

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
CÂMPUS DE DOIS VIZINHOS  
CURSO DE ESPECIALIZAÇÃO EM CIÊNCIA DE DADOS

ANA LETÍCIA LOPES TITO

**MELHORIAS AO PROCESSO DE PINTURA AUTOMOTIVA POR  
MEIO DE TÉCNICAS DE MACHINE LEARNING**

TRABALHO DE CONCLUSÃO DE CURSO

DOIS VIZINHOS  
2022

ANA LETÍCIA LOPES TITO

## MELHORIAS AO PROCESSO DE PINTURA AUTOMOTIVA POR MEIO DE TÉCNICAS DE MACHINE LEARNING

Trabalho de Conclusão de Curso apresentado ao Curso de Especialização em Ciência de Dados da Universidade Tecnológica Federal do Paraná, como requisito para a obtenção do título de Especialista em Ciência de Dados.

Orientador: Prof. Dr. Marcelo Teixeira

DOIS VIZINHOS  
2022



4.0 Internacional

Esta licença permite remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

ANA LETÍCIA LOPES TITO

**MELHORIAS AO PROCESSO DE PINTURA AUTOMOTIVA POR  
MEIO DE TÉCNICAS DE MACHINE LEARNING**

Trabalho de Conclusão de Curso apresentado ao Curso de Especialização em Ciência de Dados da Universidade Tecnológica Federal do Paraná, como requisito para a obtenção do título de Especialista em Ciência de Dados.

Data de aprovação: 24/fevereiro/2022

Marcelo Teixeira

Doutorado

Universidade Tecnológica Federal do Paraná - Câmpus Pato Branco

Dalcimar Casanova

Doutorado

Universidade Tecnológica Federal do Paraná - Câmpus Pato Branco

Jefferson Tales Oliva

Doutorado

Universidade Tecnológica Federal do Paraná - Câmpus Pato Branco

DOIS VIZINHOS  
2022

## **AGRADECIMENTOS**

Agradeço ao Cristian Pastro e à Renault do Brasil pelo apoio no desenvolvimento deste projeto e ao professor Dr. Marcelo Teixeira pela orientação e auxílio nos momentos de dificuldades.

## RESUMO

TITO, Ana Letícia. Melhorias ao processo de pintura automotiva por meio de técnicas de machine learning. 2022. 21 f. Trabalho de Conclusão de Curso – Curso de Especialização em Ciência de Dados, Universidade Tecnológica Federal do Paraná. Dois Vizinhos, 2022.

A automação da pintura automotiva é um processo complexo, composto por múltiplas etapas que aplicam camadas sensíveis de pintura na carroceria do veículo, de forma ordenada. Cada camada possui um propósito particular podendo este ser proteção ou aspectos visuais finais. Devido à interdependência entre as camadas de pintura, erros em etapas iniciais comprometem as subsequentes. Com isso, no momento em que o veículo passar pela inspeção de qualidade, este poderá ser reprovado por não estar de acordo com os padrões de qualidade exigidos, sendo enviado para retrabalho, gerando custos, no domínio automotivo, de impacto substancial. Este artigo apresenta uma abordagem de *machine learning* para identificar possíveis oportunidades de redução de custos no processo de pintura automotiva, que possam resultar em má formação do produto final. A abordagem é implementada usando técnicas de clusterização, e aplicada sobre uma base de dados reais de um processo de pintura da Renault.

**Palavras-chave:** Pintura automotiva. Ciência de dados. Automação inteligente.

## ABSTRACT

Automotive paint automation is a complex process, consisting of multiple steps that apply sensitive layers of paint to the vehicle body in an orderly manner. Each layer has a particular purpose, which can be protection or final visual aspects. Due to the interdependence between paint layers, errors in early stages compromise subsequent ones. Thus, when the vehicle is submitted to the quality inspection, it may be disapproved for not meeting the required quality standards, being sent for rework, generating costs, in the automotive domain, of substantial impact. This article presents a *machine learning* approach to identify possible cost reduction opportunities in the automotive painting process, which could result in poor formation of the final product. The approach is implemented using clustering techniques, and applied to a real database of a Renault painting process.

**Keywords:** Automotive paint; Data Science; Smart automation.

## LISTA DE FIGURAS

|                                                                                         |    |
|-----------------------------------------------------------------------------------------|----|
| Figura 1 – Pintura robotizada . . . . .                                                 | 12 |
| Figura 2 – Pontos do capo do veículo modelo L52 . . . . .                               | 13 |
| Figura 3 – Fluxograma da metodologia . . . . .                                          | 14 |
| Figura 4 – Relação da diferença de espessura entre pontos opostos - Julho . . . . .     | 16 |
| Figura 5 – Clusterização dos resultados - Julho . . . . .                               | 16 |
| Figura 6 – Relação da diferença de espessura entre pontos opostos - Setembro . . . . .  | 17 |
| Figura 7 – Clusterização dos resultados - Setembro . . . . .                            | 17 |
| Figura 8 – Relação da diferença de espessura entre pontos opostos - Outubro . . . . .   | 18 |
| Figura 9 – Clusterização dos resultados - Outubro . . . . .                             | 18 |
| Figura 10 – Relação da diferença de espessura entre pontos opostos - Novembro . . . . . | 19 |
| Figura 11 – Clusterização dos resultados - Novembro . . . . .                           | 19 |

## LISTA DE QUADROS

|                                                                   |    |
|-------------------------------------------------------------------|----|
| Quadro 1 – Evolução do processo de pintura. . . . .               | 11 |
| Quadro 2 – Faixas de custo estabelecidas para comparação. . . . . | 15 |



## SUMÁRIO

|     |                                   |    |
|-----|-----------------------------------|----|
| 1   | INTRODUÇÃO . . . . .              | 9  |
| 1.1 | ORGANIZAÇÃO DO TRABALHO . . . . . | 10 |
| 2   | REVISÃO DE LITERATURA . . . . .   | 11 |
| 3   | METODOLOGIA . . . . .             | 14 |
| 4   | DISCUSSÃO . . . . .               | 16 |
| 5   | CONCLUSÃO . . . . .               | 20 |
| 5.1 | LIMITAÇÕES . . . . .              | 20 |
| 5.2 | TRABALHOS FUTUROS . . . . .       | 20 |
|     | REFERÊNCIAS . . . . .             | 21 |

## 1 INTRODUÇÃO

A indústria de pintura automotiva passa por mudanças no desenvolvimento de materiais e processos seguido por um progresso da tecnologia de manufatura do início do século XX até os dias de hoje. O início do processo envolvia uso de pinturas que secavam ao ar livre, a cada camada e polimento, levando semanas para completar e sendo totalmente manual. A introdução da produção em massa passou a exigir pinturas mais rápidas, melhores performances dos filmes nas camadas em termos de corrosão e durabilidade das cores, compatibilidade ambiental e um processo quase totalmente automatizado para características mais acuradas (STREITBERGER; DÖSSEL, 1995).

Desde então, a modernização da pintura automotiva é alvo constante de pesquisas e inovações na indústria, sendo considerada pelas montadoras como uma área estratégica. Isso ocorre devido à sua capacidade de despertar interesse no consumidor sendo essa uma das poucas evidências palpáveis e visíveis de qualidade no automóvel (PIEROZAN, 2001). Por causa disso, a análise da qualidade da pintura automotiva tem sido abordada como benefício, uma vez que atua como ferramenta para detectar os desperdícios ou evitar reciclagem do processo de fabricação, reduzindo o custo de produção e, conseqüentemente, os custos de aquisição por parte do cliente final (DREVEK et al., 2016) .

Devido ao processo de pintura ser dividido em etapas, sendo estas a pré-limpeza, primer, base e verniz, e para evitar que as espessuras entre uma camada e outra variem muito, utilizam-se robôs para aplicar uma quantidade pré-determinada de tinta, seguindo uma programação, de forma a garantir o máximo possível de homogeneidade entre os revestimentos e, assim, assegurar um acabamento de qualidade (PIEROZAN, 2001). Contudo, apesar do avanço da tecnologia e da robótica, o processo de programação dos robôs aplicadores de tinta, assim como o processo de inspeção final, ainda são atividades essencialmente humanas. Em particular, a programação da aplicação de tinta é uma tarefa bastante sensível e qualquer variação de parâmetro do robô gera excesso ou escassez de tinta em certa camada, o que compromete a qualidade de todas as demais camadas subsequentes. Em adição a isso, ainda existe o fator de dependência entre os parâmetros de aplicação e o perfil da superfície do carro, em que cavidades, saliências e dobras requerem uma configuração específica. Dessa forma, é, em geral, um desafio descobrir para quais pontos de pintura a aplicação de tinta é crítica ou quais são historicamente críticos e devem ser melhor configurados via programação robótica.

Apesar dessa característica de criticidade na programação da aplicação de tinta, a maioria dos trabalhos da literatura têm focado em reduzir o desperdício por meio da diminuição do *lead time* (Silva; Pereira; Bond, 2017) ou aprimorar padrões de qualidade tendo em vista os custos com o retrabalho (TREVIZAN, 2013). Diante do contexto de Quarta Revolução Industrial, em que os processos produtivos são pautados pela digitalização (INDÚSTRIA, 2017), é essencial que as técnicas da literatura sejam estendidas para a descoberta de conhecimento

que possa servir de ajuste e aprimoramento ao processo sem requerer sua reestruturação física.

Com base nisso, este trabalho propõe a utilização de um método de *machine learning*, chamado K-Means, para explorar a base de espessura de tintas e identificar pontos de interesse por meio da clusterização. Os resultados podem, então, ser integrados ao sistema que controla a pintura, a fim de melhorar a acurácia do atuador e resultar em um produto final de melhor qualidade, reduzindo índices de falhas de inspeção. Um índice de custo foi associado a diferentes níveis de falha na pintura a fim de ilustrar o quão benéfico o método pode ser na prática industrial .

## 1.1 ORGANIZAÇÃO DO TRABALHO

O capítulo 2 trata da fundamentação teórica, abordando temas relacionados à pintura automática. É tratado também sobre como o processo é feito e algumas de suas características importantes no escopo do trabalho. O capítulo 3 fornece detalhes da implementação da solução idealizada pelos autores. A seguir, no capítulo 4, são discutidos os resultados obtidos e, em seguida, conclusões e trabalhos futuros são descritos pelos autores.

## 2 REVISÃO DE LITERATURA

A produção em massa de carros durante a década de 1940 requisitou novas formas de pintura com secagem mais rápida, ao mesmo tempo em que os materiais naturais foram dando espaço para os químicos e o cruzamento de novas tintas tornaram-se parte do estado da arte. [Streitberger e Dössel \(1995\)](#) mostraram que a quantidade de etapas foi reduzida para quatro ou cinco camadas, todas feitas à mão nessa época, com a função de aumentar a proteção a corrosão. Em 1950, a etapa de aplicação do primer foi alterada para um processo mais automatizado, porém difícil, devido à emissão de solventes. A eletrodeposição trouxe uma melhor proteção à corrosão ao mesmo tempo em que novas formas do processo permitiram cores mais fortes e efeitos especiais, como a finalização metálica. [Akafuah et al. \(2016\)](#) mostra que esse processo é altamente custoso, sendo impeditivo nos carros mais acessíveis, até que na década de 1980, o refinamento nos materiais e na tecnologia empregada reduziu os custos gerais do processo. A pintura automotiva continua a evoluir para satisfazer as expectativas do consumidor e legislações ambientais enquanto diminuem os custos operacionais. Um desses novos processos é citado em [Akafuah et al. \(2016\)](#) como revestimento /textitsmart, que oferece potencial para aprimorar a durabilidade adicionando novas funcionalidades como hidrofobicidade, sensibilidade, entre outras. O quadro 1 mostra a evolução do processo ao longo dos anos.

Quadro 1 – Evolução do processo de pintura.

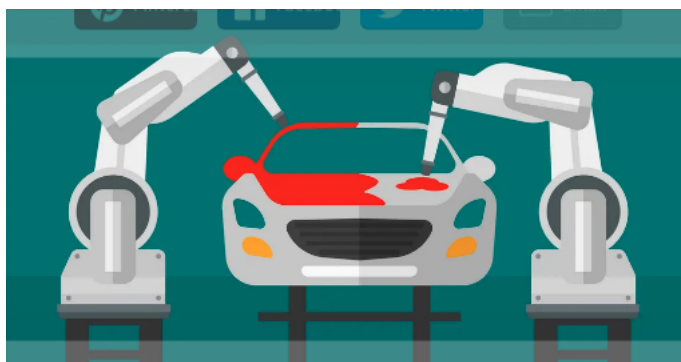
| Ano  | Tópicos                            | Aspectos                                               |
|------|------------------------------------|--------------------------------------------------------|
| 1920 | Pintura manual                     | Tempo de processamento: semanas                        |
| 1940 | Produção em massa                  | Esmaltação/forno/tempo: dia                            |
| 1970 | Performance aprimorada das camadas | CED/novos materiais                                    |
| 1980 | Legislação ambiental               | Revestimento à base de água/pó/transferência eficiente |
| 2000 | Processos automatizados            | Capacidade primeira vez/tempo: horas                   |

Fonte: [Streitberger e Dössel \(1995\)](#)

Aliado ao desenvolvimento das tecnologias e dos materiais, a qualidade da aplicação é fator chave para garantir a durabilidade da pintura, além de assegurar a satisfação do consumidor, uma vez que o acabamento estético é um dos principais fatores observados no momento da compra. Contudo, segundo [Montgomery \(1985\)](#), não é possível assegurar a qualidade em todas as partes, havendo diversos graus variáveis de imperfeições visuais aos quais os consumidores são sensíveis. A melhora da qualidade também reduz o desperdício de homens-hora e tempo-máquina para um produto melhor, garantindo, ainda, um preço acessível.

O processo de pintura é composto de uma pré-limpeza, conhecido como E-Coat, um banho químico que visa atender os requisitos anticorrosivos. Na sequência, a Clear Coat ou primer, ocorre a primeira aplicação de tinta, servindo para dar coloração as camadas posteriores. Essa camada protege a pintura contra corrosão, resistência contra lascamentos e nivelamento da superfície. Em seguida, a carroceria do veículo recebe a camada de base ou Base Coat, em que é determinada a cor do veículo. A próxima etapa é chamada Medium Prime, popularmente conhecido por verniz ou Top Coat, que dá brilho e proteção à pintura, principalmente contra danos físicos relacionados ao meio ambiente, uma vez que é nesta camada que é construída uma barreira para raios ultravioletas (PIEROZAN, 2001). A aplicação destas camadas é alternada entre automáticas, por meio de robôs, e manuais. Com isso, alguns erros são gerados e propagados ao longo do processo produtivo, resultando em defeitos e, não raramente, gera retrabalho e encarece o produto final (Casasolla et al., 2021). A Figura 1 exemplifica um veículo em uma cabine de pintura robotizada.

Figura 1 – Pintura robotizada




Fonte: RAStudio

Cada camada das etapas de pintura possui uma espessura mínima e uma máxima as quais servem para determinar se a qualidade segue os padrões predeterminados. Porém, essas medidas variam conforme o modelo e as coordenadas da carroceria do veículo. A espessura dessas camadas é medida em micrómetro ( $\mu\text{m}$ ), isto é  $1 \mu\text{m} = 10^{-6} \text{ m}$ .

A carroceria do veículo possui algumas coordenadas para fim de análise de qualidade de pintura no produto. Esses pontos são os mesmos em todas as camadas, porém cada veículo pode variar a localização desses pontos e a sua quantidade em cada modelo. Por exemplo, um modelo aleatório escolhido na linha da Renault, possui 70 pontos, distribuídos nas laterais, capô, teto e tampa traseira. O ponto localizado no lado direito do veículo, possui um ponto no lado oposto, e o mesmo ocorre em outros locais dos veículos. Alguns veículos podem ter pontos que não possuem pontos opostos, que são os que estão localizados exatamente no centro. Um exemplo é o ponto localizado no centro do teto, que não possui ponto oposto. Com isso, é possível fazer análises comparando a diferença das espessuras das camadas de tinta entre um determinado ponto A e o seu ponto oposto, B. A Figura 2 ilustra essa distribuição.

Figura 2 – Pontos do capô do veículo modelo L52



Fonte: Renault Brasil (2021)

Devido a grande quantidade de dados gerados durante esse processo, foi necessário desenvolver técnicas que buscam transformá-los em conhecimento. Este é o objetivo da área chamada de KDD, *Knowledge Discovery in Databases* (STEINER et al., 2006).

A Mineração de Dados é uma das etapas do KDD, que divide-se em seleção, pré-processamento, transformação, mineração de dados e interpretação de dados, em seu processo, utiliza conceitos de base de dados, métodos estatísticos, ferramentas para visualização e técnicas de Inteligência Artificial (SILVA, 2019).

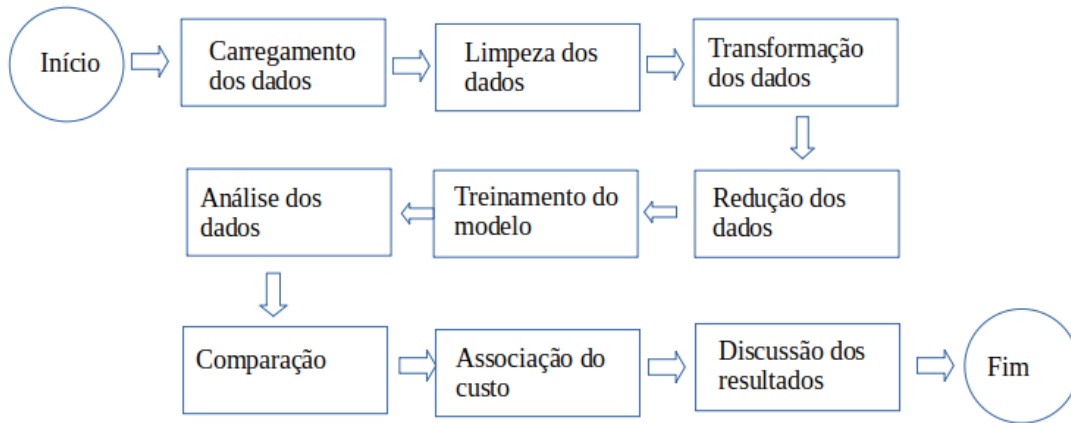
Na primeira etapa, é feita a escolha dos dados de interesse para o KDD conhecida como seleção. Após é o pré-processamento, nessa etapa os dados são alterados para que sejam filtrados ou removidos em uma formatação posterior. Na sequência é a etapa de formatação onde é realizado a transformação dos dados que restaram. Após é a mineração dos dados, em que são aplicados algoritmos de modo a classificar os dados gerando tendências ou padrões. Após é o processo de interpretação onde é possível voltar as etapas anteriores e realizar ajustes para que seja melhorado a saída e obtenha-se resultados melhores e mais significativos (SILVA, 2019).

Um dos algoritmos popular para realizar essa classificação é o K - Means, um método de segregar em torno de centroídes, diversos dados, criando clusters, o que gera o efeito de particionar n observações dentre k grupos em que cada observação pertence ao grupo mais próximo da média. Essa forma de particionamento não permite que um objeto faça parte de mais de um cluster e nem que haja conjuntos vazios, utilizando do processo iterativo para assimilar os dados em cada divisão. Apesar da alta aplicabilidade, esses algoritmos podem gerar diferentes resultados a cada execução ainda que sejam baseados no mesmo *input* (ARVAI, 2020).

### 3 METODOLOGIA

A [Figura 3](#) mostra o fluxo seguido para a construção deste trabalho.

Figura 3 – Fluxograma da metodologia



Fonte: A autoria Própria

Inicialmente, as amostras coletadas na fábrica foram divididas de acordo com os veículos, cores e etapas, de forma a permitir uma análise mais setorizada. Em seguida, estes dados foram implementados em algoritmo visando sua análise para determinar os valores que estavam discrepantes e, ainda assim, foram aprovados. Por último, um estudo crítico das condições em que esses dados foram colhidos permitiu o desenvolvimento de algumas hipóteses que não são impeditivas à aprovação do veículo, mas que representam um gasto extra de material. Com isso, determinaram-se algumas teorias que podem ter influenciado na discrepância de valores, mas que, ainda assim, culminaram na aprovação do automóvel ao final do processo, além de determinar em qual das camadas seria necessário ter mais atenção durante o processo, para evitar desperdício de materiais.

O trabalho foi iniciado com a centralização dos dados, devido às informações serem extraídas de diversas planilhas eletrônicas. Na sequência, foi iniciada a etapa de pré processamento, que possui três passos principais. O primeiro passo foi a limpeza destes, com a identificação e remoção de dados faltantes e de colunas que não eram relevantes para o estudo. Em seguida, foi feita uma análise do *dataset* utilizando, extraíndo-se informações importantes como os tipos de dados, uma vez que, para realizar a correta manipulação, é necessário que estes estejam na formatação adequada, sendo esta realizada no segundo passo do pré processamento, a transformação dos dados. Por fim, iniciou-se a última etapa, redução das informações, que consiste em filtrar as informações que serão utilizadas no estudo, como o modelo de veículo, cor e a camada a ser utilizado. Para auxiliar a escolha dos dados relevantes, foi utilizado o desvio de padrão, de forma a comparar entre todas as opções, aquelas que teriam o maior

impacto no processo.

Finalizada a etapa de pré processamento, inicia-se o treinamento do modelo com a abordagem de K-Means, um algoritmo não supervisionado que tem como objetivo agrupar dados similares e descobrir padrões, olhando para um número fixo de *clusters*, uma coleção de dados unidos devido algumas semelhanças, em um *dataset*, sendo este, também, o número de centroídes definidos, que determinam o centro do *cluster*. Dessa forma, o objetivo do algoritmo é definir a distância dos dados do centroíde, mantendo o número destes o menor possível.

Para este trabalho, foram escolhidos o modelo L52, na cor Blanc Glacier, camada Base, região do capo ( pontos 1 a 10 no veículo), meses Julho, Setembro, Outubro e Novembro variando do dia 22 ao dia 27, sendo essa configuração escolhida por serem as de maiores desvios padrões na diferença de espessura entre pontos, além de melhor direcionar o estudo para uma análise mais especializada em uma determinada região. A camada foi escolhida para reduzir o tamanho do *dataset*, representando 14% dos dados deste modelo, nesta cor, no período analisado. Inicialmente foram determinados três *clusters*, contudo, com a redução da quantidade de dados, dois foram suficientes para realizar os estudos. Utilizou-se as faixas próprias de diferença de espessura para analisar o impacto no custo, conforme definição abaixo:

Quadro 2 – Faixas de custo estabelecidas para comparação.

| Faixa | Valor      | Impacto                       |
|-------|------------|-------------------------------|
| F1    | 0 - 1.0    | Nenhum. Custo necessário      |
| F2    | 1.01 - 2.0 | Duas vezes o custo necessário |
| F3    | 2.01 - 3.0 | Três vezes o custo necessário |

Fonte: Autoria própria

Isso significa que, para uma diferença de espessura entre dois pontos opostos, inferior à 1.0, nenhum custo adicional foi necessário no processo de pintura, enquanto que, para valores entre 1.01 e 2.0, o dobro do orçado foi utilizado. Além disso, estimou-se um valor de R\$5.000,00 como sendo o gasto de material essencial utilizado no processo. Dessa forma, pontos da faixa F3 representam um gasto de R\$15.000,00, excluindo-se custo de pessoas, logística, programação, entre outros que são afetados pelo não atingimento da faixa F1.



## 4 DISCUSSÃO

O algoritmo foi desenvolvido por [Tito \(2021\)](#) e pode ser conferido no repositório GitHub. A [Figura 4](#) mostra os centróides definidos para a análise do dia 22 de julho antes da clusterização e a [Figura 5](#) mostra a nova posição dos centróides após o agrupamento. Para esta data, os pontos mostram a diferença de lados de acordo com a região do capo, podendo observar que não foram muitos locais que apresentaram diferença na espessura em relação ao seu lado oposto. De acordo com a faixa pré-estabelecida no capítulo anterior, o ponto 2 e 10 apresentaram três vezes o custo necessário para realizar o processo, enquanto que o centróide prevê representa um valor de 1,5 vezes. Os pontos vermelhos representam os centróides calculados pelo algoritmo, enquanto os pontos verdes e roxos são os *clusters* formados com os novos centróides.

Figura 4 – Relação da diferença de espessura entre pontos opostos - Julho

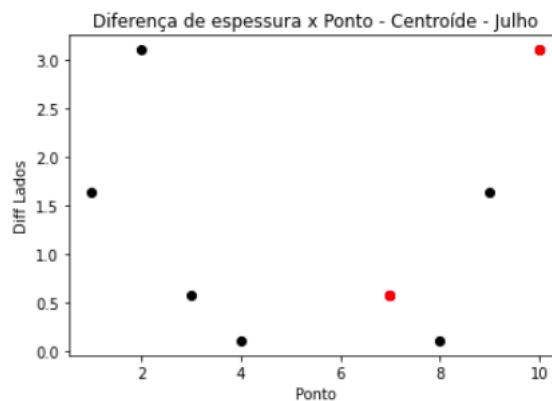



Figura 5 – Clusterização dos resultados - Julho



Analisando o dia 23 de setembro, [Figura 6](#) mostra uma diferença na espessura entre os lados opostos sendo a metade daquela apresentada em julho. Na [Figura 7](#) é possível observar que os pontos ficaram mais próximos dos centróides do que em julho, sendo que os mais distantes estão abaixo destes, representando um custo menor do que a média. Além disso, os

valores que ficaram acima são 0,125% maior do que os centróides, estando ainda na mesma faixa aplicada pra este estudo e, portanto, não representando um gasto significativo quando comparado ao mês seguinte.

Figura 6 – Relação da diferença de espessura entre pontos opostos - Setembro

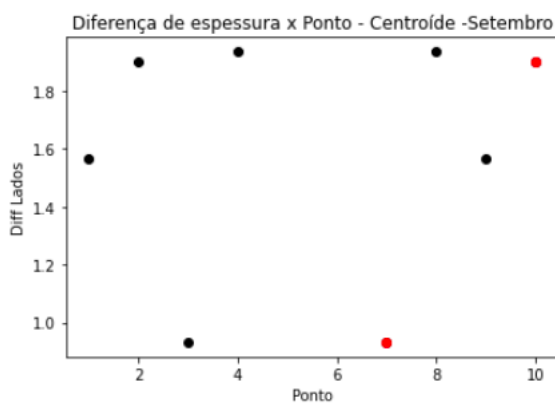



Figura 7 – Clusterização dos resultados - Setembro



Os dados de 23 de outubro se distoaram do restante dos meses observados, conforme [Figura 8](#). Neste mês, foi possível observar uma alta dispersão e escala elevada. Devido ao número de medições ser maior do que o observado nos outros meses, o custo deste reprocesso apresentou variações de R\$5000,00, gasto considerando necessário para realizar a operação, até R\$15000,00, mostrando que uma quantidade de retrabalho significativa foi necessária. Analisando apenas o ponto 2, é possível observar três momentos medidos, em que um está na faixa 3, a que representa maior gasto, um intermediário e, por último, o que utilizou apenas o necessário para realizar o serviço. Isso significa que foi necessário gastar pelo menos R\$25000,00 para realizar o serviço apenas neste ponto, apesar dos centroídes terem ficado por volta de 1,5, o que representa um gasto de R\$7500,00, conforme mostrado na [Figura 9](#). É importante observar, também, que somente nesse dia foram realizadas três medições diferentes em cada ponto, o que indica a realização de retrabalho ou uma forma errônea de realizar o registro na planilha. Ao investigar uma possível causa, notou-se que o operador que executou a atividade não era o mesmo dos outros meses, resultando em outra interpretação para a forma de marcação dos pontos.

Figura 8 – Relação da diferença de espessura entre pontos opostos - Outubro





Figura 9 – Clusterização dos resultados - Outubro



A Figura 10 indica que o operador titular da tarefa retornou à fábrica, uma vez que percebe-se uma alteração na quantidade de medições, além dos centróides estarem definidos em uma escala bem baixa e a variação está dentro da faixa, conforme Figura 11. Neste mês não houveram grandes custos associados, sendo um dos melhores resultados dos meses analisados.

Figura 10 – Relação da diferença de espessura entre pontos opostos - Novembro





Figura 11 – Clusterização dos resultados - Novembro



Com base nesses dados, foi possível observar que, no mês de Outubro houve a necessidade de muito retrabalho, devido à quantidade de vezes que o mesmo ponto foi medido, além de haver pontos com custo três vezes mais do que seria aceitável, e o dobro da média. Contudo, neste mesmo mês foi observado que houve uma mudança de quadro do pessoal da companhia e que, ao retornar ao quadro original, o cenário foi alterado, tendo apenas uma medida por ponto e uma redução de gasto considerável. Apesar disso, em Julho foi observado, também, um alto custo em alguns pontos destoantes, podendo ser associado ao clima frio, que afeta a viscosidade da tinta e pode prejudicar o processo, sendo necessário realizar esse gasto a mais para cumprir com os padrões de qualidade.

## **5 CONCLUSÃO**

Nesse trabalho, foi apresentado que as organizações podem obter informações importante por meio de análise de dados. Estes vem sendo pouco aproveitados nas tomadas de decisões, porém podem ser fundamentais afim de estabelecer melhorias contínuas no seu produto e/ou processo. Com os resultados obtidos, foi possível identificar que, ao estabelecer faixas de custos, Julho e Outubro refletiram os meses em que mais foram gastos acima da média, podendo este estar relacionado com o clima e a substituição do colaborador titular, por exemplo. Dessa forma, é necessário verificar este impacto nos processos seguintes para observar um comportamento padrão nesse período.

### **5.1 LIMITAÇÕES**

Este trabalho encontrou limitações na sua atuação devido à pouca informação sobre o ambiente em que é realizado a pintura, bem como particularidades do processo que só poderiam ser identificadas por meio de entrevistas e observações in loco. Ainda assim, foi possível perceber algumas oportunidades no processo, sendo possível seu aprimoramento.

### **5.2 TRABALHOS FUTUROS**

Para trabalhos futuros, sugere-se identificar por meio de técnicas de aprendizado de máquina qual a espessura ideal em cada ponto para que, ao final, o veículo seja aprovado conforme as exigências do padrão de qualidade. Outra sugestão é apresentar um acompanhamento do processo em tempo real, de forma a auxiliar na tomada de decisões estratégicas para a companhia.

## Referências

- AKAFUAH, N. K. et al. Evolution of the automotive body coating process—a review. **MDPI**, n. 2, 2016. Citado na página 11.
- ARVAI, K. **K-Means Clustering in Python: A Practical Guide**. 2020. Citado na página 13.
- Casasolla, J. R. et al. Técnicas de ciência de dados aplicadas à detecção de padrões de falha em processos de pintura automotiva. **XI Congresso BRasileiro de Engenharia de Produção**, 2021. Citado na página 12.
- DREVEK, P. R. et al. **Avaliação da produtividade de uma linha de pintura de veículos por meio de simulação e análise financeira**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2016. Citado na página 9.
- INDÚSTRIA, P. D. **Indústria 4.0: Entenda seus conceitos e fundamentos**. 2017. Disponível em: <<https://www.portaldaindustria.com.br/industria-de-a-z/industria-4-0/>>. Acesso em: 11 de janeiro de 2022. Citado na página 9.
- MONTGOMERY, D. **Statistical Quality Control**. Arizona: Courier Companies, 1985. Citado na página 11.
- PIEROZAN, L. **Estabilização de processos: um estudo de caso no setor de pintura automotiva**. Janeiro 2001. 121 p. Dissertação (Mestrado Profissionalizante em Engenharia) — UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL, Porto Alegre, 2001. Citado 2 vezes nas páginas 9 e 12.
- Silva, E. J.; Pereira, C. R.; Bond, D. Proposta de redução do lead time de uma linha de pintura automotiva. **Revista de Ciência & Tecnologia**, v. 13, n. 40, p. 21–45, 2017. Citado na página 9.
- SILVA, K. A. M. d. **Análise de perfis de doenças com base em técnicas de descoberta de conhecimento em bases de dados**. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2019. Citado na página 13.
- STEINER, M. T. A. et al. Abordagem de um problema médico por meio do processo de kdd com ênfase à análise exploratória dos dados. **Gestao & producao**, SciELO Brasil, v. 13, n. 2, p. 325–337, 2006. Citado na página 13.
- STREITBERGER, H.-J.; DÖSSEL, K.-F. **Automotive Paints and Coatings**. 2. ed. Weinheim: WILEY-VCH Verlag GmbH & Co, 1995. Citado 2 vezes nas páginas 9 e 11.
- TITO, A. L. **Algoritmo TCC**. 2021. Disponível em: <<https://github.com/AnaLets/Web-Projects>>. Acesso em: 05 de janeiro de 2022. Citado na página 16.
- TREVIZAN, J. G. Melhoria continua da qualidade no processo de pintura automotiva. **Produto & Produção**, 2013. Citado na página 9.