



UNIVERSIDADE REGIONAL DO CARIRI-URCA
CENTRO DE CIÊNCIAS E TECNOLOGIA- CCT
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO – DEPRO
Av. Leão Sampaio, 107. Triângulo. Cep: 63040-000 - Juazeiro do Norte – CE
Fone/Fax: (88) 3102-1123, E-mail: depro@urca.br

**TRABALHO DE CONCLUSÃO DE CURSO EM ENGENHARIA DE
PRODUÇÃO MECÂNICA**
**LEAN SIX SIGMA E A INDÚSTRIA 4.0 NA OTIMIZAÇÃO DE PROCESSOS
PRODUTIVOS**

AMANDA DUARTE FEITOSA

Juazeiro do Norte – CE
Junho/2019



UNIVERSIDADE REGIONAL DO CARIRI-URCA
CENTRO DE CIÊNCIAS E TECNOLOGIA- CCT
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO – DEPRO
Av. Leão Sampaio, 107. Triângulo. Cep: 63040-000 - Juazeiro do Norte – CE
Fone/Fax: (88) 3102-1123, E-mail: depro@urca.br

AMANDA DUARTE FEITOSA

**LEAN SIX SIGMA E A INDÚSTRIA 4.0 NA OTIMIZAÇÃO DE PROCESSOS
PRODUTIVOS**

Trabalho de Conclusão de Curso
apresentado ao Curso de Graduação em
Engenharia de Produção Mecânica para
obtenção do título de Bacharel em
Engenharia de Produção, com
habilitação Mecânica, da Universidade
regional do Cariri - Urca.

**Orientador: Prof^a. Dra. FRANCISCA JEANNE SIDRIM DE FIGUEIREDO
MENDONÇA**

Coorientador: Prof. Dr. LAURENT MULLER

Juazeiro do Norte – CE
Junho/2019

Ficha Catalográfica

Feitosa, Amanda Duarte.

Lean Six Sigma e a indústria 4.0 na otimização de processos produtivos / Amanda Duarte Feitosa; Universidade Regional do Cariri – URCA. 2019.
150 f.

Orientador (a): Prof^a. Dra. Francisca Jeanne Sidrim de Figueiredo

Trabalho de Conclusão de Curso (TCC) - Universidade Regional do Cariri – URCA,
Graduação em Engenharia de Produção

1. Indústria 4.0 2. *Lean Six Sigma* 3. *Value Stream Mapping*.



UNIVERSIDADE REGIONAL DO CARIRI-URCA
CENTRO DE CIÊNCIAS E TECNOLOGIA- CCT
CURSO DE ENGENHARIA DE PRODUÇÃO MECÂNICA
Av. Leão Sampaio, 107. Triângulo. Cep: 63040-000 - Juazeiro do Norte – CE
Fone/Fax: (88) 3102-1123

AMANDA DUARTE FEITOSA

**LEAN SIX SIGMA E A INDÚSTRIA 4.0 NA OTIMIZAÇÃO
DE PROCESSOS PRODUTIVOS**

Banca examinadora:

Prof. Dra. FRANCISCA JEANNE SIDRIM DE FIGUEIREDO MENDONÇA

Departamento de Engenharia de Produção
Universidade Regional do Cariri

Prof. Dra. TEREZA RACHEL COSTA DE OLIVEIRA

Departamento de Engenharia de Produção
Universidade Regional do Cariri

Prof. MSc. JAIR PAULINO DE SALES

Engenharia de Produção
Centro Universitário Católica de Quixada

Data da aprovação: 03/06/2019

JUAZEIRO DO NORTE – CE

JUNHO /2019

DEDICATÓRIA

Dedico este trabalho primeiramente a Deus, por todas as oportunidades que já apareceram na minha vida, e por me ajudar em tantos momentos difíceis.

A minha família por todo apoio e força, principalmente aos meus pais Francisca Barbosa Duarte e Valmir de Matos Feitosa Filho que me incentivaram aos estudos durante toda a vida, e também aos meus irmãos por todo o suporte durante a graduação.

Dedico aos meus professores e colegas da universidade por tudo que aprendi durante essa trajetória.

AGRADECIMENTOS

Agradeço a minha família por toda paciência, principalmente a minha mãe, por todo o seu amor, dedicação, apoio e fé que sempre me deram forças em estudar. A minha irmã Andressa Feitosa por seus conselhos e por ter acreditado nos meus trabalhos e projetos da universidade.

Aos professores da Universidade Regional do Cariri (URCA), principalmente a orientadora Prof. Dra. Francisca Jeanne Sidrim de Figueiredo Mendonça por acreditar no meu trabalho, e pela sua orientação do projeto de iniciação científica ofertada pela URCA, além de seus ensinamentos na pesquisa, e de seu suporte no meu desenvolvimento pessoal e profissional.

Agradeço a URCA pela oportunidade de participar do projeto BRAFITEC financiado pela CAPES, em especial a ENSGSI (*École Nationale Supérieure en Génie des Systèmes et de l'Innovation*) e ao grupo de pesquisa ERPI (*Équipe de Recherche sur les Processus Innovatifs*) por todo o apoio durante os trabalhos realizados no intercâmbio feito na França. Agradeço principalmente ao professor Laurent Muller pela sua orientação na aplicação da simulação, e por ter me apoiado diversas vezes durante a pesquisa.

Aos meus amigos Ramsés Moreira de Albuquerque e Antônio Luís Araújo Silva por toda ajuda e companheirismo no período de intercâmbio. Sou grata aos amigos da graduação Erylla Lima, Thais Cadete, Dalila Rayanne, Isis Silva, Mariane Leite, Layanne Parente. Aos meus amigos mais próximos Lucas Brasil, Giovana Feitosa e Caroline Souza que sempre estiveram ao meu lado.

A todos da empresa Singer do Brasil que me deram suporte no meu período de estágio, principalmente a Wesder Carlos, Jucenildo Viana e Ricardo Cândido que me incentivam no desenvolvimento profissional.

Em geral a todos que contribuíram nesse trabalho, e que estiveram presentes no meu crescimento pessoal e profissional.

“Seja a mudança que você quer ver no mundo” (Gândhi, Mahátma)

Resumo

Hoje em dia muitas empresas buscam soluções para obter as melhores vantagens competitivas. Pensando nisso, as indústrias estão cada vez mais em busca de metodologias que permitam melhorar os seus produtos, processos e reduzir custos, e o *Lean Six Sigma* é uma estratégia de gestão que possibilita a obtenção desses resultados. Além disso, o desenvolvimento, a incorporação e a aplicação de inovações tecnológicas recentes provocaram mudanças que levaram a uma rápida expansão nos estudos técnicos. Vários estudos revelam que este é o começo da quarta revolução industrial, a chamada indústria 4.0. Esse trabalho tem como objetivo propor uma nova maneira de analisar os processos com os dados que essa revolução será capaz de oferecer e, utilizar o *Value Stream Mapping* (VSM) para evoluir em termos de informações, tornando essa ferramenta mais dinâmica e moderna. O trabalho é de caráter exploratório, aplicado e qualitativo, e em termos de procedimento classifica-se como uma simulação. As simulações foram realizadas na AIPL (*Atelier Inter- Etablissements de Productique et Pôle de Ressources Informatiques pour la Mecanique*), onde se localiza a oficina de fabricação e montagem da equipe *Lean* FESTO, esse espaço foi usado com o propósito de se realizar alguns testes e fazer a coleta de dados. Os alunos da ENSGSI (*École Nationale Supérieure en Génie des Systèmes et de l'Innovation*) foram responsáveis pela a instalação dos equipamentos e de realizarem essa coleta. Com isso, usou-se o *Lean Six Sigma* com o intuito de avaliar todas as informações retiradas dessa atividade prática, e como consequência elaborar um VSM mais dinâmico para a nova era da indústria. Durante o processo de estudo de dados o software Minitab foi utilizado como ferramenta de análises estatísticas. No trabalho foi destacado alguns pontos fracos do VSM “clássico” e em seguida proposto um VSM mais dinâmico e confiável, com novas informações úteis para melhorar o desempenho dos processos industriais. Além disso, durante o projeto foi realizado uma pesquisa bibliográfica considerando novas metodologias de mineração de dados e seus benefícios potenciais para a análise de processos.

Palavras Chaves: Indústria 4.0, *Lean Six Sigma*, *Value Stream Mapping*.

ABSTRACT

Currently, many companies are looking for solutions to get the best competitive advantages. Increasingly, industries are looking for methodologies to improve their products to improve processes and reduce costs. With the method Lean Six Sigma it is possible to get these results. In addition, the development, incorporation, and application of recent technological innovations have caused changes and prompted a rapid expansion in technical studies. Several studies reveal that this is the beginning of the fourth industrial revolution called industry 4.0. The objective of this research is to propose a new way to analyse the processes with the data that this revolution will be able to offer and to use Value Stream Mapping (VSM) to evolve in terms of information, making this tool more dynamic and modern. Research is exploratory, applied and qualitative, and in terms of procedure, it is classified as a simulation. The simulations were carried out at AIPL (*Atelier Inter- Etablissements de Productique et Pôle de Ressources Informatiques pour la Mecanique*), where the manufacturing and assembly workshop of the Lean FESTO team is located, this space was used for the purpose of conducting some tests and to collect data. The ENSGSI (*École Nationale Supérieure en Génie des Systèmes et de l'Innovation*) students were responsible for the installation of the equipment and to carry out this collection. With this, Lean Six Sigma was used to evaluate all the information gathered from this practical activity, and as a consequence to elaborate a more dynamic VSM for the new era of the industry. During the process of data study, Minitab software was used as a statistical analysis tool. In the work was highlighted some weaknesses of the “classic” VSM and then proposed a more dynamic and reliable VSM with new information useful to improve the performance of industrial processes. Furthermore, during the project, bibliographic research was carried out considering new data mining methodologies and their potential benefits for process analysis.

Keywords: Industry 4.0, Lean Six Sigma, Value Stream Mapping.

LISTA DE ILUSTRAÇÕES

Figura 1- Linha do tempo da Revolução Industrial	17
Figura 2 - <i>Cyber-Physical Systems</i>	18
Figura 3 - Exemplo de um VSM	23
Figura 4 - Grupo <i>Lean Festo</i>	31
Figura 5 - Oficina de Fabricação <i>Lean FESTO</i>	32
Figura 6 - VSM 4.0.....	33
Figura 7 - Maleta TEA.....	34
Figura 8 - Sensores Arduinos	34
Figura 9 - Câmeras	35
Figura 10 - VSM Clássico	37
Figura 11 - Histograma de frequência dos tempos de ciclo preparação e controle (s)....	40
Figura 12 - Histograma de frequência dos tempos de ciclo montagem 2.....	40
Figura 13 - Diagrama de séries temporais de tempos de ciclo preparação, rosqueamento, controle, montagem e reparação	41
Figura 14 - Diagrama de série temporal do tempo de ciclo do posto de rosqueamento .	42
Figura 15- Box Plot de tempos de ciclos dos postos de trabalhos	43
Figura 16 - Diagrama de pontos dos postos de trabalho.....	44
Figura 17 - Gráfico de intervalo de confiança dos postos de trabalho	45
Figura 18 - Análise ANOVA.....	46
Figura 19 - Análise ANOVA.....	47
Figura 20 - Regressão linear do Lead Time e tempo de ciclo do posto rosqueamento ...	48
Figura 21- Carta de controle (tempo de ciclo do posto preparação)	49
Figura 22 - Diagrama de probabilidade de tempos de ciclo dos postos de trabalho	51
Figura 23- Diagrama de probabilidade dos tempos de ciclo do posto preparação	52

LISTA DE ABREVIATURAS

AIPL- *Atelier Inter- Etablissements de Productique et Pôle de Ressources Informaatiqes pour la Mecanique*

CEP- *Controle Estatístico de Processo*

CLARA - *Clustering Large Applications*

CPS-*Cyber-Physical Systems*

DBSCAN - *Density-Based Clustering Method Based on Connected Regions with Sufficiently High Density*

DECLUE - *Density-based Clustering*

DIANA - *Divisive Analysis*

DMAIC - *Define, Measure, Analyze, Improve, Control*

ENSGSI - *École Nationale Supérieure en Génie des Systèmes et de l'Innovation*

ERPI -*Équipe de Recherche sur les Processus Innovatifs*

IC-*Intervalo de confiança*

ICT - *Communication Information and Technology*

IOT - *Internet of things*

KDD - *Knowledge Data Discovery*

MIT - *Instituto de Tecnologia de Massachusetts*

M2M - *Machine-to-Machine*

PAM - *Partitioning Around Medoids*

ROCK - *Robust Clustering using links*

RFID- *rádio frequência*

SVM - *Support Vector Machines*

STING - *Statistical Information grid*

TEA - *Technologie Ergonomie Applications*

VSM - *value stream mapping*

Sumário

1 INTRODUÇÃO	14
1.1 OBJETIVOS	15
1.1.1 Objetivo Geral	15
1.1.2 Objetivos Específicos	15
2 REFERENCIAL TEÓRICO	15
2.1 <i>Lean Six Sigma</i>	15
2.2 Indústria 4.0	16
2.3 Aplicação do <i>Lean Six Sigma</i> na indústria 4.0	21
2.4 <i>Value Stream Mapping</i> (VSM)	23
2.5 Metodologias alternativas para explorar os dados de um processo de fabricação.....	24
2.5.1 Regra de associação	25
2.5.2 <i>Frequent Itemset Mining</i>	25
2.5.3 <i>Classification</i>	25
2.5.4 <i>Arbre de décision</i>	25
2.5.5 <i>Classification Naïve Bayes</i>	26
2.5.6 <i>Support Vector Machines</i>	26
2.5.7 <i>Algorithmes Génétiques</i>	26
2.5.8 <i>Rought Set</i>	26
2.5.9 <i>Prédiction</i>	27
2.5.10 <i>Clustering</i>	27
2.5.11 <i>Partitional Clustering</i>	27
2.5.12 <i>k-Medoids</i>	27
2.5.13 <i>Clarans</i>	28
2.5.14 <i>Fuzzy K-Means</i>	28
2.5.15 <i>Hierarchical Methods</i>	28
2.5.16 <i>Agnes</i>	28
2.5.17 <i>Diana (Divisive Analysis)</i>	29
2.5.18 <i>Cure</i>	29
2.5.19 <i>Birch</i>	29
2.5.20 <i>Rock (Robust Clustering using links)</i>	29
2.5.21 <i>DBSCAN (Density-Based Clustering Method Based on Connected Regions with Sufficiently High Density)</i>	29
2.5.22 <i>DECLUE (Density-based Clustering)</i>	30
2.5.23 <i>STING (Statistical Information grid)</i>	30

3 MÉTODO DE PESQUISA	30
4 REALIZAÇÃO DA SIMULAÇÃO	31
4.1 RESULTADOS	35
5 ANÁLISES DOS RESULTADOS.....	39
5.1 O histograma e dados estatísticos básicos	39
5.2 Representação cronológica dos dados:	41
5.3 Diagrama <i>Box Plot</i>	42
5.4 Diagrama de ponto.....	43
5.5 Gráfico de intervalos de confiança em médias:	44
5.6 Estatísticas inferenciais (comparações de médias e variâncias)	45
5.7 Regressão: O <i>Lead Time</i> está correlacionado com determinados tempos de ciclo?	47
5.8 Cartas de controles aos valores individuais	48
5.9 Teste de normalidade dos dados	49
6 CONCLUSÃO.....	51
7 REFERENCIAS	54
8 APÊNDICES	58

1 INTRODUÇÃO

A concorrência no mercado de trabalho e orientação aos clientes forçam as empresas a terem uma vantagem competitiva e, em particular, o investimento em qualidade e satisfação (ALVES et al., 2016). Desta forma, o método *Lean Six Sigma* é muito importante para melhorar os produtos, melhorar processos e reduzir custos nas empresas. Além disso, a indústria está mudando em um ritmo nunca antes visto, impulsionado pelo desenvolvimento e pelo uso de tecnologias cada vez mais sofisticadas e ágeis (COELHO, 2016). Neste contexto, existe a Indústria 4.0, que é estratégica para a integração avançada de controle com tecnologia de Internet: comunicação entre pessoas, produtos e sistemas (REINER, 2014).

A Alemanha está liderando uma transformação em direção à quarta revolução industrial, baseada na inovação na fabricação e serviços de *cyber-physical systems* (LEE et al., 2014). Este novo termo alemão poderia ser explorado pelo método *Lean Six Sigma* e, com isso, o setor poderia obter várias vantagens, como produtos mais inteligentes e produtivos, melhoria contínua no gerenciamento de qualidade e ferramentas digitais para análise ergonômica. O método *lean six sigma* pode tirar proveito de *cyber-physical systems*, aproveitando os dados fornecidos pelos sensores em contato com as pessoas e máquinas e, assim, aumentar as possibilidades de melhoria pelo *lean six sigma*.

O maior desafio da indústria é selecionar dados relevantes e processá-los de maneira significativa. Esse tipo de atividade requer sistemas tecnologicamente avançados, com capacidade de processamento em tempo real. Obter esses conhecimentos podem abrir os horizontes além da imaginação, sendo um ótimo começo para a indústria do futuro (COELHO, 2016).

O presente trabalho foi desenvolvido na *Université de Lorraine*, especificamente na ENSGSI (*École Nationale Supérieure en Génie des Systèmes et de l'Innovation*) localizada na cidade de Nancy na França, em que teve como associação ao projeto de digitalização da plataforma de formação *Lean FESTO*. O *Lean Six Sigma* é lecionado na turma de engenharia de produção, em que tem como apoio a empresa FESTO especializada em produtos e serviços para controle e automação industrial pneumáticos. Com o intuito de explorar sobre o novo universo da indústria 4.0 foi feito um estudo com base nos dados obtidos das atividades realizadas durante a aplicação da disciplina. Todas as informações bibliográficas foram obtidas no laboratório ERPI (*Équipe de Recherche*

sur les Processus Innovatifs), as atividades práticas foram feitas no AIPL (*Atelier Inter-Etablissements de Productique et Pôle de Ressources Informatiques pour la Mecanique*)

Um trabalho como esse tem como justificativa o ganho na área científica e empresarial, já que uma interação do método *Lean Six Sigma* com o novo conceito de indústria 4.0 é algo novo, e apresenta o que podemos chamar de tendências futuras nos processos produtivos das empresas.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Elaborar um VSM dinâmico com base nos conhecimentos da estratégia de gestão *Lean Six Sigma* e da indústria 4.0, buscando mostrar a importância desta ferramenta para utilização nesta nova era da indústria

1.1.2 Objetivos Específicos

- Aplicar uma simulação com os estudantes de engenharia utilizando a oficina de fabricação da equipe *Lean FESTO*.
- Explorar os dados da atividade prática da equipe *Lean FESTO* na simulação;
- Determinar as características do LSS e Indústria 4.0 para elaboração do VSM;

2 REFERENCIAL TEÓRICO

Neste capítulo serão apresentados os conceitos básicos sobre o Lean Six Sigma, a Indústria 4.0, o VSM e as Metodologias para explorar dados dos processos de fabricação.

2.1 *Lean Six Sigma*

Hoje em um ambiente competitivo, se diferenciar da concorrência e alcançar uma melhor performance é a regra a ser seguida. Nessa situação, eliminar o desperdício, adotar tecnologias avançadas, desenvolver novos produtos, obter o comprometimento dos funcionários, e conseguir a melhoria contínua dos processos de produção tornaram-se a base do desenvolvimento das empresas. Nesse contexto, as empresas que desejam vencer a concorrência devem se esforçar, para se chegar a uma gestão eficiente de seus recursos

e apoiar suas posições no mercado, para realizar ações que permitam a análise de processos e a busca de melhorias (ANDRIETTA; MIGUEL, 2002).

Atualmente, muitas indústrias procuram soluções para conseguir as melhores vantagens competitivas. Muitas delas, necessitam de métodos para melhorar seus produtos, aprimorar técnicas e reduzir custos. Através do *Lean Management* e do *six sigma* integrado nos processos de gestão e produção, é possível obter esses resultados (TENERA; PINTO, 2014). O *Lean Six Sigma* tornou-se um modelo de negócio, um símbolo de excelência, com o objetivo de eliminar o desperdício, reduzir defeitos e variações nos processos (MUTHUKUMARAN et al., 2013).

O *Lean Six Sigma* permitiu que as empresas obtivessem bons resultados, o DMAIC (*Define, Measure, Analyze, Improve, Control*) um ciclo focado em encontrar soluções para problemas é uma estrutura conjunta de melhoria contínua e esforços para reduzir os defeitos (TENERA; PINTO, 2014).

O sucesso que as empresas obtêm com o uso da metodologia *six sigma* é principalmente devido ao uso de ferramentas poderosas aplicadas em situações específicas e de forma correta, permite oferecer uma grande ajuda para a melhoria dos sistemas administrativos e manufatura, gestão da qualidade e gerenciamento de processos. Entre as ferramentas mais utilizadas podemos citar o Controle Estatístico de Processo (CEP) e cartas de controle para identificação de problemas, correlação e regressão, análise de possíveis causas e previsão de resultados, análise de modos de falha, dos seus efeitos de sua criticidade (FMEA) e para priorização e prevenção de problemas existem dispositivos como o POKA-YOKE para evitar erros (ANDRIETTA; MIGUEL, 2002).

2.2 Indústria 4.0

Com o novo conceito de indústria 4.0 o setor industrial deve se tornar mais dinâmico, moderno, digital e todo processo mais flexível com os produtos personalizados (KOLBERG; ZUHLKE, 2015). Chamada de quarta revolução industrial, a Indústria 4.0 define um *network* de empresas, máquinas, produtos e pessoas em tempo real via Internet, de acordo com Rosa (2017).


Uma revolução industrial é caracterizada por mudanças fortes e radicais, motivadas pela incorporação de tecnologias, com duplicação nas esferas econômica, social e política. Há consenso sobre a existência de três revoluções industriais, a primeira

foi entre 1760 e 1840, guiada por tecnologias como motores a vapor e ferrovias. A segunda deu entre o final do século XIX e início do século XX, as características principais foi: a eletricidade, a linha de montagem e a propagação da produção em massa (TADEU; SANTOS, 2016). A terceira, começou nos anos 1960, que rompeu com certos paradigmas através do desenvolvimento de semicondutores e tecnologias como *mainframes*, computadores pessoais e, mais tarde, a década de 1990, a Internet (TADEU; SANTOS, 2016).

O uso de componentes lógicos programáveis e robôs levou a um aumento significativo na automação da produção de acordo com Rosa (2017). No entanto, com um importante desenvolvimento e difusão de algumas das tecnologias da terceira revolução industrial e o advento e incorporação de outras tecnologias no início do século XXI, chegamos ao início de uma quarta revolução industrial (TADEU; SANTOS, 2016).

A chamada indústria 4.0 é uma rede empreendedora, máquinas, produtos e pessoas em tempo real, segundo Rosa (2017). Essa revolução nascida na Alemanha é baseada na fabricação e inovação de serviços de *Cyber Physical Systems* (LEE et al., 2014).

Figura 1- Linha do tempo da Revolução Industrial




Fonte: Adaptado de Pellerin (2016)

A indústria 4.0 é uma integração de internet com a tecnologia, estabelecendo a comunicação entre pessoas, produtos e todo o sistema (REINER, 2014). Ela está fortemente focada na melhoria contínua da eficiência, confiabilidade, produtividade das operações e especialmente no retorno do investimento. Tecnologias e tendências que facilitam isso são inúmeras e estão disponíveis hoje. As principais áreas da Indústria 4.0 são: *internet of things*, *Cyber Physical Systems* e *Big Data* (COELHO, 2016).

O processo da indústria 4.0 é utilizar a capacidade de sistemas *Cyber Physical Systems* para fornecer inteligência e comunicação aos sistemas técnicos artificiais que são chamadas de sistemas inteligentes. Esses sistemas são de uma tecnologia que sucede aos sistemas mecatrônicas e adaptadores. Essas são as características que permite a comunicação principalmente a integração do *cyber-physical systems*, internet e tecnologia, os componentes como suporte de informação e proteção do conhecimento (REINER, 2014).

Os *Cyber-Physical Systems* (CPS) são redes de entidades autônomas composto pela parte física e digital. Eles são capazes de interagir com o ambiente de maneira dinâmica. A integração do CPS na empresa oferece grandes perspectivas em relação a agilidade nos processos produtivos. A área de pesquisa sobre o CPS abrange vários domínios, como: sistemas inteligentes de manufatura, sistemas orientados a produtos, *Cloud Computing*, *Big Data* e *Machine-to-Machine* (M2M) (CARDIN et al., 2016). Esses sistemas poderão ser entendidos como uma configuração consequente de sistemas integrados, captadores com acesso à rede (REINER, 2014). A Figura 2 mostra uma abordagem de configuração que permite a criação de sistemas cibernéticos e suas aplicações como sistemas de produção cibernética.

Figura 2- *Cyber-Physical Systems*



Fonte: Reiner (2014)

A abordagem do *Cyber-Physical Systems* permite que os objetos sejam identificados, localizados e endereçados, permitindo abrir novos caminhos para a inovação. Com a fabricação por meio desse sistema é possível transportar as informações pelo que é produzido, pois toda a fabricação contém uma rede de comunicação. Uma das principais mudanças que a indústria 4.0 traz é desenvolver o gerenciamento de processos, que neste caso será descentralizado e conectado. O controle de estratégia e processo se torna mais flexível e adaptável. O principal objetivo é melhorar os processos de valor agregado e desenvolver novos modelos de gestão para fortalecer a competitividade industrial (REINER, 2014).

Além disso o CPS tem o objetivo de contribuir para a implementação de um sistema que seja flexível, seguro, e de fácil manutenção, capaz de evoluir em sua infraestrutura. Com os novos desenvolvimentos de *internet of things* e o surgimento de novas tecnologias de detecção, criar uma rede única de informações conectará fortemente sistemas e seres humanos. Com a análise avançada, o advento de *cloud computing*, a indústria do futuro pode fornecer um vasto sistema de informações que ajuda as máquinas a evitar possíveis problemas de desempenho (SCHMITT et al., 2014).

Na Indústria 4.0, as peças deixam o estoque e se identificam na linha de montagem por um chip de radiofrequência (RFID), portanto todas as peças são integradas e identificáveis (BRETTEL et al., 2014).

O impacto da Indústria 4.0 vai além da simples digitalização, passando por uma forma muito mais complexa de inovação e tecnologia, o que forçará as empresas a repensarem o modo como administram seus negócios e os desafios que enfrentam. Os processos, que estão posicionados na cadeia de valor, para pensar no desenvolvimento de novos produtos e introduzi-los no mercado, ajustando as atividades de marketing e distribuição. É importante saber que as mudanças afetarão os dois lados da cadeia de suprimentos, tanto em termos de necessidades do cliente quanto como parceiros de negócios (COELHO, 2016).

Outro termo dessa revolução é a *internet of things* (IoT) que refere-se a objetos físicos e virtuais relacionados à internet. A IoT nasceu no MIT (Instituto de Tecnologia de Massachusetts) quando, em 1999, um grupo de pesquisadores desenvolveu um trabalho em uma área de identificação por rádio frequência (RFID) conectada. Desde então, esta tecnologia tem sido impulsionada pelo surgimento e uso geral de sensores cada vez menores e econômicos, desenvolvendo dispositivos móveis, comunicação sem fio e tecnologias de nuvem. A conectividade e a interação das coisas podem criar serviços de valor agregado para o cliente, que é um dos mais fortes defensores da revolução industrial, abrindo um mundo de oportunidades e desafios (COELHO, 2016).

Atualmente o IoT faz parte de nosso cotidiano. Exemplo disso: verificar a produção do sistema de energia, encontrando o caminho mais rápido para ir do ponto A ao ponto B, considerando as condições de tráfego, controlar o ambiente de produção em tempo real, verificar o estado de desgaste de um equipamento e, se necessário, programar ou deixar o próprio equipamento planejar sua manutenção.

Hoje temos uma infinita biblioteca de informações (*Big-Data*) que podemos consultar a qualquer momento assim que precisarmos tomar uma decisão ou tivermos dúvidas sobre algo ou alguém. Muitas "coisas" podem usá-lo para tomar decisões "inteligentes" e extrapolar para antecipar o que precisamos (COELHO, 2016).

O Big Data refere-se às grandes quantidades de dados que estão ligados à rede (IoT), que produz dados em tempo real (COELHO, 2016). De acordo com o governo, no Big Data há inteligência operacional que pode dar aos gerentes visibilidade em atividades de análise de dados em tempo real para sugerir ações. Há vários serviços, como *social networks* e comércio eletrônico inteligente, precisam gerenciar dados em larga escala, o que é uma dificuldade para um banco de dados tradicional. Nesse caso, é necessária uma abordagem diferente, com Big-Data, é possível construir um sistema de arquitetura com

ferramentas projetadas especificamente para capturar e analisar dados em escala web (MARZ; WARREN, 2015).

2.3 Aplicação do *Lean Six Sigma* na indústria 4.0

Nos dias atuais muitas empresas buscam soluções para obter a melhor vantagem competitiva. Cada vez mais as empresas buscam por metodologias para melhorar seus produtos, processos e reduzir custos. Por meio de metodologia como o *Lean Six Sigma*, as empresas buscam otimizar o processo de produção (TENERA; PINTO, 2014). Hoje, o termo indústria 4.0 está se tornando cada vez mais comum para as empresas, principalmente os conceito de *internet of things*, *cyber-physical systems*, *cloud computing*, *machine-to-machine* e *Big-Data*. Desde então, vários pontos positivos surgiram, por exemplo: redução de custos, redução de desperdícios e aumento da qualidade do produto (BATISTA et al., 2017).

O *Lean* pode otimizar a velocidade e eficiência do trabalho, reduzindo o desperdício e *Six Sigma* é um plano de melhoria contínua que se destina a reduzir a variabilidade de um processo (MUTHUKUMARAN et al., 2013). Uma combinação das novas tecnologias com o método *Lean Six Sigma* pode permitir, se estiver bem integrada, melhorar a interação de pessoas e máquinas para o benefício do desempenho geral da empresa.

Além disso, com essa combinação da filosofia *Lean* corresponde à Indústria 4.0 onde os seres humanos recebem o apoio de tecnologias inovadoras. Esta integração é denominada ICT (*Communication Information and Technology*) (KOLBERG; ZUHLKE, 2015).

De acordo com Pellerin (2016) hoje as empresas têm uma quantidade crescente de informações, como por exemplo, a cadeia de suprimentos (variabilidade de custos de material, tempo de entrega, capacidade de fornecedores, etc.); linha de produção (pedidos em preparação, energia) e o ambiente de negócio em si. Com a Indústria 4.0 e o *Lean Six Sigma*, a grande quantidade de informações que são perdidas diariamente serão usados para a melhoria do processo e dos produtos.

Existem várias combinações possíveis de indústria 4.0 e o *Lean Six Sigma*, de acordo com Kolberg e Zühlke (2015):

- Operador Inteligente: O operador inteligente pode reduzir o tempo desde a ocorrência da falha até a sua notificação. Além disso, as equipes do CPS com

sensores apropriados reconhecem padrões e ativam automaticamente ações para reparar padrões em outros CPS. Com o operador inteligente, o funcionário recebe informações sobre as atividades necessárias para fabricar no tempo previsto. Além disso, os sistemas de computador recebem o padrão e podem exibi-lo em tempo real para os funcionários;

- Produto Inteligente: O produto inteligente pode conter informações sobre o *Kanban* e controlar os processos de produção. Por exemplo: Um mapeamento para coletar informações sobre produtos e cadeias de produção automaticamente;
- Máquina inteligente: O CPS pode ser conectado a processos e assim evitar erros, mas também enviar erros diretamente ao operador inteligente e informar outros sistemas para possíveis reparos. Como resultado, a produção continua mais flexível.

Assim, com uma conciliação de uma tecnologia digital e sistema *Lean*, é possível oferecer uma redução de custo para as empresas.

O impacto da Indústria 4.0 não é apenas uma simples digitalização, é também uma forma muito mais complexa de inovar através da combinação de múltiplas tecnologias, forçando as empresas a repensar seus negócios e processos, por exemplo, pensando no desenvolvimento de novos produtos, introdução no mercado ou ajustar as ações de marketing e distribuição em tempo real (COELHO, 2016). A combinação de modernos paradigmas de interação e componentes de software modulados permitirá maior flexibilidade e dinamismo na função, bem como sua eficácia na aplicação (SCHMITT et al., 2014).

Segundo Schwab (2016), existem quatro principais mudanças esperadas no setor:

- Mudança nas expectativas do cliente;
- Produtos mais inteligentes e produtivos;
- Novas formas de colaboração e parcerias;
- Transformando o modelo de negócios em um modelo digital;

Os produtos e serviços são aprimorados com a integração de recursos digitais, com o uso de materiais novos e inteligentes, sensores capazes de monitorar em tempo real, estatísticas de desempenho e evitar desvios da operação normal, correção de desvios

antes que se transformem em defeitos para maximizar seu uso, reduzir custos e aumentar o valor realizado para o cliente (COELHO, 2016).

Com a implementação de tecnologias inovadoras, há também a oportunidade de aproveitar o ambiente digital para melhorar a análise ergonômica. Assim, isso pode contribuir para a melhoria contínua da gestão da qualidade e, ao mesmo tempo, tornar o trabalho menos doloroso e mais produtivo (HOVANEK, 2017). Além disso, com a aplicação do *Lean Six Sigma* na indústria 4.0, há outros benefícios, exemplo disso: um ambiente mais inovador, competitivo, eficiente e atrativo.


2.4 Value Stream Mapping (VSM)

O VSM (*value stream mapping*) é uma técnica importante usada na abordagem *Lean* para determinar e visualizar o desperdício no processo de produção. Visa destacar o desperdício em um sistema de manufatura com o objetivo final de reorientar as práticas de produção para alinhar com o pensamento *Lean* e planejar melhorias futuras. Em alguns casos, o desperdício pode ser inevitável, mas um dos objetivos da atividade do VSM é tornar esse trabalho claro e avaliar se os desperdícios podem ser reduzidos ou eliminados (BROWN et al., 2014). O VSM é útil em todos os estágios do processo *Lean*, o valor agregado e o não agregado são analisados usando o VSM como uma ferramenta visual (AR; AL-ASHRAF, 2012).

O problema com o VSM é que ele representa apenas o fluxo de valor do sistema atual. Ela faz a análise do processo real, mas não pode prever como as coisas vão mudar no futuro próximo. Mas, se o VSM estiver associado a uma simulação, você poderá prever as alterações no sistema atual e do sistema futuro (STADNICKA; LITWIN, 2019).

A figura 3 apresenta o clássico modelo da realização do VSM de uma empresa, considerando as diversas etapas de trabalho e também vários pontos de controle e abastecimento.

Figura 3 - Exemplo de um VSM



Fonte: A autora (2019)

2.5 Metodologias alternativas para explorar os dados de um processo de fabricação

A mineração de dados é uma importante área de pesquisa e é usada em diferentes campos, como finanças, pesquisa clínica, educação, saúde, etc (PANDEY, 2016). A etapa de mineração de dados inclui pesquisa eficiente baseada em conhecimento no contexto de aplicativo KDD (*Knowledge Data Discovery*) (GOLDSCHMIDT et al., 2015).

A escolha da técnica depende frequentemente do tipo de atividade de KDD a ser realizada (GOLDSCHMIDT et al., 2015). As atividades de exploração de dados podem ser classificadas em duas categorias: preditivas e descritivas. Modelos preditivos analisam um problema específico para prever os valores de um ou mais atributos. Modelos descritivos apresentam informações interessantes para o especialista (GOLDSCHMIDT et al., 2015).

O objetivo principal da mineração de dados é encontrar relações entre dados e fornecer informações que possam ser uma previsão de tendências futuras com base no passado. Pensando nisso foi feita uma pesquisa bibliográfica que ajudasse no projeto a ser trabalhado.

Existem muitas áreas nas quais metodologias de processo foram definidas e estão sendo ativamente usadas. Entre as metodologias para a exploração de dados para um processo estão:

2.5.1 Regra de associação

O propósito de extrair regras de associação é encontrar a relação de associação entre termos diferentes em um banco de dados. Seu princípio básico é encontrar elementos que impliquem a presença de outros elementos na mesma transação. Também são frequentemente usadas regras de associação quando os atributos são binários, presentes, e a maioria dos valores de atributos associados a uma determinada instância estão ausentes (WITTEN; FRANK, 2005).

2.5.2 Frequent Itemset Mining

Este é o método de mineração de dados mais conhecido e popular. Originalmente foi desenvolvido para a análise de compras, atualmente é utilizado em quase todas as atividades que exigem a descoberta de regularidades entre variáveis nominais (BORGELT, 2012).

2.5.3 Classification

A tarefa de classificação consiste em examinar as características de um objeto e enquadrá-las em conjuntos pré-definidos. Eles são usados para prever o tipo de valores de variáveis categóricas (VASCONCELOS; CARVALHO, 2004).

2.5.4 Arbre de décision

O método de classificação de árvore de decisão é uma ferramenta muito útil em mineração de dados. As árvores de decisão podem modelar respostas discretas ou contínuas dividindo em segmentos não sobrepostos que correspondem aos nós terminais

(folhas) da árvore. Começa com o nó raiz que contém todos os dados e terminando quando certos critérios são atendidos (CHEN et al., 2016).

2.5.5 Classification Naïve Bayes

Naive Bayes é um dos mais eficientes algoritmos de aprendizado indutivo para aprendizado de máquina e mineração de dados (ZHANG, 2004). É uma técnica estatística (probabilidade condicional) baseada no teorema de *Thomas Bayes* (CAMILO; SILVA, 2009).

2.5.6 Support Vector Machines

SVM (*Support Vector Machines*) é uma técnica de aprendizado desenvolvida por V. Vapnik e sua equipe que pode ser considerada como um novo método para a formação de classificadores de polinômios, redes neurais ou funções radiais (OSUNA et al., 1997). Com este método é possível obter alta precisão e modelar situações não-lineares complexas, especialmente criando uma versão de interpretação simples e pode ser usada para relações lineares e não-lineares. Não funciona, claro, com conjuntos de dados muito grandes, porque o tempo de treinamento é muito caro (CAMILO; SILVA, 2009).

2.5.7 Algorithmes Génétiques

O *Algorithmes Génétiques* usa uma pesquisa para otimizar problemas de alta complexidade ou problemas mal compreendidos. É amplamente utilizado quando o espaço de pesquisa é grande e tem muitos ótimos locais. Os algoritmos genéticos são usados principalmente em conjuntos neurais que servem como um guia para o processo de aprendizagem de algoritmos de mineração de dados, e não para encontrar modelos. Eles também são usados na forma de regras de associação ou algum outro forma na mineração de dados para gerar hipóteses sobre variáveis e dependências entre elas (PANDEY, 2016).

2.5.8 Rought Set

Esta é uma técnica com dois objetivos: revelar estruturas relevantes em conjuntos de dados e classificar objetos. Esta teoria foi desenvolvida para a manipulação de incertezas e imprecisões no contexto do conjunto de dados inerente a muitos problemas

práticos. A teoria fornece meios sistemáticos para eliminar informações sem importância através de um processo de redução (OLIVEIRA, 2013).

2.5.9 *Prédiction*

A atividade de *prédiction* é descobrir um valor futuro de uma variável com interferência nos dados atuais (JAIN; SRIVASTAVA, 2013). Esse método prova que previsões numéricas podem prever valores futuros. Como previsão há regressão, as técnicas de regressões podem modelar a relação de variáveis independentes com uma variável dependente (CAMILO; SILVA, 2009).

2.5.10 *Clustering*

Nesse grupo não há classes predefinidas, os registros são agrupados com o banco de dados de similaridade, o usuário determinará os grupos finais (BERRY; LINOFF, 2004). Geralmente é executado quando não há informações disponíveis sobre a associação de elementos de dados a classes predefinidas. Por essa razão, o agrupamento é tradicionalmente considerado parte da aprendizagem não supervisionada (DEEPA; SUJATHA, 2014).

2.5.11 *Partitional Clustering*

Esse tipo de algoritmo divide o conjunto de dados em um número especificado de *clusters*. Esses algoritmos devem tentar minimizar alguns critérios (por exemplo, uma função de erro quadrada) e, portanto, podem ser tratados como problemas de otimização. A função de critério pode enfatizar a estrutura local ou global dos dados e sua otimização é um procedimento iterativo. Algoritmos de *Partitional clustering* visam descobrir a partição presente no conjunto de dados, otimizando uma função com objetivo específico e melhorando iterativamente a qualidade das partições (LEUNG et al., 2000).

2.5.12 *k-Medoids*

É uma variante de *k-means*, nesse algoritmo, em vez de calcular o centro do grupo e usá-lo como referência, ele trabalha com o conceito de agrupamento mais central de objetos. As mais conhecidas são as variações dos algoritmos PAM (*Partitioning Around Medoids*) e CLARA (*Clustering Large Applications*) (CAMILO; SILVA, 2009).

2.5.13 *Clarans*

CLARANS (*Clustering Large Applications*) baseado em *Random Search* foi desenvolvido a partir de algoritmos PAM e CLARA para gerenciar grandes volumes de dados. CLARANS funciona como o PAM, o processo de *clustering* pode ser apresentado procurando um gráfico onde cada nó é uma solução potencial, isto é, um conjunto de *k-medoids* (DEEPA; SUJATHA, 2014).

2.5.14 *Fuzzy K-Means*

Uma das técnicas mais populares de clusterização difusa é o algoritmo *K-means* (BLÖMER et al., 2016). O algoritmo *Fuzzy k-Means* é uma melhoria do *K-Means*. A principal diferença é que permite que um ponto de dados faça parte de vários clusters. Ele atribui a cada valor de probabilidade pontual como parte de cada *cluster* e, em seguida, os centroides de cluster são calculados com base nas posições e probabilidades de cada ponto (XHAFA et al., 2016).

2.5.15 *Hierarchical Methods*

O método funciona agrupando objetos de dados em uma hierarquia ou uma "árvore" de *clusters*. A representação de objetos de dados na forma de uma hierarquia é útil para a síntese e visualização de dados (HAN et al., 2012). Dois tipos de métodos hierárquicos podem ser encontrados: Aglomerativo e Divisivo.

2.5.16 *Agnes*

O algoritmo de Agnes é um método de *clustering* hierárquico. No algoritmo, em primeiro lugar, cada objeto é considerado um cluster. Em seguida, eles são mesclados passo a passo, de acordo com determinados critérios. O algoritmo *agnes* é um método de link exclusivo e cada cluster pode ser representado por todos os objetos. A semelhança entre dois clusters é determinada pela menor distância entre eles. O processo de mistura de cluster é conduzido repetidamente até que o objeto inteiro seja finalmente associado à formação de um cluster. No *clustering*, o usuário define o número final de clusters como uma condição final (HUANG et al., 2015).

2.5.17 Diana (*Divisive Analysis*)

Hierarquia na ordem inversa, ela aborda a inversão Aglomerativa Hierárquica de Agrupamento. Um grande cluster composto por todos os n objetos. Em cada estágio, o maior cluster disponível é dividido em dois clusters até que, finalmente, todos os clusters sejam compostos de objetos únicos (PATNAIK; BHUYAN, 2016).

2.5.18 Cure

O *CURE* é um algoritmo hierárquico muito útil que tem a capacidade de identificar um cluster de forma arbitrária e destacar os valores aberrantes. Em *Cure*, cada cluster é representado por um número fixo de pontos bem dispersos chamados pontos representativos de um determinado cluster (LATHIYA; RANI, 2016).

2.5.19 Birch

O *Birch* usa o conceito de funcionalidade de cluster para descreve-lo, e uma árvore de cluster para representar a sua hierarquia. Esse treinamento hierárquico facilita as técnicas de agrupamento para alcançar uma excelente velocidade. É eficaz para o agrupamento progressivo e dinâmico de objetos que chegam (KAUR; SINGH, 2015).

2.5.20 Rock (Robust Clustering using links)

O *ROCK* é um algoritmo de *clustering* hierárquico que funciona com dados amostrados. Esse método é um dos algoritmos mais conhecidos para agrupar um conjunto de dados amostrados categóricos. *ROCK* envolve muito gerenciamento e cálculo de dados (PATIDAR et al., 2016).

2.5.21 DBSCAN (*Density-Based Clustering Method Based on Connected Regions with Sufficiently High Density*)

Existem funções em que a distribuição de dados é bastante densa e que alguns métodos não apresentam resultados satisfatórios, o DBSCAN é o mais apropriado para essas situações. É um dos algoritmos de cluster mais comuns e mais citado na literatura científica (ANIKIN; GAZIMOV, 2017).

2.5.22 DECLUE (*Density-based Clustering*)

É um algoritmo também indicado quando a distribuição de dados é densa, é baseada em fundamentos matemáticos. Inicialmente, era destinado a grandes bancos de dados multimídia, porque esse tipo de banco de dados requer um agrupamento de vetores de recursos de grande dimensão. Além disso, o DENCLUE é mais rápido que outros algoritmos (IDRISSI et al., 2015).

2.5.23 STING (*Statistical Information grid*)

Com o algoritmo STING, a área espacial é dividida em células retangulares. Existem vários níveis diferentes dessas células correspondentes a uma resolução diferente e essas células formam uma estrutura hierárquica (SUMAN; RANI, 2017).

3 MÉTODO DE PESQUISA

O presente trabalho foi realizado na *Université de Lorraine*, no laboratório ERPI (*Équipe de Recherche sur les Processus Innovatifs*), a aplicação das atividades práticas com a equipe *Lean FESTO* ocorreram no AIPL (*Atelier Inter- Etablissements de Productique et Pôle de Ressources Informatiques pour la Mecanique*).

O objetivo desse trabalho se classifica como exploratório. Segundo Ganga (2012), afirma que esse tipo de pesquisa é desenvolvida com o intuito de propor uma compreensão inicial de um problema pouco explorado, amplo e desconhecido. O objetivo da pesquisa exploratória é estudar problemas em situações em que há pouco conhecimento, e com isso possa descobrir novas práticas e desenvolver modelos novos (BERTO; NAKANO, 2014).

De acordo com Ganga (2012) o trabalho tem como natureza uma pesquisa aplicada, pois procura produzir conhecimentos para aplicação prática, focados à solução de problemas específicos, envolvendo verdades e interesses locais.

Segundo Ganga (2012) a natureza desta pesquisa é quali-quantitativa. De acordo com Cauchik (2010) a abordagem qualitativa tem a preocupação de obter informações sobre as perspectivas dos indivíduos, interpretando o ambiente onde o problema ocorre. Para Ganga (2012) um trabalho quantitativo pode ser entendido como uma linguagem matemática e computacional, que utilizam técnicas estatística e experimentais (simulação) para obter valores numéricos das propriedades de um sistema.

Em relação ao procedimento, o estudo é uma simulação. Este se refere ao método de estudo com ampla variedade de modelos do mundo real por meio de avaliação numérica e utilização de software com o intuito de conduzir o experimento numérico, e com isso possa gerar uma boa compreensão do comportamento do sistema. Os resultados após as análises podem mostrar uma visão futura do sistema auxiliando a tomada de decisão (GANGA, 2012).

Os instrumentos utilizados foram o TEA (*Technologie Ergonomie Applications*), que são sensores sem fio e software de análise, ele tem como objetivo medir a aceleração dos movimentos e as respirações do usuário; o arduino que tinha como função medir os tempos de ciclo de cada operação; as câmeras para ter uma visão global da operação, e utilização do software Minitab para o estudo estatístico.

O trabalho seguiu as seguintes etapas: coleta de dados dos instrumentos utilizados, análises das informações obtidas, construção do VSM comum, aplicação das informações, e em seguida a construção do VSM com todas as informações possíveis que atendessem as visões da indústria 4.0, o que chamamos de VSM 4.0.

4 REALIZAÇÃO DA SIMULAÇÃO

O *Lean Six Sigma* é ministrado na *Université de Lorraine* especificamente na ENSGSI para os alunos da engenharia, tem como objetivo fazer com que os estudantes saibam otimizar a performance e lucratividade das empresas por meio da melhoria dos processos. A simulação *Lean FESTO* foi criada para mostrar aos alunos os princípios das ferramentas do *Lean*. Todas as simulações são realizadas no AIPL.

O AIPL é um centro regional de recursos educacionais que oferece à ENSGSI maneiras práticas de concluir cursos e atividades práticas. Durante a simulação foram usados dispositivos para simular a cadeia de suprimentos de uma empresa, denominada FESTO, que produz, monta e vende cilindros pneumáticos.

É na simulação que os alunos aplicam as ferramentas do *Lean Six Sigma* vistas nas aulas teóricas. A simulação dura 35 minutos, formada por 12 a 18 alunos, cada um com um trabalho específico: cliente, administrador de vendas, fornecedor, logística, embalagem, controle, qualidade, fabricante. A Figura 4 demonstra o processo de fabricação:


Figura 4 - Grupo Lean Festo



Fonte: Guyot et al (2017)

A ENSGSI estava desenvolvendo um projeto para configurar sistemas de aquisição de dados que tornariam possível, para fins educacionais, fornecer mais medidas quantitativas aos alunos. O projeto contém como essencial os dados coletados, para uma melhor compreensão, a Figura 5 mostra a oficina de fabricação da FESTO.

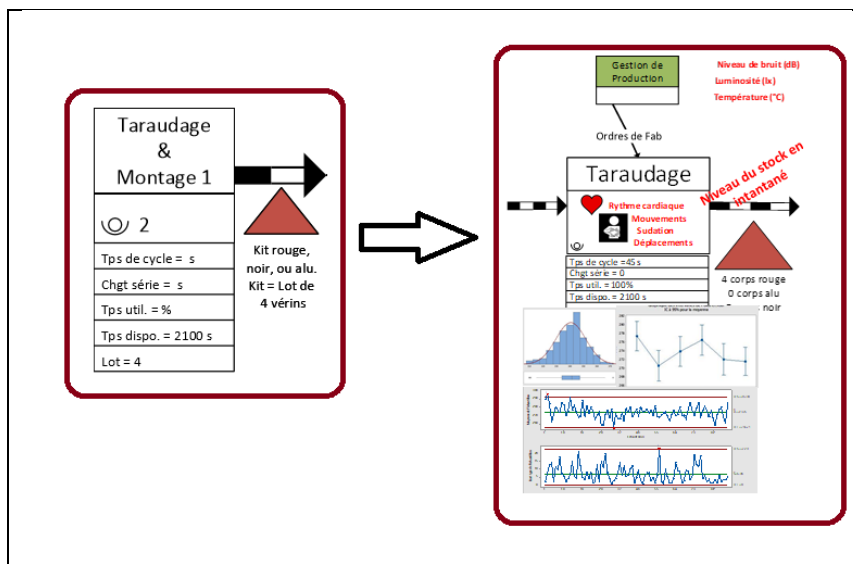
Figura 5 - Oficina de Fabricação *Lean* FESTO



Fonte: Autora (2018)

Com o projeto de digitalização da plataforma de treinamento *Lean* do AIPL (*Lean FESTO*) foi feito uma análise dos dados experimentais obtidos da simulação. Através das informações extraídas passamos a enriquecer o *Value Stream Mapping*, e imaginar essa ferramenta mais dinâmica e moderna, conforme mostra a figura 6.

Figura 6 - VSM 4.0



Fonte: A autora (2017)

Para construir um VSM 4.0, utilizamos novos instrumentos com a intenção de medir tudo o que parece importante para alimentar de informações o VSM. As ferramentas experimentais foram:

- Maleta TEA - *Technologie Ergonomie Applications*: Sensores sem fio e software de análise. Nele há dois tipos de sensores, o acelerômetro que mede a aceleração linear de uma pessoa nos eixos x, y e z, fazendo a transferência de dados em tempo real. O sensor de respiração que mede movimentos torácicos, permitindo analisar o ritmo respiratório e a amplitude das respirações fazendo a transferência em tempo real. A Figura 7 mostra a Maleta.


Figura 7 - Maleta TEA



Fonte: A autora (2017)

- Arduino: Para medir os tempos de ciclo foram utilizados sensores Arduinos que foram implantados entre os diferentes postos de trabalho. Este sistema inclui um sensor que detecta as datas de passagem dos cilindros e, assim, calcula os tempos entre os estoques.

Figura 8 - Sensores Arduinos



Fonte: A autora (2017)

- As câmeras: Obter uma visão global, com três GoPro com ventosa e um tripé portátil para aquisição no Captiv. Conforme mostrado na Figura 9, as câmeras foram instaladas em uma posição que pode ser usada para observar todos os participantes do vídeo.

Figura 9 - Câmeras



Fonte: A autora (2017)

Os instrumentos foram colocados em prática pelos alunos do primeiro ano de engenharia da ENSGSI, em que tinha como atividade prática instalar as ferramentas e fazer a captura de dados.

Os testes foram realizados em dois dias diferentes. A primeira simulação ocorreu em 27 de abril de 2017 e a segunda em 4 de maio de 2017. A primeira mobilizou 15 alunos, três câmeras (um para uma visão global, uma GoPro e um portátil em tripé), um sensor de passagem Arduino na estação de derivação e sensor de aceleração TEA no posto de controle. A segunda teve 18 pessoas na sala com mais equipamentos para coletar os dados: quatro câmeras (uma câmera nova no tripé e três câmeras GoPro), vários sensores de passagem Arduino entre os postos de rosqueamento, controle e embalagem, e o sensor do acelerômetro TEA no posto de rosqueamento e o sensor de respiração conectado a uma pessoa em logística.


4.1 RESULTADOS

O projeto de pesquisa inicial foi usar os dados de todos esses sensores para explorar as possibilidades de enriquecer o VSM da empresa FESTO. O tempo limitado e a grande quantidade de dados obtidos não nos permitiram verificar toda a quantidade de informações fornecidas pelas ferramentas. Além disso, esses dados contêm poucas informações contextuais essencialmente presentes nos vídeos. Tudo isso nos obrigou a restringir o escopo do estudo.

A opção foi utilizar principalmente os vídeos da segunda simulação para extrair, por tempo e observação, os tempos de ciclo de cada estação de trabalho, o tempo de estoque, o tempo de viagem da logística, o *lead time* e também certas observações: como tempos de espera, queda de produtos, reparos, etc. Além disso, certos detalhes da ferramenta do TEA foram usadas no trabalho.

O primeiro passo foi construir o VSM "clássico" do FESTO. Este VSM é apresentado na Figura 10.

Figura 10 - VSM Clássico



Somente os dados de tempo de ciclo dos postos de trabalho foram explorados. Os tempos de ciclo no VSM Clássico são, as médias, comumente utilizados na estratégia *Lean*.

A análise clássica consiste, portanto, em comparar os tempos médios de ciclo por estação e tentar equilibrá-los de acordo com a teoria das restrições. No VSM apresentado na Figura 11, seria para reduzir ou dividir em dois estágios a subestação 2, que é o pós gargalo.

A fim de enriquecer este VSM, várias representações gráficas foram previstas e construídas com os dados obtidos a partir da segunda simulação. Estes dados são os tempos de ciclo dos postos de trabalhos retirados do vídeo. Com essas informações, podemos obter resultados interessantes usando o software de processamento estatístico Minitab como uma ferramenta analítica.

Todas as representações e testes realizados podem ser encontrados no Apêndice deste documento. Somente as análises que ilustram nossa demonstração foram incluídas no corpo do trabalho.

Além disso, com a pesquisa bibliográfica sobre a mineração de dados, foram obtidas informações sobre as vantagens de se usar diferentes métodos. Ela pode ser organizada de acordo com a abordagem de informações que o ambiente fornece, ou seja, é necessário que se explore a classificação e a função dos dados. Classificar os diferentes métodos de mineração é essencial para saber como podemos retirar de informações importantes para o ambiente de trabalho.

Para um trabalho como esse, usar os diferentes métodos de mineração pode trazer como vantagens novos tipos de análises para aplicar no VSM, essas vantagens são:


- Organizar melhor as informações e tornar o VSM mais produtivo;
- Proporcionar maior flexibilidade para lidar com o problema a ser resolvido;
- Grandes quantidades de dados na linha de produção podem ser analisados rapidamente;
- Tornar o VSM mais dinâmico e compreensível, com isso pessoas sem conhecimento estatístico podem interpretar o modelo e comparar com suas próprias ideias e obter informações úteis para os postos de trabalho para otimizar o processo;

5 ANÁLISES DOS RESULTADOS

5.1 O histograma e dados estatísticos básicos


O histograma de frequência dos tempos de ciclo é um gráfico útil para analisar a forma e identificar vários modos ou valores discrepantes. Nas Figuras 11 e 12 identificamos os pontos aberrantes no tempo do ciclo de preparação e a bimodalidade representada no gráfico. Esses elementos são novas maneiras de pesquisar as causas do aumento nos tempos médios de ciclo.

Figura 11 - Histograma de frequência dos tempos de ciclo preparação e controle (s)



Fonte: A autora (2017)

Figura 12 - Histograma de frequência dos tempos de ciclo montagem 2




Fonte: A autora (2017)

5.2 Representação cronológica dos dados:

O seguinte diagrama de séries temporais ilustra os altos picos e assim confirma os pontos mais aberrantes vistos nas Figuras 13 e 14, mas acima de tudo torna possível localizar esses pontos no tempo. Seus dados permitem, com a ajuda do vídeo, revisar os eventos da sala de atividades práticas e identificar as causas do prolongamento desses tempos.


Figura 13 - Diagrama de séries temporais de tempos de ciclo preparação, rosqueamento, controle, montagem e reparação



Fonte: A autora (2017)

Na Figura 14 há uma diminuição nos tempos de ciclo da estação de rosqueamento. Podemos supor que a pessoa está cada vez mais rápida porque ganhou mais habilidade durante a simulação. Esse fenômeno de aprendizado passaria completamente despercebido e não seria tratado com o VSM clássico com base nas médias do tempo de ciclo.

Figura 14 - Diagrama de série temporal do tempo de ciclo do posto de rosqueamento




Fonte: A autora (2017)

5.3 Diagrama Box Plot

A representação em diagrama *box plot* dos tempos de ciclo sem os valores extremos da montagem 2. Podemos observar que as médias são diferentes, o que também permite uma análise *lean* clássica, mas vemos especialmente que a variabilidade de vários postos de trabalho não é o mesmo. Assim, o posto de preparação, com 50 segundos de tempo médio de ciclo, parece não ter prioridade para melhorar e, no entanto, é ele que é o mais variável. As causas dessas variações devem ser encontradas e erradicadas.

Figura 15- Box Plot de tempos de ciclos dos postos de trabalhos




Fonte: A autora (2017)

5.4 Diagrama de ponto

Podemos verificar a frequência das distribuições e analisar suas dispersões. Com esta análise, todos os valores do tempo de ciclo são identificados. Desde então, é possível comparar a dispersão entre estações de trabalho e observar onde há maior variabilidade. Em resumo, este gráfico é uma boa alternativa para ver a dispersão quando as amostras não são muito grandes.

Figura 16 - Diagrama de pontos dos postos de trabalho



Fonte: A autora (2017)

5.5 Gráfico de intervalos de confiança em médias:

A exibição de intervalos de confiança permite relativizar algumas médias que seriam baseadas em poucos dados ou em uma amostra muito dispersa.


Aqui, o tempo médio de ciclo de reparação é muito menos confiável do que o de controle.

Esse tipo de informação nos permitiria qualificar a média usada com um indicador de confiança na margem.

$Erro = IC / \bar{x}$. Por exemplo: Tempo de ciclo de Controle= $3/20 = 15\%$

Tempo de ciclo de Reparação= $20/40 = 50\%$

Figura 17 - Gráfico de intervalo de confiança dos postos de trabalho



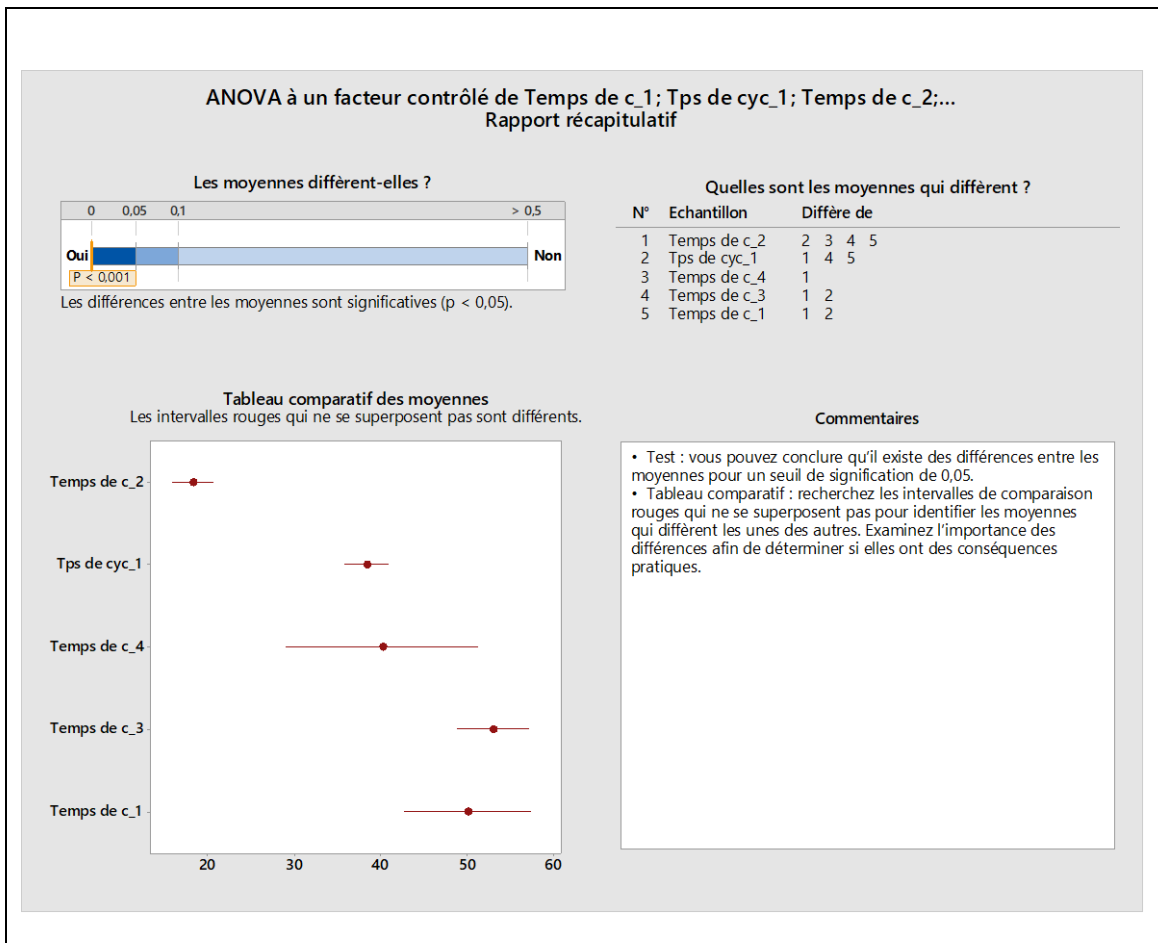
Fonte: A autora (2017)

5.6 Estatísticas inferenciais (comparações de médias e variâncias)

A análise ANOVA foi realizada com nível de confiança de 95%. O gráfico mostrou que há uma diferença entre as médias dos cinco grupos.


ANOVA é uma ferramenta muito interessante para adicionar ao VSM porque podemos usar o intervalo de confiança (IC) no teste. Portanto, a informação é mais confiável para uma boa tomada de decisão. Isso é o que o diferencia do VSM clássico: informações mais confiáveis.

Figura 18 - Análise ANOVA



Fonte: A autora (2017)

Figura 19 - Análise ANOVA



Fonte: A autora (2017)


5.7 Regressão: O *Lead Time* está correlacionado com determinados tempos de ciclo?

Pode ser muito interessante associar o *lead time* total a um modelo linear em determinados tempos de ciclo do processo, pois isso permite encontrar as causas do alongamento do *lead time*.

Nesse caso, percebe-se que quando o tempo de rosqueamento dura mais, o tempo de espera é maior, se houver uma redução do tempo de ciclo de rosqueamento o *lead time* diminui.

A regressão linear, no entanto, não foi possível com os outros tempos de ciclo e revelou um limite em nossos dados. Para fazer esse tipo de correlação, são necessários pares de valores (*lead time* e tempo de ciclo de um posto de trabalho) para o mesmo *vérin* (objeto pneumático produzido pela empresa). Isso não é possível para a maioria das nossas pesquisas, pois leva intuitivamente a considerar produtos que contenham as informações coletadas durante o ciclo de fabricação.

Figura 20 - Regressão linear do *Lead Time* e tempo de ciclo do posto rosqueamento




Fonte: A autora (2017)

5.8 Cartas de controles aos valores individuais

Com o gráfico de controle, podemos ver que existem valores fora do limite de controle, portanto, esses resultados podem indicar as causas anormais de variação do processo.

Figura 21- Carta de controle (tempo de ciclo do posto preparação)




Fonte: A autora (2017)

5.9 Teste de normalidade dos dados

Foi realizado um teste de normalidade nos tempos de ciclo das operações e é possível observar quais dados seguem a distribuição Normal. Podemos perceber na Figura 22 que os tempos de ciclo de rosqueamento (*taraudage*) e montagem 2 (*montage 2*) seguem uma distribuição normal. Essa normalidade reflete uma variabilidade aleatória do tempo de ciclo. Portanto, é interessante procurar por que certos tempos de ciclo não têm uma variação aleatória

Figura 22 – Testes de normalidade dos dados



Fonte: A autora (2017)

Se, por exemplo, a linha de Henry é mostrada como o tempo de ciclo do posto de preparação, de acordo com o gráfico da Figura 23.

Existem três grupos distintos de valores, dois dos quais parecem normais. Essa observação possibilita continuar as investigações buscando os critérios de estratificação que possam explicar esses três grupos de dados.


Este último ponto sublinha o interesse de ter um máximo de informação contextual sobre o funcionamento do processo, ou de ser capaz de recuperar essas informações retrospectivamente. Se cada tempo de ciclo medido estiver associado a um dado que seja possível encontrar no vídeo facilitaria ou permitiria a análise das causas. Com a multiplicação

de objetos conectados e o *big data* pode, portanto, representar os potenciais importantes para alcançar esses objetivos.

Nós só exploramos anteriormente uma pequena parte das possíveis análises de dados, a mais comum do método *Six Sigma*. Eles mostraram o valor do processamento estatístico de dados de um processo e, assim, questionam os valores médios normalmente usados nos VSMs dos processos *lean* tradicionais.

Seria interessante, no entanto, explorar outros métodos de análise, deixando assim o campo restrito do método *Six Sigma*.

Figura 23- Diagrama de probabilidade dos tempos de ciclo do posto preparação



Fonte: A autora (2017)

6 CONCLUSÃO

O *Lean Six Sigma* (LSS) foi descrito como uma estratégia de gestão para otimização e aperfeiçoamento de processos e seus resultados. Essa metodologia é uma combinação de duas filosofias, *Lean Manufacturing* e *Six Sigma*. O *Lean*, originado no sistema Toyota, se tornou amplamente conhecido nos anos de 1982, visa melhorar a eficiência de uma organização

reduzindo o desperdício. O *Six Sigma* é um plano de melhoria contínua que visa reduzir a variabilidade de produtos e processos, e foi desenvolvido na década de 1980 pela Motorola em uma tentativa de melhorar a qualidade, reduzindo a variabilidade em suas operações de fabricação.

Hoje, com a indústria 4.0, construímos a visão futura da produção. Buscamos a otimização de cadeias de valor através da criação de uma produção dinâmica, autônoma e controlada. As soluções da Indústria 4.0 combinadas com o *lean six sigma* possibilita um novo caminho de análises em processos produtivos e, portanto, podem aprimorar o desempenho dos futuros negócios. Graças a princípios como sistemas *Cyber Physical Systems* (CPS), operador inteligente, produto inteligente, máquina inteligente e planejador inteligente podem fornecer informações que muitas vezes não estão disponíveis em uma linha de processo comum, a implementação desses novos elementos é uma maneira altamente inovadora de produzir com mais eficiência e eficácia.

Neste trabalho foi proposto um VSM 4.0, em que aprofundamos a ideia do VSM comum, ou seja, identificar os desperdícios durante o processo de produção com uma profunda análise estatística. O trabalho elaborado com a turma *Lean FESTO* foi uma oportunidade para testar essa proposta, houve uma coleta de dados durante a aplicação da atividade prática dos alunos, e assim montar um VSM bem mais aprofundado. As análises feitas mostraram muitas pistas de identificação de problemas invisíveis em um VSM clássico, o do trabalho realizado permite uma avaliação muito mais rica, podendo identificar as causas dos problemas de maneira mais dinâmica, o que torna mais fácil em uma visão de indústria 4.0

Pensando em uma análise mais dinâmica foi destacado alguns pontos interessantes, uma delas foi o histograma. Com essa ferramenta foi visto pontos aberrantes no tempo do ciclo de preparação e a bimodalidade representada no gráfico.

Com o diagrama de séries temporais identificou-se altos picos e assim confirmando os pontos mais aberrantes. Além disso, com os dados e os vídeos foram identificados as causas do prolongamento desses tempos. Além do mais, há uma diminuição nos tempos de ciclo do posto de trabalho de rosqueamento, com isso é suposto que a pessoa estar cada vez mais rápida porque ganhou mais habilidade durante a simulação. Esse fenômeno de aprendizado passaria completamente despercebido e não seria tratado com o VSM “clássico” com base nas médias do tempo de ciclo.

Um ponto bastante interessante foi o *lead time* correlacionado com determinados tempos de ciclo do processo, pois encontrou-se as causas do seu prolongamento.

Outro ponto a ser destacado foi a carta de controle, notou-se que existiam valores fora do limite de controle, logo esses resultados podem indicar as causas anormais de variação do processo.

E por último o teste de normalidade, que foi observado quais dados seguiam distribuição normal.

Pelo tempo limitado não foi possível explorar a quantidade de dados disponíveis, portanto pareceu importante listar os métodos de mineração de dados que podem ser úteis, e que se tornam interessantes como objeto de estudo para trabalhos futuros.

7 REFERENCIAS

- ALVES, J.L.L., XAVIER, A.S., SILVA, A.A., ALBUQUERQUE, R.M., ALENCAR, T.C. Seis sigma e sua aplicabilidade como ferramenta de qualidade em processos industriais. In: **XXXIV Encontro nacional de engenharia de produção**. João Pessoa/PB, 2016.
- ANDRIETTA, J.M., MIGUEL, P.A.C. A Importância do método seis sigma na gestão da qualidade analisada sob uma abordagem teórica. **Rev. de ciências e tecnologia**. v. 11, p. 91-98, n. 20, São Paulo, 2002.
- ANIKIN, I.V., GAZIMOV, R.M. Privacy Preserving DBSCAN Clustering Algorithm for Vertically Partitioned Data in Distributed Systems. **International Siberian Conference on Control and Communications (SIBCON)**, 2017.
- AR, R., AL-ASHARAF, M. Production Flow Analysis through Value Stream Mapping: A Lean Manufacturing Process Case Study. **Procedia Engineering**. v.41,p.1727-1734, 2012.
- BATISTA, N.C., MELICIO, R., MENDES, V.M.F. Services enabler architecture for smart grid and smart living services providers under industry 4.0. **Energy and Buildings journal**. v.141, p.16-27. Elsevier, 2017.
- BERRY, M.J.A., LINOFF, G.S. Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management. Indianapolis, Indiana: **Copyright**, 2004.
- BERTO, Rosa Maria Villares de Souza; NAKANO Davi. **Revisitando a produção científica nos anais do Encontro Nacional de Engenharia de Produção**. Produção, v.24, p. 225–232, 2014.
- BORGELT, Christian. Frequent item set mining. **Wires Data Mining and knowledge discovery**. v. 2, p. 437-456, 2012.
- BLÔMER, J., BRAUER, S., BUJNA, K. A Theoretical Analysis of the Fuzzy K-Means Problem. **16th International Conference on Data Mining (ICDM)**, 2017.
- BRETTEL, M., FRIEDERICHSEN, N., KELLER, M., ROSENBERG, M. How Virtualization, Decentralization and Network Building Change the Manufacturing Landscape: An Industry 4.0 Perspective. **International Scholarly and Scientific Research & Innovation**. v.8,p.37-44, 2014.
- BROWN, A., AMUNDSON, J., BADURDEEN, F. Sustainable value stream mapping (Sus-VSM) in different manufacturing system configurations: application case studies. **Journal of Cleaner Production**, v. 85, p.164-179, 2014.
- CAMILO, Cássio Oliveira., SILVA, João Carlos da. Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas. **Instituto de Informática**, Universidade Federal de Goiás, 2009.
- CARDIN, O., LEITAO, P., THOMAS, A., TRENTESAUX, D. Cyber-physical systems for future industrial systems. **IFAC World Congress**. p. 15-17. Mar, 2016.
- CAUCHICK, P.A. et al. Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operação. Rio de Janeiro: **Elsevier**, 2010.
- COEHO, Pedro Miguel Nogueira. Rumo à Indústria 4.0. Dissertação (Mestrado). **FCTUC**, 2016.

CHEN. J., WANG. T., ABBEY. R., PINGENOT. J. A Distributed Decision Tree Algorithm and Its Implementation on Big Data Platforms. **IEEE International Conference on Data Science and Advanced Analytics**. p. 752-761, 2016.

DEEPA. M.S., SUJATHA. Dr.N. Comparative Studies of Various Clustering Techniques and Its Characteristics. **Int. J. Advanced Networking and Applications**. v.5,p.2104-2116, 2014.

GANGA, G.M.D. Trabalho de conclusão de curso (TCC) na Engenharia de Produção. São Paulo: **Atlas**, 2012.

GUYOT, Q., LAMANE, Y., PANNETIER, N., TEILLET, A. **Mise en place de système d'acquisition de données dans le cadre du Lean Manufacturing**, (Relatorio em Engenharia)- Université de Lorraine, Nancy, 2017.

GOLDSCHMIDT, R.R., PASSOS, E., BEZERRA, E. Data Mining: Conceitos, técnicas, algoritmos, orientações e aplicações. Rio de Janeiro: **Elsevier**, 2015.

HAN, J.W., KAMBER, M., PEI, J. Data Mining Concepts and Techniques. Waltham Ma Estados Unidos: **Elsevier**, 2012.

HOVANEK, M. Digital factory as a prerequisite for successful application in the area of ergonomics and human factor. **Theoretical Issues in Ergonomics Science ISSN**, v.18, p. 35-45. Taylor & Francis, 2017.

HUANG, W., DING, C., WANG, S., HU, S. An Efficient Clustering Mining Algorithm for Indoor Moving Target Trajectory Based on the Improved AGNES. **IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)**, p. 1318-1323, 2015.

IDRISSI, A., REHIOUI, H., LAGHRISSI, A., RETAL, S. An improvement of DENCLUE algorithm for the data clustering. **5th International Conference on Information & Communication Technology and Accessibility (ICTA)**, 2015.

JAIN, N., SRIVASTAVA, V. Data Mining Techniques: A survey paper. **IJRET: International Journal of Research in Engineering and Technology**, v.2, p. 116-119, 2013.

KAUR, J., SINGH, H. Performance Evaluation of a Novel Hybrid Clustering Algorithm using Birch and K-Means. **Annual IEEE India Conference (INDICON)**, 2015.

KOLBERG, D., ZÜHLKE D. Lean Automation enabled by Industry 4.0 Technologies. **IFAC-Papers OnLine**. v.28, p. 1870-1875. Elsevier, 2015.

LATHIYA, P. RANI, R. Improved CURE clustering for big data using Hadoop and Mapreduce. **International Conference on Inventive Computation Technologies (ICICT)**, v.3, 2017.

LEE, J., KAO, H., YANG, S. Service innovation and smart analytics for Industry 4.0 and big data environment. **The 6th CIRP Conference on Industrial Product-Service Systems**, v.16, p.3-8. Elsevier, 2014.

LEUNG, Y., ZHANG., J., XU, Z. Clustering by scale-space filtering. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, p. 1396 – 1410, 2000.

MARZ, N., WARREN, J. Big Data: Principles and best practices of scalable real-time data systems. **Manning Publications**, 2015.

- MUTHUKUMARAN, G., VENKATACHALAPATHY, V.S., PAJANIRADJA, K. Impact on integration of Lean Manufacturing and Six Sigma in various applications - a review. **Journal of Mechanical and Civil Engineering**, v.6, p.98-101, 2013.
- OLIVEIRA, Rubiane Heloisa. **Modelagem de Sistemas MIMO baseada em Conjuntos Aproximados**. 2013. 124 f. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Itajubá, Itajubá, 2013.
- OSUNA, E., FREUND, R., GIROSI. Training Support Vector Machines: an Application to Face Detection. **IEEE Computer Society Conference on Computer Vision and Pattern Recognit**, p. 17-19, 1997
- PATIDAR, A., JOSHI, R., MISHRA, S. Implementation of Distributed ROCK algorithm for clustering of large categorical datasets and its performance analysis. **3rd International Conference on Electronics Computer Technology**, p.79-83, 2016.
- PANDEY, Subhash Chandra. Data Mining Techniques for Medical Data: A Review. **Computer Science & Engineering**, p.972-982, 2016.
- PATNAIK, A. K., BHUYAN, P. Divisive Analysis (DIANA) of hierarchical clustering and GPS data for level of service criteria of urban streets. **Alexandria Engineering Journal**, p. 407-418, 2016.
- PELLERIN, R., RIVEST, L., DANJOU, C. Prendre part à la révolution manufacturière ?. **CEFRIO**. Nov, 2016.
- REINER, A. Industrie 4.0 - Advanced Engineering of Smart Products and Smart Production. **Research Gate**. Out 2014.
- ROSA, P.V.T. Oportunidades de inserção profissional na indústria 4.0. in: **Simpósio Internacional Indústria 4.0**, Curitiba/PR. SENAI, 2017.
- SANTOS, Luciano Costa., GOHR, Cláudia Fabiana., SANTOS, Eder Jonis dos. Aplicação do Mapeamento do fluxo de valor para a implantação da produção enxuta na fabricação de fios de cobre. **Revista Gestão Industrial**. v.7, n. 4, p. 118-139, 2011.
- SUMAN., RANI, P. A Survey on STING and CLIQUE Grid Based Clustering Methods. **International Journal of Advanced Research in Computer Science**, v. 8, p. 1510-1512, 2017.
- SCHMITT, M., LOSKYLL, M., ZUEHLKE, D. Development of a Framework for Dynamic Function Deployment and Extension by Using Apps on Intelligent Field Devices. **IFAC World Congress**, v.19,p. 2611- 2616. Aug, 2014.
- SCHWAB, K. The fourth Industrial Revolution. United States. **Crown Publishing Group**, 2016.
- STADNICKA, D., LITWIN, P. Value stream mapping and system dynamics integration for manufacturing line modelling and analysis. **International Journal of Production Economics**. v. 208, p. 400-411, 2019.
- TADEU, Hugo Braga., SANTOS, Eduardo Stock dos. O que seria a Indústria 4.0?. **Fundação Dom Cabral**. Belo Horizonte, 25 jan. 2016.
- TENERA, A., PINTO, L.C. A Lean Six Sigma (LSS) project management improvement model. *Procedia - Social and Behavioral Sciences*. v.119, p.912-920. Elsevier, 2014.

VASCONCELOS, Livia Maria Rocha de., CARVALHO, Cedric Luiz de. Aplicação de Regras de Associação para Mineração de Dados na Web. **Instituto de Informática**, Universidade Federal de Goiás, 2004.


WITTEN, H.I., FRANK, E., MARK. A.H., Data Mining: Practical Machine Learning Tools and Techniques. Burlington, Estados Unidos: **Elsevier**, 2005.

XHAFA, F., BOGZA, A., CABALLE, S., BAROLLI, L. Fuzzy k-Means Performance Evaluation. **International Conference on Intelligent Networking and Collaborative Systems**, p. 110-116, 2016.

ZHANG, Harry. The Optimality of Naive Bayes. **American Association for Artificial Intelligence**. Copyright, Canada, 2004.


8 APÊNDICES

I - Representação gráfica da simulação




Fonte: Autora (2017)

II- Representação de frequência dos tempos de ciclos (histogramas e dados básicos de estatística)






Fonte: Autora (2017)



Fonte: Autora (2017)

Rapport récapitulatif pour Temps de cycle Réparation (s)



Test de normalité d'Anderson-Darling

A au carré 1,16
Valeur de P < 0,005

Moyenne 40,286
EcTyp 17,130
Variance 293,451
Asymétrie -0,967935
Aplatissement -0,492388
N 14

Minimum 8,000
1er quartile 26,750
Médiane 50,000
3e quartile 53,250
Maximum 55,000


Intervalle de confiance = 95 % pour la moyenne
30,395 50,177

Intervalle de confiance = 95 % pour la médiane
26,949 53,051


Intervalle de confiance = 95 % pour l'écart type
12,419 27,598

Fonte: Autora (2017)


III- Representação cronológica de dados




Fonte: Autora (2017)



Fonte: Autora (2017)




Fonte: Autora (2017)




Fonte: Autora (2017)

IV- Representação cronológica do lead time total do processo




Fonte: Autora (2017)




Fonte: Autora (2017)

V- Box Plot (média, mediana, valores médios e junções de médias)




Fonte: Autora (2017)

VI- Representação do diagrama de pontos dos tempos de ciclo



Fonte: Autora (2017)


VII- Representação de Intervalos de Confiança em ciclos médios



Fonte: Autora (2017)


VIII- Estatísticas inferenciais (comparações de médias e variâncias)

Os testes foram realizados sem os valores extremos detectados anteriormente.




Fonte: Autora (2017)

IX-ANOVA com assistência automática



Fonte: Autora (2017)




Fonte: Autora (2017)

ANOVA à un facteur contrôlé de Temps de c_1; Tps de cyc_1; Temps de c_2;... Rapport		
Vérifier	Statut	Description
Données aberrantes		Certains points de données sont aberrants par rapport aux autres points du même échantillon. Les données aberrantes pouvant fortement influencer sur les résultats, essayez d'identifier leur cause. Ces points apparaissent en rouge sur le rapport de diagnostic. Pour identifier la ligne de la feuille de travail, placez votre curseur sur un point ou utilisez la fonction de balayage de Minitab. Corrigez les erreurs de mesure ou d'entrée des données. Supprimez les données associées aux causes spéciales et réexécutez l'analyse.
Effectif d'échantillon		L'échantillon est suffisant pour détecter des différences entre les moyennes.
Normalité		Certains effectifs d'échantillons sont inférieurs à 15, ce qui peut poser un problème de normalité. Si les données ne sont pas distribuées normalement, la valeur de p peut s'avérer inexacte avec de petits échantillons. De plus, les données aberrantes peuvent fortement influencer sur les résultats du test. La normalité ne pouvant pas être vérifiée de façon fiable sur les petits échantillons, interprétez les résultats du test avec la plus grande vigilance.
Variance égale		L'Assistant de Minitab utilise la méthode de Welch, qui ne suppose pas, ni ne requiert l'égalité des variances des échantillons. La recherche indique que le test est réalisé correctement avec des variances inégales, même lorsque les effectifs d'échantillons ne sont pas égaux.

Fonte: Autora (2017)

X- Teste de comparação de variâncias entre os tempos de ciclo



Fonte: Autora (2017)

XI- Teste da igualdade das variâncias

Méthode

Hypothèse nulle Toutes les variances sont égales
Hypothèse alternative Au moins une variance est différente
Seuil de signification $\alpha = 0,05$

Intervalles de confiance de Bonferroni à 95 % pour les écarts types

Echantillon	N	EcTyp	IC
Temps de cycle Prépa (s)	30	19,2850	(12,0268; 33,8281)
Tps de cycle TARAUDAGE (s)	29	5,6221	(3,2555; 10,6556)
Temps de cycle Contrôle (s)	29	3,8369	(2,6702; 6,0508)
Temps de cycle Montage 2 (s)	20	9,4059	(6,4102; 15,8420)
Temps de cycle Réparation (s)	14	17,1304	(9,4756; 37,9518)

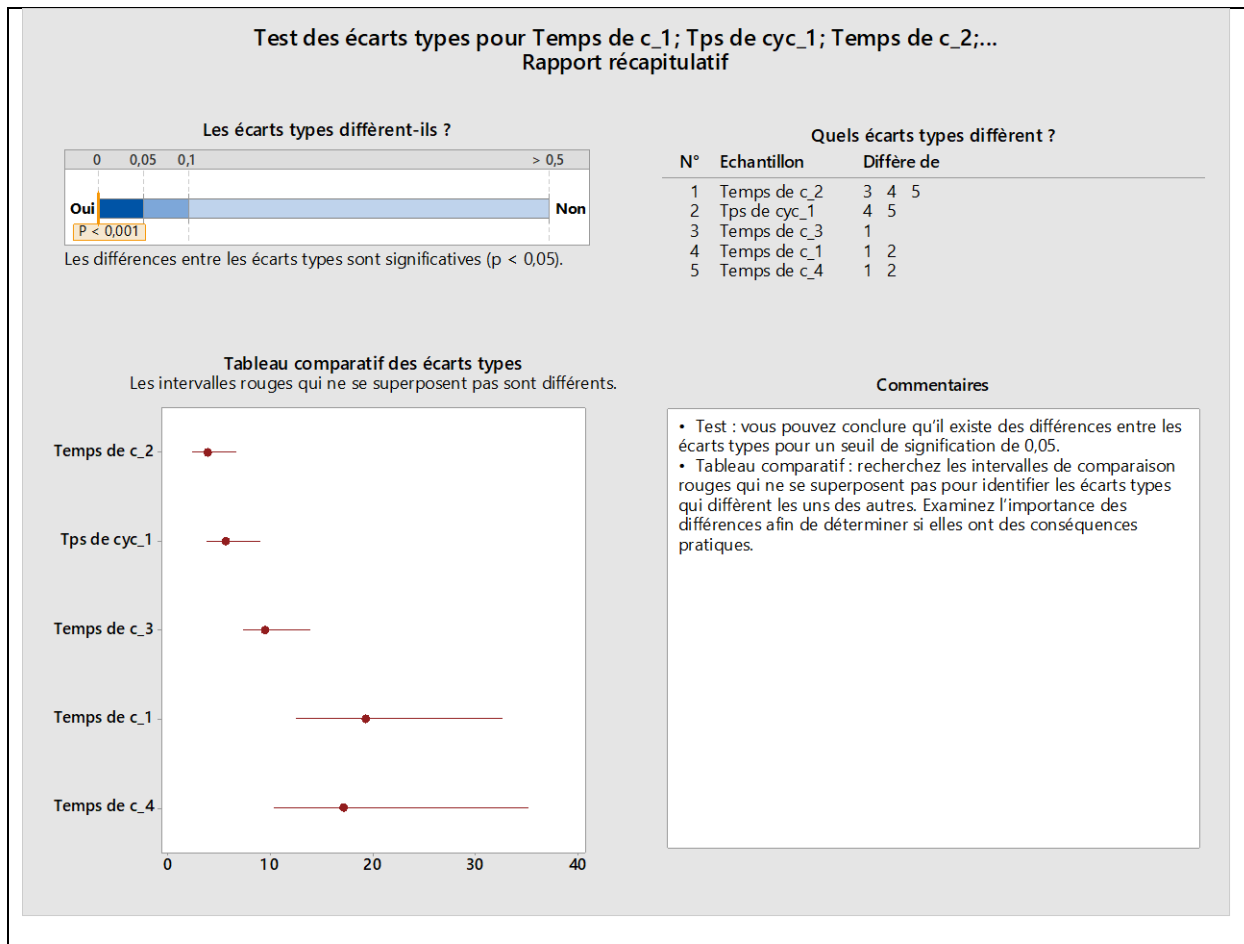
Niveau de confiance individuel = 99 %

Tests

Méthode	Statistique du test	Valeur de P
Comparaisons multiples	—	0,000
Levene	6,05	0,000

Fonte: Autora (2017)

XII-Teste de comparação de desvios padrão




Fonte: Autora (2017)

Test des écarts types pour Temps de c_1; Tps de cyc_1; Temps de c_2;...
Rapport des statistiques descriptives

Echantillon	Effectif d'échantillon	Statistiques		
		Moyenne	EcTyp	IC individuel à 95 % pour EcTyp
Temps de c_1	30	50,133	19,285	(13,576; 29,310)
Tps de cyc_1	29	38,414	5,6221	(3,7466; 9,0480)
Temps de c_2	29	18,310	3,8369	(2,9315; 5,3859)
Temps de c_3	20	53,05	9,4059	(7,1024; 13,810)
Temps de c_4	14	40,286	17,130	(11,194; 30,483)

Fonte: Autora (2017)

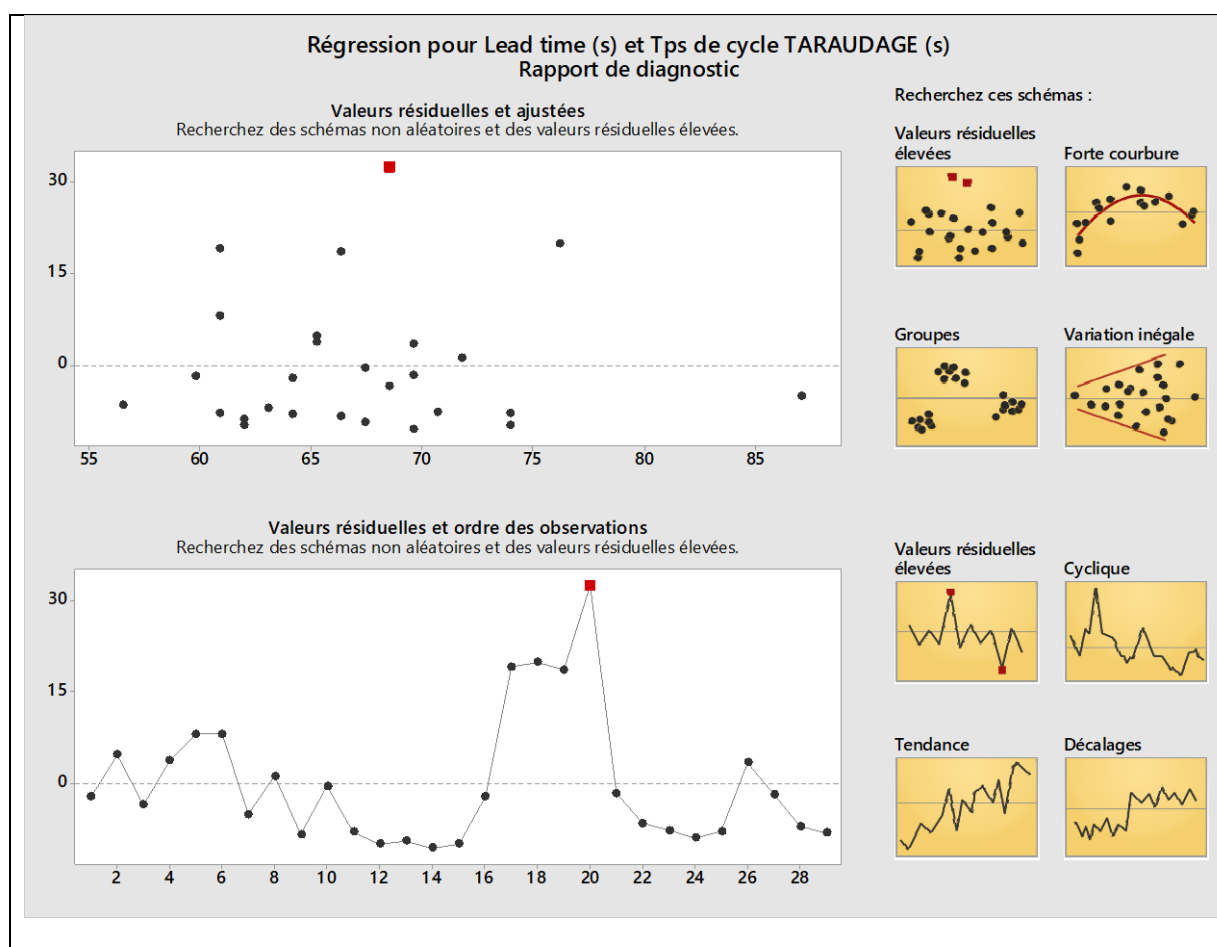


Fonte: Autora (2017)


Test des écarts types pour Temps de c_1; Tps de cyc_1; Temps de c_2;...		
Rapport		
Vérifier	Statut	Description
Données aberrantes		Certains points de données sont aberrants par rapport aux autres points du même échantillon . Les données aberrantes pouvant fortement influencer sur les résultats, essayez d'identifier leur cause. Ces points apparaissent en rouge sur le rapport de diagnostic. Pour identifier la ligne de la feuille de travail, placez votre curseur sur un point ou utilisez la fonction de balayage de Minitab. Corrigez les erreurs de mesure ou d'entrée des données. Supprimez les données associées aux causes spéciales et réexécutez l'analyse.
Normalité		Cette analyse utilise le test de Bonett. Si les échantillons sont suffisamment grands, le test est réalisé correctement pour les données normales comme pour les données non normales.
Validité du test		L'effectif d'échantillon de Temps de c_4 étant inférieur à 20, la valeur de p risque d'être inexacte. Augmentez l'effectif d'échantillon pour qu'il soit au moins égal à 20.

Fonte: Autora (2017)

XIII- Regressão



Fonte: Autora (2017)






Fonte: Autora (2017)

Régression pour Lead time (s) et Tps de cycle TARAUDAGE (s)		
Rapport		
Vérifier	Statut	Description
Quantité de données		Votre effectif d'échantillon (n = 29) n'est pas assez grand pour vous permettre d'obtenir une estimation très précise de l'importance de la relation. Les mesures de l'importance de la relation, telles que le R carré et le R carré ajusté, peuvent varier énormément. Pour obtenir une estimation plus précise, utilisez des échantillons plus grands (en général 40 ou plus).
Données aberrantes		- Valeurs résiduelles élevées : un point de données présente une valeur résiduelle élevée et n'est pas correctement ajusté par l'équation. Ce point apparaît en rouge sur les diagrammes et se trouve à la ligne 20 de la feuille de travail. - Valeurs de X aberrantes : un point des données présente une valeur de X aberrante, ce qui peut entraîner le rapprochement de la ligne d'ajustement vers le point aberrant et son éloignement par rapport aux autres points. Ce point apparaît en rouge sur le rapport de sélection du modèle et se trouve à la ligne 7 de la feuille de travail. Pour identifier les lignes de la feuille de travail, placez votre curseur sur un point ou utilisez la fonction de balayage de Minitab. Les données aberrantes pouvant fortement influencer sur les résultats, essayez d'identifier la cause des aberrations. Corrigez les erreurs de mesure ou d'entrée des données. Supprimez les données associées aux causes spéciales et réexécutez l'analyse.
Normalité		Comme vous disposez d'au moins 15 points de données, la normalité n'est pas un problème. Si le nombre de points de données est faible et que les valeurs résiduelles ne sont pas distribuées normalement, la valeur de p utilisée pour déterminer l'existence d'une relation importante entre X et Y risque d'être inexacte.
Ajustement du modèle		Vous devez évaluer l'ajustement du modèle et des données en fonction de vos objectifs. Vérifiez les éléments suivants sur la ligne d'ajustement : - L'échantillon couvre l'étendue des valeurs de X de façon appropriée. - Le modèle s'ajuste bien à n'importe quelle courbure des données (évitez de sur-ajuster les données). - La ligne s'ajuste parfaitement dans les zones concernées.


Fonte: Autora (2017)

XIV- Carta de controle aos valores individuais






Fonte: Autora (2017)




Fonte: Autora (2017)




Fonte: Autora (2017)


XV- Carta de controle com as médias (com n=3)




Fonte: Autora (2017)




Fonte: Autora (2017)




Fonte: Autora (2017)



Fonte: Autora (2017)




Fonte: Autora (2017)




Fonte: Autora (2017)


XVI- Testes de normalidade dos dados:




Fonte: Autora (2017)




Fonte: Autora (2017)




Fonte: Autora (2017)



Fonte: Autora (2017)




Fonte: Autora (2017)




Fonte: Autora (2017)


XVII- Teste de conformidade




Fonte: Autora (2017)




Fonte: Autora (2017)




Fonte: Autora (2017)



Fonte: Autora (2017)





Fonte: Autora (2017)




Fonte: Autora (2017)

Rapport récapitulatif pour Temps de déplacement_1



Intervalles de confiance = 95 %



Test de normalité d'Anderson-Darling

A au carré 14,83
Valeur de P < 0,005

Moyenne 3,7034
EcTyp 3,6941
Variance 13,6463
Asymétrie 3,4226
Aplatissement 13,1368
N 118


Minimum 1,0000
1er quartile 2,0000
Médiane 3,0000
3e quartile 4,0000
Maximum 23,0000

Intervalle de confiance = 95 % pour la moyenne
3,0299 4,3769


Intervalle de confiance = 95 % pour la médiane
2,0000 3,0000

Intervalle de confiance = 95 % pour l'écart type
3,2753 4,2366

Fonte: Autora (2017)





Fonte: Autora (2017)



Fonte: Autora (2017)

Rapport récapitulatif pour Temps de déplacement_1

Trajet = ClientAd.Vends



Test de normalité d'Anderson-Darling

A au carré 3,01
Valeur de P < 0,005

Moyenne 1,8824
EcTyp 0,7288
Variance 0,5312
Asymétrie 0,685455
Aplatissement 0,882840
N 34


Minimum 1,0000
1er quartile 1,0000
Médiane 2,0000
3e quartile 2,0000
Maximum 4,0000

Intervalle de confiance = 95 % pour la moyenne
1,6281 2,1367

Intervalle de confiance = 95 % pour la médiane
2,0000 2,0000

Intervalle de confiance = 95 % pour l'écart type
0,5879 0,9593


Intervalle de confiance = 95 %



Fonte: Autora (2017)

Rapport récapitulatif pour Temps de déplacement_1

Trajet = Mont2Ad.Vends



Test de normalité d'Anderson-Darling

A au carré 5,47
Valeur de P < 0,005

Moyenne 5,5263
EcTyp 4,6426
Variance 21,5533
Asymétrie 2,70546
Aplatissement 7,11407
N 38


Minimum 2,0000
1er quartile 3,0000
Médiane 4,0000
3e quartile 6,0000
Maximum 23,0000

Intervalle de confiance = 95 % pour la moyenne
4,0003 7,0523

Intervalle de confiance = 95 % pour la médiane
4,0000 4,4205


Intervalle de confiance = 95 % pour l'écart type
3,7849 6,0063

Intervalles de confiance = 95 %



Fonte: Autora (2017)

Rapport récapitulatif pour Temps de déplacement_1 Trajet = ReparationClient



Test de normalité d'Anderson-Darling

A au carré 0,51
Valeur de P 0,076


Moyenne 4,2500
EcTyp 4,5735
Variance 20,9167
Asymétrie 1,81107
Aplatissement 3,38033
N 4

Minimum 1,0000
1er quartile 1,2500
Médiane 2,5000
3e quartile 9,0000
Maximum 11,0000

Intervalle de confiance = 95 % pour la moyenne
-3,0274 11,5274


Intervalle de confiance = 95 % pour la médiane
1,0000 11,0000

Intervalle de confiance = 95 % pour l'écart type
2,5908 17,0524



Fonte: Autora (2017)

Graphique des intervalles de Temps de déplacement_1 et Trajet IC à 95% pour la moyenne



L'écart type regroupé a été utilisé pour calculer les intervalles.

Fonte: Autora (2017)