

ANÁLISE DA TOMADA DE DECISÃO PELO ENGENHEIRO DE PRODUÇÃO NA INDÚSTRIA 4.0: UM ESTUDO DE CASO DE UMA EMPRESA DO SETOR SIDERÚRGICO

DECISION MAKING ANALYSIS BY THE PRODUCTION ENGINEER IN INDUSTRY 4.0: A CASE STUDY OF A STEEL COMPANY

Juan David Pinto¹
Sânzio Wakheiná da Rocha Rodrigues²
Vitor Gabriel Campolina de Oliveira³
Maria Aparecida Fernandes de Almeida⁴

RESUMO

Desde a primeira revolução industrial, as indústrias têm passado por transformações em seus processos, objetivando a eficiência e eficácia em suas atividades. Atualmente, já se vive as mudanças causadas pela quarta revolução industrial, também conhecida como indústria 4.0. A era da internet industrial trabalha com máquinas inteligentes, comunicação direta entre sistemas e assertividade humana na tomada de decisão, através da análise robusta de dados. Este trabalho objetiva mostrar como o engenheiro de produção pode se valer dos benefícios propiciados pela indústria 4.0 na hora da tomada de decisão, com a interpretação de grandes bancos de dados, *big data*, e assertividade na identificação de causas raiz para problemas industriais. Para isso, ferramentas computacionais e sensoriais são empregadas e permitem diminuir o tempo de percepção, análise, decisão e implantação. Além da revisão bibliográfica dos conceitos da quarta revolução industrial esse trabalho também apresenta o estudo de caso de um problema real no setor siderúrgico que foi sanado utilizando uma ferramenta de análise automática de dados, unindo os conceitos de *machine learning*, estatística e ferramentas da qualidade.

Palavras-chave: Indústria 4.0. Quarta revolução industrial. Bancos de dados. Otimização. Tomada de decisão.

ABSTRACT

Since the First Industrial Revolution, industries have passed for process transformation, aiming at efficacy and efficiency in your activities. In addition, it is already being experienced the changes caused by the Fourth Industrial Revolution, also known as Industry 4.0. The era of the industrial internet works with intelligent machines, direct communication between systems and human assertiveness in decision making, through robust data analysis. This work aims to show how the Production Engineer can benefit from the benefits provided by Industry 4.0 at the time of decision making, with the interpretation of large databases (Big Data) and assertiveness in identifying root causes for industrial problems. For this, the computational and sensorial tools are used and allow to decrease the time of perception, analysis, decision and implantation. In addition to the literature review of the concepts of the Fourth Industrial Revolution, this paper

¹ Graduando em Engenharia de Produção, PUC Minas Unidade Barreiro. E-mail: juandavidpinto@gmail.com

² Graduando em Engenharia de Produção, PUC Minas Unidade Barreiro. E-mail: sanziorocha.nunes@hotmail.com

³ Graduando em Engenharia de Produção, PUC Minas Unidade Barreiro. E-mail: vitorgco97@gmail.com

⁴ Professora Doutora do curso Engenharia de Produção, PUC Minas. E-mail: mafernandesalmeida@gmail.com

presents a case study of a real problem in the steel sector that was healed using an automatic data analysis tool, joining the concepts of Machine Learning, Statistics and Quality Tools.

Keywords: Industry 4.0. Fourth Industrial Revolution. Databases. Optimization. Decision Making.

1 INTRODUÇÃO

Com o mercado cada vez mais competitivo as empresas são obrigadas a desenvolverem seus processos internos, almejando satisfazer às necessidades de seus clientes, garantir a qualidade de seus produtos e reduzir os custos de produção.

Para isso, nos tempos contemporâneos, são requisitadas a rápida coleta, filtragem e análise dos dados, para que problemas sejam solucionados de forma ágil e com a tomada de decisão assertiva. A indústria 4.0 vem para ajudar as empresas a se manterem competitivas e atender o cliente da forma que ele espera.

Segundo Dias (2011), atualmente é possível perceber um grande aumento no volume de dados existentes, provocando uma assimetria em relação a capacidade analítica humana. A quantidade de dados a serem analisados pelos usuários tornou-se esmagadora. Assim, torna-se necessária uma forma de gerenciá-los e simplificá-los, priorizando o mais importante e disponibilizando-o de forma direta e assertiva para o envolvido.

Para Santos et al.(2018), de modo a alcançar processos eficazes é fundamental uma estruturação nas empresas. Esta deve permitir a interligação e disponibilidade das informações (ao nível de produção) continuamente atualizadas em tempo real; sendo capaz de propiciar tomadas de decisões frente às rápidas alterações do mercado.

A indústria 4.0 desenvolve diversos sistemas com intuito de oferecer uma coleta de dados personalizada e estratégica, baseada em históricos e tendências. Dentre eles, destacam-se a internet das coisas (IoT), sensoramento do processo, serviços em nuvem, *big data* e análises estatísticas inteligentes, que passam a ser cada vez mais adotadas nos processos industriais (Frank, 2018).

Segundo McAfee et al.(2012), o crescimento e adoção de *big data* permite que os níveis gerenciais das organizações sejam capazes de medir os parâmetros chave do processo e aprofundar radicalmente os conhecimentos dentro do próprio negócio; e junto à experiência, tomar decisões e melhorar a performance dos processos.

Além disso, tornou-se possível a realização de simulações para analisar determinados comportamentos e tendências. Na indústria 4.0, sistemas virtuais são comumente utilizados como forma de criar um ambiente virtual semelhante ao real, contando com conexões entre *softwares*, sensores, produtos e monitores. Para isso, tornou-se imprescindível uma comunicação entre todos os componentes da coleta de dados, pessoas envolvidas e sistemas centralizadores dos dados em tempo real durante todo o processo produtivo (Sackey; Bester, 2016).

De acordo com Yuan et al.(2015), por meio da comunicação entre todas essas partes e todos os dispositivos, têm-se a capacidade de tomada de decisão rápida e respostas em tempo real, como: previsão de quebras, ajustes autônomos realizados pela própria máquina e automação para garantir a eficácia dos parâmetros.

O objetivo geral do trabalho é realizar um estudo de caso tratando um defeito de não qualidade dentro de uma siderúrgica, utilizando de ferramentas estatísticas de análise e de tecnologias provenientes da Indústria 4.0 para identificar sua causa raiz.

Como objetivos específicos, destaca-se:

1. Realizar uma pesquisa bibliográfica dos conceitos da indústria 4.0;
2. Comparar a performance no processo decisório e na tomada de ações entre o engenheiro de produção e a máquina que utiliza das tecnologias da indústria 4.0;

3. Identificar oportunidades de melhoria e de adoção de novas tecnologias da indústria 4.0 para futuras expansões da empresa;

2 REFERENCIAL TEÓRICO

O referencial teórico consiste num resumo de discussões já publicadas por outros autores; possibilitando a fundamentação e consistência a todo o estudo sobre o tema a ser discutido.

2.1 Indústria 4.0


2.1.1 Conceito geral

Segundo KAGERMANN (2013), a primeira revolução industrial iniciou-se com a revolução mecânica, no final do século XVIII, quando foram introduzidas máquinas de manufatura que disponibilizaram um novo conceito de produção, o qual permitia agilidade os processos fabris de bens e auxiliava o homem em serviços repetitivos. Por volta da virada do século XX, as máquinas foram aprimoradas com a segunda revolução, na qual se tornou possível a produção em massa de bens com ajuda da expansão da eletricidade e com base na divisão do trabalho.

A evolução continuou, fomentada pelo aumento da produtividade e redução de custos. No início dos anos 1970 houve o surgimento da terceira revolução industrial, que permanece até os dias de hoje. Essa nova era permitiu o aumento na automação dos processos de manufatura, possibilitando não apenas máquinas que substituem o homem em trabalhos manuais como também em atividades intelectuais, tendo como base a eletrônica e a tecnologia da informação (TI).

E por fim, denominada em 2011 pelo governo alemão como “indústria 4.0”, a quarta revolução industrial utiliza robustos conceitos de tecnologia da comunicação, autoanálise e recursos de informação, com o objetivo de evoluir o processo de manufatura e negócio.

Figura 1 – Os quatro estágios da revolução industrial



Fonte: KAGERMANN; WAHLSTER; HELBIG (2013) - ADAPTADA.

Segundo Silveira (2017), o termo indústria 4.0 foi utilizado pela primeira vez na Alemanha, em 2011, onde através do projeto denominado "*High-tech strategy 2020 for Germany*", o governo alemão traçou estratégias voltadas para a tecnologia e avanço do país.

A esse respeito, para Roblek et al.(2016), a indústria 4.0 é baseada em conceitos e tecnologias que incluem: sistemas *cyber-físicos*, a internet das coisas (IoT), a internet dos

serviços e a fábrica inteligente. Esta indústria é fomentada pela constante comunicação via internet que permite uma interação e troca de informações não apenas entre humanos como entre humanos e máquina e até mesmo entre diferentes máquinas.

As transformações provenientes da indústria 4.0 são capazes de promover o desenvolvimento dos processos industriais, afetando diretamente a flexibilidade, velocidade, produtividade e qualidade dentro da organização (Tessarini, 2018). Sendo assim, na indústria 4.0, a utilização da internet das coisas e da internet dos serviços muda a forma com a qual as companhias enxergam a agregação de valor dentro dos processos (Roblek et al., 2016).

2.1.2 Smart factory (SF) – Fábrica inteligente

A *smart factory* (SF) desenvolve produtos e serviços inteligentes, com máquinas inteligentes, em cadeias de abastecimento inteligentes, para consumidores cada vez mais exigentes (HUBA et al, 2016).

A partir disso, as fábricas modificadas por esses pensamentos tornaram-se inteligentes: o CPS monitora processos físicos, cria cópias virtuais do mundo físico, toma decisões descentralizadas, se comunica com a internet das coisas (IoT) e ambos cooperam entre si e com os humanos em tempo real, contribuindo para o aprimoramento da cadeia de valor empresarial (HERMANN, PENTEK e OTTO, 2015).

2.1.3 Big data

De acordo com Rocha (2015), informação é algum fato ou acontecimento do mundo real que pode ou não ser registrado ou armazenado. Já o dado é a representação da informação e pode ser armazenado na forma de dispositivos de armazenamento, quadros, cadernos, *softwares*, etc.

Um banco de dados consiste em um conjunto de dados integrados que proporcionam uma trabalhabilidade para um grupo de pessoas, atendendo suas necessidades (HEUSER, 2010). Atualmente os bancos de dados tornaram-se essenciais e indispensáveis dentro das organizações, oferecendo tanto segurança nos dados, quanto facilidade e agilidade nos processos de busca pelos dados necessários (ROCHA, 2015).

Considerando o crescimento na quantidade de dados disponíveis, existe uma boa razão para acreditar que a análise inteligente dos dados vai se tornar um ingrediente essencial para o desenvolvimento tecnológico (SMOLA, 2008).

O *big data* está diretamente ligado à coleta e análise de um grande volume de dados. De acordo com Dumbill (2012), *big data* é o dado que excede a capacidade de processamento dos sistemas convencionais de gestão de dados. Os dados são muito grandes, movem-se rapidamente ou não cabe nas estruturas de dados. Para tirar proveito destes dados, escolhe-se um modo alternativo de processá-lo.

A coleta de dados gerados por máquinas com capacidade de registro em tempo real é feita por *softwares*, que armazenam esses dados em *big data* onde a capacidade analítica do engenheiro de produção se fará necessária. Segundo TOTVS (2018), a capacidade do engenheiro tomar uma decisão mais assertiva com a utilização de sistema como *big data* se torna mais precisa; uma vez que temos uma grande quantidade de dados sendo gerada no ambiente industrial que possibilitará visibilidade aos processos industriais de tal maneira que gestores ou sistemas computacionais serão capazes de tomar decisões mais assertivas.

De acordo com McAfee e Brynjolfsson (2012) o *big data* auxilia no tratamento e trabalho com quatrilhões de bytes, que atualmente são gerados nas empresas em um único conjunto de dados.

O *big data* possibilita não apenas uma solução para o volume de dados gerados, como também o aumento na velocidade e na variedade desses dados. Segundo McAfee (2012), essa velocidade de tratamento de dados fornece uma vantagem competitiva óbvia: informações em tempo real permitem agilidade na identificação de falhas no processo produtivo e, em alguns casos, até a prevenção da ocorrência de tais falhas; corrigindo então os parâmetros necessários.

2.1.4 IoT (*internet of things*) – Internet das coisas

Este processo de análise de dados não se encontra centralizado apenas nas pessoas, mas também nas máquinas, principalmente com o advento dos conceitos da internet das coisas (IoT). Para Fachini et al. (2017), a IoT simboliza a integração de todas as coisas, adicionando tecnologia aos objetos e impactando em ações de nosso cotidiano, bem como na realidade industrial; como, por exemplo, o emprego de sensores que monitoram a saúde da máquina e avaliam os pontos necessários de revisão, disparando sinais para que estes sejam feitos por algum responsável ou mesmo por outro maquinário.

Para Zambarda (2014), a IoT consiste em uma revolução tecnológica capaz de integrar e conectar os itens utilizados no dia-a-dia à rede mundial de computadores. Sendo que a tendência é a união gradual entre o mundo físico e o mundo digital tornem-se um só, através da comunicação entre os diferentes dispositivos, conectados através de alguma rede em comum.

2.1.5 IoS (*internet of services*) – Internet dos serviços

Para Terzidis et. al. (2012), o principal foco da IoS é oferecer sistemicamente novas soluções capazes de agregar valor ao produto e ao serviço oferecido. Neste contexto, as informações tornam-se essenciais como forma de *feedback* e direcionadora de ações.

Segundo Freund et. al. (2016), a IoS não se resume apenas a monitorar objetos, pois iria bem além disso. Os *softwares* podem ser utilizados para extrair dados críticos e realizar análises de otimização e redução de custos, revelando padrões que acarretam vantagens para uma organização, como: mais rentabilidade, produtividade e satisfação dos clientes.

A IoS consiste no atrelamento de serviços à IoT, ou seja, sua utilização dentro de um sistema integrado, onde o produto passa a tomar forma de serviços e agregar mais valor ao cliente final (MENA, 2018).

2.1.6 Machine Learning – Aprendizado de máquinas

Outro conceito muito utilizado no contexto da indústria 4.0 e na aceleração do processo de coleta e análise de dados é o *machine learning*. Para Gibson e Patterson (2017), o ML consiste na utilização de algoritmos para extrair dados brutos e descarregá-los em um modelo capaz de cruzar outros dados registrados e definir saídas e análises próprias.

Para Hurwitz (2018), o ML permite que um dado sistema consiga se desenvolver e aprender continuamente a partir dos dados registrados, sendo possível inclusive registrar novos dados em seu banco, prever possibilidades e tendências.

ML consiste em uma forma de IA capaz de aprender e interpretar novas informações a partir de seu próprio banco de dados; não sendo necessário recorrer a programação externa ou por terceiros. Sendo assim, algoritmos são responsáveis por analisar os dados existentes, identificar pontos de melhorias e prever saídas do sistema, resultando assim em modelos cada vez mais precisos (HURWITZ, 2018). O grande sucesso do ML encontra-se na eficácia das análises realizadas para resolução de problemas, capazes de superar até mesmo o desempenho de grandes analistas (SILVA, 2016).

2.1.7 Sistemas cyber-físicos (CPS)

Na indústria 4.0, os CPS são construídos a partir da interação entre *softwares*, sensores, máquinas, peças em desenvolvimento e monitores para acompanhamento das características do processo. Criando assim, uma cópia virtual do mundo real capaz de descentralizar a tomada de decisões (SACKEY, 2016).

A principal característica observada dentro dos CPS é a integração entre o meio e as variáveis físicas e empíricas com o ambiente computacional, através do emprego de sensores e atuadores (Silva, 2018).

2.2 Tomada de decisão

O processo de tomada de decisões é algo constante e fundamental dentro das organizações, podendo estas variarem entre questões triviais ou mais complexas. É importante ressaltar que estas são feitas através de pessoas. Portanto, diversos fatores afetam as decisões tomadas: desde percepções, crenças e valores até o ambiente local e estado contextual do responsável por sua execução (BERTONCINI, 2016).

Segundo Lousada (2011), percebe-se atualmente uma forte tendência à construção de modelos e formas de facilitação dentro do processo de tomada de decisão, uma vez que estes permitem aos gestores uma melhor análise quanto a estrutura organizacional e aos fatores ali presentes, provendo assim saídas mais eficientes.

A aplicação da indústria 4.0 surge como uma alternativa a descentralização das tomadas de decisões, sendo capaz de dar maior autonomia aos demais envolvidos do processo partindo de uma facilitação e simplificação dos dados trabalhados. Sendo assim, pode-se dizer que no contexto da indústria 4.0 observa-se um impacto direto dentro das práticas de gerenciamento e uma aceleração no fluxo decisório (SILVA, 2018).

2.3 Metodologia DMAIC

Segundo Cleto (2011), um conjunto de pessoas trabalhando em prol da resolução de um determinado problema tende a se complementar ao nível de conhecimento e levantar informações valiosas para alcançar a eficácia. Entretanto, para isso é essencial a utilização de uma metodologia orientadora. Neste contexto, a metodologia DMAIC consiste num sequenciamento de etapas dividido em definir, medir, analisar, implementar e verificar.

Para Souza et. al. (2007), a primeira etapa é a “*D - define*” (definir), em que o objetivo é abranger os parâmetros e desempenhos do processo e entender o foco da atuação. A segunda etapa, “*M - measure*” (medir), determina o foco do problema, avaliando sua localização, intensidade, cenários e afins. A etapa 3 de análise, “*A - analyse*”, é a responsável por identificar e analisar os impactos das causas sobre um determinado problema, avaliando suas correlações e seus graus de variabilidade. Segundo Donin (2018), a fase 4 de implementar ou melhorar, “*I - improve*”, é aquela que permite a alteração do processo, eliminando perdas, desperdícios e a recorrência do problema. Esta última fase de verificação, “*check*” é aquela que garante a continuidade daquela melhoria realizada, garantindo que aqueles novos padrões sejam transferidos ao proprietário, certificando seus treinamentos e assegurando a eficácia e eficiência do processo.

3 METODOLOGIA

Esta seção demonstra os métodos utilizados para desenvolvimento do trabalho. Tal pesquisa baseou-se em uma estratégia quantitativa de pesquisa, de caráter exploratório, por meio de um estudo de caso.

Utilizou-se a aplicação *web process analytics* como ferramenta de análise dos dados e o método DMAIC como metodologia de gestão das etapas de condução do estudo, visando garantir uma governança estruturada.

Inicialmente na fase *define*, o problema a ser investigado foi definido considerando a importância no mesmo contexto em que a empresa está inserida. Para realizar a escolha do objeto de estudo utilizou-se o método do diagrama de pareto como ferramenta objetiva de classificação dos defeitos para evidenciar os principais problemas provenientes do processo de aciaria, porém que geram impactos diretos no seu cliente, o processo de laminação. Após o levantamento do histórico de defeitos, sua classificação decrescente e *brainstorming* com os engenheiros de qualidade da aciaria foi identificado como a melhor oportunidade de estudo a redução do índice de sucata por delaminação no laminador.

Na fase *measure* foram levantadas as condições iniciais, evidenciando como o problema está na situação atual, qual a extensão do mesmo, quais os indicadores são utilizados para controlá-lo e quais os desvios já mapeados. Ainda dentro da fase de medição, é preciso estimar uma meta que guie todo estudo. A meta se baseou no índice de tubos sucateados por delaminação entre janeiro de 2018 e junho de 2019.

Com a definição do objeto de estudo, contextualização do mesmo e verificação das condições iniciais, se deu início a fase *analyze*. Dentro desta etapa foi realizada a coleta dos dados, cujo processo foi feito de forma automática através de sensores industriais e armazenados em um sistema *cloud*. Para tratar os dados a aplicação *web* utilizada *process analytics* buscou o banco de dados relacional anteriormente gerado através do registro automático de dados em um *data lake*.

Os pesquisadores então definiram na aplicação quais as restrições seriam analisadas, sendo elas: data, pedido, aço, diâmetro, parede, ordem, corrida e o tipo de defeito. Com tais restrições definidas a ferramenta tratou os dados de forma estatística. Com o foco do trabalho a estatística descritiva se mostrou mais adequada à análise, gerando informações como: medidas de tendência central, de variabilidade ou dispersão.

As medidas de tendência central são: média, mediana e moda; Já as medidas de variabilidade incluem: desvio padrão, variância, valor máximo e mínimo. Com os gráficos estatísticos gerados foi possível dar continuidade a fase de análise, onde a ferramenta buscou identificar a causa raiz do defeito, correlacionando os dados de processos analisados com os resultados de qualidade do conjunto de tubos inspecionados. Ainda na etapa de análise, foi possível realizar uma comparação de desempenho entre o método tradicional de análise de processos, que contempla a utilização de *softwares* convencionais de análises estatísticas e montagem manual de bancos de dados versus os novos métodos de análises de dados como o *process analytics*, este que já se comunica diretamente a uma base de dados com um *big data* onde dados de processo de diversos bancos diferentes são armazenados no sistema *cloud*, permitindo acesso direto da aplicação a toda a base, otimizando o tempo de levantamento e correlação de dados.

Esse estudo se limitou as etapas de definição, medição e análise, como foco principal da tomada de decisão. As etapas de melhoria – *improve* e controle e padronização – *control* não fazem parte do escopo do estudo.

4 DESENVOLVIMENTO

A empresa objeto do estudo desenvolvido está passando por um processo de transformação cultural, buscando maior engajamento e disciplina operacional de seus funcionários. Atrelado a isso, a redução de custos entra como um dos principais pilares para garantir a sobrevivência da empresa no mercado nacional e internacional.

Tendo um objetivo desafiador de reduzir seus custos internos para garantir a capacidade competitiva da empresa e simplificar sua gestão, a empresa depende dos esforços de cada um

para contribuir para esta estratégia. A aciaria, área produtiva onde o estudo foi desenvolvido é considerado uma das áreas chave para a organização, sendo necessária a dedicação do time para resolução imediata de seus problemas. A figura 2 mostra a sequência de processos existentes na aciaria.

Figura 2: Processos aciaria




Fonte: Elaborado pelos autores

Problemas de não qualidade representam um custo elevado para as empresas do setor siderúrgico. A empresa em estudo tinha como desafio reduzir seu custo com os problemas de não qualidade em 30%. Em virtude dessa meta, diversas frentes de resolução mais otimizada de problemas foram sendo desenvolvidas, uma delas foi o desenvolvimento de um *software* para análises de parâmetros de processos, estes que por consequência podem causar defeitos em seu produto.

O objetivo do *software* é evidenciar causas não comuns e reduzir o tempo de identificação das causas dos problemas. O *software* foi utilizado para identificar a causa da não-qualidade delaminação, este defeito é gerado no processo de aciaria, mas sua identificação é dada no processo de laminação, a figura 3 mostra as etapas de tal processo.

Figura 3: Processos de laminação




Fonte: Elaborado pelos autores

O estudo foi desenvolvido utilizando a metodologia DMAIC como ferramenta de condução sistêmica de suas etapas. Nesta seção é abordado cada uma dessas etapas e seus resultados.

4.1 Define

O primeiro passo realizado foi a definição clara do objeto de estudo através da classificação decrescente dos principais problemas de não qualidade que são identificados no processo de laminação. A figura 4 mostra o resultado dessa classificação com o quadro geral de todos os defeitos identificados na laminação.


Figura 4: Tubos sucateados no laminador jan/2018 e jun/2019 por não qualidade



Fonte: Elaborado pelos autores

Contudo, buscando atuar em um problema gerado pelo processo fornecedor (no caso, a aciaria) a classificação por pareto foi realizada novamente visando identificar quais os principais problemas que a aciaria causa em seu cliente. Assim, na figura 5 evidencia-se que o defeito delaminação é o segundo maior problema no quadro atual de não qualidade propiciado pelo processo de aciaria. Sendo assim, considera-se fundamental atuar neste problema.

Figura 5: Tubos sucateados no laminador entre jan/18 e jun/19 por não qualidade geradas na aciaria



Fonte: Elaborado pelos autores

Para validar a importância do projeto na fase de definição do problema, deve-se estimar o ganho financeiro que este trará caso atingido a meta planejada. O *business case* é a tarefa compreendida dentro da etapa de definição do problema que visa quantificar e monetizar o impacto do estudo, atrelando sua importância financeira. Desta forma foi desenvolvido o *business case*.

A figura 6 mostra que, durante o ano de 2018, a empresa onde o estudo foi desenvolvido teve um dispêndio financeiro de R\$401.164,00 devido ao sucateamento de tubos de aço por delaminação, o que corresponde a um índice de 0,11%. A meta do estudo foi reduzir em 30% o índice de sucata por delaminação no laminador, o que corresponde a uma meta de aproximadamente 0,08%, gerando um ganho anualizado estimado de R\$120.349,00.

Figura 6: Business case para validação do ganho esperado com o projeto

Valores							
Gerência	Descrição do Motivo	Qtd (Ton)	Custo Var S/ Cr Suc	Créd Var ref à Sucat	Custo Var S/ Cr Suc		R\$/ton
2 SUPER. LAMINAÇÃO	DEL Delaminação	333	605.823	365.474	240.349		721
3 SUPER. TRATAMENTO	DEL Delaminação	67	158.385	79.477	78.908		1.173
5 SUPER. FLEX LINE	DEL Delaminação	50	129.763	47.856	81.907		1.632
Total Geral		451	893.971	492.807	401.164		890

Baseline	0,11% %
Meta	0,08% %
Redução	30% %
Redução	135 ton

Redução	120.349 R\$
----------------	--------------------

Fonte: Elaborado pelos autores

Como o defeito estudado pode ser gerado por processos diferentes de fabricação, se fez necessário mapear o fluxo de suprimento entre processos fornecedores e processos clientes, com o objetivo de delimitar os limites de atuação. A figura 7 fornece este mapeamento através da SIPOC, sigla que significa *supplier, input, process, output* e *costumer*. A figura ainda demonstra os limites do processo, isto é, onde o defeito tem sua origem e onde tem sua identificação realizada.

Figura 7: SIPOC (Fornecedor – Entrada – Processo – Resultado – Consumidor)


FORNECEDOR	ENTRADA	PROCESSO	RESULTADO	CLIENTE	
Matéria-prima	Ferro-gusa (sólido / líquido) e sucata	FEA (forno a arco elétrico) - fusão de carga sólida e redução de carbono e fósforo	Aço líquido	Forno Panela	Processo siderúrgico
Forno a Arco Elétrico	Aço líquido	Forno Panela - Ajuste a composição química e a temperatura do aço	Aço líquido	Desgaseificação a vácuo	
Forno Penela	Aço líquido	Desgaseificação a vácuo	Aço líquido desgaseificado	Lingotamento Contínuo	
Desgaseificação a vácuo	Aço líquido desgaseificado	Lingotamento Contínuo	Barras fundidas	Linha de acabamento de barra	
Linha de acabamento	Barras fundidas	Barras de corte	Blocos	RHF	Processo de laminação
Barras de corte	Blocos	RHF - aquecimento de blocos	Bloco Aquecido	CTP e PQF	
RHF	Bloco Aquecido	CTP e PQF - Rolling (transformação mecânica das inclusões)	Tubos	Inspeção MPB	
CTP e PQF	Tubos	Inspeção MPB - inspeção de defeitos no tubo	Tubos inspecionados	Inspeção visual	

Limite de processos: START - Forno a arco elétrico	Limite do processo: END - Inspeção MPB
--	--

Fonte: Elaborado pelos autores


O projeto se torna importante, pois o índice de sucateamento de tubos por delaminação aumentou no início de 2019 conforme apresentado no indicador na figura 8, ele demonstra os resultados consolidados das três áreas onde o defeito é identificado, MPB, equipamento presente no laminador que identifica a delaminação através do ROWA, Q&T e Flex, área de tratamento térmico que tem como equipamento identificador do defeito o ultrassom.

Conforme a figura 8, o índice de sucata por delaminação aumentou após uma mudança na tolerância de *headscrap*, que consiste no sucateamento da primeira parte das barras lingotadas, com o objetivo de eliminar impurezas que se concentram no início de lingotamento. Como essa alteração foi realizada buscando reduzir o custo com sucata dentro da aciaria, se fez necessário analisar os parâmetros de fabricação do aço e por consequência buscar as causas do aumento do índice de delaminação.

Figura 8: Índice de sucata por delaminação

Fonte: Elaborado pelos autores

A fim de validar a meta que inicialmente foi estimada para o projeto, na fase de definição foi utilizada a técnica do primeiro quartil, comprovando estatisticamente que a meta prevista tem chances reais de ser alcançada conforme a figura 9.


Figura 9: Definição da meta – Minitab

Fonte: Elaborado pelos autores

4.2 Measure

A segunda etapa do estudo se deu pelos resultados das condições iniciais e medição do processo no estado atual. A figura 10 exemplifica visualmente o defeito delaminação que foi abordado anteriormente. Este defeito é muito comum no processo siderúrgico e consiste em uma inclusão de alguma substância externa na mistura metálica fundida, a qual não se homogeneiza com o restante do material. Sendo assim, quando o processo de solidificação é concluído observam-se algumas heterogeneidades pela peça. A partir disso, essas funcionam como acumuladoras de tensão, podendo provocar trincas, rupturas e outros defeitos que impactam diretamente a utilização do produto final.


Figura 10: Delaminação através de microscopia eletrônica



Fonte: Elaborado pelos autores

A delaminação é identificada em equipamentos presentes nos processos de laminação e têmpera. A fim de validar a capacidade de repetibilidade e reprodutibilidade (R&R) de tais equipamentos foi aplicado um teste estatístico para tal. O teste foi realizado utilizando 5 tubos nos quais previamente era sabido a presença de delaminação e dois operadores responsáveis pela calibração do equipamento. A figura 11 mostra os resultados do teste R&R (repetibilidade e reprodutibilidade) desenvolvido nos equipamentos MPB – laminador e ultrassom – têmpera. Os testes garantiram a capacidade dos equipamentos de identificar 100% dos tubos que apresentem delaminação e também de identificação do defeito em um mesmo tubo, independentemente da quantidade de vezes que aquele tubo for inspecionado.


Figura 11: Teste R&R MPB e ultrassom – Minitab



Fonte: Elaborado pelos autores

Ainda dentro das condições iniciais, foi realizada uma estratificação física da localização do defeito. Seu objetivo era evidenciar, caso verdadeiro, se os defeitos são concentrados em certa parte da corrida ou se eram distribuído proporcionalmente por todas as barras lingotadas. A figura 12 mostra que a estratificação foi válida, deixando claro que o defeito se concentra na primeira corrida da sequência. Dentro dessa corrida foi realizada uma nova classificação por pareto, mostrando que a barra 2, ou seja, a primeira barra logo após o *headscrap*, é responsável por aproximadamente 36,5% da incidência de delaminação. Reduzindo ainda mais a localização física do defeito nota-se que dentro da barra 2, seu primeiro bloco é o grande concentrador de delaminação. Dessa forma, fica claramente comprovado que a causa do defeito investigado é proveniente de parâmetros que se relacionam com o início de lingotamento.

Figura 12: Estratificação de pareto por corrida na sequencial, barras na primeira corrida e bloco na segunda barra




Fonte: Elaborado pelos autores

4.3 Analyse

O processo de análise é a etapa mais complexa em um estudo de investigação, uma vez que a ocorrência do defeito é sabida, ainda que sua causa não. Para iniciar esse processo de investigação foi realizado o mapeamento do processo no qual o produto é submetido, a fim de garantir que todas as possíveis variáveis atreladas a cada processo seriam investigadas. É possível notar na figura 13 esse mapeamento, mostrando o fluxo de valor dentro da aciaria, separando as etapas dentro de três processos. Processo forno a arco elétrico, processo de desgaseificação a vácuo e processo de lingotamento contínuo, sendo estes os processos onde variáveis foram investigadas para identificação da causa.

Figura 13: Mapa do processo




Fonte: Elaborado pelos autores

Delimitou-se o escopo de processos e após mapeamento de suas etapas foi realizado um *brainstorming*. Tal procedimento consiste no levantamento de todas as possíveis causas que

inicialmente são previstas apenas pelo sentimento metalúrgico dos especialistas no processo. Durante uma reunião foram levantadas 14 possíveis causas que seriam então validadas estatisticamente para garantir a identificação da causa raiz. A figura 14 apresenta o resultado deste levantamento, classificando todas as possíveis causas por processo de onde ela é proveniente.


Figura 14: Levantamento de causas através de *brainstorming*



Fonte: Elaborado pelos autores


Após o levantamento destas variáveis é o momento da utilização do *software process analytics*. Conhecendo a localização física do defeito, são aplicados filtros de seleção na tela principal do programa. Os filtros contemplam o período a ser analisado, tipo de projeto, diâmetro da barra, aço, diâmetro do tubo, parede do tubo, código da corrida lingotada e da ordem laminada, conforme figura 15.

Figura 15: Tela inicial *process analytics*



Fonte: Elaborado pelos autores

Os dados são carregados e a ferramenta se encarrega de correlaciona-los, apontando através de uma matriz de importância a quão aquela variável justifica a incidência do defeito, conforme a figura 16.

Figura 16: Matriz de importância

Fonte: Elaborado pelos autores

Partindo da base de importância exibida pelo *software* os dados são validados estatisticamente para verificar se realmente existe uma correlação matemática entre a causa e o efeito, no caso, delaminação. A figura 17 fornece tais análises, evidenciando com base no primeiro resultado apontado pela matriz de importância que o tempo de aquecimento do distribuidor tem influência sobre a ocorrência do problema. O “valor P” é o número que através do cálculo estatístico de comparação de medianas valida a diferença entre materiais ruins (com defeito) e materiais bons.

Figura 17: Teste de mood para tempo de aquecimento do distribuidor


Estatísticas								
Status	n	Desvio Padrão	Máximo	Média	Mínimo	1° Q	Mediana	3° Q
Bom	529	32.12	296	226.26	174	204	219	254
Ruim	569	40.98	335	210.14	171	190	196	218

Teste de hipótese entre tubos defeituosos e aprovados

Resultado do teste de Mood:
P-value 0

Fonte: Elaborado pelos autores


O gráfico de *boxplot* reúne uma gama de informações como localização, dispersão, assimetria, comprimento da cauda e *outliers*. A figura 18 apresenta o *boxplot* para o tempo de aquecimento do distribuidor de forma visual, demonstra a clara diferença entre o resultado de qualidade de tubos que foram tiveram seu aço produzido com um tempo de aquecimento do distribuidor maior em detrimento dos que tiveram o tempo menor.

Figura 18: Boxplot para tempo de aquecimento do distribuidor

Fonte: Elaborado pelos autores

A partir da identificação da possível causa do problema, é possível aferir algumas suposições de interações entre variáveis com o conhecimento metalúrgico dos especialistas no processo; uma vez que a ferramenta já apontou o caminho crítico a ser analisado. Logo, atrelado ao tempo de aquecimento do distribuidor foi suposto que o tempo de aquecimento da válvula submersa também influenciaria no problema. Construiu-se então um gráfico de dispersão considerando que ambas as variáveis influenciaram nos resultados de qualidade dos tubos. O gráfico da figura 19 mostra que nas corridas produzidas com um tempo de aquecimento do distribuidor menor que 220 minutos e um tempo de aquecimento da válvula submersa menor que 150 minutos houve a ocorrência de tubos com delaminação.

Figura 19: Gráfico de dispersão tempo de aquecimento do distribuidor x tempo de aquecimento da válvula submersa.



Fonte: Elaborado pelos autores

Com a utilização da ferramenta de análise automática de dados e predição de defeitos fica evidente a otimização temporal da fase de análise. Um projeto padrão, que busca investigar a causa para um problema nessas mesmas circunstâncias teria uma duração média de sua fase de análise de dois meses. Com o *software* a etapa de análise para as primeiras duas variáveis identificadas teve a duração de 2,5 dias, uma otimização em tempo de aproximadamente 57 dias.

Tornando assim a tomada de decisão por parte do time de engenharia mais rápida e assertiva. Todas as análises foram realizadas fundamentadas em bases estatísticas, retirando a subjetividade da identificação de causas.

Este estudo se limitou a mostrar as fases que precedem a etapa de análise e os ganhos que um *software* detentor de uma série de conceitos que a indústria 4.0 apresentou para auxiliar a tomada de decisão do departamento de engenharia.

5 CONCLUSÃO

A quarta revolução industrial apresenta como uma das principais bases a tratativa e a importância dada à informação e aos dados. A análise e interpretação dos dados permitem a tomada de decisão, definição de ações a serem executadas e direcionam melhorias dentro dos processos.

Dentro da indústria siderúrgica analisada, o processo de tomada de decisão era centralizado no setor de engenharia. Os dados e parâmetros de produção eram coletados a partir do PLC (*programmable logic controller* – controlador lógico programável) da máquina, mas a análise dos mesmos era complexa e restrita a poucos capazes de realizá-la. Considerando esse

cenário, a indústria 4.0 surge como maneira de revolucionar tais atividades e facilitar a análise dos dados pelo departamento de engenharia. Dentre suas ferramentas, destacam-se: *big data*, armazenamento em nuvem e *machine learning*.

Atendendo a um dos objetivos específicos, foi realizado uma pesquisa bibliográfica nos principais conceitos da indústria 4.0. Dessa forma, foi possível compreender as ferramentas adotadas pela empresa no estudo de caso, tais como *big data*, nuvem, armazenamento em nuvem e *machine learning*. Também foi possível avaliar outras ferramentas que podem ser aplicadas em paralelo, de forma a melhorar ainda mais esse processo de tomada de decisões.

A partir dos conceitos da 4.0 e da análise dos impactos quanto à tomada de decisão pelo departamento de engenharia, é possível comparar a performance do mesmo com o sistema integrado, no que tange ao processo de análise e tomada de decisão no processo. Para tal, foram considerados dois postos-chaves: tempo de análise e confiabilidade.

No estudo de caso proposto, devido a complexidade do processo, estima-se que 1 ano permite uma assertividade de mais de 90% e 3 anos para mais de 99%. Por consequência, é essencial manter a mão de obra qualificada durante esse período. Como oportunidades de melhoria e adoção de novas tecnologias observa-se que a IoT, a IoS e a implantação de sistemas *cyber-físicos* permitem uma maior integração entre os diferentes dispositivos e um menor tempo de resposta na tomada de ações no processo.

Considerando o contexto atual, a partir do modelo ideal de parâmetros fornecido pela máquina, deve haver a intervenção humana para realizar as modificações e correções no processo, resultando em um elevado tempo para execução de mudanças e maior risco de erros no *input* dos novos parâmetros. Entretanto, tal procedimento pode ser feito originalmente pelo próprio sistema, através da comunicação entre os dispositivos e aprofundamento dos pilares da 4.0.

A partir da percepção do problema e da correção necessária, a própria máquina sinaliza o ponto do processo que precisa ter algum parâmetro alterado. O sistema, de maneira autônoma, realiza a modificação; não sendo requisitada a intervenção humana, permitindo a comunicação em tempo real e eliminando o erro humano na nova parametrização. Dessa forma, é possível entender como a indústria 4.0 contribui para o aumento da flexibilidade e da interoperabilidade das máquinas.

A utilização das ferramentas da indústria 4.0 proporciona uma simplificação do processo decisório, sendo descentralizado do departamento de engenharia. Neste contexto, a própria máquina passa a se controlar e a tomar decisões a partir das variações do processo e das sinalizações fornecidas pelo sistema inteligente.

REFERÊNCIAS

BERTONCINI, Cristine; BRITO, Adriana; LEME, Elisangela; SILVA, Ismael; SILVA, Thiago Ferreira da; PERRI, Ricardo Alves. **Processo Decisório: Tomada De Decisão**. Disponível em: <http://faef.revista.inf.br/imagens_arquivos/arquivos_destaque/QjxD DqGcS5r3dHL_2013-5-3-12-8-34.pdf>. Acesso em: 07 mai. 2019.

CLETO, Marcelo; QUINTEIRO, Leandro. GESTÃO DE PROJETOS ATRAVÉS DO DMAIC: UM ESTUDO DE CASO NA INDÚSTRIA AUTOMOTIVA. **Revista Produção Online**, Paraná, v. 11, n. 1, p. 210 – 239, 2011. Disponível em: <<https://www.producaoonline.org.br/rpo/article/view/640>>. Acesso em: 16 abr. 2019.

DIAS, Pedro Ricardo. **Recommending media content based on machine learning methods**. 2011. 111 f. Dissertação (Mestrado em Engenharia Informática) – Fundação de Ciências e Tecnologia, Universidade Nova de Lisboa, Lisboa, 2011.

DONIN, Marcelo. **Proposta De Melhoria Baseada Na Metodologia Dmaic Em Uma Unidade De Pronto Atendimento De Saúde**. 2018. 73 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Produção) – Departamento de engenharia de produção, Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2018.

DUMBILL, Edd et all. **Big Data Now Current Perspectives**. Disponível em: <http://cdn.oreillystatic.com/oreilly/radarreport/0636920028307/Big_Data_Now_2012_Edition.pdf> Acesso em: 30 abr. 2019

FACHINI, Moisés; MESQUITA, Nathalia; OLIVEIRA, Rafael; FRANÇA, Patrícia. **Internet das coisas: uma breve revisão bibliográfica**. Conexões, ciências e tecnologias, Fortaleza, v. 11, n. 6, p. 85 – 90, dez. 2017. Disponível em: <<http://www.conexoes.ifce.edu.br/index.php/conexoes/article/viewFile/1007/1096>>. Acesso em: 05 mai. 2019.

FRANK, Alejandro; DALENOGARE, Lucas; BENITEZ, Guilherme; AYALA, Néstor. The expected contribution of Industry 4.0 technologies for industrial performance. **Internacional Jornal of Production Economics**, Grenoble, n. 204, p. 383 – 394, 2018. Disponível em: <<https://www.elsevier.com/locate/ijpe>>. Acesso em: 28 abr. 2019.

FREUND, Fabiana; STEENBOCK, Fernando; MARANGONI, Guirahy; VIEIRA, José; DE DEUS, Sérgio; ANGONESE, Angela. Novos negócios baseados em internet das coisas. **Revista FAE**, v. 1, p. 7 – 25, 2016. Disponível em: <<https://revistafae.fae.edu/revistafae/article/viewFile/402/286>>. Acesso em: 20 mai. 2019.

HERMANN, Mario; PENTEK, Tobias; OTTO, Boris. **Design Principles for Industrie 4.0 Scenarios: A literature review**. Technische universitat Dortmund, Dortmund, 2015. Disponível em: <https://www.thiagobranquinho.com/wp-content/uploads/2016/11/Design-Principles-for-Industrie-4_0-Scenarios.pdf>. Acesso em: 13 abr. 2019.

HEUSER, Carlos. **Projeto de Banco de dados**. 4. ed. Sagra Luzzatto, 1998. 206 p.

HUBA, M.; KOZAK, S. From **E-learning to Industry 4:0**. 2016 International Conference on Emerging eLearning Technologies and Applications (ICETA), 2016.

HURWITZ, Judith; KRISCH, Daniel. **Machine Learning for dummies**. IBM Limited Edition, n. 1, 2018. 75 p.

KAGERMANN, H.; WAHLSTER, W.; HELBIG, J. **Recommendations for implementing the strategic INDUSTRIE 4.0**. April, p. 4-7, 2013.

LOUSADA, Mariana; VALENTIM, Marta. Modelos de tomada de decisão e sua relação com a informação orgânica . **Perspectiva em Ciências da Informação**, v. 16, n. 1, p. 147 – 164, 2011. Disponível em: <<http://www.scielo.br/pdf/pci/v16n1/a09v16n1.pdf>>. Acesso em: 18 mai. 2019.

MCAFEE, Andrew; BRYNJOLFSSON, Erik. **Big Data: the management revolution**. Harvard Business Review, Denver, out. 2012. Disponível em: <<https://hbr.org/2012/10/big-data-the-management-revolution>>. Acesso em: 11 abr. 2019.

MENA, Isabela. **Verbete Draft: o que é Internet dos Serviços**. 2018. Disponível em: <<https://projetodraft.com/verbete-draft-o-que-e-internet-dos-servicos/>>. Acesso em: 11 mai. 2019.

PATTERSON, Josh; GIBSON, Adam. **Deep Learning: a practitioner's approach**. Editora O'Reilly, n. 1, 2017. 532 p.

ROBLEK, Vasja; MESKO, Maja; KRAPEZ, Alojz. **A Complex view of industry 4.0**. Sage Open, Estados Unidos, abr. 2016. Disponível em: <<https://journals.sagepub.com/doi/full/10.1177/2158244016653987>>. Acesso em: 21 abr. 2019.

ROCHA, Julio; DIAS, Jaime. **Importância dos bancos de dados nas aplicações**. 2015. – Universidade Paranaense (UNIPAR), p. 1-5, Paraná, 2015.

SACKEY, S.M.; BESTER, A. **Industrial engineering curriculum in industry 4.0 in a south african context**. 2016. 111 f. Dissertação (Mestrado em Engenharia Informática) – Fundação de Ciências e Tecnologia, Universidade Nova de Lisboa, Lisboa, 2016.

SANTOS, Beatrice P.; ALBERTO, A.; LIMA, T.D.F.; CHARRUA-SANTOS, F.M.B. Indústria 4.0: Desafios e Oportunidades. **Revista Produção e Desenvolvimento**, Covilhã, v. 4, n. 1, p. 111 – 124, jan. 2018. Disponível em: <<http://revistas.cefetrj.br/index.php/producaoedesenvolvimento>>. Acesso em: 10 abr. 2019.

SILVA, Denise Aliny. **Indústria 4.0 Com Foco Nos Sistemas Cyber Físicos**. 2018. 45 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Eletrônica) – Coordenação de Engenharia Eletrônica, Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2018.

SILVA, Luís. **Utilização da deep learning em ações de controle**. Revista do TCU, Brasília, v. 48, n. 135, p. 18 – 23, jan/abr. 2016. Disponível em: <<https://revista.tcu.gov.br/ojs/index.php/RTCU/article/view/1321>>. Acesso em: 03 mai. 2019.

SILVEIRA, C. B. **O que é a Indústria 4.0 e como ela vai impactar o mundo**. Citisystems. 2017. Disponível em: <<https://www.citisystems.com.br/industria-4-0/>>. Acesso em: 10 jun. 2018.

SMOLA, Alex. **Introduccion to Machine Learning**. Cambridge University Press, Cambridge, 2008. Disponível em: <<http://alex.smola.org/drafts/thebook.pdf>>. Acesso em: 25 abr. 2019.

SOUZA, Ana Paula Felipe; COELHO, Tânia; SANTOS, Rosimeire Expedita. DMAIC: UMA ALTERNATIVA PRA A MELHORIA CONTÍNUA DA QUALIDADE. V EPCC, Maringá, 2007. Disponível em: <http://www.cesumar.br/prppge/pesquisa/epcc2007/anais/ana_paula_felip_de_souza2.pdf>. Acesso em: 11 jun. 2019.

TERZIDIS, Orestis; OBERLE, Daniel; FRIESEN, Andreas; JANIESCH, Christian; BARROS, Alistair. (2012). **The Internet of Services and USDL**. 1-16. 2012

TESSARINI, Geraldo; SALTORATO, Patrícia. Impactos da indústria 4.0 na organização do trabalho: uma revisão sistemática da literatura. **Revista Produção Online**, Florianópolis, v. 18,

n. 2, p. 743 – 769, 2018. Disponível em: <<https://producaoonline.org.br/rpo/article/view/2967>>. Acesso em: 15 abr. 2019.

TOTVS. **Big Data: entenda as principais vantagens de utilizar na sua empresa.** 2018. Disponível em: < <https://www.totvs.com/blog/big-data/>> Acesso em: 14 abr. 2019

YUAN, Xiao; ANUMBA, Chimay; PARFITT, Kevin. **Review of the potential for a cyber-physical system approach to temporary structure monitoring.** International Journal of Architectural Research, Pensilvânia, v. 4, n. 3, p. 26 – 44, nov. 2015. Disponível em: < <http://archnet-ijar.net/index.php/IJAR/article/view/841>>. Acesso em: 12 abr. 2019.

ZAMBARDA, Pedro. **‘Internet das Coisas’: entenda o conceito e o que muda com a tecnologia.** 2014. Disponível em: <<https://www.techtudo.com.br/noticias/noticia/2014/08/internet-das-coisas-entenda-o-conceito-e-o-que-muda-com-tecnologia.html>>. Acesso em: 04 mai. 2019.