



# ConBRepro

XI CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



01 a 03  
de dezembro 2021

## Técnicas de ciência de dados aplicadas à detecção de padrões de falha em processos de pintura automotiva

Jian Rodrigo Casasolla, Ana Letícia Lopes Tito, Cristian Roberto Pastro, Marcelo Teixeira  
Universidade Tecnológica Federal do Paraná

**Resumo:** A automação da pintura automotiva é um processo delicado, composto por múltiplas etapas que, ordenadamente, aplicam camadas sensíveis de pintura na carroceria do veículo. Cada camada possui um propósito particular que, inicialmente, é atrelado à proteção e, por fim, define os aspectos visuais finais. Devido à interdependência entre as camadas de pintura, erros em camadas internas em geral comprometem as camadas subsequentes. Com isso, no momento em que o veículo passar pela inspeção de qualidade, ao final do processo, este poderá ser reprovado por não estar de acordo com os padrões exigidos, sendo enviado para retrabalho. Este artigo apresenta uma abordagem de ciência de dados para identificar padrões no processo de pintura automotiva, que possam resultar em má formação do produto final. A abordagem é implementada usando a ferramenta Google Colaboratory, com bibliotecas para a linguagem Python, e aplicada sobre uma base de dados reais de um processo de pintura. Resultados mostram que é possível antecipar ao sistema de controle padrões de atuação com menor probabilidade de falha de inspeção.

**Palavras-chave:** Pintura automotiva, ciência de dados, automação inteligente.

## Data Science Techniques Applied to Detecting Failure Patterns in Automotive Painting Processes

**Abstract:** Automotive paint automation is a delicate process, consisting of multiple steps that neatly apply sensitive layers of painting to vehicles. Each layer has a particular purpose that is initially linked to protection and, finally, defines the final visual aspects. Due to the interdependence among paint layers, errors in internal layers often compromise subsequent layers. Thus, at the time the vehicle passes through the quality inspection, at the end of the process, it may be rejected for not complying with the required standards, being sent for rework. This article presents a data science approach to identifying patterns in the automotive painting process that could result in poor final product formation. The approach is implemented using the Google Collaborative tool, with libraries for the Python language, and applied to a real database of a painting process. Results show that it is possible to anticipate to the control system performance patterns that have less probability of failure in the inspection process.

**Keywords:** Automotive painting, data science, smart automation.

## 1. Introdução

O processo de pintura automotiva envolve múltiplas etapas interdependentes. Elas se estendem desde a definição de um ambiente controlado de produção, passam pela manipulação de vários componentes químicos, tais como bases, tintas, solventes e catalisadores, pelas etapas de calibração e coordenação automática de atuadores responsáveis pela aplicação da pintura, e culminam no processo de inspeção de qualidade do produto final. Uma boa qualidade de pintura depende da harmonia e da sincronia entre todas essas etapas iniciais. Se bem-sucedidas, elas levam a uma taxa aceitável de qualidade do produto final que, no caso automotivo, é verificada por inspeção visual em pontos discretos da linha de produção e determina a aprovação ou não do veículo.

Inovações no processo de pintura automotiva têm sido apresentados em pesquisas e criação de produtos na indústria, e tidas pelas montadoras como estratégias para, não só agilizar tal tarefa, como também para remover pessoas de ambientes insalubres de trabalho e, principalmente, para agregar qualidade ao processo, reduzindo a taxa de falhas de inspeção, desperdícios, custos e retrabalho (TAUCITA, SANTOS e ALMEIDA, 2013).

Em geral, robôs são utilizados para aplicar uma quantidade pré-determinada de tinta em cada camada seguindo uma programação definida pelo sistema de controle. Contudo, gerar as trajetórias de atuação dos robôs e realizar a inspeção do resultado final da pintura ainda são atividades essencialmente humanas (TREVIZAN, 2013). Isso reduz a eficiência do processo e não garante a homogeneidade das etapas de inspeção, cujo efeito final é subjetivo (DRUMOND et al., 2013).

Na literatura, aspectos de inspeção de qualidade de pintura são determinados por ferramentas que detectam os desperdícios e evitam a reciclagem do processo de fabricação (DREVEK, 2016). Para Trombini (2011), as linhas de pinturas são agrupadas em formato de lotes, evitando trocas de cor, reduzindo os custos e melhorando a qualidade, enquanto Moreira (2018), sugere a instalação de uma cabine de pintura com sistemas de exaustão, porém neste trabalho serão realizadas análises sobre dados reais com técnicas de ciências de dados.

Esse artigo propõe, uma abordagem de ciência de dados para detectar padrões de injeção de pintura que culminam em defeitos de inspeção. O objetivo é, então, usar essa inteligência para auxiliar na calibração do sistema de atuação, levando a uma aplicação de tinta menos propensa a erros de qualidade final. Serão utilizadas bibliotecas da linguagem Python para manipulação e análise de dados reais de um processo de pintura da Renault do Brasil. Inicialmente, as amostras coletadas pela engenharia de dados na fábrica foram pré-processadas de acordo com os veículos, cores e etapas, de forma a permitir uma análise mais setorizada. A partir das informações gerenciais, serão levantados parâmetros de aplicação que podem comprometer a eficácia da qualidade do produto final.

## 2. Conceitos relacionados à pintura automotiva


A pintura em um veículo demanda de um processo sofisticado, dividido em diversas etapas, que possuem uma sequência típica de aplicação, cada qual com sua finalidade, sendo que a nomenclatura varia de acordo com a literatura ou montadora.

O processo inicia-se com uma pré-limpeza, chamada de *E-Coat*, um banho químico que visa atender os requisitos anticorrosivos. Na sequência, na etapa de *Clear Coat* ou primer, ocorre a primeira aplicação de tinta, é um fundo que serve 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. É nesta camada que é construída uma barreira para raios ultravioletas (PIEZORAN, 2001).

A aplicação de tais camadas é alternada entre aplicações automatizadas, por meio de robôs (CONNER et al., 2005), e manuais, por meio de pessoas com aplicadores de tinta. Com isso, alguns erros são possivelmente gerados e propagados ao longo do processo produtivo (TREVIZAN, 2013), resultando em defeitos, como um grumo de tinta, que pode ser confundido com uma sujeira e não raramente gera retrabalho e encarece o produto final. A identificação dessas anomalias possui, portanto, relação direta com o custo e a produtividade da linha de manufatura (DREVEK, 2016). A figura 1 exemplifica um veículo em uma cabine de pintura robotizada.

**Figura 1 – Robôs em processo de pintura**



**Fonte: TAUCITA, SANTOS e ALMEIDA (2013)**

Cada camada das etapas de pintura possui uma espessura mínima e uma máxima, e elas 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 ( $\mu m$ ), isto é  $1 \mu m = 10^{-6} m$ .

## **2.1 Pontos de pintura na carroceria do veículo**


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 de carro compacto possui tipicamente 52 pontos, distribuídos nas laterais, capô, teto e tampa traseira. Um 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 opostos correspondentes, e.g., os de posição central no teto.

Conhecer essa arquitetura é importante para viabilizar análises comparativas entre pontos correspondentes, percebendo então a diferença das espessuras das camadas de tinta entre um determinado ponto A e o seu ponto oposto, B.

A figura 2 representa pontos típicos de pintura para um modelo genérico de veículo.


**Figura 2 – Pontos da lateral direita do veículo modelo 1A1**



Fonte: Adaptado de GALIMOVMA79 (2021)

A figura 3 ilustra pontos típicos para o teto e capô de veículo genérico.


**Figura 3 – Pontos da lateral esquerda do veículo modelo 1A1**



Fonte: Adaptado de GALIMOVMA79 (2021)

A figura 4 mostra pontos típicos para a pintura da tampa traseira, ou porta-malas.

**Figura 4 – Pontos tampa traseira do veículo modelo 1A1**



Fonte: Adaptado de GALIMOVMA79 (2021)

Percebe-se uma quantidade razoável de pontos que, em conjunção, geram a percepção visual final. Quanto maior a quantidade de pontos, maior a tendência de homogeneidade da pintura, mas maior também é a dificuldade de programar o sistema de atuação.

## **2.2 Coleta de dados brutos**

Dados são observações documentadas, ou resultados de determinadas medições, que formam a base para a geração de informações (SPLUGUES, 2017). Em ambientes fabris, é comum a coleta de dados brutos, ou seja, frutos de observações que não sofreram a interferência de sujeitos ou qualquer outra manipulação eletrônica. Tais dados podem então ser armazenados como coletados, ou mediante pré-processamento, em formato de papel, arquivos eletrônicos, figuras, vídeos, leituras de instrumentos, etc. Em muitas ocasiões, esses dados podem conter erros como ruídos de sensores, dados faltantes ou até mesmo erros de digitação.

Dada a diversidade de formatos de armazenamento, é usual que pouca ou nenhuma informação possa ser extraída ou interpretada diretamente de dados brutos. Um tipo de repositório que armazena esse tipo de estruturas computacionais heterogêneas são os *data lakes (DL)* (OLIVEIRA, 2020), e eles servem a propósitos de processamento de informação.

No processo de pintura automotiva, seja ele manual ou automatizado, são gerados muitos dados com essa natureza heterogênea. Geralmente, eles servem a propósitos de registro direto dos aspectos do processo, mas são pouco aproveitáveis para fins de informação, conhecimento e tomada de decisões. Isso não torna menos rica a base de dados, mas requer um processo sistemático de extração de conhecimento.

Com a vasta lista de tecnologias e ferramentas voltadas ao processamento de grandes e heterogêneas bases de dados, como o sistema distribuído *apache Hadoop, MapReduce* e *YARN*, desenvolvidas nas últimas décadas, tem sido cada vez mais viável implementar sistemas de informação capazes de explorar DLs e retornar, de maneira automática e efetiva, interpretações que de longe extrapolam a percepção humana. Essas constatações se alinham aos propósitos deste artigo e são exploradas na sequência.

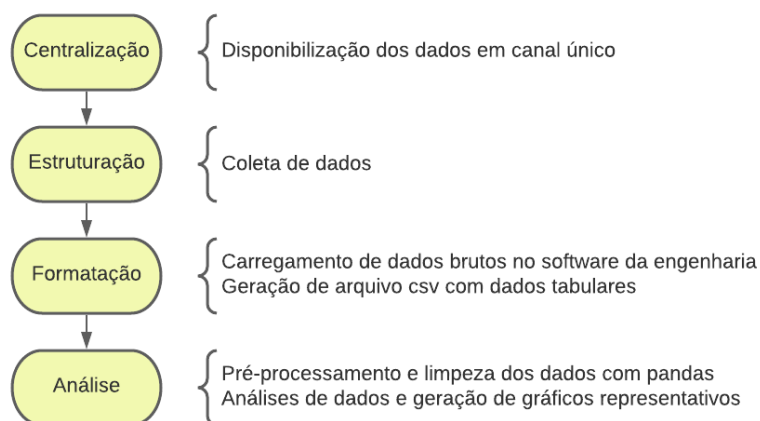
## **3. Uma proposta para a detecção de padrões em pintura automotiva**

O primeiro passo para a construção deste trabalho foi a composição da base de dados. Os dados em questão se originam de múltiplas fontes ao longo do processo de pintura, como planilhas, sistemas de sensoriamento, anotações manuais, etc. Cada setor ao longo da linha detém o conhecimento de uma parte do processo, cada qual com perfis profissionais e finalidades distintas. A heterogeneidade de perfis ao longo da linha, e de finalidades de atuação no processo, potencializa a variedade dos dados gerados e o seu perfil de armazenamento. Desse modo, implementar uma visão holística sobre a linha é praticamente inviável, afetando sensivelmente o processo de tomada de decisões.

Uma possibilidade, a qual foi adotada nesse trabalho, é estabelecer um sistema de centralização dos dados, ainda que em formatos distintos, para posterior acesso e processamento. Essa centralização culmina na construção do DL a ser usado para subsidiar o processo de extração de conhecimento sobre a pintura automotiva. A Figura 5 mostra a metodologia adotada para as etapas de construção a processamento da base.



**Figura 5 – Fluxograma da metodologia aplicada**



**Fonte: Autoria própria (2021)**

Esse esquema de estruturação, inspirado em DLs, teve como premissa o armazenamento dos dados em sua forma bruta e original, de modo que a formatação dos dados ocorre no momento em que ele é solicitado por um usuário. Isso difere sensivelmente dos métodos convencionais de processamento de informação, não baseados em DLs, para os quais a estruturação dos dados antecede o armazenamento efetivo. Constata-se, portanto, que os DLs são mais versáteis ao longo do processamento da informação, pois podem servir à construção de diferentes perfis de visualização, além de causarem menos sobrecarga à fase de pré-processamento.

Em DLs, dados são identificados e classificados por meio de *tags*. Assim, a construção da informação passa, sobretudo, pelo gerenciamento, manipulação e extração dessas *tags* de forma automatizada, diretamente dos arquivos que compõe o banco de dados.

Resultados anteriores apresentam um sistema que pode ser usado para esse propósito, de engenharia de dados e manipulação de *tags* (PASTRO, 2020). Tal arquitetura, foi usada nesse trabalho para o acesso e extração de dados do DL relativo ao processo de pintura da Renault do Brasil. Como resultado, obteve-se o formato tabular de dados, assim como pretendido por esse trabalho para fins de processamento das técnicas de ciência de dados e descoberta de conhecimento propostas. Na forma utilizada neste trabalho após a extração de *tags*, linhas da tabela correspondem a registros de fatos, e as colunas são as características referente aos fatos.

A figura 6 representa uma amostra do *dataset*, com os dados descaracterizados.

**Figura 6 – Dataset**

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
1	Data	Modelo	Executante	Cor	ID	Camada	Ponto	EspessuraCamada	MaximoEsp	MinimoEsp	Qualidade	Regiao	Lado	PontoOposto	EspessuraOposta	Diff_Lados
2	07/05/2019	2B2	Nome1	Cor A	1122233	E-Coat ou cata	1	19,50	25	17	boa	capo	E	18	19	0,50
3	07/05/2019	2B2	Nome1	Cor A	1122233	E-Coat ou cata	2	20,00	25	17	boa	capo	E	19	19	1,00
4	07/05/2019	2B2	Nome1	Cor A	1122233	E-Coat ou cata	3	20,50	25	17	boa	capo	E	20	19	1,50
5	07/05/2019	2B2	Nome1	Cor A	1122233	E-Coat ou cata	4	21,00	25	17	boa	capo	C	21	20	1,00
6	07/05/2019	2B2	Nome1	Cor A	1122233	E-Coat ou cata	5	21,50	25	17	boa	capo	C			
7	07/05/2019	2B2	Nome1	Cor A	1122233	E-Coat ou cata	6	22,00	25	17	boa	capo	C	25	20	2,00
8	07/05/2019	2B2	Nome1	Cor A	1122233	E-Coat ou cata	7	22,50	25	17	boa	capo	D			
9	07/05/2019	2B2	Nome1	Cor A	1122233	E-Coat ou cata	8	23,00	25	17	boa	capo	D	26	20	3,00

**Fonte: Autoria própria (2021)**

A coluna A mostra a data em que o dado foi coletado; a coluna B expõe os modelos dos veículos, que estão representado com a nomenclatura 1A1, 2B2, 3C3, 4D4 e 5E5; na sequência, tem-se o responsável pela execução da linha de pintura; a cor final que será aplicado no veículo; o código de identificador único de veículo, por meio do qual a linha de pintura identifica qual é o modelo de veículo e qual cor deve ser utilizada; a coluna F identifica a camada, podendo ser *E-Coat*, *Clear Coat*, *Base Coat* ou *Top Coat*, a coluna G refere-se ao ponto de pintura na carroceria, em que a coordenada do ponto pode variar de

acordo com o modelo do veículo; a coluna H, I e J mostram as espessuras da camada naquele determinado ponto, em micrômetros, com registros de valores máximos e mínimos; a coluna K informa se I e J estão dentro dos padrões de qualidade para aquela classe; L expõe a região onde o ponto (coluna G) está localizado na carroceria, podendo identificar informações como capô, custódia (localizado entre a porta traseira e a tampa traseira ou porta-malas), paralamas dianteiro, porta dianteira, porta-malas, porta traseira e teto; a coluna M refere-se a qual lado o ponto está em relação à coluna região; N e O mostram o ponto e a espessura oposta em relação a coluna “Ponto” e “EspessuraCamada”; a coluna P contém a diferença em micrômetro entre as colunas “EspessuraCamada” e “EspessuraOposta”.

Ao todo, o dataset é composto por 16 colunas, 154.596 linhas de registros de dados e uma linha referente ao título das colunas (*header*).

#### 4. Construção experimental

Para a implementação dos conceitos de ciência de dados, foi utilizada a ferramenta Google Colab ou Google Collaboratory, que é um de serviço de armazenamento em nuvem de notebooks, gratuito, hospedado pela *Google*, e voltado a criação e execução de códigos em linguagem Python, com recursos de computação científica (ROVEDA, 2019).

Para finalidades similares, poderiam ser utilizados outros recursos computacionais, como a ferramenta desktop jupyter notebook, spyder, entre outros. A escolha pela ferramenta Google Colab foi sustentada pelo fato de que ela não necessita da instalação e nem de configurações específicas de software ou hardware, sendo executando diretamente via navegador, facilitando uma eventual reprodução dos experimentos que se seguem. Sem perda de generalidade, as mesmas implementações propostas aqui poderiam ser reproduzidas e executadas em outras ferramentas de propósito similar.

Na ferramenta Google Colab, foram utilizadas algumas bibliotecas, dentre elas a *pandas*, que é uma biblioteca essencial para ciência e análise de dados. Escrita em Python e de fácil utilização, a *pandas* serve à múltiplas análises exploratórias e manipulação dos dados, oferecendo as permissões de leitura, manipulação, agregação e plotagem de dados (RIBEIRO, 2020). Outra biblioteca utilizada é *NumPy*, voltada à computação científica e a recursos de visualização de dados. Também, foi utilizado a biblioteca *Matplotlib*, que serve ao propósito de visualização de dados em Python (LIMA, 2018).

Com a biblioteca *pandas*, foram exploradas as etapas de pré-processamento e limpeza dos dados, visando eliminar inconsistências e redundâncias. Por exemplo, nas colunas “PontoOposto”, “EspessuraOposta” e “Diff Lados”, foi inserido o valor 0 para os registros que estão como NaN, ou seja, registros que não possuem informações de dados e que poderiam comprometer a execução das análises. Também foram implementadas conversões de colunas que estão com dados como string, para um formato numérico mais sintonizado com os aspectos de análise. Conforme necessidade, também foram eliminadas algumas colunas do dataframe.

##### 4.1 Experimentos

Para fins de análise de qualidade, foi considerada a possibilidade de detecção dos registros que possuem uma qualidade ruim, ou seja, que obtiveram a medida de sua espessura de pintura, em alguma das camadas, fora do intervalo mínimo e máximo considerado para os padrões de qualidade predefinidos. Dos 154.595 registros processados, 44.475 correspondem a essa qualidade. A tabela 1 representa como os dados estão divididos.

**Tabela 1 – Detecção de padrões problemáticos, por modelo**

<b>Modelo</b>	<b>Quantidade</b>	<b>% do total de pontos ruins</b>	<b>% em relação ao total de pontos coletados</b>	<b>Ocorrência de problemas</b>
1A1	10.592	23,82%	6,85%	Maior frequência na região das maçanetas
2B2	10.593	23,82%	6,85%	Quando utilizado cor B, maior ocorrência de problemas na camada de verniz
3C3	8.076	18,16%	5,22%	Maior ocorrência na região da custódia
4D4	4.661	10,48%	3,01%	Concentração na região do porta malas
5E5	10.553	23,73%	6,83%	Maior frequência na camada de verniz em toda carroceria quando utilizado a cor A

**Fonte: Autoria própria (2021)**

Através da biblioteca *pandas*, foi possível identificar, dentre os pontos mais problemáticos do modelo de veículos 1A1, que os pontos 18 e 60, ambos estão localizados na parte da maçaneta do veículo, sendo um ponto no lado direito e outro no lado esquerdo. Sendo assim, podemos concluir que os acabamentos dessa região podem interferir na qualidade de pintura do veículo.

No modelo 3C3, os pontos que mais costumam ultrapassar os limites toleráveis de erro são os pontos localizados na região da custódia. Já para o modelo 4D4, que pelos dados coletados retrata ser o modelo com menos pontos problemáticos, expõe a concentração de problemas na região do porta-malas. Dos 10 pontos mais problemáticos desse modelo, 8 são desta região.

No modelo 5E5, percebe-se que os problemas se concentram na última camada, que é o verniz (*Medium Prime*). Porém, os problemas ocorrem geralmente com a cor A. Pode-se concluir, assim, que quando a cabine do veículo for da cor A, ela apresenta maior propensão de que a camada de verniz extrapole os limites de qualidade de pintura.


Já para o modelo 2B2, constata-se que a utilização da cor B potencializa as possibilidades de que a última camada fique mais espessa, extrapolando o limite tolerável definido para o padrão de qualidade.

Para todos os pontos considerados críticos, 61,62% dos defeitos ocorrem na última camada de aplicação, que é o verniz. Como trata-se da última camada da carroceria, ela não acarreta interferências nas demais camadas e, por essa razão, geralmente os veículos são aprovados, já que os defeitos nessa camada não impactam tanto na percepção de qualidade pelo cliente.

Outra informação que podemos destacar é que a primeira camada, o banho químico (*E-coat*), não se tem registros de imperfeições na espessura na pintura. A figura 7, mostra dados da evolução do processo pelo período de um ano, em que pontos críticos são comparados a pontos historicamente estáveis em termos de qualidade de pintura, separados pelas camadas que os compõem.




**Figura 7 – Estabilidade da espessura dos pontos de pintura**



Fonte: Autoria Própria (2021)

Como os dados foram coletados ao longo de todo o ano, podemos inferir que o clima também pode interferir na qualidade da pintura. Os meses considerados mais quentes na região sul do Brasil (dezembro, janeiro, fevereiro e março) possuem índices de pintura dentro dos padrões estabelecidos. A figura 8 ilustra a detecção de anomalias em cada mês do ano, considerando-se todos os modelos de veículos avaliados.

**Figura 8 – Detecção de qualidade ao longo de 1 ano**



Fonte: Autoria Própria (2021)

Dos 512 veículos que foram avaliados, 72,27% correspondem às cores A e B, sendo que as outras 9 cores correspondem ao percentual restante de 27,73%. Do total de veículos avaliados, todos eles expuseram, em algum ponto, de alguma camada, condições em que a espessura ficou fora dos padrões qualidade. Porém, todos foram associados à aprovação após inspeção visual.

## 5. Conclusão

Este artigo apresenta como técnicas de ciência de dados podem ser úteis às organizações em seus processos de tomadas de decisões, afim de estabelecer melhorias contínuas no seu produto. Em particular, foi mostrado como um processo de pintura automotiva poderia

se beneficiar dessas técnicas para manufaturar produtos com índices de qualidade superiores e não detectáveis pela percepção humana. Foi mostrado como detectar regiões de veículos, pontos, camada, cores e períodos mais críticos do ano para o processo.

Para trabalhos futuros, sugere-se usar outros métodos pautados em aprendizado de máquina para estimar qual seria a espessura ideal para cada ponto de pintura, para que ao final o veículo seja aprovado conforme as exigências do padrão de qualidade. Outra sugestão é apresentar esses dados para a organização de forma online, através de uma ferramenta que de suporte aos gestores na tomada de decisão em tempo real.

## Referências

- CONNER, David C. et al. Modelagem de deposição de tinta para planejamento de trajetória em superfícies automotivas. IEEE Transações em Ciência e Engenharia de Automação, v. 2, n. 4, p. 381-392, 2005.
- DE OLIVEIRA SPLUGUES, Vinicius. Transformando Dados Brutos em Indicadores de Logística. 2017. Tese de Doutorado. Universidade Estadual De Campinas.
- DREVEK, Paulo Roberto et al. Avaliação da produtividade de uma linha de pintura de veículos por meio de simulação e análise financeira. 2016. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná.
- DRUMOND, Thiago Antônio de Paula et al. Aplicação de técnicas de produção sustentável no processo de pintura automotiva. 2013.
- GALIMOVMA79. Depositphotos. Disponível em: <<https://br.depositphotos.com/90475196/stock-illustration-car-line-draw-insurance-rent.html/>> Acesso em: 10 set. 2021.
- LAVINE, Barry K.; BRANCO, Collin; ALLEN, Matthew. Análise forense de tintas automotivas usando um sistema de pesquisa de biblioteca infravermelha assistida por reconhecimento de padrões: Ford (2000-2006). Jornal Microquímico, v. 129, p. 173-183, 2016.
- LIMA, S. Visualização de dados em Python: Matplotlib em: <<https://king.host/blog/2018/03/visualizacao-de-dados-matplotlib/>> Acesso em: 29 ago. 2021.
- MOREIRA, Marcelo Felipe. Análise de instalação de uma cabine de pintura com sistemas de exaustão para empresas de funilaria com demanda reduzida. 2018.
- OLIVEIRA, Mariana Gonçalves de. Modelagens de um Data Lake: de dados brutos a área de negócio. 2020.
- PASTRO, Cristian Roberto et al. Um framework para a integração de dados heterogêneos em ambientes industriais. Paraná: CONBREPPO, 2020.
- PIEROZAN, Leonardo. Estabilização de processos: um estudo de caso no setor de pintura automotiva. 2001.
- RIBEIRO, L. Introdução a Biblioteca Pandas Disponível em: <<https://medium.com/tech-grupozap/introdu%C3%A7%C3%A3o-a-biblioteca-pandas-89fa8ed4fa38>> Acesso em: 29 ago. 2021.

- ROSA, Fábio et al. Nova tecnologia solvente para pintura automotiva isenta de composto aromático. In: CONGRESSO INTERNACIONAL DE TINTAS ABRAFATI. 2013.
- ROVEDA, U. Google Colab: o que é, como usar e quais são as vantagens? Disponível em: <<https://kenzie.com.br/blog/google-colab/>> Acesso em: 29 ago. 2021.
- SILVA, Kaique Augusto Moraes da. Análise de perfis de doenças com base em técnicas de descoberta de conhecimento em bases de dados. 2019. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.
- TAUCITA, Fabrício de Mello; SANTOS, Pâmela Marcélia de Siqueira; ALMEIDA, Valquíria de. Presença de robôs de pintura na indústria automotiva. 2013. Disponível em: <<https://www.aedb.br/wp-content/uploads/2015/05/6640.pdf>> Acesso em: 20 de set. 2021.
- TREVIZAN, João Pedro Gonçalves. Melhoria contínua da qualidade no processo de pintura automotiva. 2013.
- TROMBINI, Amanda. Utilização de técnicas de planejamento de experimentos na análise de viabilidade de alterações no processo de pintura de grades Antracite em uma indústria automotiva. 2011.