

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
DEPARTAMENTO DE ENGENHARIA DE MATERIAIS
CURSO DE ENGENHARIA DE MATERIAIS

GUILHERME BÁCCARA MIRANDA

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL EM UMA LINHA DE PINTURA
INDUSTRIAL

BELO HORIZONTE

2020

GUILHERME BÁCCARA MIRANDA

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL EM UMA LINHA DE PINTURA
INDUSTRIAL

Trabalho de Conclusão de Curso apresentado no
Curso de Graduação em Engenharia de Materiais
do Centro Federal de Educação Tecnológica de
Minas Gerais como requisito parcial para obtenção
do título de Bacharel em Engenharia de Materiais.

Orientador: Prof. Dr. Almir Gonçalves Vieira

Coorientador: MSc Brenno Sant'Ana

BELO HORIZONTE

2020

GUILHERME BÁCCARA MIRANDA

**UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL EM UMA LINHA DE PINTURA
INDUSTRIAL**

Trabalho de Conclusão de Curso no Curso de Graduação em Engenharia de Materiais do Centro Federal de Educação Tecnológica de Minas Gerais aprovado no dia 03 de dezembro de 2020 pela banca examinadora composta pelos membros abaixo:

Prof. Dr. Almir Gonçalves Vieira

Centro Federal de Educação Tecnológica de Minas Gerais

Profª. Dra. Ivete Peixoto Pinheiro

Centro Federal de Educação Tecnológica de Minas Gerais

Prof. Dr. Nilton da Silva Maia

Centro Federal de Educação Tecnológica de Minas Gerais

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, Rejane e Wendherson, por todo o suporte dado durante minha vida.

Agradeço também aos meus familiares e amigos por todo apoio de sempre.

Aos meus orientadores, Almir e Brenno, que me orientaram muito bem durante toda a elaboração do trabalho.

A todos os professores do CEFET MG, em especial a Professora Ivete, que me auxiliou de forma excepcional em várias oportunidades.

RESUMO

A Inteligência Artificial (IA) é uma tecnologia capaz de fazer com que os computadores realizem tarefas mimetizando o pensamento humano, fazendo isso através da tomada de informações do seu entorno e decidindo sua resposta com base no que aprendeu. Nesse trabalho utilizou-se um algoritmo de Inteligência Artificial de rede neural artificial (ANN) para otimizar a aplicação de um processo de pintura manual em uma linha de produção, que envolve grande quantidade de parâmetros e variáveis tais como: a temperatura, a velocidades do ar, viscosidade da tinta, a disposição dos pintores no interior das cabines de pintura, a antropometria dos pintores, a produção diária, as espessuras finais das camadas de tinta das peças pintadas e o número de peças pintadas no dia. Após estes dados serem introduzidos no algoritmo e treinados, foi proposta uma configuração ideal para os pintores e os parâmetros da cabine. Esta configuração proposta foi testada em condições reais, no qual os pintores e os parâmetros da cabine definidos foram analisados tendo em vista sua influência no resultado da produção diária e na contagem dos defeitos de pintura, visando sua viabilidade.

Palavras-chave: Inteligência Artificial, aprendizado de máquina, pintura manual, defeitos de pintura

ABSTRACT

Artificial Intelligence (AI) is a technology capable of making computers perform tasks by mimicking human thought, accomplishing this by taking information from their surroundings and deciding their response based on what they have learned. In this work an Artificial Intelligence algorithm of artificial neural network (ANN) was used to optimize the application of a manual painting process in a production line, which involves a large number of parameters and variables such as: temperature, air velocity, viscosity of paint, the arrangement of painters inside the painting booths, anthropometry of painters, daily production, the final thicknesses of the paint layers of the pieces painted and the number of pieces painted in the day. After this data was entered into the algorithm and trained, an ideal configuration has been proposed for the painters and the cabin parameters. This proposed configuration was tested in real conditions, in which the painters and the cabin parameters defined were to be analyzed in view of their influence on the result of daily production and on the counting of paint defects, aiming at their viability.

Keywords: Artificial Intelligence, machine learning, manual painting, painting defects

LISTA DE FIGURAS

Figura 1- Camadas de revestimento e suas espessuras.....	18
Figura 2 - Estrutura de um processo de pintura de máquinas de bens de capital	19
Figura 3 - Evolução das ondas das Revoluções Industriais.....	20
Figura 4 - Esquema de funcionamento de uma Rede Neural Artificial	24
Figura 5 - Etapas do aprendizado de máquina.....	27
Figura 6 - Layout do processo onde os dados foram obtidos.....	28
Figura 7 - Parâmetros sendo recolhidos in loco	29
Figura 8 - Antropometria do Corpo Humano	30
Figura 9 - Iteração do algoritmo.....	35
Figura 10 - Resultado da melhor combinação proposta	36
Figura 11 - Layout Ideal dos Pintores em Linha	38
Figura 12 - Peça com defeito de escorrido de tinta	39
Figura 13 - Quantidade de defeitos de escorrido de tinta.....	40
Figura 14 - Tempo utilizado no ciclo PDCA antes da utilização de IA.....	41
Figura 15 - Tempo utilizado no ciclo PDCA após a utilização de IA.....	41

LISTA DE TABELAS

Tabela 1 - Saídas do Algoritmo para determinada peça	36
---	----

SUMÁRIO

1 INTRODUÇÃO	13
2 OBJETIVOS	14
2.1 Objetivos Gerais	14
2.2 Objetivos Específicos	14
3 REVISÃO BIBLIOGRÁFICA	15
3.1 Pintura Veicular	15
3.2 Etapas do processo de Pintura	16
3.2.1 Jateamento de Granalha	16
3.2.2 Pré-Tratamento	16
3.2.3 Eletrodeposição	17
3.2.4 Primer	17
3.2.5 Top Coat	17
3.2.6 Quality Gate	19
3.3 Indústria 4.0	19
3.4 Inteligência Artificial	21
3.4.1 Histórico	22
3.5 Aprendizado de Máquina (Machine Learning)	23
3.5.1 Redes Neurais Artificiais	24
3.6 Ferramentas utilizadas em projetos de Melhoria Contínua	25
3.6.1 Design de Experimentos (DoE)	25
3.6.2 PDCA	26
4 MATERIAIS E MÉTODOS	27
4.1 Coleta de Dados	28
4.2 Escolha de ferramentas para aplicação do algoritmo	31
4.2.1 <i>Python</i>	32
4.2.2 <i>Anaconda</i>	33
4.2.3 <i>TensorFlow</i>	33
4.2.4 <i>Scikit-learn</i>	33
4.2.5 <i>Numpy</i>	34
4.2.6 <i>Pandas</i>	34

4.2.7 Keras.....	34
4.3 Treinamento do Algoritmo	34
4.4 Testagem do Algoritmo	35
5 RESULTADOS E DISCUSSÕES	36
5.1 Configuração Ótima de Linha.....	36
5.2 Lógica do PDCA na Realização de Projetos	40
6 CONCLUSÃO.....	42
6.1 TRABALHOS FUTUROS	43
REFERÊNCIAS BIBLIOGRÁFICAS	43

LISTA DE ABREVIATURAS

CEP - Carta Estatística de Processo

DoE - Design of Experiments

IA - Inteligência Artificial

IIoT - Internet Industrial das Coisas

IoT - Internet of Things

MIT - Instituto de Tecnologia de Massachusetts

PDCA - Plan-Do-Check-Act

ANN - Redes Neurais Artificiais

TI - Tecnologia da Informação

TO - Tecnologia Operacional

VOC - Composto Orgânico Volátil

1 INTRODUÇÃO

A escolha do tema deste estudo se deu pela realização de um projeto de redução de custos realizado na empresa em que o autor desse Trabalho de Conclusão de Curso estagiou, tendo em vista a proximidade do tema com a Engenharia de Materiais e com uma das competências de todo Engenheiro: otimizar o processo produtivo por meio de novas tecnologias. O projeto foi realizado em uma empresa de produção de bens de capital da região de Contagem, a qual por motivos de privacidade e segredo industrial, terá seu nome suprimido.

A aplicação de pintura é um dos processos mais importantes na produção de veículos. O revestimento de pintura fixado à superfície melhora o aspecto visual ao incluir sombreamento, brilho e também garantindo uma camada de proteção contra as intempéries e prolongando a vida útil da parte externa (KOTTWITZ, 2019).

A melhoria da qualidade do processo de pintura passa, em primeiro lugar, pelo interesse da empresa em ser mais competitiva por meio de processo de melhoria contínua com redução de gastos. A qualidade da pintura do veículo é um dos fatores primordiais no controle de qualidade, tendo em vista que pequenos reparos, polimentos feitos de formas incorretas, ou até acidentes podem facilmente danificar a tinta e ficarem evidentes na entrega do produto. (AKAFUAH,2016)

Com a Quarta Revolução Industrial, novas tecnologias estão presentes cada vez mais nas indústrias de todo o mundo, influenciando a produtividade, conhecimento, emprego e habilidades de todos que estão inseridos nela. Com essa nova fase é esperado que novas tecnologias sejam englobadas dentro do processo produtivo para auxiliar na automação e controle dos processos de manufatura. Como por exemplo, é esperado que a indústria 4.0 reduza os custos produtivos entre 5% e 8% no total do custo da manufatura (RÜBMANN et al., 2015). Segundo McKinsey & Company (2015), no Brasil a introdução dessas tecnologias já é realidade, com várias empresas já utilizando ferramentas como a Internet das Coisas (IoT) e *Big Data* nas suas operações diárias, gerando melhorias na produtividade.

E um processo de fabricação, há muitas variáveis que se associam entre si, ao longo de todo o fluxo do processo. As diferenças entre estas variáveis são complexas, portanto, é impossível para um ser humano compreender a relação envolvida entre elas. Segundo Sorensen et al. (2009), um exemplo é a aplicação de pintura manual, que, além da flutuação dos

parâmetros do processo, há também a interferência dos operadores na qualidade do produto final .

A necessidade de se usar Inteligência Artificial (IA) aplicada ao processo de fabricação surgiu após resultados de um *Design* de Experimentos (DoE) previamente aplicado com sucesso neste processo, revelando que, após o conhecimento dos parâmetros do sistema, a mão-de-obra treinada e as ferramentas configuradas, o número de defeitos de pintura diminuiu. Essa redução evidenciou que há uma interferência humana no processo, e o uso de IA poderia quantificá-la, tornando possível a matematização do desempenho do operador. O conhecimento adquirido em Engenharia de Materiais possibilitou que fossem traçadas tais condições de contorno para estudo desse processo. Além disso, na realização de projetos de redução de custo, já se foi levantado que a maior parte do tempo é utilizado no planejamento do mesmo.

Nesse trabalho o autor irá descrever como foi realizado um projeto de otimização utilizando Inteligência Artificial dentro de uma linha de pintura, destacando a factibilidade da aplicação de um algoritmo dentro de uma linha de produção. São examinadas todas as fases do processo, suas variáveis e o resultado final do mesmo.

2 OBJETIVOS

2.1 Objetivos Gerais

Utilizar técnicas de Inteligência Artificial para otimização do processo de uma linha de pintura industrial.

2.2 Objetivos Específicos

- Encontrar uma configuração-ótima para a linha de pintura analisada.
- Realizar uma matematização da aplicação de tinta por parte do operador e os limites da mesma.
- Otimizar a realização de processos na forma de iterar os valores e testar as hipóteses mais rapidamente utilizando um algoritmo.

3 REVISÃO BIBLIOGRÁFICA

3.1 Pintura Veicular

Segundo Toda (2013), o processo de realizar a pintura de um veículo é uma das operações mais onerosas da indústria automotiva. Esse processo normalmente envolve 30-50% dos custos de uma fábrica. Esse alto custo ocorre devido ao fato de que se é necessário que os revestimentos sejam de alta qualidade e também ao fato de que é necessário atender às rígidas regulamentações ambientais. Galitsky e Worrell (2008) expõem que esses custos são envolvidos na energia utilizada para o manuseio e condicionamento do sistema de ventilação de ar das cabines, bem como para a secagem da tinta e tratamento das emissões geradas pelas gotas de tinta que não são depositadas nas superfícies metálica dos veículos. Além disso as cabines de pintura devem ser limpas para remover solvente evaporado, partículas de tinta pulverizadas em excesso e poluentes.

De acordo com Akafuah (2016), no início da história da indústria automotiva, os carros eram pintados com um tipo de verniz que era escovado sobre as superfícies do veículo. Esse revestimento era lixado e alisado, e então o verniz era reaplicado e retocado para estabelecer várias camadas do revestimento. Depois que esse processo era realizado diversas vezes, os veículos eram finalmente polidos para produzir superfícies brilhantes.

Em 1923, DuPont De Nemours desenvolveu sistemas de verniz que ofereciam várias opções de cor e também melhor aplicabilidade através do uso de pistolas de tinta spray. O processo de pintura continua a evoluir satisfazendo as expectativas dos clientes e as regulamentações ambientais, ao mesmo tempo em que reduzem os custos de fabricação. (AKAFUAH,2016)

Em outras palavras, o processo de pintura evoluiu tanto na estruturação química quanto física. Entretanto, de acordo com Fazenda et al. (2009) a evolução trouxe padronização do processo e, de maneira geral, as empresas do setor automotivo e industrial têm tendências similares na estruturação das linhas de produção de pintura.

3.2 Etapas do processo de Pintura

De acordo com Akafuah (2016), o processo de pintura é dividido em etapas, a fim de que o produto final consista em muitas camadas diferentes. Elas são:

- Jateamento de Granalha
- Pré-tratamento
- Eletrodeposição:
- *Primer*
- *TopCoat*
- *Quality Gate*

3.2.1 Jateamento de Granalha

A etapa inicial no processo de pintura envolve o tratamento superficial das peças para remover os resíduos físicos e químicos dos processos de usinagem soldagem, a fim de obter a qualidade e a condição de superfície exigida. Entre os métodos de tratamento de superfície, o método abrasivo (de jateamento) é o mais utilizado. Nesse processo, um fluxo de meio abrasivo com alta energia cinética é gerado e forçado sobre a superfície da peça a ser limpa. (PI et al., 2011)

3.2.2 Pré-Tratamento

Segunda etapa do processo, onde ocorre a limpeza da superfície da peça metálica por meio de um banho químico, removendo e limpando o excesso de metal e formando uma estrutura de superfície apropriada permitindo a ancoragem de uma camada de proteção anticorrosiva. (AKAFUAH, 2016). Segundo Mahajan (2019), esse processo remove e limpa o excesso de metal da superfície, firmando assim uma estrutura ideal para que ocorra a ancoragem de uma camada de proteção contra corrosão. O método consiste na limpeza da superfície para remover os óleos e impurezas que sobram do processo de estampagem e de soldagem mediante três processos primários de desengraxe, condicionamento e fosfatização.

O pré-tratamento ajuda o primer (polímero de fixação) a aderir ao metal. Isso ocorre devido ao fato de que o tratamento com fosfato aplica uma camada inerte de fosfato metálico, proporcionando resistência à propagação da corrosão. Uma outra solução que também está presente nesse banho é a solução desengordurante, a qual é composta de sais alcalinos e surfactantes. (MAHAJAN,2019). Akafuah (2016) também acrescenta que a próxima sequência

é a ativação da superfície, evento que cria locais de nucleação para o crescimento de cristais de fosfato, com o objetivo de melhorar os mecanismos de ligação na superfície.

3.2.3 Eletrodeposição

Essa etapa é feita sob a ação de uma corrente elétrica, e tem por finalidade principal dar à superfície pintada proteção anticorrosiva. (AKAFUAH, 2016). Durante essa operação, uma mistura de resina, ligantes e uma pasta contendo pigmentos é submergida no tanque em que será feita a eletrodeposição. De acordo com Mahajan (2019), a solução final dentro do tanque consiste cerca de 80% de água deionizada e 20% de tinta. Uma corrente elétrica aplicada, e ao final desse processo ele fornecerá proteção contra corrosão, durabilidade e maior resistência para os substratos utilizados.

3.2.4 Primer

De acordo com Akafuah (2016), a aplicação de primer faz com que ocorra um preenchimento das pequenas imperfeições e arranhões que podem aparecer durante as etapas anteriores de pré-tratamento e pelo lixamento. Além disso, a maioria das superfícies metálicas têm imperfeições superficiais que surgem das operações de prensagem, estampagem e soldagem, sendo necessário esse preenchimento. Seguindo essa linha de raciocínio, Barletta et al (2006) diz que a utilização do primer é muito importante para que se tenha um bom aspecto final da peça pintada. O primer é um polímero condutivo, fazendo com que seja possível a aplicação de tinta através do processo eletrostático.

A camada de primer é importante para a resistência ao lascamento devido ao choque de pedregulhos. Quando esse impacto ocorre, ele expõe o metal nu às intempéries, e essa lascamento e posterior exposição inevitavelmente levará à corrosão. Sendo assim, uma boa aderência da camada superior de tinta à superfície do primer garante uma menor perda de aparência visual se ocorrer uma retirada de lascas. Portanto, é comum incorporar cores adequadas em primers compatíveis com a camada superior, mascarando danos à camada superior causados por lascas de pedra. (AKAFUAH, 2016)

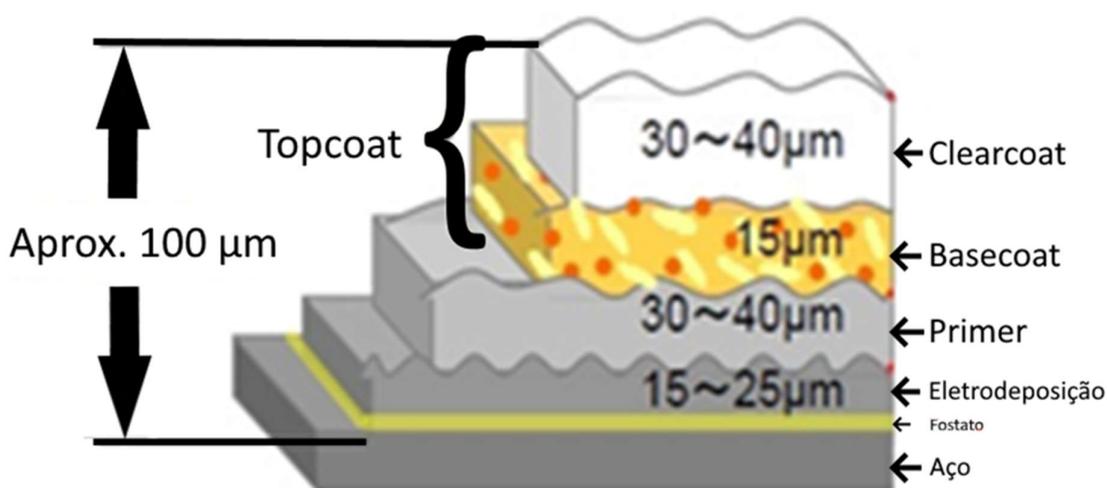
3.2.5 TopCoat

A etapa final no processo de pintura do substrato metálico consiste na aplicação de duas camadas - a camada base (*Basecoat*) e a camada transparente (*Clearcoat*). De acordo com Fazenda (2005), esse sistema tem como etapa primária a aplicação de uma camada de *basecoat* pigmentado sobre a superfície anteriormente em que foi aplicado o primer. Ao final dessa aplicação, os solventes têm de evaporar por um período de 2 a 3 minutos, etapa essa chamada

de flash off. Finalmente aplica-se o *clearcoat*, que segundo Akafuah (2006), é um verniz que proporciona um revestimento de proteção contra as intempéries, corrosão e degradação causada pela radiação ultra violeta (UV), promovendo assim uma retenção de cor e um acabamento uniforme. Segundo Fazenda (2005), O mesmo processo de aplicação de basecoat é repetido na aplicação do clearcoat. A peça, com todas as camadas, é aquecida na estufa para que o verniz cure.

As várias camadas de revestimento e suas respectivas espessuras são destacadas na Figura 1.

Figura 1- Camadas de revestimento e suas espessuras.



Fonte: Adaptado de AKAFUAH (2006)

A aplicação dessas camadas finais ocorre dentro de cabines especiais de pulverização que incluem sistemas importantes para o balanceamento do processo, tais como: Sistemas de manuseio de ar para controle de temperatura, umidade, limpeza e captura de Compostos Orgânicos Voláteis (VOC). O sistema de manuseio de ar contém um fluxo de ar horizontal e vertical, meios de filtração para controlar a quantidade de particulados como poeira e sujeira. Na parte inferior da cabine tem-se água corrente e grande fluxo de ar, que são usados para capturar partículas de tinta em lavadores úmidos. O fluxo de ar controlado dentro da cabine transporta as partículas de tinta para o equipamento de captura na parte inferior da cabine. A força e a direção do fluxo de ar, a eficiência da filtração e as características do equipamento de revestimento determinam a eficiência da operação de aplicação de tinta e a qualidade do acabamento final. (AKAFUAH,2006)

3.2.6 Quality Gate

De acordo com Rana et al. (2018), a indústria de veículos exige altos níveis de qualidade, produtividade e competitividade de produtos, bem como a utilização de processos de melhoria contínua. Para atingir esse objetivo, muitas empresas fabricantes de veículos usam ferramentas de controle de qualidade para melhorar a qualidade do produto com zero defeitos e uma satisfação alta do cliente.

Durante a produção, se houver qualquer desvio dos parâmetros do processo ou do equipamento na produção pode-se descobrir a causa raiz no Quality Gate e continuar verificando até que volte à produção normal do lote. Cada estação de trabalho possui parâmetros de qualidade como hora de retrabalho, taxa de reparo, que após quantificadas, ajudam a descobrir a causa raiz no caso de qualquer problema na produção. (JUDI,2020)

A inspeção manual de qualidade é realizada no *Quality Gate*, ao final da linha de produção após a estufa, como evidenciado na Figura 2, podendo essa inspeção ser realizada tanto por meio da análise visual, tanto por diferentes dispositivos de medição, tais como: medição de cores, construção de filme, medição da aparência, medição de brilho. (RANA, 2018)

Figura 2 - Estrutura de um processo de pintura de máquinas de bens de capital



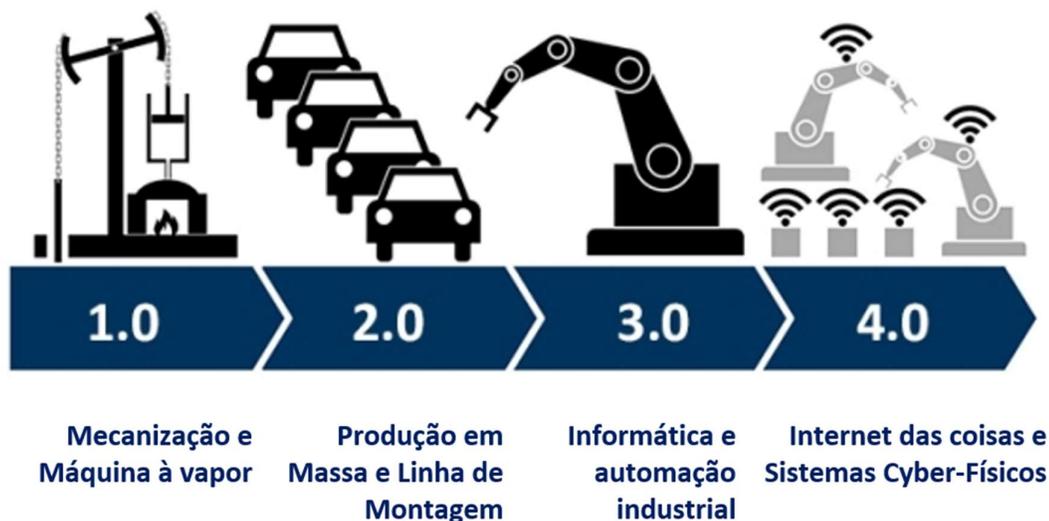
Fonte: Próprio Autor

3.3 Indústria 4.0

Ao longo dos anos, o contexto mundial de manufatura tem sido caracterizado pelos contínuos avanços que levam a mudanças radicais na produção e processos. O advento da

máquina a vapor trouxe para a primeira revolução industrial em 1700 a utilização da energia do vapor como fonte para a movimentação de máquinas antiquadas. A segunda revolução foi juntamente com a eletricidade, trazendo a difusão de meios de transporte mais rápidos. Chegando à terceira revolução industrial, a engenharia assistida por computador foi o principal facilitador da automatização, fazendo com que um sistema seja rápido e facilmente reprocessado. Atualmente, está em curso a quarta revolução industrial, que combina Tecnologia da Informação (TI) e Tecnologia Operacional (TO) aplicadas a toda a cadeia de produção por meio da Internet. A quarta revolução industrial é geralmente referida também com o termo "Indústria 4.0", proposto na feira de Hannover, na Alemanha, em 2011 (Gilchrist, 2016). A figura 3 ilustra as quatro revoluções industriais.

Figura 3 - Evolução das ondas das Revoluções Industriais



Fonte: (SORDAN, 2020)

De acordo com Schuh et al (2015), as fábricas inteligentes contam com a interação em três vertentes: A primeira delas é a relação administrativa entre pessoas, a segunda é a relação entre a pessoa e a máquina, garantindo o input dos comandos e configurações propostas. Finalmente existe também a interação entre máquinas, com a automação dos processos. Com essa conexão entre esses três pontos, acontece uma integração do mundo físico e virtual, com uma maior facilidade e abertura de informações captadas por meio de sensores.

A necessidade da indústria 4.0 é de converter as máquinas regulares em máquinas autoconscientes e de autoaprendizagem para melhorar o seu desempenho global e a gestão da manutenção com alta interação (LEE; KAO; YANG, 2014). A indústria 4.0 visa a construção

de uma plataforma de fabricação aberta e inteligente para aplicação de informação em rede industrial (BAHRIN; OTHMAN; AZLI; TALIB, 2016). O monitoramento de dados em tempo real, o acompanhamento do estado de produção e das posições do produto, bem como a manutenção das instruções para controlar os processos de produção, são as principais necessidades da Indústria 4.0 (ALMADA-LOBO, 2016).

Os quatro principais pilares da Indústria 4.0 são a Internet das Coisas (IoT), a Internet Industrial das Coisas (IIoT), a fábrica baseada na nuvem e a fábrica inteligente que ajuda a transformar o processo de fabricação em um processo totalmente digitalizado e inteligente (EROL; JÄGER; HOLD; OTT; SIHN, 2016). Esses pilares da Indústria 4.0 irão transformar a produção, que antes era caracterizada como uma produção isolada para um fluxo de produção totalmente integrado, automatizado e otimizado. Isso leva a uma maior eficiência e mudança nas relações de produção tradicionais entre fornecedores, produtores e clientes, bem como entre humanos e máquinas (RÜBMANN et al., 2015).

3.4 Inteligência Artificial

A Inteligência Artificial (IA) é o campo da Engenharia que trata da teoria e prática do desenvolvimento de sistemas que apresentam características associadas à inteligência no comportamento humano, tais como percepção, processamento da linguagem natural, resolução e planejamento de problemas, aprendizagem e adaptação. O seu principal objetivo é compreender e mimetizar o comportamento inteligente no ser humano, nos animais e nos agentes artificiais, com objetivo final de tornar o trabalho com computadores tão fácil como trabalhar com pessoas, e desenvolver sistemas homem-máquina que explorem a integração do raciocínio humano e automatizado (TECUCI, 2011).

O ser humano é um ser que possui como diferencial a sua extrema inteligência, a qual contribui de forma muito grande para a sua sobrevivência e conseguinte evolução. O processo de pensamento é estudado para entender melhor a forma como pensamos e criamos esse conhecimento nas mais diversas áreas. A Inteligência Artificial tenta compreender e construir plataformas tão inteligentes como o nosso cérebro (NORVIG; RUSSELL, 2013).

O cérebro humano é uma grande rede de neurônios que processam informações. Os cientistas têm trabalhado no desenvolvimento de estruturas artificiais com funções semelhantes às do cérebro humano para programar capacidades cognitivas para a IA. Este subcampo de programação da IA é conhecido como 'Redes Neurais Artificiais' (ANNs). Inicialmente, o desenvolvimento das ANNs foi fraco devido ao fraco poder de processamento de

computadores, mas recentemente, os programas de IA desenvolveram-se de forma eficiente e funcional devido aos avanços no poder de processamento dos computadores na quarta revolução Industrial (DACOMBE, 2020).

De acordo com Tecuci (2011), a Inteligência Artificial é um campo interdisciplinar muito amplo que tem várias raízes, que se cruzam com vários campos. Ao contrário do que muitos pensam, a IA não abrange somente disciplinas de informática, mas também Matemática, Linguística, Psicologia, Neurociência, Engenharia Mecânica e muitos outros. A maioria dos sistemas de IA são desenvolvidos como componentes de aplicações complexas, no qual acrescentam inteligência de várias maneiras, como por exemplo, raciocinando com dados prontos, processando linguagem natural, aprendendo e adaptando-se.

3.4.1 Histórico

A inteligência artificial é um conceito antigo como a informática, e desde o início, os pesquisadores estavam interessados em desenvolver sistemas informáticos inteligentes. Turing (1950) introduziu os conceitos de aprendizado de máquina, algoritmos genéticos e reforço da aprendizagem em seus experimentos. O nome "inteligência artificial" foi proposto por John McCarthy quando ele e outras figuras importantes da IA (Marvin Minsky, Allen Newell, Herbert Simon) organizaram um workshop de Verão em Dartmouth, Canadá, em 1956.

A Conferência em Dartmouth foi seguida por um período de quase duas décadas com sucessos significativos no campo da IA. Um exemplo precoce foi um programa de computador ELIZA, criado entre 1964 e 1966 por Joseph Weizenbaum no Instituto de Tecnologia de Massachussets (MIT). ELIZA era uma ferramenta de processamento de linguagem natural capaz de simular uma conversa com um humano e um dos primeiros programas capazes de tentar passar o Teste de Turing. (HAENLEIN; KAPLAN, 2019)

As redes neurais artificiais voltaram ao holofote quando, em 2015, AlphaGo, um programa desenvolvido pela Google, foi capaz de vencer o campeão do mundo em um jogo de xadrez. Esse programa alcançou o seu alto desempenho ao utilizar um tipo específico de rede neural artificial chamada *Deep Learning* (Aprendizagem Profunda) (SILVER, et al, 2016).

3.5 Aprendizado de Máquina (*Machine Learning*)

A aprendizagem de máquinas (*Machine Learning*) pode ser definida como a capacidade de um sistema de adquirir e de integrar conhecimentos mediante observações em larga escala, e de melhorar e ampliar-se, aprendendo novos conhecimentos em vez de ser programado com esses conhecimentos. (WOOLF,2009).

Segundo Bertozzo (2019), esses sistemas de aprendizado aprendem a partir dos dados e que podem tomar uma decisão quase sem intervenção humana. O *Machine Learning* pode ser usado em um grande espectro de áreas, tais como pesquisa na web, filtro de spam de e-mails, anúncios, classificação de imagens e outras aplicações. Para poder tratar todos os casos de identificação de padrões de um programa ou poder analisar dados, algoritmos são capazes de aprender e inferir conhecimento em dados aprendidos e novas entradas.

Segundo Pinto (2016), no *Machine Learning* é feito o estudo e implementação de algoritmos que aprendem e fazem previsões a partir de um conjunto de dados, através da realização de previsões baseadas em conhecimento prévio. Esse modelo tem como entrada um conjunto de treinamento, o qual está relacionado com a situação a ser analisada. Assim as previsões feitas são baseadas nesses dados e não de instruções de um programa.

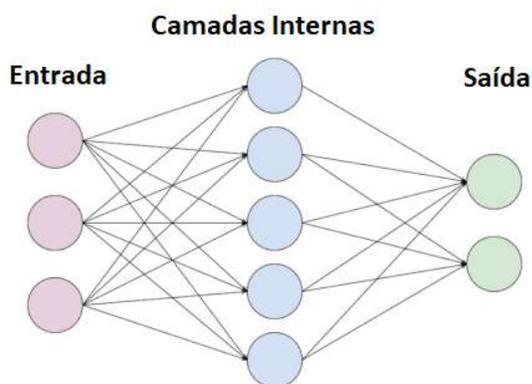
Na teoria da aprendizagem de máquinas, o conceito de aprendizagem é normalmente dividido em três tipos que ajudam a ilustrar o espectro do campo: aprendizagem supervisionada, não supervisionada e reforçada. Na aprendizagem supervisionada, são dados exemplos de exemplos de aprendizagem de produtividade e de produtividade corretas, sendo necessário inferir um mapeamento a partir daí. Provavelmente, a tarefa mais importante é a classificação de padrões, onde os vetores de dados de entrada têm que ser atribuídos a diferentes classes. (SCHULD, et al., 2014)

Segundo Schuld, et al. (2014), aprendizagem não supervisionada descreve o processo de encontrar padrões em dados sem experiência prévia ou exemplos. Esse tipo de tarefa está relacionada à classificação, sem o objetivo de tratar novos dados. Já a aprendizagem reforçada se dá quando cada recompensa positiva em um resultado reforça a estratégia atual, enquanto que a punição leva a uma adaptação de análise do algoritmo.

3.5.1 Redes Neurais Artificiais

Uma Rede Neural Artificial (ANNs) é uma estrutura artificial capaz de funcionar como o cérebro humano, processando informação complexa por meio dos seus neurónios artificiais e ser capaz de resolver problemas. São sistemas com unidades interligadas em várias unidades, chamadas neurônios. Os neurônios artificiais são baseados no funcionamento dos neurônios humanos, e ao trabalharem juntos, têm a capacidade de resolver problemas complexos, alimentados por uma tabela de dados históricos fornecida. Como é ilustrado na Figura 4, várias camadas da rede neural estão interligadas umas com as outras. (VERAS, 2013).

Figura 4 - Esquema de funcionamento de uma Rede Neural Artificial



Fonte: (DACOMBRE,2020)

Na camada de entrada, os dados são apresentados à rede neural, de modo que esta é a primeira camada a ter contato com os dados entregues para a rede. As camadas internas são responsáveis pela análise dos dados e pela realização das associações e reconhecimento dos padrões dos dados obtidos, e no final, a resposta é entregue por meio da camada de saída (GOH, 1995)

As redes neurais aprendem mediante a adaptação ao ambiente que está inserida, e pode ser utilizado para diferentes fins. Exemplos de redes neurais já utilizadas em engenharia incluem modelação de materiais, avaliação de danos e mesmo análises estruturais. (VANLUCHENE,1990)

Segundo Carvalho (2019), os neurônios artificiais dessas redes neurais são a base do funcionamento da mesma. Com a entrada de dados, a rede faz os cálculos e gera uma saída de dados, por meio dos conhecimentos adquiridos nos quais ela foi treinada. Cada neurônio está

interconectado por meio de redes de comunicação, as quais têm certos pesos, gerando assim uma resposta diferente.

3.6 Ferramentas utilizadas em projetos de Melhoria Contínua

De acordo com Khan et al. (2018), a melhoria contínua é uma tentativa lógica de descobrir e aplicar novas formas de trabalho para fazer melhorias no processo, trazendo inovações passo a passo para o trabalho e envolvendo funcionários para trazer novas ideias para o local de trabalho. Os principais fabricantes mundiais veem a qualidade dos seus processos como meio para superar a concorrência. Assim, as empresas alocam recursos para desenvolver projetos que buscam analisar os parâmetros produtivos, tais como taxas de deficiência, avaliação de produtos e desempenho das operações. Isso permite que a empresa tenha uma grande participação no mercado e ao mesmo tempo reduza os seus custos, fazendo com que os seus preços fiquem mais competitivos.

Na empresa em que o presente projeto foi desenvolvido, os projetos de melhoria contínua são denominados projetos *Kaizen*, que significa "boa mudança". Portanto, *Kaizen* significa melhoria contínua, que pode ser feita em termos de custo, qualidade e entrega, de modo que técnicas diferentes podem ser usadas para melhorar os processos para aumentar as vendas e a participação no mercado. A metodologia *Kaizen* ficou conhecida em todo o mundo por ser utilizada em larga escala no Sistema Toyota de Produção, que se baseia em esforços contínuos para melhoria do sistema. (DHAFR et al., 2006)

3.6.1 Design de Experimentos (DoE)

O Design de Experimentos, também conhecido como *Design* de Experimentos (DoE), é uma abordagem estatística de otimização de variáveis de um processo que permite a variação de múltiplos fatores simultaneamente com o objetivo de selecionar os melhores padrões técnicos para um determinado processo. (MURRAY et al., 2016). De acordo com Fontão (2011), quando se utiliza essa técnica, pode-se verificar processos de diversas complexidades, utilizando ferramentas estatísticas para analisar as variáveis que fazem parte do processo e melhorá-las. A utilização desse modelo estatístico em que ocorre um planejamento e avaliação acerca dos resultados do experimento é importante, já que o fenômeno pode ser estudado de uma forma mais precisa, como aborda Costa *et al* (2008).

Segundo Kerlinger (1973), a definição de experimento pode ser dada como uma pesquisa onde uma ou mais variáveis são alteradas a fim de se observar o comportamento de mudança nas variáveis dependentes concomitantemente à manipulação de variáveis

independentes. Por meio da realização desses experimentos, pode-se conhecer melhor as variáveis e como elas influenciam o comportamento do processo como um todo, levando assim a uma tomada de decisão mais assertiva, já que um processo mais regulado possui um menor custo e tempo de realização.

3.6.2 PDCA

Em um processo fabril, os resultados reais de uma operação são comparados com uma meta ou um ponto definido de chegada. O caminho entre essas duas etapas é caracterizado por medidas corretivas que são adotadas caso ocorra alguma grande disparidade. A natureza repetida e contínua da melhoria contínua segue esta definição usual de controle e é representada pelo ciclo PDCA (KNIGHT et al., 2012).

Para Longaray et al. (2017) a etapa de planejamento estabelece objetivos e metas sobre itens que serão avaliados e os métodos para alcançá-los. A segunda etapa é a execução dos procedimentos padrão e o início do treinamento das pessoas que irão realizar o trabalho. Em seguida a execução do trabalho e a coleta de dados. A etapa de verificação consiste em comparar os resultados obtidos com a meta traçada em primeiro lugar a partir dos dados coletados nos passos anteriores. O último passo, a ação corretiva, busca eliminar o problema em dois momentos: Em primeiro lugar agir sobre o resultado do problema, colocando o processo novamente em funcionamento e agir sobre as causas do problema, a fim de evitar sua repetição.

4 MATERIAIS E MÉTODOS

Para realizar a metodologia proposta nesse trabalho, primeiramente foram buscadas informações em meios eletrônicos relativos a pintura e a programação relacionada ao *Machine Learning*. Além disso, referências foram utilizadas das disciplinas de Corrosão e Degradação de Materiais e Programação de Computadores I e II. Finalmente, foi utilizado como referência metodológica de artigos lidos e matérias informativas referentes a esses temas supracitados. A metodologia utilizada para realizar o link entre Inteligência Artificial e o processo de Pintura foi pioneira na empresa em que o projeto foi feito.

Para a construção do algoritmo de aprendizagem de máquina em um processo de pintura industrial, a metodologia utilizada foi dividida em vários passos, como ilustrado na Figura 5, a fim de se obterem resultados mais assertivos com a realidade do processo, sendo eles:

Passo 1: Coleta dos parâmetros *in loco* nas cabines de pintura e ao final do processo;

Passo 2: Escolha das ferramentas, recursos e bibliotecas de programação ideais para a construção do algoritmo e análise dos dados através de Machine Learning;

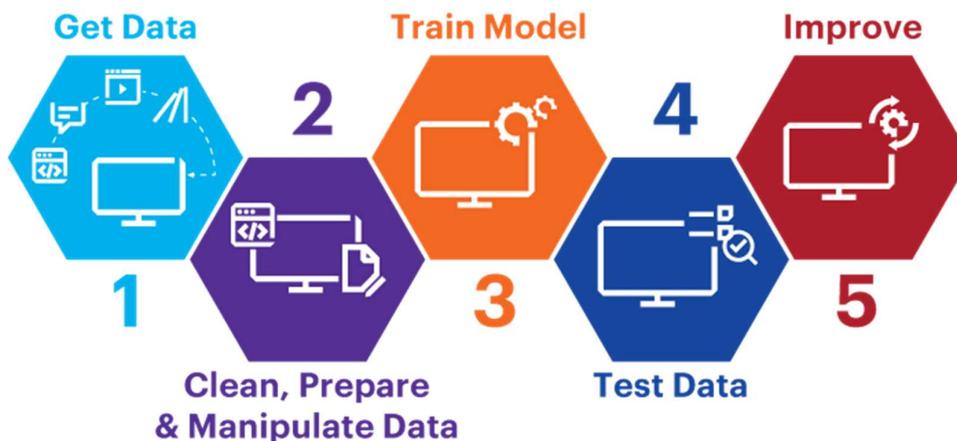
Passo 3: Processamento de dados;

Passo 4: Interpretação de dados;

Passo 5: Análises acerca do algoritmo e dos resultados obtidos.

Toda a construção do algoritmo foi feita utilizando a linguagem de programação *Python*, devido a facilidade de programação e suporte por meio da comunidade e bibliotecas disponíveis.

Figura 5 - Etapas do aprendizado de máquina



Fonte: (DEV,2020)

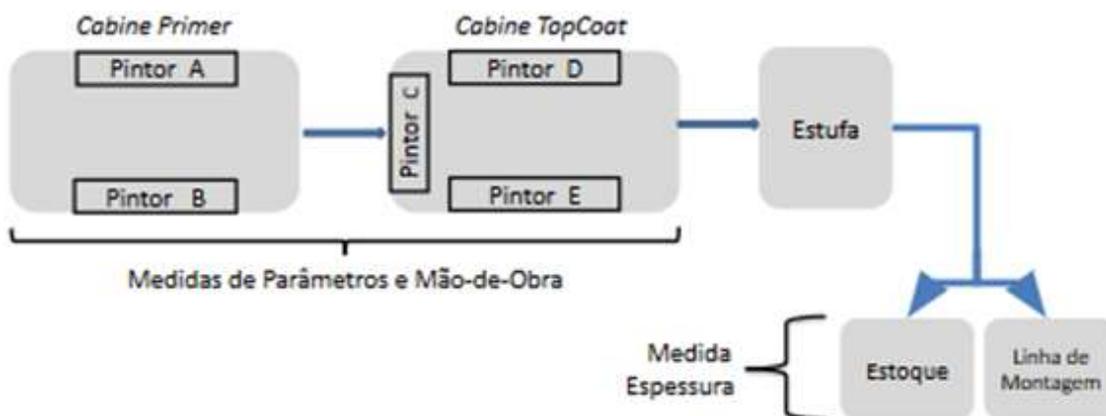
4.1 Coleta de Dados

A coleta de dados foi realizada de acordo com a realidade da empresa e possibilidade de obtenção de dados durante a rotina de produção de veículos. Sabe-se que em um projeto de *Machine Learning*, dependendo de onde o projeto ocorre, tais dados estarão disponíveis de formas diferentes e utilizados também em formatos diferentes.

Para obter o conjunto de dados utilizados para a otimização da linha de produção de Pintura Industrial Automotiva, o conjunto de dados foi obtido *in loco* na linha de produção durante 30 dias. Tal obtenção de dados foi realizada diariamente pelo autor, impactando positivamente a mudança de medição de qualidade da área. Em um primeiro momento foram feitos registros do interior das Cabines de Pintura, como mostrado na Figura 7, observando o clima (umidade relativa do ar, insolação e temperatura) no dia da medição, a produção diária total, os parâmetros associados ao processo e finalmente o layout e antropometria dos pintores, sendo ilustrado na Figura 6. No final da linha, onde as peças já estavam pintadas, analisou-se a espessura final da camada de tinta.

Para a obtenção dos dados dentro da cabine, foi utilizado o Anemômetro AZ9871, instrumento capaz de medir diversos parâmetros tais como a velocidade do ar, volume de ar, temperatura, umidade e temperatura da cabine. Para a medida de espessura de camada de tinta, foi utilizado o Espessímetro Byko-Test 4500. O tempo de escoamento da tinta foi medido usando um copo Zahn. A tinta é despejada no interior do copo, depois o copo é levantado e mede-se o tempo, em segundos, que o líquido gasta para escoar totalmente pelo furo inferior.

Figura 6 - Layout do processo onde os dados foram obtidos



Fonte: Próprio Autor

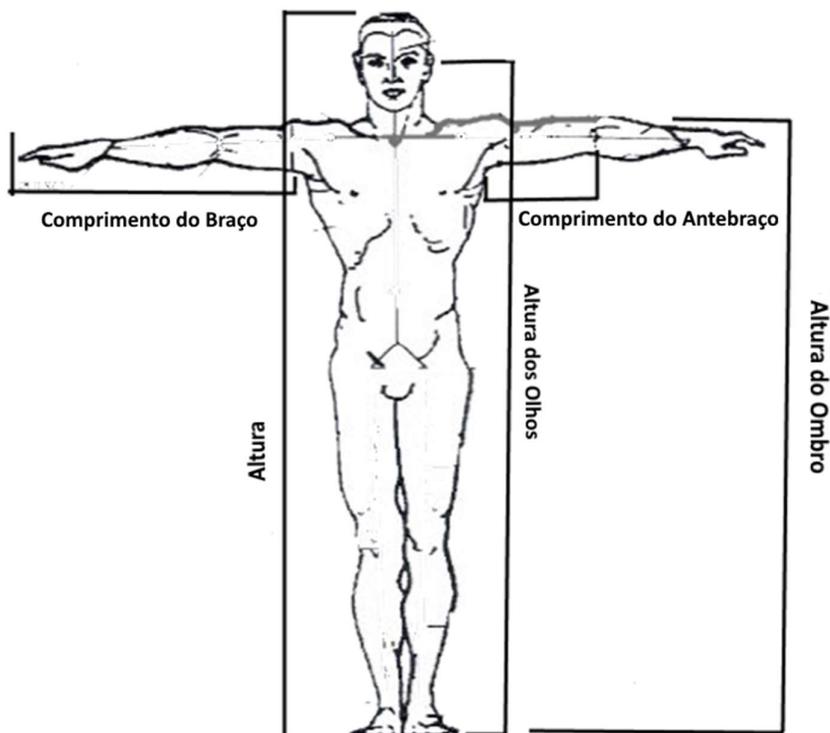
Durante a realização das medidas dos parâmetros, os pintores eram trocados diariamente nas suas posições dentro da cabine, com o objetivo de entender como essa variável impactava as peças pintadas. Dentro da primeira cabine de *Primer*, dois pintores ficam localizados em plataformas móveis que se deslocam nos três eixos do espaço. Já na cabine de *TopCoat*, há a presença de três pintores, sendo que dois deles ficam localizados em plataformas móveis e o terceiro no chão.

Figura 7 - Parâmetros sendo recolhidos in loco



Fonte: Próprio Autor

Segundo a Enciclopédia Global (2020), a Antropometria é uma técnica em que são feitas medidas e contraposições de dados sobre as características do corpo humano. Como ilustrado na Figura 8, o corpo humano pode ser dividido em várias partes de interesse para um estudo.

Figura 8 - Antropometria do Corpo Humano

Fonte: Adaptado de Enciclopédia Global (2020)

A antropometria dos pintores foi medida antes do processo de pintura. As propriedades físicas dos pintores influenciam o processo de pintura manual, devido ao fato de que as peças pintadas têm alturas, larguras e características diferentes, tais como: chassi, eixo, biela, braço de lança, dentre outros. Os pintores aplicam a tinta enquanto estão em pé em suas plataformas mecânicas, e suas propriedades físicas afetam a forma como a tinta é aplicada em determinadas regiões das peças.

Um exemplo da antropometria dos pintores é que um pintor que tem menor altura dos olhos (distância entre os olhos e o chão) tem mais dificuldades para pintar certas regiões do que outro pintor que tem uma maior altura dos olhos. Há uma necessidade de equilibrar as medidas antropométricas para o processo de fabricação (neste caso específico, a pintura manual), otimizando a posição dos trabalhadores e tornando o sistema mais eficiente.

As medições de espessura, feitas com o auxílio do espessímetro digital, eram realizadas diariamente após as peças terem sido pintadas e já secas. Pontos específicos de medição foram atribuídos nas peças, a fim de medir a espessura de forma consistente ao longo de todo o comprimento da mesma.

Quanto maior o número de pontos específicos utilizados e o número de medidas realizadas, mais fácil é para o algoritmo encontrar um padrão entre os valores de entrada (O layout dos pintores e os parâmetros de cabine) e os valores de saída (Espessura de Tinta).

Depois de realizadas as medidas, elas foram transformadas em variáveis para serem analisadas pelo algoritmo. Esse *dataset* possui 15 variáveis, descritas a seguir:

- *Prod* = Número de peças pintadas na Pintura.
- *Tempcabpri* = Temperatura na cabine de Primer.
- *Varcabpri* = Velocidade do ar na cabine de Primer.
- *Pintorcabpri1* = Posição do pintor 1 na cabine de Primer.
- *Pintorcabpri2* = Posição do pintor 1 na cabine de Primer.
- *Tempcabtop* = Temperatura na cabine de TopCoat.
- *Varcabtop* = Velocidade do ar na cabine de TopCoat.
- *Pintor1cabtop* = Posição do pintor 1 na cabine de TopCoat.
- *Pintor2cabtop* = Posição do pintor 2 na cabine de TopCoat.
- *Pintor3cabtop* = Posição do pintor 3 na cabine de TopCoat.
- *Peca* = Tipo de peça que foi pintada.
- *Cor* = Cor da peça que está sendo pintada.
- *Viscosidade* = Tempo de escoamento da tinta no copo Zahn no dia em que a mesma foi aplicada.
- *Jateamento* = Se a peça passou ou não pelo jato de granalha.
- *Clima* = Clima do dia da aplicação

4.2 Escolha de ferramentas para aplicação do algoritmo

Em um contexto atual de utilização de programação para aprendizado de máquina, o *Python* foi escolhido devido a sua maior versatilidade e vantagem na utilização para esse fim. Existem diversas bibliotecas e ferramentas que fazem com que o *Python* seja a linguagem mais utilizada nesse contexto, como por exemplo o *scikit-learn* que é utilizado para o aprendizado

de máquina, o Pandas para manipulação de dados e o *Numpy*, ferramenta que faz diversos cálculos computacionais.

As ferramentas de programação foram utilizadas devido à sua extensa utilização já comprovada por meio de diversos programas e situações por diversos outros usuários da comunidade de ciência de dados. O conhecimento da existência dessas ferramentas e o caráter multidisciplinar desse projeto contribuíram para que fosse utilizadas as principais soluções presentes dessa área. Essas ferramentas foram modeladas para utilização para a especificidade desse projeto, ou seja, a otimização de uma linha de Pintura. Além disso, na implementação do algoritmo foi revisada toda a documentação da biblioteca para que a utilização da mesma esteja de acordo com o objetivo proposto.

Assim, será feita a descrição de cada ferramenta e da biblioteca que foi utilizada no algoritmo, a fim de que possa ficar claro a pretensão do motivo das mesmas serem usadas.

4.2.1 Python

De acordo com Bertozzo (2019), a área de ciência de dados é caracterizada pela diversidade de ferramentas a serem utilizadas e também de abordagens para o reconhecimento de padrões e análise de dados. Esses problemas podem ser sanados utilizando várias linguagens de programação e diversos algoritmos diferentes para chegar em uma predição de resultados.

Entretanto, como a linguagem de uso geral, o *Python* tem visto um grande crescimento de popularidade dentro da comunidade científica de computação, de forma que as mais recentes bibliotecas de *Machine Learning* e de *Deep Learning* são baseadas em *Python*. Com seu foco na facilidade de leitura, *Python* é uma linguagem de programação que é amplamente reconhecida por ser fácil de aprender e capaz de aproveitar o poder das linguagens de programação em nível de sistema quando necessário. Além desses benefícios, a comunidade desenvolve e compartilha várias ferramentas e bibliotecas disponíveis, fazendo com que o *Python* seja especificamente utilizado pra trabalho em ciências de dados e aprendizagem de máquinas. (RASCHKA et al., 2020)

Bertozzo (2019) explana que além do *Python*, linguagens como ‘R’ e Java são muito utilizadas, sendo a linguagem R utilizada como contra partida gratuita em softwares estatísticos com alto custo e que utilizam gráficos estatísticos. O mesmo mostra também como *Python* é uma linguagem amplamente utilizada no processamento de dados, com uma curva de

aprendizagem curta e rápida e vasta gama de recursos disponibilizados pela comunidade para que seja feita a programação desejada.

A comunidade *Python* cresceu significativamente durante a última década e, segundo um relatório apresentado por GitHub (2020), “a principal força motriz por trás do crescimento da *Python* está em uma comunidade em rápida expansão de profissionais e hobbyistas de ciências de dados”. Segundo Raschka (2020), isso se deve em parte à facilidade de uso dessa linguagem e sua rede de apoio de usuários. Também se deve a viabilidade de ser utilizada no Machine Learning, bem como com o crescimento da infraestrutura privada de nuvens e soluções de processamento de dados como o *Google Cloud*, *Amazon AWS* e *Microsoft Azure*, que são capazes de lidar com volumes de dados massivos, possibilitando um rápido trabalho. A capacidade de criação e desenvolvimento de algoritmos de forma simples, escalável e acelerada possibilitou um desenvolvimento maciço de recursos digitais para serem utilizados em diversos backgrounds e disciplinas diferentes.

4.2.2 Anaconda

Anaconda é uma distribuição gratuita e de código aberto das linguagens de programação *Python* e R para computação científica (ciência de dados, aplicações de aprendizado de máquinas, processamento de dados em larga escala, análise preditiva, dentre outros.), que visa simplificar o gerenciamento e a implantação de pacotes. *Python* e Anaconda apoiam uma vasta quantidade de processos no trabalho com dados científicos, desde a obtenção, manipulação e processamento de dados, até a visualização e comunicação dos resultados da pesquisa. (ANACONDA, 2020)

4.2.3 TensorFlow

O TensorFlow é uma interface para compilar algoritmos de aprendizagem de máquinas e uma plataforma de implementação para executar tais algoritmos. A utilização do TensorFlow é muito versátil, podendo ser executado de forma simples em uma grande variedade de dispositivos, desde telefones e tablets até computadores interligados em rede. O sistema é flexível e pode ser usado para expressar uma ampla variedade de algoritmos, incluindo algoritmos de treinamento e inferência para modelos de redes neurais profundas. (TENSORFLOW. 2020)

4.2.4 Scikit-learn

O Scikit-learn é uma biblioteca para o *Python* que é utilizada no contexto de *Machine Learning*, realizando algoritmos de classificação, regressão e agrupamento de valores utilizados

na programação. Ele é chamado para ser utilizado dentro do algoritmo na forma de *sklearn*. Suas funções são o treinamento, testes e avaliações das métricas do algoritmo, na forma de regressões, classificações, seleção de modelos e pré-processamento. (SCIKIT-LEARN..., 2020)

4.2.5 Numpy

O Numpy é uma distribuição utilizada em *Python* que possibilita que o o algoritmo trabalhe com operações numéricas envolvendo arranjos, vetores e matrizes de várias dimensões. Pode-se dizer que o Numpy oferece suporte a cálculos avançados no *Python* como softwares já consagrados como o MATLAB. (NUMPY..., 2020)

4.2.6 Pandas

O Pandas é uma biblioteca utilizada com o *Python* que tem como objetivo a manipulação e análise de dados. É uma grande mudança quando se trata de analisar dados com *Python* e é uma das ferramentas mais preferidas e amplamente utilizadas na manipulação de dados, se não a mais utilizada. (PANDAS..., 2020)

4.2.7 Keras

Keras é uma Interface de Programação de Aplicação (API) de aprendizado profundo escrito especificamente para a linguagem *Python*, executado na plataforma *TensorFlow*. Essa interface foi desenvolvida para que seja possível ter uma uma rápida experimentação na utilização de redes neurais, de forma que a mesma fornece uma alta velocidade de iteração para os algoritmos. (KERAS..., 2020)

4.3 Treinamento do Algoritmo

O *Machine Learning* é caracterizado como um algoritmo supervisionado, há a necessidade de usar um *dataset* para que ele seja treinado. No caso desse trabalho, os dados obtidos em uma planilha foram divididos em duas partes: A primeira delas, o dataset de treinamento, consistiu em 80% dos dados, enquanto a parte de testagem nos 20% restantes.

O *dataset* de treinamento é utilizado com o objetivo de que o modelo veja e aprenda com estes dados. O algoritmo encontra relações, desenvolvem a compreensão do todo, tomam decisões e avaliam sua precisão a partir dos dados de treinamento que são dados. E quanto melhores forem os dados de treinamento, melhor será o desempenho do modelo.

Após feito o treinamento, o algoritmo foi testado com os 20% restante dos dados da planilha. O conjunto de dados do *dataset* de teste fornece as bases para que se possa avaliar o modelo e a sua factibilidade de utilização na linha. Esse conjunto de dados é utilizado com o

objetivo de realizar uma estimativa de como o modelo foi treinado e estimar as propriedades do mesmo.

4.4 Testagem do Algoritmo

Após realizar testes com o algoritmo, verificou-se que ele é confiável para ser utilizado em previsões por meio da sua assertividade quando está sendo compilado com o restante do *dataset*. A metodologia de testagem do algoritmo se dá mediante o uso da biblioteca Numpy que é programada utilizando o TensorFlow. Como ilustrado na Figura 9, à medida que o algoritmo é iterado utilizando os valores das variáveis previamente atribuídas (na parte esquerda da interface do programa), ele retorna o valor *loss* (Perda, localizada na parte direita da figura) que é analisado.

A métrica de precisão é usada para medir o desempenho do algoritmo de uma forma que possa ser interpretada. A perda é o resultado de uma má previsão. Uma perda é um número que indica quão ruim foi a previsão do modelo em um único exemplo. Se a previsão do modelo for perfeita, a perda é zero, caso contrário, a perda é maior. O objetivo do testagem de um modelo é encontrar um conjunto de pesos e medidas que tenham baixa perda.

Tal valor é atualizado à medida em que cada conjunto de parâmetros é iterado, e retornam uma porcentagem, a qual evidencia que os valores com menores porcentagens são melhores, pois o algoritmo está errando menos.

Figura 9 - Iteração do algoritmo

```
Epoch 93/100
2399/2399 [=====] - 0s 68us/step - loss: 21.5854
Epoch 94/100
2399/2399 [=====] - 0s 71us/step - loss: 21.5882
Epoch 95/100
2399/2399 [=====] - 0s 71us/step - loss: 21.5907
Epoch 96/100
2399/2399 [=====] - 0s 69us/step - loss: 21.5897
Epoch 97/100
2399/2399 [=====] - 0s 69us/step - loss: 21.5851
Epoch 98/100
2399/2399 [=====] - 0s 69us/step - loss: 21.5856
Epoch 99/100
2399/2399 [=====] - 0s 69us/step - loss: 21.5866
Epoch 100/100
2399/2399 [=====] - 0s 72us/step - loss: 21.5923
```

Fonte: Próprio Autor

5 RESULTADOS E DISCUSSÕES

5.1 Configuração Ótima de Linha

Após o algoritmo realizar todas as suas iterações, ele retorna, por meio do seu aprendizado anterior e predição futura os valores ideais para a linha de pintura analisada, como ilustrado na Figura 10.

Figura 10 - Resultado da melhor combinação proposta

```
File "zmq/backend/cython/socket.pyx", line 242, in
zmq.backend.cython.socket._send_copy

File "zmq/backend/cython/checkrc.pxd", line 12, in
zmq.backend.cython.checkrc._check_rc

KeyboardInterrupt

In [2]:
In [2]: comb_melhor
Out[2]:
array([[ '72', '28.0', '0.8', 'A', 'B', '28.0', '0.8', 'C', 'E', 'D',
        'CHICX', 'Cinza', 'Sim', '17', 'Ensolarado']], dtype='<U32')
```

Fonte: Próprio Autor

Essa combinação é um valor de saída que compõe todas as 15 variáveis previamente adicionadas e analisadas pelo algoritmo. Após o algoritmo encontrar um padrão que estava se repetindo nas mais diversas condições nos valores ideais de processo, ele retornou, por meio da chamada *comb_melhor* toda essa junção de padrões de processo, clima e localização dos Pintores.

Os resultados encontrados estavam dentro dos parâmetros de processo normais para a Pintura, analisados pela Carta Estatística de Processo (CEP), apesar de que em alguns dias de coleta de dados os mesmos estavam pontualmente fora do normal. Isso evidencia que o algoritmo reconheceu esses desvios de processo e que as melhores combinações são as que estão dentro dos valores estatísticos padrão para a realidade desse processo, como ilustrado na Tabela 1.

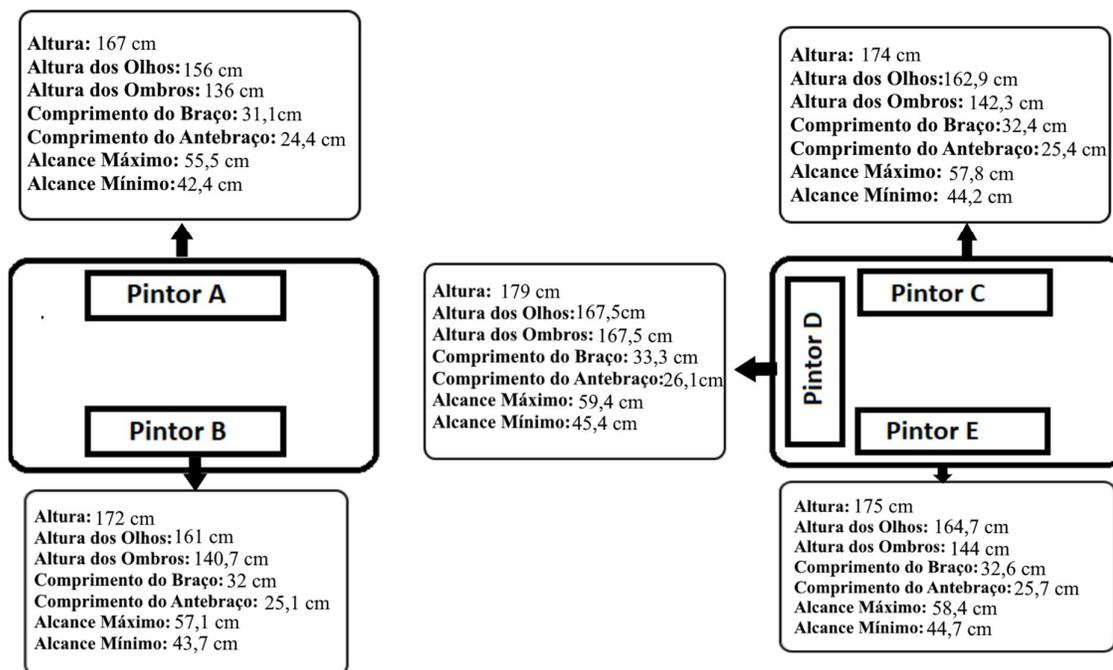
Tabela 1 - Saídas do algoritmo para determinada peça

Variável	Resultado
Temperatura Cabine Primer	28°C
Velocidade do Ar Cabine Primer	0,8 m/s
Pintor da Primeira Plataforma	A
Pintor da Segunda Plataforma	B
Velocidade do Ar Cabine TopCoat	0,8 m/s
Pintor da Primeira Plataforma	C
Pintor da Segunda Plataforma	E
Pintor no Solo	D
Peça Analisada	CHICX
Cor Utilizada	Cinza
Passagem pelo Jateamento	Sim
Tempo de Escoamento no copo Zahn	17 s
Clima para Aplicação	Ensolarado

Foi proposto esse método supervisionado para o diagnóstico e correlações entre as muitas variáveis do processo de pintura. Este método é baseado em um entendimento prévio de como as variáveis são importantes para o processo, como as ferramentas estão funcionando totalmente para a aplicação da tinta e como os operadores foram totalmente treinados para realizar suas tarefas diárias. A rede neural fornece a interpretação da decisão por meio da configuração ideal que foi extraída.

Em uma representação gráfica de como seria o *layout* dos pintores dessa linha de pintura, associado a antropometria dos mesmos, pode-se fazer algumas inferências. Os pintores A, B, C e E estão em cabines mecânicas, e não precisam ter alturas mais altas para pintar as peças, ao contrário do pintor D, que trabalha no nível do solo, e tem a altura maior. O Pintor D precisa alcançar peças mais altas para pintar, portanto, precisa de comprimentos de braços maiores e altura maior do que os operadores nas cabines mecânicas. O algoritmo escolhe esta posição ideal para eles com base em seus resultados de pintura anteriores, como ilustrado na Figura 11.

Figura 11 - Layout Ideal dos Pintores em Linha



Fonte: Próprio Autor

Esse *layout* evidencia como os pintores permanecem na mesma posição pintando todas as peças, enquanto alguns deles são mais aptos em pintar certas peças, ou estão mais acostumados a isso. Isto pode causar resultados não ideais. Aliado ao melhor layout para os pintores no processo, pode-se determinar os melhores parâmetros antropométricos do trabalhador para uma pintura ideal na empresa.

O defeito do tipo escorrido de tinta, como evidenciado na Figura 12, é um dos defeitos que acontecem com maior frequência no processo e geram um impacto no mesmo. A presença dele caracteriza uma aplicação incorreta da tinta, sendo necessário ações corretivas.

A configuração colocada em prática após a análise do algoritmo evidenciou que a pintura foi realizada de uma melhor forma. A presença de defeitos de pintura visíveis e reportada no Quality Gate diminuiu, como ilustrado na Figura 13, garantindo assim, também, a redução de custos envolvidos como consumo de tinta em excesso e retrabalho. Os custos envolvidos na realização desse projeto foram estratificados em custos de mão-de-obra para a realização do mesmo. Com o conhecimento prévio da melhor configuração para cada peça a ser pintada na linha fornecida pelo algoritmo, haverá menos defeitos de pintura.

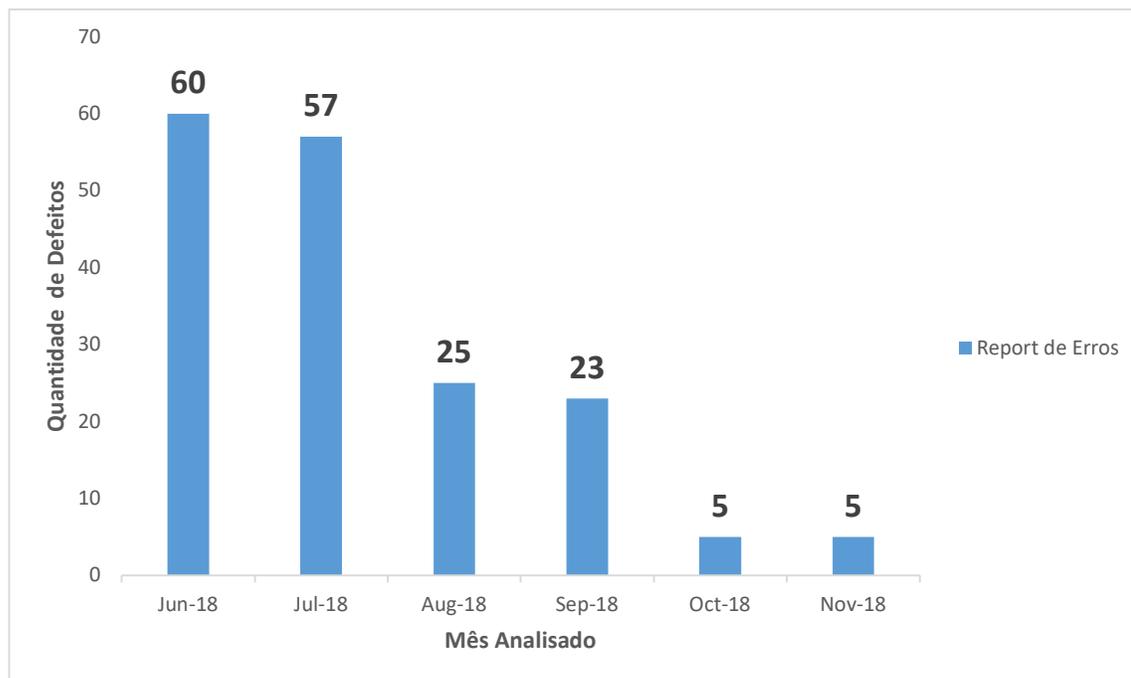
Figura 12 - Peça com defeito de escorrido de tinta



Fonte: Próprio Autor

No gráfico da Figura 13 pode-se visualizar como a aplicação do DoE no início de agosto de 2018 impactou positivamente os resultados de produção, gerando uma redução de 41% nesse tipo de defeito. Mesmo após a realização desse DoE, em que os parâmetros do sistema foram conhecidos, a mão de obra foi treinada e as ferramentas configuradas, o número de defeitos de pintura diminuiu. Entretanto, essa redução evidenciou que havia uma interferência humana no processo e parâmetros em relação ao desempenho da operação de pintura.

Sendo assim, após a compilação e utilização do algoritmo em linha no início de outubro de 2018, houve uma redução de 80% dos defeitos se comparado com os meses de agosto e setembro de 2018. Isso evidencia que há uma correlação direta entre o desempenho e o humor dos operadores. Portanto, é importante entender o que é ruído fixo e passível de ser matematizado e a parte relativa às características psicofísicas dos operadores, de forma que essa última não é passível de otimização.

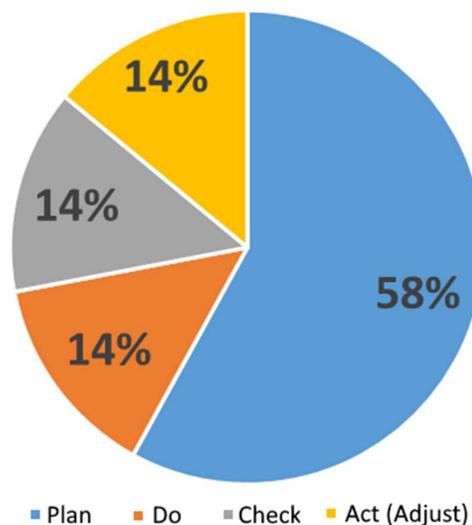
Figura 13 - Quantidade de defeitos de escorrimento de tinta

Fonte: Próprio Autor

5.2 Lógica do PDCA na Realização de Projetos

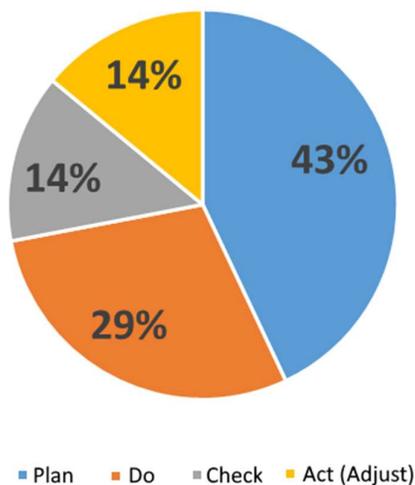
A utilização do algoritmo faz com que seja possível analisar uma grande quantidade de dados em um espaço curto de tempo, facilitando assim a tomada de decisão no que concerne ao conhecimento total do problema. Um benefício principal quando se utiliza a IA na realização de projetos ocorre quando o foco está nos membros da equipe de desses projetos. Grande parte do tempo é gasto na criação de registros, relatórios e várias outras tarefas repetitivas. Quando se faz que a IA realize essas tarefas, os funcionários podem alocar seus tempos de trabalho em nas tarefas mais importantes, tornando assim o processo mais eficiente e economizando tempo e custos.

Isso ficou evidente nesse projeto em uma mudança do tempo total de cada etapa do ciclo PDCA. Na realização tradicional de projetos, a maior parte do tempo despendido (58%) pela equipe que realizava o mesmo era na parte “*Plan*” (Planejamento), enquanto no ciclo “*Do*” despendia somente 14% do tempo total, como ilustrado na Figura 14. Nessa primeira etapa todos os dados eram analisados manualmente, e caso os dados fossem muito grandes (como no caso de um DoE que possui cerca de 3.000 parâmetros envolvidos), correlações e interpretações seriam muito difíceis de serem feitas, senão impossíveis.

Figura 14 - Tempo utilizado no ciclo PDCA antes da utilização de IA

Fonte: Próprio Autor

Com a utilização da IA, nesse projeto houve uma grande redução do tempo utilizado na etapa “Plan”, de 58% para um valor final de 43%, como pode ser analisado na Figura 15. Uma consequência dessa redução é o ganho de tempo do ciclo “Do” (29%) para realizar ações importantes e necessárias como o desenvolvimento de outros projetos da empresa. Os ciclos “Check” (Checar) e “Adjust” (Ajustar) continuaram sendo responsáveis por 14% do tempo total despendido na realização desse projeto, já que são etapas em que são feitas observações se as mudanças funcionaram e se ainda existem problemas na execução.

Figura 15 - Tempo utilizado no ciclo PDCA após a utilização de IA

Fonte: Próprio Autor

6 CONCLUSÃO

O desenvolvimento do presente trabalho possibilitou a realização de se utilizar um algoritmo programável de Inteligência Artificial em uma linha de produção. No caso específico da Pintura Industrial, tal algoritmo é factível de ser utilizado para otimizar a performance, tendo em vista que após a introdução do mesmo a quantidade de defeitos reportados mensalmente diminuiu.

Isso se deve ao fato de que o algoritmo resultou em uma configuração específica para a pintura de peças dentro da linha de Pintura. A configuração de parâmetros de processo e de operadores antes utilizada era única para todas as peças que passavam para ser pintadas. Com a introdução dessa nova ferramenta, houve o conhecimento de que para cada peça pode-se ter uma configuração específica, com o objetivo de otimizar a pintura individual.

A redução de defeitos de pintura foi uma consequência da personalização do processo. Ficou evidenciado que há um limite de melhora da pintura, que tem como barreira as características humorísticas do operador, que transcendem o ambiente fabril. Tendo em vista a antropometria dos mesmos, observou-se que a diferença de altura entre os operadores impacta a forma que os mesmos pintam, tendo em vista que trabalhadores que não têm o auxílio das plataformas mecânicas possuem a necessidade de terem uma altura maior e maiores alcances para realizarem a pintura em partes mais difíceis das peças.

Em relação a utilização de algoritmos para a solução de problemas, ficou claro que o uso destes levam a um aumento de eficiência. Os resultados do presente trabalho mostraram a redução do tempo gasto pelos funcionários na análise e planejamento das atividades aumentando o tempo disponível para que possam realizar outras atividades dentro da empresa, enquanto os computadores realizam as atividades monótonas e análises mais rápidas que o ser humano.

6.1 TRABALHOS FUTUROS

Tendo em vista os resultados obtidos nesse projeto pelo uso de Inteligência Artificial, trabalhos futuros podem ser desenvolvidos com o objetivo de:

- Otimizar o algoritmo com mais dados e variáveis.
- Estender a utilização desse algoritmo e da metodologia em outras áreas da empresa;
- Utilizar os conceitos de Inteligência Artificial nos laboratórios do Departamento de Engenharia de Materiais do CEFET/MG para auxiliar na análise de resultados e tomada de decisão.

REFERÊNCIAS BIBLIOGRÁFICAS

- AKAFUAH, Nelson et al. Evolution of the automotive body coating process : a review. **Coatings**, [S.L.], v. 6, n. 2, p. 24-28, 13Jun. 2016.
- ALMADA-LOBO, Francisco. The Industry 4.0 revolution and the future of Manufacturing Execution Systems (MES). **Journal of Innovation Management**, [S.L.], v. 3, n. 4, p. 16-21, 24Jan. 2016. University of Porto.
- ANACONDA | The World's most popular data science platform.2019. Disponível em: <<https://www.anaconda.com/distribution/>>. Acesso em: 30 set. 2020
- BAHRIN, Mohd Aiman Kamarul; OTHMAN, Mohd Fauzi; AZLI, Nor Hayati Nor; TALIB, Muhamad Farihin. INDUSTRY 4.0: a review on industrial automation and robotic. **Jurnal Teknologi**, [S.L.], **Penerbit UTM Press** v. 78, n. 6-13, p. 327-345, 28 Jun. 2016..
- BARLETTA, M.; GISARIO, A.; TAGLIAFERRI, V. Electrostatic spray deposition (ESD) of polymeric powders on thermoplastic (PA66) substrate. **Surface & Coatings Technology**. v. 201. p. 296-308. 2006
- BERTOZZO, Richard Junior. Aplicação de *Machine Learning* em dataset de consultas médicas do sus. 2019. 1 v. **Trabalho de Conclusão de Curso** (Graduação) - Curso de Sistemas de Informação, Universidade Federal de Santa Catarina, Florianópolis, 2019
- COSTA, E. P.; POLITANO, P. R. Modelagem e mapeamento: técnicas imprescindíveis na gestão de processos de negócios. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 2008, Rio de Janeiro.
- DACOMBE, James. An introduction to Artificial Neural Networks (with example). Disponível em: <<https://medium.com/@jamesdacombe/an-introduction-to-artificial-neural-networks-with-example-ad459bb6941b>>. Acesso em: 3Out. 2020.
- DHAFR, Nasreddin et al. Improvement of quality performance in manufacturing organizations by minimization of production defects. **Robotics And Computer-Integrated Manufacturing**, [S.L.], v. 22, n. 5-6, p. 536-542, Out.2006. Elsevier BV.
- DEV, Mr.. ML(Machine Learning) and It's cmodels Disponível em: <<https://medium.com/@devendra.bhumca2014/ml-machine-learning-and-its-models-f44dcc5ae306>>. Acesso em: 19 out. 2020.
- ENCICLOPÉDIA GLOBAL. O Que é antropometria? Disponível em: <<http://www.megatimes.com.br/2013/04/o-que-e-antropometria.html>>. Acesso em: 22 out. 2020.
- EROL, Selim; JÄGER, Andreas; HOLD, Philipp; OTT, Karl; SIHN, Wilfried. Tangible Industry 4.0: a scenario-based approach to learning for the future of production. **Procedia Cirp**, [S.L.], **Elsevier BV** v. 54, p. 13-18, 2016.
- FAZENDA, J. M. R. **Tintas & vernizes – Ciência e Tecnologia**. 3 ed.. Editora Edgard Blucher. 2005.
- FAZENDA, Jorge M.R. et al. **Paints and varnishes**. 4 ed. São Paulo: - Blucher, 2009

FONTÃO, Henio et al. **Aplicação da ferramenta planejamento de experimentos no marketing de relacionamento: um estudo no varejo**. p. 215-233, 2 dez. 2018. Antonella Carvalho de Oliveira.

GITHUB. The State of the octoverse. Disponível em: <<https://octoverse.github.com/>>. Acesso em: 13 set. 2020.

GALITSKY, Christina; WORRELL, Ernst. Energy efficiency improvement and cost saving opportunities for the vehicle assembly industry. **An Energy Star Guide For Energy And Plant Managers**, [S.L.], v. 5, n. 8, p. 327-345, 1 jan. 2008.

GILCHRIST, Alasdair. **Industry 4.0: The industrial internet of things**. Estados Unidos: Apress, 2016.

GOH, A.t.c..Back-propagation neural networks for modeling complex systems. **Artificial Intelligence In Engineering**, [s.l.], Elsevier BV v. 9, n. 3, p.143-151, -Jan. 1995..

HAENLEIN, Michael; KAPLAN, Andreas. A brief history of artificial intelligence: on the past, present, and future of artificial intelligence. **California Management Review**, [S.L.], v. 61, n. 4, p. 5-14, 17 Jul. 2019.

JUDI, Hairulliza Mohamad. **Applications and Experiences of Quality Control**, Bangi, p. 495-508, 12 set. 2020.

KERAS: **The python Deep Learning library**. [S. l.]: 2019. Disponível em: <<https://keras.io/>>. Acesso em: 18 out. 2020

KERLINGER. **Metodologia da pesquisa em ciências sociais**. São Paulo: Epu, 1973.

KHAN, Hamid Ullah et al. Impact of Continuous improvement on organization performance insight from pakistan: an empirical study. international journal of innovation, **Management and Technology**, [S.L.], p. 7-14, 2018. EJournal Publishing.

KNIGHT, John E. et al. Applying the PDCA Cycle to the Complex Task of Teaching and Assessing Public Relations Writing. **International Journal Of Higher Education**, [S.L.], v. 1, n. 2, p. 327-345, 4 jun. 2012. Sciedu Press. <http://dx.doi.org/10.5430/ijhe.v1n2p67>.

KOTTWITZ, Leandro Spanemberg. **Controle de qualidade da repintura automotiva em oficinas de pequeno porte**. 2019. -. Trabalho de Conclusão de Curso (Graduação) - Curso de Engenharia Mecânica, Uniiversidade Regional do Noroeste do Estado do Rio Grande do Sul, Penambi, 2019.

LEE, Jay; KAO, Hung-An; YANG, Shanhu. Service innovation and smart analytics for industry 4.0 and big data environment. *Procedia Cirp*, **Elsevier BV**. [S.L.], v. 16, p. 3-8, 2014.

LONGARAY, André Andrade et al. Proposta de aplicação do ciclo PDCA para melhoria contínua do sistema de confinamento bovino: um estudo de caso. **Sistemas & Gestão**, [S.L.], v. 12, n. 3, p. 353-61, 5 set. 2017.

MAHAJAN, SM et al. Review on automotive body coating process. **International Journal of Engineering and Management Research**, [S.L.], v. 9, n. 2, p. 103-106, 10 abr. 2019. Vandana Publications.

MATOS, Jhonata de Souza. **A indústria 4.0 na economia brasileira: seus benefícios, impactos e desafios**. 2018. 49 f. Trabalho de Conclusão de Curso (Graduação) - Curso de Ciências Econômicas, Universidade Federal de Uberlândia, Uberlândia, 2018.

McKinsey & Company. Industry 4.0 How to navigate digitization of the manufacturing sector. abril 2015

MURRAY, Paul M. et al. The application of design of experiments (DoE) reaction optimisation and solvent selection in the development of new synthetic chemistry. **Organic & Biomolecular Chemistry**, [S.L.], v. 14, n. 8, p. 2373-2384, 2016. Royal Society of Chemistry (RSC).

NUMPY: fundamental package for scientific computing with Python. [S. l.], 2019. Disponível em: <<https://numpy.org/>>. Acesso em: 05 out. 2020

NORVIG, Peter; RUSSELL, Stuart. **Inteligência artificial**. Tradução da . 3. ed. Rio de Janeiro: Elsevier Editora, 2013.

PANDAS: Python Data Analysis Library. [S. l.], 2018. Disponível em: <<https://pandas.pydata.org/index.html>>. Acesso em: 05 out. 2020.

PI, Vu Ngoc et al. A study on cost optimization of steel shot blasting systems. **Applied Mechanics and Materials**, [S.L.], v. 52-54, p. 568-572, mar. 2011. Trans Tech Publications, Ltd..

PINTO, Vitor Arins. **Redes neurais convolucionais de profundidade para reconhecimento de textos em imagens de captcha**. 2016. 1 v. **Trabalho de Conclusão de Curso (Graduação) - Curso de Sistemas de Informação**, Universidade Federal de Santa Catarina, Florianópolis, 2016.

RANA, Masud; ZHANG, Xinmin; AKHER, Sayed Abdul. Determination of factors and quality control of car painting based on FMEA and SPC.V2. **Modern Mechanical Engineering**, [S.L.], v. 08, n. 02, p. 158-177, 2018. Scientific Research Publishing Inc.. <http://dx.doi.org/10.4236/mme.2018.82011>.

RASCHKA, Sebastian; PATTERSON, Joshua; NOLET, Corey. *Machine Learning in Python: main developments and technology trends in data science, machine learning, and artificial intelligence*. **Information**, [S.L.], v. 11, n. 4, p. 193-345, 4Abr. 2020.

RICH, Elaine; KNIGHT, Kevin; **Inteligência artificial**. 2. ed. **São Paulo**: MAKRON, 1994.

RÜBMANN, M. et al. Industry 4.0: The future of productivity and growth in manufacturing industries. **Boston Consulting Group**. Boston, p. 20. 2015

SCIKIT-LEARN: *Machine Learning in Python*. [S. l.], 2019. Disponível em: <<https://scikit-learn.org/>>. Acesso em: 06 out. 2020.

SCHULD, Maria et al. An introduction to quantum machine learning. **Contemporary Physics, Informa UK Limited** [S.L.], v. 56, n. 2, p. 172-185, 15Out. 2014..

SILVER, David; HUANG, Aja; MADDISON, Chris J.; GUEZ, Arthur; SIFRE, Laurent; DRIESSCHE, George van Den; SCHRITTWIESER, Julian; ANTONOGLOU, Ioannis; PANNEERSHELVA, Veda; LANCTOT, Marc. Mastering the game of go with deep neural

networks and tree search. **Nature**, [S.L.], v. 529, n. 7587, p. 484-489, Jan. 2016. Springer Science and Business Media LLC.

SORDAN, Prof. Me. Juliano Endrigo. O desafio da indústria 4.0 para as empresas brasileiras. Disponível em: <<https://www.fatecsertaozinho.edu.br/noticia/o-desafio-da-industria-4-0-para-as-empresas-brasileiras>>. Acesso em: 03 out. 2020.

SØRENSEN, P. A. et al. Anticorrosive coatings: a review. **Journal of Coatings Technology and Research**, [S.L.], v. 6, n. 2, p. 135-176, 9Jan. 2009. Springer Science and Business Media LLC.

TENSORFLOW **White Papers**. <Disponível em: <https://www.tensorflow.org/about/bib>>. Acesso em: 21Out. 2020.

TODA, Kimio, editor. **Automotive painting technology: a Monozukuri-Hitozukuri perspective**. Springer, 2013.

TURING, A. M.. I. **Computing machinery and intelligence**. Mind, [S.L.], v., n. 236, p. 433-460, 1 out. 1950. Oxford University Press (OUP)

VERAS, Carlos Vinicius Aladim. **Estudo comparativo de técnicas de redes neurais artificiais na previsão da velocidade do vento em curto prazo**. 2013. 57 f. – Tese de Engenharia de Computação (Doutorado), Universidade de Pernambuco, Recife, 2013.

VANLUCHENE, R. D.; SUN, Roufei. Neural networks in structural engineering. **Computer-aided Civil and Infrastructure Engineering**, [s.l.], v. 5, n. 3, p.207- 215, Set.1990. Wiley.

VERGÉS, Gisele Ribeiro. **Estudo do desempenho de sistemas de pintura para materiais das redes de distribuição de energia elétrica situadas em regiões litorâneas**. Dissertação (Mestrado) - Curso de Pós-Graduação em Engenharia, Área de Concentração em Engenharia e Ciências dos Materiais, da Universidade Federal do Paraná. Curitiba, 2005

WEISSMAN, Steven A. et al. Design of Experiments (DoE) and process optimization. A review of recent publications. **Organic Process Research & Development**, [S.L.], v. 19, n. 11, p. 1605-1633, 29 ago. 2014. American Chemical Society (ACS).

WOOLF, B. P. Building intelligent interactive tutors: student-centered strategies for revolutionizing e-learning. **Morgan Kaufmann Publishers/Elsevier**, 2009.