das pontuações obtidas pela IA quando treinada com os dados de Campinas

Quando comparando os arranjos 1B e 2B, o primeiro quartil não sofre grandes variações, bem como o valor de Q2. Quando adicionado informações de oxidação de Campinas na fase de treinamento, a IA foi capaz de obter maiores pontuações, uma vez que sua capacidade de generalização aumentou, resultando em um aumento no valor máximo. O fato da IA não ter sido treinada no cenário 2B com os dados de Campinas interferiu em sua performance, por conta das diferenças construtivas dos prédios. A IA não foi capaz de por exemplo, encontrar alguns telhados, o que impactou na segmentação de oxidações.

Examinando o arranjo 3B, os valores obtidos foram maiores quando comparados com 1B e 2B, o que indica o aumento da performance da IA quando adicionado os dados de Campinas durante o treinamento. No arranjo 4B, quando os dados de Campinas foram adicionados ao treinamento da IA para encontrar telhados e oxidações, observa-se que o Q1 manteve o resultado obtido no arranjo 3B, enquanto o Q3 aumentou. Este aumento indica não somente a grande diferença de padrões de infraestrutura presentes nas diferentes localidades, como também a diferença de padrões de oxidação. A figura 12 ilustra um exemplo da performance obtida pela melhor IA, treinada com dados de Campinas e Curitiba. Neste exemplo, a IA obteve um score de 0,706 para uma imagem da planta de Campinas, sendo capaz até mesmo de segmentar a maioria das áreas contendo oxidações. A figura 13 mostra outro teste, onde a IA obteve um score de 0,525. Apesar do score menor quando comparado aos resultados observáveis na figura 12, a IA foi capaz de segmentar mais oxidações do que a operação manual de indicação de localização de oxidação feita por um profissional.




Figura 12: ilustração da performance da IA. À esquerda a imagem a olho nu, ao centro o processo de “ensinar” à IA as oxidações, à direita a constatação feita pela IA



Figura 13: ilustração da performance da IA. À esquerda a imagem a olho nu, ao centro o processo de “ensinar” à IA as oxidações, à direita a constatação feita pela IA com segmentações ainda maiores do que lhe foi indicada

5. CONCLUSÕES

Neste trabalho, uma inteligência artificial capaz de detectar e classificar oxidações em coberturas de prédios fabris foi desenvolvida, os cenários são duas plantas industriais da Robert Bosch. Testes foram realizados para avaliar a performance da inteligência artificial. O treinamento da IA foi feito com imagens obtidas nas plantas industriais Robert Bosch de Curitiba e Campinas, e a IA foi submetida a etapas de validação e testes. A fim de encontrar os melhores parâmetros para aquisição de dados, uma análise Taguchi foi realizada, onde concluiu-se que os melhores resultados são obtidos quando a altura de voo é de 30 m, a velocidade de deslocamento é de 25 km/h e a iluminância é de 110.000 lux.

A inteligência artificial foi capaz de encontrar oxidações em ambas as plantas industriais, mas algumas limitações foram observadas. O problema ao qual a IA é submetida é complexo, por conta da grande gama de diferenças de características de uma oxidação à outra, bem como a particularidade das arquiteturas dos prédios presentes em diferentes localidades. O aprimoramento da IA é possível, sendo necessários mais cenários e conjuntos de dados, aumentando a sua capacidade de generalização.

Este trabalho acadêmico foi desenvolvido com objetivo da obtenção do grau de mestre em Engenharia de Manufatura pela Universidade Federal do Paraná. Os ganhos que este projeto pode trazer à área de facilities são enormes, uma vez que a inspeção de telhados industriais se torna rápida, ágil, mais barata e mais segura. Atualmente o projeto tem número de inscrição de patente registrada e, recentemente foi aprovado e será apresentado na conferência do International Society of Transdisciplinary Engineering, evento internacional patrocinado pelo Massachusetts Institute of Technology (MIT).

6. REFERÊNCIAS

Callister, William D., and David G. Rethwisch. “*Materials science and engineering: an introduction.*” Vol. 9. New York: Wiley, 2018.

Deshpande, Adit (2016). *A Beginner's Guide To Understanding Convolutional Neural Networks* [online]. Disponível em: <https://adeshpande3.github.io/A-Beginner's-Guide-To-Understanding-Convolutional-Neural-Networks/>.

G2MT Labs (2015). *Corrosion will cost the US economy over \$1.1 trillion in 2016* [online]. Disponível em: <https://www.g2mtlabs.com/cost-of-corrosion/>

Howard, John. "Artificial intelligence: Implications for the future of work." *American Journal of Industrial Medicine* 62.11 (2019): 917-926.

Koch, Gerhardus. "Cost of corrosion." *Trends in oil and gas corrosion research and technologies* (2017): 3-30.