

Bianca Voltarelli Panico

**Implementação de Data Driven Decision Management (DDDM)  
em uma Linha de Manufatura de Asas**

Trabalho de Conclusão de Curso  
(TCC) submetido ao Curso de  
Graduação em Engenharia Elétrica da  
Universidade Federal de Santa  
Catarina como parte dos requisitos  
para obtenção do grau de Bacharel em  
Engenharia Elétrica

Orientador: Prof. Richard Demo  
Souza, Dr.

Florianópolis  
2020

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Panico, Bianca Voltarelli  
Implementação de Data Driven Decision Management (DDDM)  
em uma Linha de Manufatura de Asas / Bianca Voltarelli  
Panico ; orientador, Richard Demo Souza, 2020.  
65 p.

Trabalho de Conclusão de Curso (graduação) -  
Universidade Federal de Santa Catarina, Centro Tecnológico,  
Graduação em Engenharia Elétrica, Florianópolis, 2020.

Inclui referências.

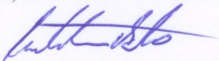
1. Engenharia Elétrica. 2. Mineração de dados. 3.  
Tomada de decisão. 4. Dados. 5. Data Science. I. Demo  
Souza, Richard . II. Universidade Federal de Santa  
Catarina. Graduação em Engenharia Elétrica. III. Título.

Bianca Voltarelli Panico

**Implementação de Data Driven Decision Management (DDDM)  
em uma Linha de Manufatura de Asas**

Este Trabalho foi julgado adequado como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica e aprovado, em sua forma final, pela Banca Examinadora

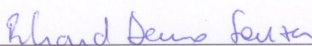
Florianópolis, 12 de fevereiro de 2020.



---

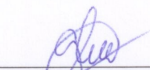
Prof. Renato Lucas Pacheco, Dr.  
Coordenador do Curso de Graduação em Engenharia Elétrica, em  
exercício

**Banca Examinadora:**



---

Prof. Richard Demo Souza  
Orientador  
Universidade Federal de Santa Catarina



---

Prof. Glauber Brante  
Universidade Tecnológica Federal do Paraná



---

Prof. Erlon Finardi  
Universidade Federal de Santa Catarina



Este trabalho é dedicado a todos que são apaixonados pelo o que a Engenharia proporciona.





## AGRADECIMENTOS

Nada mais justo do que meu primeiro agradecimento ser para minha mãe. Agradeço por todo suporte e incondicional apoio que me foi dado durante toda minha vida e, principalmente, durante esses cinco anos. Você para mim, mãe, é o exemplo de mulher determinada, guerreira e amorosa, que quero levar para minha vida. Você me motiva em continuar crescendo e conquistando cada vez mais. Sempre vai ser para você e por você.

Agradeço ao meu irmão, Felipe, por sempre estar do meu lado, me apoiando, puxando minha orelha e me ensinando como ter um dos maiores corações do mundo. Ao meu primo Danilo, só tenho a agradecer por todo apoio, carinho e por ser um exemplo para mim. Vocês dois são minha figura paterna, eu só espero ser um pouquinho do que vocês foram e são para mim, para o Rafa e para a Ana Flor.

À minha tia Dina, que aguentou minhas bagunças e ausências durante alguns anos, eu sempre vou ser muito grata. Tenho muito orgulho da mulher guerreira que você é, tia.

Aos meus amigos, não tenho nem palavras, sempre disse que muito do que sou e conquisto agora é devido à vocês. Vocês me moldaram, me fizeram uma pessoa melhor e fizeram com que Floripa fosse desde o primeiro momento o meu lar. Eu amo muito vocês e guardo todas lembranças com muito carinho.

Um agradecimento especial à Brunna Casagrande e ao Danilo Oliveira, meus “amores de TCC”. Eu não ia conseguir começar e terminar sem vocês.

Aos meus colegas da EMBRAER, Ivan, Alessandro, João, Maurício e Marcus, agradeço por me ensinarem tanto profissionalmente, como também sobre a vida em uma perspectiva diferente da minha.

Por fim, agradeço ao meu orientador e professor Richard, por me pressionar quando preciso e ser tão direto e pertinente em suas correções, mesmo com meus atrasos. Você foi um dos meus melhores professores durante a graduação e te considero um exemplo a ser seguido. Agradeço também ao professor Pacheco que sempre me ajudou e me aconselhou durante o curso.







*"Information is the oil of the 21st century, and analytics is the combustion engine."*

(Peter Sondergaard, 2011)



## RESUMO

Neste trabalho é apresentado resultados da implementação da abordagem de *Data Driven Decision Management* (DDDM) em uma linha de manufatura de asas de avião. Para isso foi desenvolvido uma plataforma que adquire, minera e exibe dados em tempo real referentes ao processo automatizado de furação de uma asa. A metodologia de *Cross Industry Standard Process for Data Mining* (CRISP-DM) foi utilizada para ajudar no desenvolvimento da plataforma, visando obter *dashboards* mais eficientes para tomada de decisões. A implementação do DDDM nesse processo tem como resultado um aumento de 147% na cadência mensal de produção, além de gerar uma economia estimada em, aproximadamente, US\$170.000,00 em até dois anos.

**Palavras-chave:** DDDM. Mineração de dados. Tomada de decisão. Dados. *Data Science*.



## **ABSTRACT**

This work presents results of the implementation of the Data Driven Decision Management (DDDM) approach in an airplane wing manufacturing line. For this, it was developed a platform that acquires, mines and displays data in real time related to the automated process of drilling a wing. The Cross Industry Standard Process for Data Mining (CRISP-DM) methodology was used to help in the development of the platform, aiming to obtain more efficient dashboards for decision making. The implementation of DDDM in this process results in a 147% increase in the monthly production rate, besides to generating an estimated savings of approximately U\$ 170,000.00 in up to two years.

**Keywords:** DDDM. Data mining. Decision making. Data. Data science.





## LISTA DE FIGURAS

Figura 1 - Fluxo do processo KDD .....	29
Figura 2 - Pilares da Indústria 4.0 .....	31
Figura 3 - Ciclo de vida original do modelo CRISP-DM.....	38
Figura 4 – Fluxograma da integração CRISP-DM e DDDM .....	40
Figura 5 - <i>Log</i> de processo .....	43
Figura 6 - <i>Log</i> de alarmes.....	45
Figura 7 - Exemplo do banco de dados MongoDB com dados .....	47
Figura 8 - Gráfico de performance .....	49
Figura 9 - Gráfico tempo furação por ferramentas.....	49
Figura 10 - Gráfico de tempo de atividades dentro do <i>setup</i> .....	50
Figura 11 - Gráfico de tempo de ocorrência por alarme.....	50
Figura 12 - Gráfico de progresso de produção de uma asa .....	51
Figura 13 - Gráfico de balanceamento de robô na linha de produção ...	51
Figura 14 - Gráfico de monitoramento de vida de ferramenta .....	52
Figura 15 - Gráfico de análise de furos realizados pela posição XYZ..	52
Figura 16 - Gráfico de performance para exemplo de caso.....	54
Figura 17 - Gráfico de <i>setup</i> para exemplo de caso .....	55
Figura 18 - Gráficos de tempo de furação por ferramenta para exemplo de caso.....	56
Figura 19 - Gráficos de tempo de ocorrência de alarme para exemplo de caso.....	57
Figura 20 - Gráficos de balanceamento de linha para exemplo de caso	58
Figura 21 - Gráfico de comparação dos casos <i>As Is</i> e <i>To Be</i> .....	2960
Figura 22 - Gráfico de ganho anual quando aplicada a abordagem DDDM .....	61



## **LISTA DE TABELAS**

Tabela 1 - Necessidades de cada stakeholder.....	41
Tabela 2 - Principais colunas do <i>log</i> de processo e seus significados...	44



## **LISTA DE ABREVIATURAS E SIGLAS**

MD – Mineração de dados

KDD – *Knowledge Discovery in Databases*

BCG – *Boston Consulting Club*

ABDI – Agência Brasileira de Desenvolvimento Industrial

KPI – *Key Performance Indicator*

CRISP-DM – *Cross Industry Standard Process for Data Mining*

DDDM – *Data Driven Decision Management*



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>27</b>
1.1	OBJETIVOS .....	28
<b>1.1.1</b>	<b>Objetivo geral</b> .....	<b>28</b>
<b>1.1.2</b>	<b>Objetivos específicos</b> .....	<b>28</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>29</b>
2.1	DATA MINING .....	29
2.2	INDÚSTRIA 4.0 .....	30
2.3	KEY PERFORMANCE INDICATOR .....	33
<b>3</b>	<b>METODOLOGIA</b> .....	<b>37</b>
3.1	CRISP-DM .....	37
3.2	DATA DRIVEN DECISION MANAGEMENT .....	39
<b>4</b>	<b>DESENVOLVIMENTO</b> .....	<b>41</b>
4.1	BUSINESS UNDERSTANDING .....	41
4.2	DATA UNDERSTANDING .....	43
4.3	DATA PREPARATION .....	46
4.4	MODELING .....	47
<b>4.4.1</b>	<b>Indicadores de performance</b> .....	<b>48</b>
<b>4.4.2</b>	<b>Indicadores de balanceamento de linha</b> .....	<b>51</b>
<b>4.4.3</b>	<b>Indicador de vida útil de broca</b> .....	<b>52</b>
<b>4.4.4</b>	<b>Indicador de <i>hole position</i></b> .....	<b>52</b>
4.5	EVALUATION E DEPLOYMENT .....	53
4.6	RESULTADOS .....	54
<b>4.6.1</b>	<b>Gráfico de performance</b> .....	<b>54</b>
<b>4.6.2</b>	<b>Gráfico de tempo de atividades dentro do <i>setup</i></b> .....	<b>55</b>
<b>4.6.3</b>	<b>Gráfico de tempo de furação por ferramentas</b> .....	<b>56</b>
<b>4.6.4</b>	<b>Gráfico de tempo de ocorrência por alarme</b> .....	<b>57</b>
<b>4.6.5</b>	<b>Gráficos de balanceamento de linha</b> .....	<b>57</b>
<b>4.6.6</b>	<b>Gráfico de análise de furos realizados pela posição XYZ</b> .....	<b>58</b>
<b>5</b>	<b>CONCLUSÃO</b> .....	<b>63</b>

<b>6</b>	<b>REFERÊNCIAS.....</b>	<b>65</b>
----------	-------------------------	-----------



## 1 INTRODUÇÃO

Com o advento da Indústria 4.0, cada vez mais a automação de tarefas e o controle de dados e informações tem ganhando destaque nos processos industriais. Empresas de diferentes nichos, buscam nas vertentes dessa revolução meios para melhoria e otimização de processos, que geram diretamente mais lucro e economia.

Nesse contexto, a vertente de *Big Data* é o principal motor dessa 4ª Revolução Industrial, pois sendo um dos resultados dos processos automatizados, temos cada vez mais dados. Segundo Aizhan Tursunbayeva *et al.* (2018), 90% de todos os dados do mundo até 2018 foram gerados em 2016 e 2017. Essa inundação de dados, traz mudanças também no modo de tomada de decisão das empresas que passam a evitar decisões que possam a vir sofrer influências pessoais e optam por aquelas regidas por dados.

Um estudo da McKinsey (2010) sobre mil grandes negócios mostrou que, quando as organizações trabalham para reduzir o efeito do viés pessoal em seus processos de tomada de decisão, elas obtinham retornos até 7% maiores.

De acordo também com a pesquisa de Andrew McAfee e Erik Brynjolfsson, do MIT, as empresas que injetam *big data* e *analytics* em suas operações mostram taxas de produtividade e lucratividade 5% a 6%, respectivamente, superiores às de seus pares (Harvard Business Review, 2012).

O setor aeronáutico brasileiro também vem sofrendo grandes alterações nesse contexto, principalmente na implantação de sistemas automatizados no chão de fábrica para o processo de manufatura. Segundo Campbell (2006), a etapa de furação dentro da Manufatura de um avião corresponde a 60% do custo do processo, devido a esse alto percentual essa foi uma das primeiras etapas a serem automatizadas. Hoje já são encontrados robôs e rebitoras que possibilitam a melhora na precisão dos furos, na velocidade do processo, na segurança dos operadores, entre outros.

Entretanto, mesmo com a automatização o processo ainda possui gargalos de produção originados por problemas não identificados. Nesse contexto, os dados revelam-se como uma oportunidade para a identificação desses problemas e uma maneira para viabilizar a tomada de decisão baseada em informações concretas, possibilitando maior lucratividade, retorno e eficiência produtiva.

## 1.1 OBJETIVOS

### 1.1.1 Objetivo geral

O trabalho tem como objetivo geral: aplicar a abordagem de *Data Driven Decision Management* (DDDM) na produção de uma linha de manufatura de asas de avião.

### 1.1.2 Objetivos específicos

Foram definidos alguns objetivos específicos que auxiliarão que o objetivo geral seja alcançado. Estão listados a seguir.

- a) Fazer a revisão bibliográfica sobre o CRISP-DM (*Cross Industry Standard Process for Data Mining*) e DDDM;
- b) Compreender o processo de manufatura de asas de avião, com foco principal no processo de furação automatizada;
- c) Listar os requisitos de projeto de automação na manufatura de asas de avião;
- d) Obter dados de robôs de furação de asas de avião;
- e) Compreender os dados utilizados;
- f) Fazer a mineração dos dados obtidos;
- g) Aplicar regra de negócio nos dados minerados;
- h) Consolidar os dados resultantes em forma de gráficos, tabelas ou *dashboards*<sup>1</sup>;
- i) Aplicar a abordagem DDDM nas visibilidades criadas;
- j) Estimar economias geradas pela tomada de decisão através de dados.

---

<sup>1</sup> Um *dashboard* é a apresentação visual das informações mais importantes e necessárias para alcançar um ou mais objetivos do negócio, consolidadas e ajustadas em uma única tela para que a informação possa ser monitorada de forma ágil.

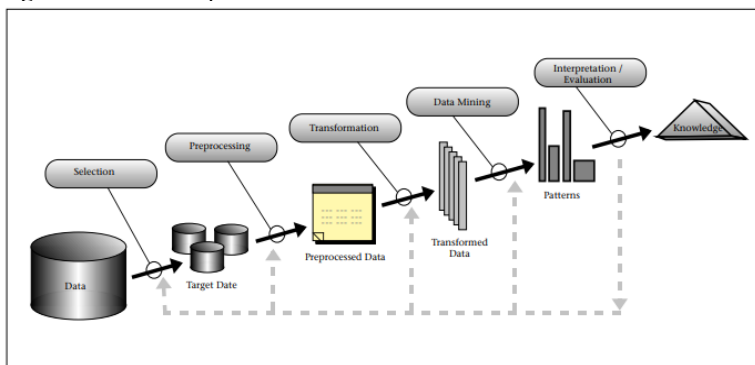
## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 DATA MINING

*Data mining*, ou mineração de dados (MD), se tornou uma disciplina estabelecida no âmbito da ciência da computação. As origens da MD podem ser rastreadas até o final dos anos 80, quando o termo começou a ser usado. (Kantardzic, 2011).

Segundo Fayyad (1996), no início dos anos 90, a MD era comumente reconhecida como um subprocesso dentro de um processo maior chamado descoberta de conhecimento em bancos de dados ou KDD (*Knowledge Discovery in Databases*), relacionada à descoberta de "informações ocultas". Outros subprocessos que fazem parte do processo KDD são a preparação de dados (armazenamento, limpeza de dados, pré-processamento) e a análise e visualização de resultados. Para fins práticos, KDD e MD são vistos como sinônimos, mas tecnicamente um é um subprocesso do outro, como é observado na Figura 1.

Figura 1 – Fluxo do processo KDD



Fonte: *From Data Mining to Knowledge Discovery in Databases* (1996)

A MD tem duas vertentes: a predição e a descrição. A primeira, envolve algumas variáveis ou campos no banco de dados para prever valores desconhecidos ou futuros de outras variáveis de interesse. Já a descrição, concentra-se em encontrar padrões para descrever os dados. Os objetivos dessas vertentes podem ser obtidos usando métodos específicos de MD, que são apresentados a seguir. (Fayyad *et al.*, 1996).

- Classificação: é uma função que mapeia (classifica) um item dos dados em um dos campos predefinidos (Weiss e Kulikowski, 1991).
- Regressão: é uma função que mapeia um item dos dados em uma variável com valor real.
- Clusterização: tarefa que procura identificar um conjunto finito de categorias ou *clusters* para descrever os dados (Jain e Dubes, 1988).
- Sumarização: método para encontrar uma descrição compacta para um subconjunto de dados.
- Modelagem de dependência: consiste em encontrar um modelo que descreve dependências significativas entre as variáveis.

Assim, a MD é uma tentativa de obter conhecimento a partir de massas de dados. Em outras palavras, a MD é o processo de descobrir correlações, padrões e tendências significativas, analisando grandes quantidades de dados armazenados nos bancos de dados.

A premissa desse processo é uma argumentação ativa, ou seja, não é o usuário que define o problema e seleciona os dados e suas ferramentas. As suas próprias ferramentas analisam os dados, descobrem problemas ou oportunidades, e então diagnosticam o comportamento dos negócios, requerendo a mínima intervenção do usuário.

## 2.2 INDÚSTRIA 4.0


O termo Indústria 4.0 ou quarta Revolução Industrial, foi introduzido publicamente pela primeira vez em 2011, por Kagermann (2011), sob uma iniciativa de aumentar a competitividade alemã na indústria de manufatura. Segundo ele, essa nova revolução é apresentada principalmente pelo novo modelo exigido pelo mercado, no qual tendências mercadológicas apontam cada vez mais a exigência de fábricas inteligentes.

Santos (2015, p. 12) apresenta a Indústria 4.0 como:

[...] um projeto no âmbito da estratégia de alta tecnologia do governo alemão que promove a informatização da Manufatura. O objetivo é chegar à fábrica inteligente (Smart Manufacturing) que se caracteriza pela capacidade de adaptação, a eficiência dos recursos e ergonomia, bem como a integração de clientes e parceiros de negócios em processos de negócios e de valor. Sua base tecnológica é composta por sistemas físicos/cibernéticos e a Internet das Coisas. Especialistas acreditam que a Indústria 4.0 ou a quarta revolução industrial poderia ser realizada dentro de uma década (SANTOS, 2015, p 12).

As transformações associadas ao conceito da Indústria 4.0 apresentam potencial para aumentar a flexibilidade, a velocidade, a produtividade e a qualidade dos processos de produção (BCG, 2015). Para alcançar esses resultados, nove tecnologias foram definidas como pilares dessa revolução, sendo elas representadas na Figura 2.

Figura 2 – Pilares da Indústria 4.0



Fonte: Endeavor Brasil (2017)

Trabalhando juntas elas transformarão a produção (BCG, 2016). Células isoladas e otimizadas se unirão com um fluxo de produção totalmente integrado, automatizado e otimizado, levando maior eficiência e mudança nos relacionamentos tradicionais de produção entre fornecedores, produtores e clientes - bem como entre humanos e máquinas.

Vale ressaltar um desses pilares, *Big Data e Analytics*. A análise baseada em grandes conjuntos de dados na manufatura, proporciona o aumento da performance e otimização dos processos industriais. Dentro da Indústria 4.0, os dados têm fontes distintas que se interligam e se tornam padrões para tomada de decisão em tempo real. Assim, é possível identificar falhas ou otimizar o processo dos outros pilares da revolução, como por exemplo, dos robôs autônomos. Além disso, esse pilar influenciará diretamente áreas como controle de qualidade e manutenção preditiva: atividades antes feitas por engenheiros, agora serão feitas por algoritmos.

Em um estudo da BCG (2015), para fornecer uma compreensão quantitativa do potencial impacto mundial da Indústria 4.0, eles analisaram os modos de fabricação na Alemanha e descobriram quatro benefícios diretos, a seguir.

- Produtividade: nos próximos cinco a dez anos, as melhorias de produtividade serão de 15 a 25%.
- Receita: a nova demanda por equipamentos aprimorados e novas aplicações de dados, bem como a demanda dos consumidores por produtos mais personalizados, gerará um crescimento adicional de receita de cerca de 30 bilhões de euros.
- Emprego: levará a um aumento de 6% nos empregos nos próximos dez anos e a demanda por engenheiros pode ser de 10% maior. Porém, vale ressaltar que haverá uma mudança nas habilidades requeridas, profissões com atividades de produção repetitivas devem acabar, o que traz um desafio para esse novo momento.
- Investimento: a adaptação dos processos de produção para incorporar a Indústria 4.0 exigirá um investimento de 250 bilhões de euros nos próximos dez anos.

No contexto nacional, segundo levantamento da ABDI, a estimativa anual de redução de custos industriais no Brasil, a partir da migração da indústria para o conceito 4.0, será de, no mínimo, R\$ 73 bilhões/ano. (ABDI Governo Federal)

## 2.3 KEY PERFORMANCE INDICATOR

A manufatura enxuta se concentra na eliminação de fontes de desperdício e na busca contínua de maneiras de melhorar a organização. Para avaliar e medir os processos, as organizações costumam usar indicadores de desempenho (*Key Performance Indicator*, KPI) (Franceschini et al., 2007). Os KPIs são tão úteis que são usados em uma infinidade de empresas e em combinação com uma variedade de filosofias de negócios, de *Lean* à *Six Sigma*.

De acordo com Adriaanse (1993), os KPIs têm como objetivo simplificar, quantificar, analisar e comunicar. Seus principais indicadores de desempenho são fatores rastreados pelas organizações para analisar seus processos de fabricação. Esses critérios são usados para medir o sucesso em relação a um conjunto de metas ou objetivos predeterminados. O gerenciamento visual é um sistema no qual os KPIs são exibidos no chão de fábrica para fornecer objetivos claros e visíveis aos funcionários da linha de frente. Critérios relacionados à produção, qualidade e eficiência da produção exibidos claramente para incentivar o desempenho dos funcionários. Assim, a utilização de indicadores de desempenho é uma das formas das organizações obterem vantagens competitivas. (Pyzdek, 2003).

Os KPIs podem ser divididos em categorias de atuação, dentre algumas delas, podemos citá-los abaixo:

- indicadores de produtividade: estão relacionados ao uso dos recursos da empresa em relação a entrega.
- indicadores de qualidade: são responsáveis por identificar as não conformidades do processo.
- indicadores de capacidade: mede a capacidade de resposta de um processo.
- indicadores estratégicos: auxiliam na orientação de como a empresa está em relação aos seus objetivos já definidos.

Dentro dessas categorias, os KPIs variam de empresa para empresa, mas existem sete que são comuns dentro de um sistema produtivo, como vemos a seguir.

- Contagem: refere-se à quantidade de um produto criado. Pode se referir à produção total de um turno, uma semana ou desde a última troca de máquinas, entre outros.
- Taxa de rejeição: as medidas de taxa de rejeição medem a produção de sucata, ela é utilizada para manter essa quantidade dentro dos limites aceitáveis.
- Taxa: a taxa mede a velocidade com que as mercadorias são produzidas. Taxas mais lentas significam diminuição nos lucros e taxas mais rápidas podem afetar a qualidade do produto. A taxa deve-se manter constante, como definido em projeto
- Alvo: são os valores esperados na saída.
- Tempo de Takt: a quantidade de tempo que leva para concluir uma tarefa ou processo. O rastreamento e a exibição dessas informações ajudam o fabricante a identificar onde estão ocorrendo gargalos em um processo.
- Eficácia Geral do Equipamento (OEE): é a medida de se seus recursos, pessoal ou maquinário, estão sendo usados com eficiência.
- Tempo de inatividade programado e não programado: tempo em que o processo, operador ou máquina está parado.
- Tempo de *setup*<sup>2</sup>: tempo gasto com toda configuração ou troca de material ou máquina no processo, pode ser minimizado com o SMED (*Single Minute Exchange of Die* ou “troca rápida de ferramenta”).

---

<sup>2</sup> O *setup* pode ser de duas formas: *setup in* ou *setup out*. No primeiro caso, ele ocorre em alguma etapa durante o processo. Já no segundo, pode ocorrer antes do processo iniciar ou após seu término.



Assim, os KPIs ajudam a garantir que os processos sejam eficientes e que as metas definidas pela organização sejam monitoradas e atingidas.



### 3 METODOLOGIA

No presente Trabalho de Conclusão de Curso serão utilizados dois subsídios para auxiliar o desenvolvimento. A metodologia CRISP-DM, explicada no próximo tópico, subsidiará o desenvolvimento de uma plataforma que tem como resultado visibilidades sobre um processo de furação de asas de avião.

Nesse resultado, será aplicada a abordagem de DDDM, apresentada no tópico consecutivo. Essa abordagem, por sua vez, não tem o objetivo de guiar o desenvolvimento do projeto, mas sim quantificar retornos desse desenvolvimento e mostrar fontes de economia em um processo, através da tomada de decisões através de dados.

#### 3.1 CRISP-DM

CRISP-DM é uma metodologia que fornece uma abordagem estruturada para o planejamento de projetos de MD. Ela foi concebida por um consórcio de empresas desse setor e financiada pela União Europeia, na década de 90, com o intuito de desenvolver essa área até então pouco explorada.

A MD transforma todo volume de dados em informações úteis para tomada de decisão e a metodologia CRISP-DM trabalha exatamente em cima disso, reunindo as melhores práticas para que ele seja o mais produtivo e eficiente possível.

Segundo Chapman (2000), a metodologia é composta por seis fases, organizadas de maneira cíclica, cujo fluxo é unidirecional, possibilitando ir e voltar entre as suas fases e tarefas.

O modelo apresentado na Figura 3, rege a metodologia. Essas fases partem desde o entendimento do negócio e especificações do projeto, até sua implantação, como são descritos nos tópicos a seguir.

Figura 3 – Ciclo de vida original do modelo CRISP-DM



Fonte: IBM Knowledge Center (2012)

A etapa *Business Understanding* é a etapa inicial do projeto e considerada a mais importante. Ela garante que o projeto atenda às necessidades dos usuários e a entrega corresponda às expectativas do cliente, o que é primordial para a geração de valor (SMART VISION EUROPE, 2016). Assim, essa fase tem como foco identificar o problema a ser resolvido, fazer perguntas ao cliente e estabelecer o objetivo do projeto, o mais próximo possível da necessidade do cliente. Sendo importante também, entender como ele afeta a empresa e descobrir fatores que possam influenciar o resultado do projeto. Ao fim dessa etapa, é possível definir os requisitos necessários do projeto e seu escopo.

O segundo estágio, chamado de *Data Understanding*, começa com a coleta inicial dos dados, prosseguindo com atividades para familiarização deles. Nessa etapa, é necessário identificar a fonte de obtenção dos dados, bem como suas qualidades e restrições técnicas.

A fase de *Data Preparation*, é complementar à anterior. Com o entendimento dos dados, agora é possível organizá-los da melhor forma para atingir o objetivo do projeto. Para isso, nessa etapa é feita a seleção dos dados que serão utilizados, a sua limpeza e a construção de novas variáveis, que são necessárias para o modelo.

A aplicação de técnicas de modelagem e regras de negócio acontecem na quarta etapa, *Modeling*. Nela os dados são inseridos em um algoritmo.

Na quinta fase, *Evaluation*, temos a avaliação das funcionalidades, dos objetivos e dos critérios de sucesso definidos na primeira etapa. São lançadas versões betas para teste, *feedback*, revisão e correção de erros.

Na última etapa, *Deployment*, são definidos os planos de acesso e governança, assim como planos de manutenção, treinamentos e, conseqüentemente, a apresentação dos resultados.

### 3.2 DATA DRIVEN DECISION MANAGEMENT

O presente projeto, além de seguir o método CRISP-DM, irá utilizar a abordagem de DDDM. Essa abordagem envolve a coleta de dados com base em objetivos específicos ou KPIs, analisando padrões ou possibilidade de ganhos, com o objetivo de utilizá-los para desenvolver estratégias e atividades que trazem melhores resultados.

Fundamentalmente, DDDM significa trabalhar em direção aos principais objetivos do negócio, por meio de dados verificados e analisados, sem deixar que quesitos pessoais interfiram.

Esses dados podem ter dois tipos:

- qualitativo: dados que não são definidos por números ou métricas, como entrevistas, vídeos e imagens;
- quantitativo: definidos em números e estatísticas, onde mediana, desvio padrão e outros métodos estatísticos desempenham um papel fundamental.

Além disso, um fluxo típico de DDDM envolve quatro fases (BAMBRYCK, 2010): aquisição de dados, mineração de dados, consolidação e comunicação de dados e tomada de decisão. Algumas dessas fases lembram fases da metodologia CRISP-DM, mas aqui a tomada de decisão é o foco.

A parte de aquisição de dados, refere-se às atividades de obtenção de dados, que podem originar de formulários, consulta a base de dados já existentes ou processos de monitoração em tempo real. O ideal é que após a aquisição, os dados sejam organizados em um banco de dados ou em planilhas.

O processo de MD, como já comentado, é a parte principal do processo, tendo como entrada uma base de dados e como saída um


conhecimento (FAYYAD *et al.*, 1996). Essa etapa trará valor aos dados, a partir da aplicação de lógicas de negócio e algoritmos.

Complementar à mineração, a consolidação e comunicação de dados, são responsáveis por ‘mostrar o valor’ dos dados, resumindo-os através de tabelas, gráficos e *dashboards*. Nessa etapa, é essencial saber o objetivo a ser atingido com a aplicação do DDDM para obter melhores formas de apresentação deles.

A última fase, a de tomada de decisão, utiliza as ferramentas e dados gerados nas etapas anteriores para definir ações baseadas em dados.

Assim, como as fases do método CRISP-DM e da abordagem DDDM se completam, neste projeto, a utilização do primeiro terá como objetivo estruturar e guiar a criação do sistema e, conseqüentemente, criar *inputs* para que abordagem DDDM seja utilizada na tomada de decisão e melhoria do processo. O fluxograma apresentado na Figura 4 mostra essa interação.

Figura 4 – Fluxograma da integração CRISP-DM e DDDM



Fonte: Elaborado pela autora (2020)

## 4 DESENVOLVIMENTO

A Indústria Aeronáutica já tem dado seus primeiros passos em direção a nova revolução industrial, principalmente com a utilização de robôs nas etapas de montagem na linha de produção. Porém, mesmo com essas novas tecnologias, ainda há paradas não programadas, não conformidades e desperdício no processo.

Com isso, identifica-se a oportunidade de melhoria no processo automatizado de furação de uma empresa aeronáutica brasileira com a criação de uma plataforma de *Data Science*, chamada DRIMS (*Drilling Robots Integrated Management System*), que gera KPIs para tomada de decisões.

Para tal, foi aplicada a metodologia CRISP-DM que, como citado anteriormente, através do processo de MD gera valor nos dados desses robôs. As etapas dessa metodologia aplicadas ao projeto serão apresentadas a seguir.

### 4.1 BUSINESS UNDERSTANDING

Para o começo desta etapa, primeiramente foi necessário entender todo o processo de manufatura de asas de um avião, mas com foco principal no processo de furação e nos processos onde os robôs interferiam, visto que os dados proviam deles.

Com o entendimento do processo, identificou-se os *stakeholders* como sendo os engenheiros, supervisores e gerentes das quatro áreas de Engenharia (Manufatura, Qualidade, Manutenção e Produção), os colaboradores do chão de fábrica e o Diretor de Engenharia da empresa.

As necessidades de cada um geraram um banco de ideias e as principais foram transcritas em requisitos funcionais da plataforma, como pode-se observar na Tabela 1.

Tabela 1 - Necessidades de cada *stakeholder*

Stakeholder	Necessidade (requisito funcional)
Engenheiro de Manufatura	Medir o tempo de produção de uma asa
Engenheiro de Manufatura	Medir o tempo do ciclo de furação de uma asa
Engenheiro de Manufatura	Medir o tempo que o processo ficou parado

Engenheiro de Manufatura	Medir o tempo que o processo fez setup
Engenheiro de Manufatura	Medir o tempo que cada ferramenta trabalha
Engenheiro de Produção	Identificar o balanceamento de linha através da utilização dos robôs
Engenheiro de Qualidade	Identificar os furos faltantes no processo
Engenheiro de Qualidade	Identificar os furos não conformes no processo
Engenheiro de Qualidade	Prever vida útil das ferramentas
Engenheiro de Manutenção	Medir o tempo de cada alarme de parada
Gerente e Diretor	Ter resultados numéricos para explicar tempos de paradas, ociosidade e não conformidade

Fonte: Elaborado pela autora (2019)

Além dos requisitos funcionais, as conversas com os *stakeholders*, geraram também os primeiros requisitos não-funcionais, ou seja, relacionados ao uso da plataforma em termos de desempenho, usabilidade, confiabilidade, segurança, disponibilidade, manutenção, governança, ferramentas e tecnologias envolvidas. Eles são listados abaixo.

- Atualização dos dados: os dados devem ser atualizados em um intervalo de no máximo 20 segundos.
- Interface atrativa e amigável: as visibilidades devem estar logicamente apresentadas aos usuários e serem intuitivas;
- Disponibilidade da plataforma: a plataforma deve estar ativa 24 horas por dia.
- Governança: apenas pessoas com permissão podem ter acesso às visibilidades.
- Segurança: a plataforma deve seguir os padrões de segurança de TI em todos seus estágios.
- Escalabilidade: a plataforma ser escalável para outros robôs.



## 4.2 DATA UNDERSTANDING

Na etapa de *Data Understanding*, é necessário entender os dados: qual a sua fonte, se há dados em branco, como eles se relacionam e que tipo de informações e valor é possível retirar deles.

Os dados se originam dos robôs de furação do processo de manufatura de uma asa, as informações contidas neles referem-se a resultados de diversos sensores que esses sistemas automatizados possuem e são exibidas relacionadas a cada furo feito.

Esses robôs em específico, geram dois tipos de *logs*<sup>3</sup>, um de processo e outro de alarmes. O primeiro relaciona cada furo gerado (representado pela linha de uma tabela), com 127 informações vindas dos sensores (referente às colunas da tabela). Na Figura 5, é apresentada uma parte desse *log*.

Figura 5 – Log de processo

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W
timestamp	PROG	BlockNum	HOLE_ID	Hole Status	ROBOT	User	DATE	TOOLS	NP	SLOT	ROW	COL	CLAMP	AX THRU1	THRU2	D180	D1890	D280	D2890	D380	D390	
10:02:54	N	COUPLIN	PROG01	Coopon Dr	7	Robot 3	Operator 1	HHHHHHH 117	NP-LargeT	2	1	2	75	HHHHHHH	0	110,485	110,475	11,040	11,053	0	0	
10:05:38	N	COUPLIN	PROG01	Coopon Dr	7	Robot 3	Operator 1	HHHHHHH 117	NP-LargeT	2	1	3	75	HHHHHHH	0	110,455	110,485	11,043	11,053	0	0	
10:10:00	N	41591	N2030	H511101.1	7	Robot 3	Operator 1	HHHHHHH 117	NP-LargeT	2	1	3	95	HHHHHHH	0	11,043	11,063	11,042	11,061	0	0	
10:14:22	N	41591	N2030	H511101.1	7	Robot 3	Operator 1	HHHHHHH 117	NP-LargeT	2	1	3	95	HHHHHHH	0	11,043	11,060	110,450	11,063	0	0	
10:16:28	N	41591	N2030	H511101.1	7	Robot 3	Operator 1	HHHHHHH 117	NP-LargeT	2	1	3	95	HHHHHHH	0	110,445	11,057	110,425	110,595	0	0	
10:18:55	N	41591	N2030	H511101.5	5	Robot 4	Operator 1	HHHHHHH 198	NP-SmallT	2	1	4	45	HHHHHHH	0	0	0	0	0	0	0	
10:22:57	N	41591	N2030	H511101.1	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:28:52	N	41591	N2030	H511101.8	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:29:20	N	41591	N2030	H511101.8	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:28:52	N	41591	N2030	H511101.1	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:30:17	N	41591	N2030	H511101.1	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:30:41	N	41591	N2030	H511101.1	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:37:48	N	41591	N2030	H511101.6	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:38:17	N	41591	N2030	H511101.6	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:39:02	N	41591	N2030	H511101.6	5	Robot 3	Operator 1	HHHHHHH 198	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:50:57	N	41591	N2030	H511101.6	5	Robot 3	Operator 1	HHHHHHH 199	NP-SmallT	2	1	3	45	HHHHHHH	0	0	0	0	0	0	0	
10:51:15	N	COUPLIN	PROG01	Coopon Dr	7	Robot 4	Operator 1	HHHHHHH 109	NP-SmallT	2	1	4	75	HHHHHHH	6,279	62,805	6,278	6,279	0	0	0	
10:52:15	N	COUPLIN	PROG01	Coopon Dr	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	75	HHHHHHH	0	0	0	0	0	0	0	
11:01:27	N	41591	N1100	H511101.8	7	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	6,278	62,805	62,785	62,875	0	0	0	
11:01:51	N	41591	N1100	H511101.8	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	
11:02:19	N	41591	N1100	H511101.8	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	
11:02:44	N	41591	N1100	H511101.8	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	
11:03:08	N	41591	N1100	H511101.8	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	
11:03:32	N	41591	N1100	H511101.8	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	
11:04:57	N	41591	N1100	H511101.8	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	
11:04:24	N	41591	N1100	H511101.8	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	
11:04:46	N	41591	N1100	H511101.8	5	Robot 3	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	
11:00:13	N	41591	N1100	H511101.8	5	Robot 4	Operator 1	HHHHHHH 109	NP-SmallT	2	1	6	65	HHHHHHH	0	0	0	0	0	0	0	

Fonte: Elaborado pela autora (2019)

Essas informações incluem desde a hora que o furo foi feito, bem como o seu diâmetro, a força aplicada para fazê-lo, e diversas outras medições. Na Tabela 2, são exibidas as principais colunas geradas, entre as 127, com seus significados.

<sup>3</sup> Processo de registro de eventos relevantes num sistema computacional.

Tabela 2 - Principais colunas do *log* de processo e seus significados

<b>Nome da coluna</b>	<b>Significado</b>
timestamp	Hora que o processo de um furo começou a ser feito
PROG	Definição do programa, se é um furo ou um furo feito em corpo de prova (CDP)
Hole_ID	ID do furo
Robot	Robô que fez o furo
TOOL	Tipo de broca utilizada
D1@0	Diâmetro de entrada do furo em relação ao primeiro material
D1@90	Diâmetro de saída do furo em relação ao primeiro material
D2@0	Diâmetro de entrada do furo em relação ao segundo material
D2@90	Diâmetro de saída do furo em relação ao segundo material
MAT1	Primeiro material que está sendo furado
MAT2	Segundo material que está sendo furado
holeLL	Limite inferior para o diâmetro
holeUL	Limite superior para o diâmetro
X	Coordenada X do furo em relação ao eixo do robô
Y	Coordenada y do furo em relação ao eixo do robô
Z	Coordenada Z do furo em relação ao eixo do robô
CAUSE	Motivo pelo qual o furo não foi terminado

Fonte: Elaborado pela autora (2019)

Já o segundo tipo de *log* refere-se a uma lista de alarmes, com horário de ocorrência, como é mostrado na Figura 6.

Figura 6 – Log de alarmes

Log de alarmes, 28.11.2017 13:16:05.527

Apareceu	Eliminado.	Número	Texto
28.11.17 13:13:29.004		700050	Feed Hold ativo!
28.11.17 13:13:28.981		510117	Dispositivo de segurança accionado.
28.11.17 13:12:20.262	28.11.17 13:12:27.522	700050	Feed Hold ativo!
28.11.17 13:12:20.240	28.11.17 13:12:27.522	510117	Dispositivo de segurança accionado.
28.11.17 13:12:00.585	28.11.17 13:12:06.170	67011	Robot deslocado desde ultimo waypoint conhecido! O robot vai agora recolher o braco e mover-se para uma posicao segura! Certifique-se de que o robot pode movimentar-se seguramente. pressione CYCLE START para continuar. Se nao e seguro, RESET e fazer JOG do Robot para uma posicao segura.
28.11.17 13:11:57.270	28.11.17 13:11:57.298	17212	Gerenciamento de ferramentas: carregar a ferramenta manual T='empty_1'#1, n.' duplo 00001 no fuso/porta-ferramentas 1
28.11.17 13:11:32.168	28.11.17 13:11:54.213	700050	Feed Hold ativo!
28.11.17 13:11:32.168	28.11.17 13:11:54.213	510117	Dispositivo de segurança accionado.
28.11.17 13:11:11.089	28.11.17 13:11:11.197	150206	Can't find alarm text index file "oem_indexparams_ptb.qn"
28.11.17 13:11:02.490	28.11.17 13:11:02.490	150204	----- Partida do registro de alarmes -----
28.11.17 12:54:04.159		700235	E-Stop Botao Pendente HT2
28.11.17 12:54:04.165		3000	Parada de emergência
28.11.17 12:54:02.486	28.11.17 12:54:04.159	700050	Feed Hold ativo!
28.11.17 12:54:02.486	28.11.17 12:54:04.159	510117	Dispositivo de segurança accionado.
28.11.17 12:53:39.758	28.11.17 12:53:51.551	700235	E-Stop Botao Pendente HT2

Fonte: Elaborado pela autora (2019)

Tais alarmes podem ser apenas sinalizações enquanto o processo ainda ocorre ou mesmo casos de parada do processo até o erro ser corrigido. Neles também há uma divisão em três áreas: erros de produção, de manutenção ou de processo.

Ao fim do entendimento dos dados, comprova-se ou não a viabilidade técnica dos requisitos definidos na fase de *Business Understanding*, pois agora é possível analisar se os dados conseguem trazer as informações pedidas na fase anterior.

Ao fim dessas duas fases, já está definido onde se quer chegar com a plataforma, sendo possível traçar os critérios de sucesso do projeto, listados a seguir.

- Possuir e monitorar os indicadores e dados definidos como requisitos.
- Possuir a plataforma DRIMS disponível na rede da empresa.

- Atualização dos dados em segundos.
- Confiabilidade dos dados.
- Visibilidades serem de fácil leitura e apresentarem dados que ajudem os *stakeholders*.
- Traçar planos de ações a partir das visibilidades;
- Tomar decisões baseadas nas visibilidades.
- O projeto pode ser escalável para todos os robôs de furação.

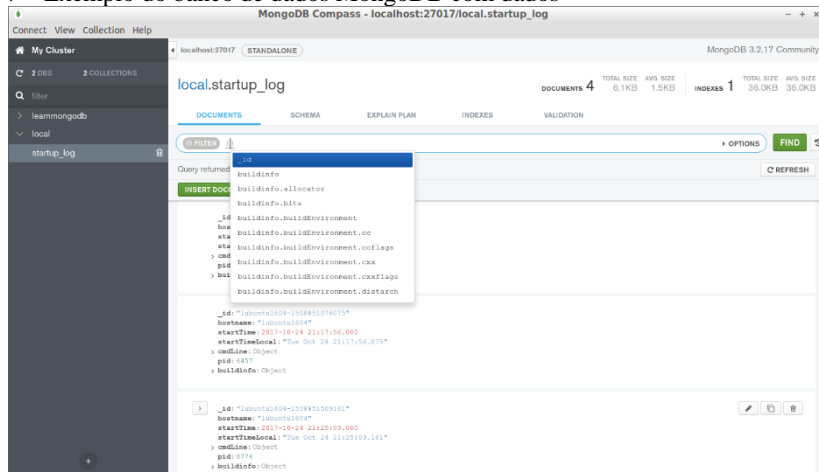
Por último, as ferramentas que serão utilizadas nas próximas etapas para o desenvolvimento e aplicação das regras de negócio nos dados e da criação de visibilidades também são definidas.

Assim, para o armazenamento e limpeza dos dados, é utilizado o banco de dados não relacional MongoDB. A escolha foi feita visto que a escalabilidade é um dos objetivos do projeto e pelos dados não necessitarem serem divididos por tabelas. Para o desenvolvimento da lógica, utilizou-se a linguagem de programação *Python*, essa que tem muitas bibliotecas prontas na área de *Data Science* e *Machine Learning*, por ser extensível e possuir ferramentas para o desenvolvimento de websites, como o *Django*, que também é utilizado no projeto. Na criação das visibilidades, foi feito um site com *dashboards* com a linguagem *Java Script* e uma biblioteca específica chamada *Highcharts*, que auxiliava na criação dos gráficos.

### 4.3 DATA PREPARATION

Nessa fase de modelagem, os dados são coletados dos robôs através de uma rotina com um intervalo de 20 segundos e injetados no banco de dados MongoDB, como representado pelo exemplo da Figura 7.

Figura 7 – Exemplo do banco de dados MongoDB com dados



Fonte: Lubuntu Blog (2017)

Com ferramentas do próprio banco, os dados são organizados, limpos e tratados, descartando linhas que faltem algumas informações chaves como, por exemplo, o *timestamp*, ou removendo linhas duplicadas, entre outros.

#### 4.4 MODELING

A parte mais importante na construção da plataforma DRIMS acontece na etapa de *Modeling*, pois nesse momento os dados são modelados através de lógicas de negócio implementadas em *Python* e são criadas os KPIs com seus resultados, para criar valor.

Quando citado ‘criar valor’ aos dados, refere-se à pegá-los em seu estado bruto, já passados por um processo de organização e limpeza, e usando todo conhecimento obtido na fase de *Business e Data Understanding* e traduzi-los em regras de negócio que representam o processo e são pontos críticos de interesse dos *stakeholders*. Dessa forma, os dados agora representam métricas que podem influenciar no processo de uma maneira indireta, mas que afeta a economia e lucro do processo.

Para isso, são usados os requisitos pré-definidos (listados anteriormente na Tabela 2), aliados a um pensamento do que se espera encontrar como resultado nos *dashboards*. Assim, diversas conversas e adaptações ocorrem nessa etapa, sempre colocando em foco a opinião do

*stakeholder*, que define que tipo de gráfico fica melhor para visualização do processo (gráfico de barras, pizza, histograma, entre outros) e um fator muito importante, que são os filtros.

Os filtros são criados para selecionar as informações já dentro de uma visibilidade. Por exemplo, no caso de KPI de tempo de takt de uma asa, pode-se selecionar a asa de um avião X, asa direita ou esquerda ou ambas. Desse modo, eles são essenciais para que os resultados de interesse refiram-se exatamente ao momento e ao escopo pesquisado.

Assim, dentro dos requisitos que já foram definidos, a plataforma DRIMS possui alguns painéis de visibilidades com KPIs ligados a três áreas: Manufatura, Qualidade e Manutenção. Essas áreas relacionam-se com as categorias de atuação dos KPIs.

Na área de Manufatura, o foco é na performance do processo de furação, ou seja, quanto tempo demora, se a linha está equilibrada, qual é o tempo médio de furação por ferramenta, entre outros. Na Qualidade, relaciona-se a qualidade do furo, se ele está sendo feita dentro dos parâmetros e a identificação das causas de não qualidade. Por último, a área de Manutenção, fica responsável por cuidar da vida do robô, e identificar motivos de paradas deles.

Nos próximos tópicos, serão apresentadas algumas visibilidades e sobre o que elas tratam. Porém, ressalta-se que seus valores são ilustrativos, não correspondendo a valores reais e às regras de negócio envolvidas para criação das visibilidades, pois estas não podem ser mostradas, devido à confidencialidade das informações.

#### **4.4.1 Indicadores de performance**

Esse painel relaciona-se com os KPIs já citados de tempo de takt, tempo de *setup*, tempo de inatividade e taxa. Por isso, ele é subdividido em três partes, como mostra a Figura 8.

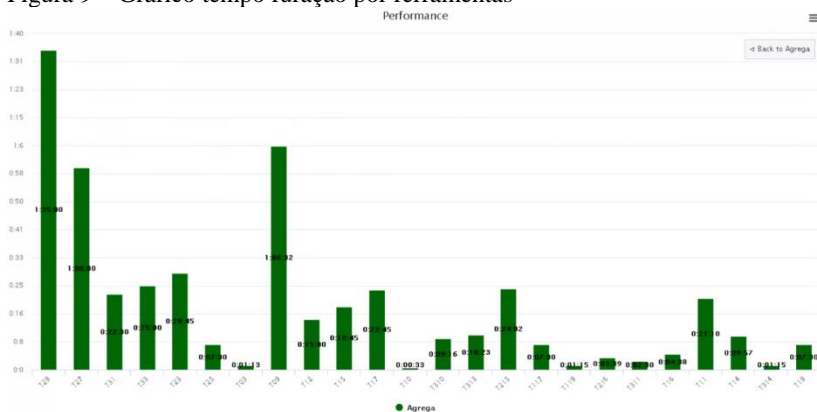
Figura 8 – Gráfico de performance



Fonte: Elaborado pela autora (2019)

Em verde é mostrado o tempo em que o processo fez uma atividade que “agrega” valor (nesse caso, a furação), ou seja, tempo em que o processo não tem desperdício, visto que está fazendo uma ação necessária. Como um *drilldown* dessa parte, ou seja, quando se clica sobre ela, tem-se um outro gráfico que mostra quais ferramentas furaram nesse intervalo e por quanto tempo, como observado na Figura 9.

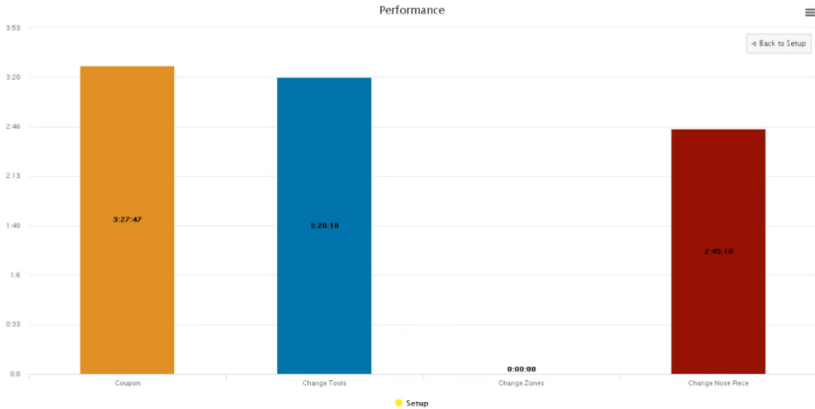
Figura 9 – Gráfico tempo furação por ferramentas



Fonte: Elaborado pela autora (2019)

Em amarelo é representado o tempo de *setup* que também tem um *drilldown* que separa seu somatório de tempo em atividades menores como troca de ferramenta, troca de zona do robô, CDP (corpo de prova, momento que se faz testes do processo) e troca de *Nouse Piece* (peça onde se encaixa uma broca de furação). Essa divisão é vista na Figura 10.

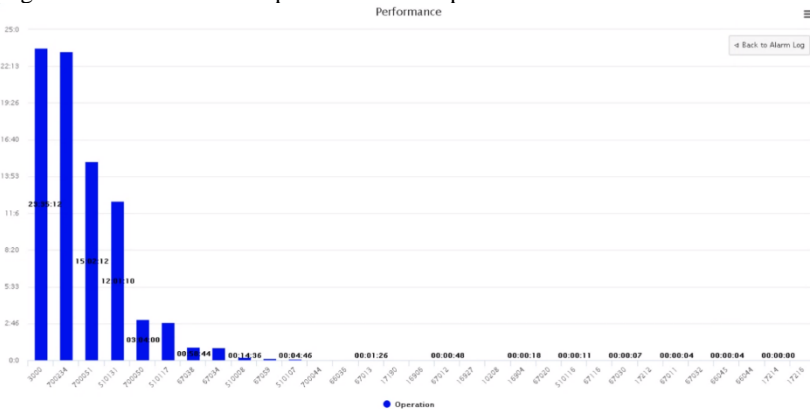
Figura 10 – Gráfico de tempo de atividades dentro do *setup*



Fonte: Elaborado pela autora (2019)

Na parte vermelha, temos o tempo em que o processo está parado. Clicando sobre a ela, é possível ver quais alarmes ocorreram durante esse período, como é possível ver na Figura 11.

Figura 11 – Gráfico de tempo de ocorrência por alarme



Fonte: Elaborado pela autora (2019)

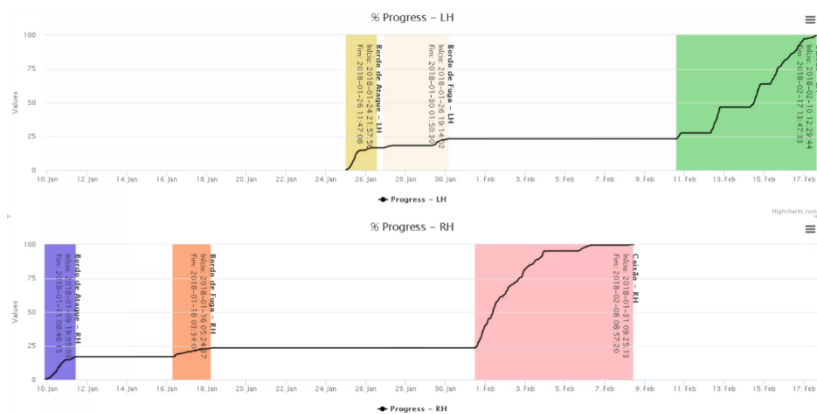


Essa informação é obtida através do *log* de alarmes, comentado anteriormente. Cada alarme, é representado por um código que já tem um significado e tipo de tratativa pré-estabelecida.

#### 4.4.2 Indicadores de balanceamento de linha


Outros dois gráficos são exibidos para entender como a linha está balanceada em relação aos seus quatro robôs, Figura 12, e quando um produto entra e sai da linha de produção, apresentado na Figura 13.

Figura 12 – Gráfico de progresso de produção de uma asa



Fonte: Elaborado pela autora (2019)

Figura 13 – Gráfico de balanceamento de robô na linha de produção



Fonte: Elaborado pela autora (2019)

### 4.4.3 Indicador de vida útil de broca

A Figura 14 representa o diâmetro de furos de uma broca em relação ao número de furos, além disso é calculada uma reta por regressão linear.

Figura 14 – Gráfico de monitoramento de vida de ferramenta

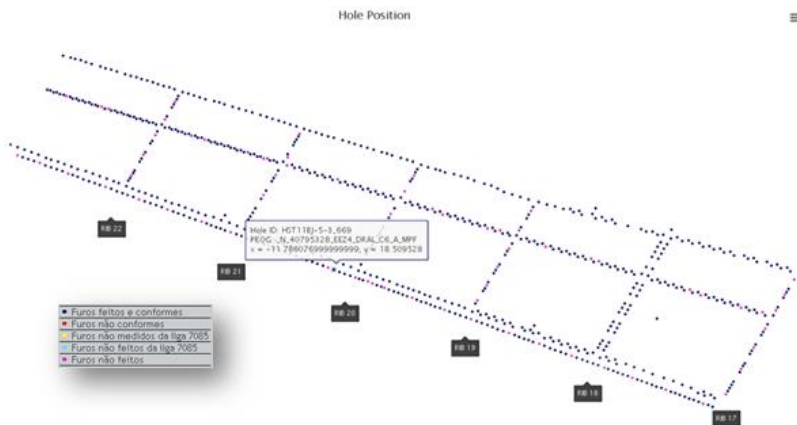


Fonte: Elaborado pela autora (2019)

### 4.4.4 Indicador de hole position

Nesse indicador, através das coordenadas X, Y e Z dos furos e outras informações, é possível observar quais furos foram feitos ou não e aqueles que apresentaram algum erro. A Figura 15 apresenta os resultados desse gráfico.

Figura 15 – Gráfico de análise de furos realizados pela posição XYZ



Fonte: Elaborado pela autora (2019)

## 4.5 EVALUATION E DEPLOYMENT

As duas últimas fases são apresentadas juntas, por se tratarem da entrega da plataforma. A parte de *Evaluation*, com seus testes e *feedbacks*, aconteceram durante todo o desenvolvimento visto que foi utilizado o *framework Scrum*<sup>4</sup> para planejamento de projeto. Assim, ao fim, os *stakeholders* já haviam pedido as alterações necessárias em quesitos de usabilidade e disposição de informação e salientado alguns erros que já foram corrigidos.

Em relação a avaliação quanto aos requisitos e critérios de sucesso:

- a) Requisitos funcionais: todos os requisitos funcionais foram cumpridos, através do resultado das visibilidades criadas.
- b) Requisitos não funcionais: todos foram cumpridos.
  - As ferramentas de programação pré-estipuladas foram utilizadas.
  - Os dados estão sendo atualizados em um intervalo de 20 segundos.
  - A plataforma está disponível 24 por dia, dentro dos padrões de TI e com acesso controlado.
  - Os gráficos foram considerados como de fácil interpretação pelos *stakeholders*.
  - A estrutura da plataforma pode ser escalável para outros robôs.
- c) Critério de sucesso: todos os critérios foram cumpridos e tiveram aprovação do cliente.

Na fase de *Deployment*, a plataforma foi disponibilizada para todos funcionários que podiam ter acesso, através de uma página web. Esse acesso era feito pelo mesmo login do e-mail corporativo.

Como plano de manutenção e suporte, um desenvolvedor tem alocado seis horas semanais para essas atividades e em caso de parada ou erros o suporte deverá ser imediato.

Nessa fase também fica planejado o desenvolvimento de novas versões para outros robôs de furação e um banco de ideias que deve ser

---

<sup>4</sup> *Scrum* é um *framework* de gerenciamento de projeto e organização do trabalho, em que as equipes trabalham como uma unidade integrada com cada membro desempenhando um papel bem definido, com atividades de curto prazo e *feedback* constante. (Scrum.org, 2019)

sempre atualizado com novos tipos de visibilidades que podem agregar valor ao processo.

Assim, a plataforma DRIMS é feita através da metodologia CRISP-DM, com todos seus objetivos alcançados e como resultado tem visibilidades geradas a partir de dados atualizados a cada 20 segundos sobre o processo automatizado de furação de asas.

## 4.6 RESULTADOS

A partir dos KPIs gerados pela plataforma criada, é necessária a aplicação da abordagem DDDM em cada *dashboard* para haver resultados quantitativos, visando economia, lucro, eficiência e qualidade.

Para atingir os resultados e comprovar a abordagem, deverão ser feitas estimativas de ganho. Para isso, como primeiro passo, utiliza-se de dados do atual do processo, *As is*, que são obtidos da plataforma. Para cada gráfico será mostrado como o processo está naquele momento, a descrição do problema encontrado, a causa raiz, contramedidas ou soluções e assim, os ganhos gerados. O resultado será um cenário de como deveria ser, *To be*, que retrata os potenciais de redução.

### 4.6.1 Gráfico de performance

O *As Is* usado de exemplo é apresentado na Figura 16.

Figura 16 – Gráfico de performance para exemplo de caso



Fonte: Elaborado pela autora (2019)


Esse caso apresenta 80h18min de parada e 49h56min de agregação de valor. Foram notados através dos dados, três grandes problemas que impactam diretamente no tempo de parada e setup, sendo eles: os furos de alargamento são feitos manualmente, o robô está demorando para fazer o mapeamento do pré-furo e a troca dos parafusos de referência está ocorrendo como *setup in*, aumentando o tempo de parada. A causa raiz para cada um deles, respectivamente, é: painel fora de posição, a identificação do pré-furo requer ajuste manual e troca do parafuso de referência como *setup in*. Como solução, é traçado um plano de alinhar os furos de alargamento antes, automatizar o mapeamento do pré-furo e realizar a troca do parafuso de referência como *setup out* do processo. Atuando nesses três problemas, pode-se eliminar 9h46min do tempo de parada, ou seja, uma redução de 12,2%.

De forma análoga, foram encontrados dois macroproblemas para o tempo de agregação de valor: o processo requer medição de 100% dos furos e a movimentação do robô não está otimizada. A causa raiz do primeiro caso é a estabilidade do processo que não está validada, para o segundo, o ponto é que a programação não está otimizada. Como solução deve-se medir furos por amostras e otimizar a movimentação na programação off-line. Atuando-se nesses dois problemas, pode-se reduzir 7h04min do tempo de agregação de valor, ou seja, uma redução de 14,2%.

#### 4.6.2 Gráfico de tempo de atividades dentro do *setup*

O *As Is* atual usado de exemplo é apresentado na Figura 17. Ele é um *drill down* da área amarela do gráfico utilizado anteriormente.

Figura 17 – Gráfico de *setup* para exemplo de caso



Fonte: Elaborado pela autora (2019)

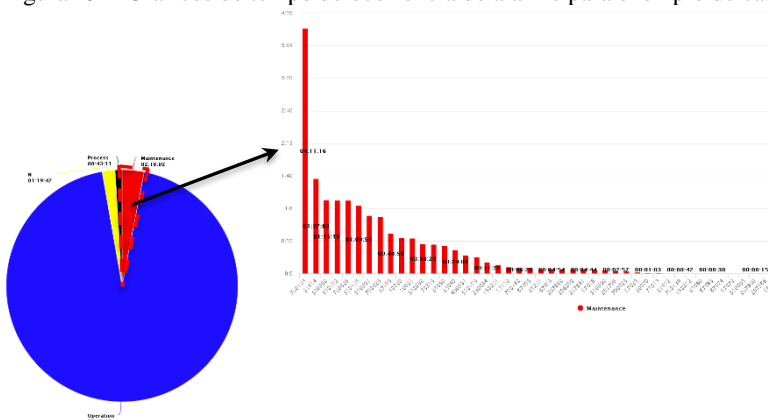


principalmente, nas brocas de maior uso e ciclo, estima-se uma redução de até 4h (8%) no tempo de furação.

#### 4.6.4 Gráfico de tempo de ocorrência por alarme

Esse gráfico, apresentado na Figura 19, representa as 80h18min de parada, subdivididas em alarmes que ocorreram nesses intervalos. Antes de haver esse gráfico que mostra o motivo das paradas através dos alarmes, não se sabia onde tratar o problema, havendo muita demora para o prognóstico. Outro ponto é que, com o entendimento dos padrões de disparo desses alarmes, é possível fazer uma análise preditiva de erro. Assim, a causa raiz dessa enorme quantidade de paradas é a dificuldade de diagnóstico dos problemas. Atuando-se na prevenção dos itens de maior repetitividade nas paradas de manutenção, estima-se redução de cerca de 03h27min (4,3%).

Figura 19 – Gráficos de tempo de ocorrência de alarme para exemplo de caso



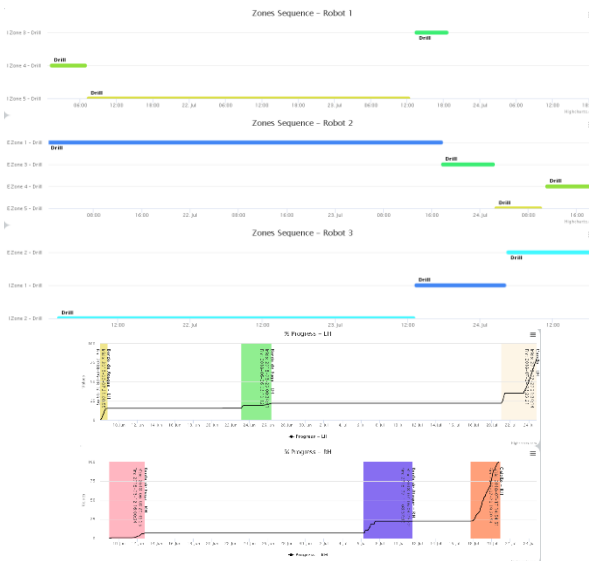
Fonte: Elaborado pela autora (2019)

#### 4.6.5 Gráficos de balanceamento de linha

Quando analisados os indicadores de balanceamento de linha, apresentados na Figura 20, repara-se o não balanceamento dessa. Isso gera ociosidade para os robôs (contabilizando no tempo de parada:

80h18min). Analisando os intervalos de ociosidade e comparando com outras fontes de dados, identifica-se que a causa raiz desse problema é a falta de peças, recursos e operadores durante o processo. Caso o cumprimento do balanceamento seja feito, é possível reduzir até 06h37min (8,3%) do tempo de parada.

Figura 20 – Gráficos de balanceamento de linha para exemplo de caso



Fonte: Elaborado pela autora (2019)

#### 4.6.6 Gráfico de análise de furos realizados pela posição XYZ

O trabalho que era realizado para identificação dos furos faltantes e não conformes, era o principal problema. Esse trabalho era feito de forma manual, onde o Engenheiro de Qualidade comparava duas tabelas para buscar as informações. Segundo dados, eram gastos 40h de Engenharia por asa para fazer essa atividade que enfrentava problemas como: grande quantidade de dados, dificuldade para analisar as informações e informações não disponíveis. O As Is era feito através da



tabela do log de processo, que foi mostrada na Figura 5, onde devia-se comparar todos os números de identificação dos furos para saber se haviam faltantes e não conformes.

Dessa forma, com a criação do gráfico de análise de furos realizados pela posição XYZ, Figura 15, foi possível a criação de relatórios automáticos. O tempo gasto para essa nova atividade é de apenas 5min por asa, obtendo uma redução de 99% para geração dos mesmos dados.

Assim, fazendo as reduções obtidas nesses seis itens, do *As Is* inicial do projeto, é possível alcançar:

- Redução potencial de Parada de 21,2h (26,4%);
- Redução potencial de *Setup* de 8,6h (63,2%);
- Redução potencial do tempo do ciclo de furação de 14,7h (29,4%).

Figura 21, representa essas reduções.

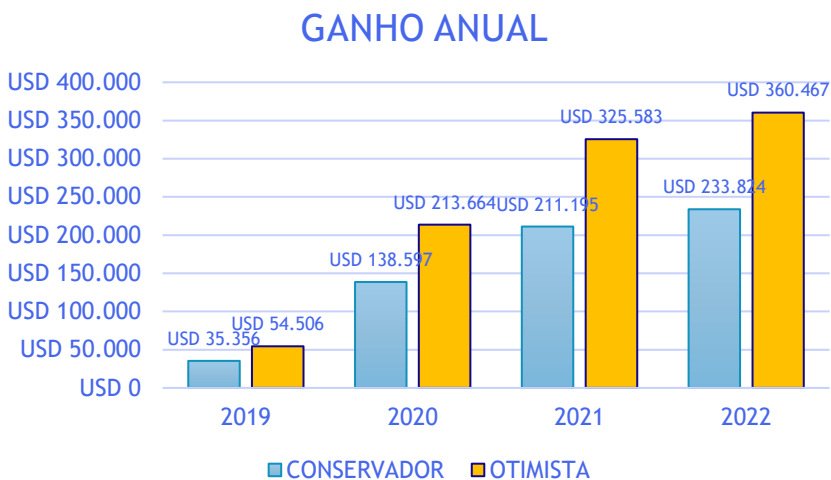
Figura 21 – Gráfico de comparação dos casos *As Is* e *To Be*

Fonte: Elaborado pela autora (2019)

A partir da implementação do DDDM, a cadência mensal do processo tem um aumento de 147%.

Além disso, tendo algumas premissas de quantos operadores trabalham no processo, taxa hora de operação, taxa hora de manutenção, valor hora homem de engenharia e produção, e cadência anual, é possível fazer uma estimativa conservadora e otimista de ganho anual para os próximos quatro anos, como apresentado na Figura 22.

Figura 22 – Gráfico de ganho anual quando aplicada a abordagem DDDM



Fonte: Elaborado pela autora (2019)

Um outro problema abordado, agora pelo gráfico de monitoramento de vida de ferramenta, Figura 14, é que as ferramentas são substituídas conforme informações do fornecedor. Por exemplo, a ferramenta Y pode fazer 3000 furos, após isso deve ser descartada. Porém, isso gera um possível descarte de ferramenta antes do fim da vida útil. Esse problema acontece devido à falta do monitoramento da “qualidade do furo” vs “vida da broca”. Com o uso do gráfico para otimização da vida da ferramenta, deve haver uma redução do custo recorrente com ferramentas, as quais são bem altos.



## 5 CONCLUSÃO

O presente projeto mostrou que, com a implementação da abordagem DDDM em um processo produtivo, a tomada de decisão através de dados traz resultados mais significativos e assertivos para uma empresa, afetando diretamente o lucro e otimização do processo.

Após a divulgação dos resultados que foram obtidos com a plataforma DRIMS, em uma empresa do ramo aeronáutico, foi pedido para que a plataforma fosse replicada para diferentes processos automatizados que disponibilizam dados. Essa abordagem dá à empresa vantagens econômicas e uma inclusão cada vez maior na Indústria 4.0.

Com o mundo caminhando cada vez mais para um lado da digitalização, a quantidade de dados só tende a crescer e aqueles que souberem interpretá-los, atingirão seus objetivos com mais rapidez e assertividade.



## 6 REFERÊNCIAS

ADRIAANSE, A.. **Environmental policy performance indicators**. Netherlands: Gravenhage, 1993.

AGÊNCIA BRASILEIRA DE DESENVOLVIMENTO INDUSTRIAL. **Agenda brasileira para a Indústria 4.0**. Disponível em: <<http://www.industria40.gov.br/>>. Acesso em: 27 ago. 2019.

BAMBRICK-SANTOYO, Paul. **Driven by Data: A Practical Guide to Improve Instruction**. Nova York: Jossey-Bass, 2010.

BARTON, Dominic; COURT, David. **Making advanced Analytics work for you**. 2012. Disponível em: <<https://hbr.org/2012/10/making-advanced-analytics-work-for-you>>. 07 ago. 2019

CAMPBELL JR., Flake. **Manufacturing Technology for Aerospace Structural Materials**. Missouri: Elsevier Scientific, 2006.

CHAPMAN, P.; CLINTON, J.; KERBER, R.; KHABAZA, T.; REINARTZ, T.; SHEARER, C.; WIRTH, R.. **CRISPDM 1.0 step-by-step data mining guide**. 2000. Disponível em: <[https://pdfs.semanticscholar.org/5406/1a4aa0cb241a726f54d0569efae1c13aab3a.pdf?\\_ga=2.135481585.1302496502.1580725881-705925820.1580725881](https://pdfs.semanticscholar.org/5406/1a4aa0cb241a726f54d0569efae1c13aab3a.pdf?_ga=2.135481585.1302496502.1580725881-705925820.1580725881)>. Acesso em: 14 set. 2019.

FAYYAD, Usana; PIATETSKY-SHAPIRO, Gregory; SMYTH, Padhraic . **From Data Mining to Knowledge Discovery in Databases**. 1996. Disponível em: <<https://webcache.googleusercontent.com/search?q=cache:LSNL95REYPMJ:https://www.aaai.org/ojs/index.php/aimagazine/article/view/1230/1131+&cd=2&hl=pt-BR&ct=clnk&gl=br>>. Acesso em: 14 set. 2019.

FRANCESCHINI, F.; GALETTO, M.; MAISANO, D.. **Classification of Performance and Quality Indicators in Manufacturing**. 2006. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.461.4608&rep=repl&type=pdf>>. Acesso em: 14 set. 2019.

GERBERT, Philipp; LORENZ, Markus; RÜßMANN, MICHAEL; WALDNER, Manuela; JUSTUS, Jan, ENGEL, Pascal; HARNISCH,

Michael. **Industry 4.0: The Future of Productivity and Growth in Manufacturing Industries.** 2015. Disponível em: <[https://www.bcg.com/pt-br/publications/2015/engineered\\_products\\_project\\_business\\_industry\\_4\\_future\\_productivity\\_growth\\_manufacturing\\_industries.aspx](https://www.bcg.com/pt-br/publications/2015/engineered_products_project_business_industry_4_future_productivity_growth_manufacturing_industries.aspx)>. Acesso em: 27 ago. 2019.

JAIN, A. K.; DUBES, R. C. **Algorithms for Clustering Data.** New Jersey: Prentice-Hall, 1988.

KAGERMANN, H.; WAHLSTER, W.; HELBIG, J. **Recommendations for implementing the strategic initiative Industrie 4.0.** 2013. Disponível em: <<https://www.din.de/blob/76902/e8cac883f42bf28536e7e8165993f1fd/recommendations-for-implementing-industry-4-0-data.pdf>> Acesso em: 14 set. 2019.

KANTARDZIC, Mehmed. **Data Mining: Concepts, Models, Methods, and Algorithms.** New Jersey: IEEE Press, 2011.

LOVATTO, Dan; SIBONY, Oliver. **Left unchecked, subconscious biases will undermine strategic decision making. Here's how to counter them and improve corporate performance.** 2010. Disponível em: <<https://www.mckinsey.com/business-functions/strategy-and-corporate-finance/our-insights/the-case-for-behavioral-strategyf>>. 07 ago. 2019

MICROSTRATEGY INCORPORATED. **Data Mining Explained.** Disponível em: <<https://www.microstrategy.com/us/resources/introductory-guides/data-mining-explained>>. Acesso em: 27 ago. 2019.

PYZDEK, T. **The Six Sigma Handbook.** 2003. Disponível em: <[https://www.academia.edu/13628867/The\\_Six\\_Sigma\\_Handbook\\_A\\_Complete\\_Guide\\_for\\_Green\\_Belts\\_Black\\_Belts\\_and\\_Managers\\_At\\_All\\_Levels](https://www.academia.edu/13628867/The_Six_Sigma_Handbook_A_Complete_Guide_for_Green_Belts_Black_Belts_and_Managers_At_All_Levels)>. Acesso em: 14 set. 2019.

SCRUM ORG. **What is Scrum?** Disponível em: <<https://www.scrum.org/resources/what-is-scrum>>. Acesso em: 20 jan. 2020.



SILVA, Luciano. **Tomada de Decisão Baseada em Dados (DDDM) e Aplicações em Informática em Educação**. 2015. Disponível em: <<https://www.br-ie.org/pub/index.php/pie/article/view/3550>>. Acesso em: 27 ago. 2019.

SILVA, E. L. D.; MENEZES, E. M.. **Metodologia da Pesquisa e Elaboração de Dissertação**. 4. ed. Florianópolis: Universidade Federal de Santa Catarina Ufsc, 2005. 139 p.

SMARTVISION. **An overview of the CRISP DM methodology**. Disponível em: <<https://smartvision-me.com/the-crisp-dm-data-mining-methodology/>>. Acesso em: 27 ago. 2019.

TURSUNBAYEVA, Aizhan; DI LAURO, Stefano; PAGLIARI, Claudia. **People analytics—A scoping review of conceptual boundaries and value propositions**. 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0268401218301750>>. Acesso em: 14 set. 2019.

WEISS, S. I.; KULIKOSKI, C. **Computer Systems That Learn: Classification and Prediction Methods from Statistics, Neural Networks, Machine Learning, and Expert Systems**. San Francisco: Morgan Kaufmann Publisher, 1991.

WIRTH, Rüdiger; HIPPE, Jochen. **CRISP-DM: Towards a Standard Process Model for Data Mining**. Disponível em: <<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.198.5133&rep=rep1&type=pdf>>. Acesso em: 14 set. 2019.