

ESTUDO DE CASO DE DESENVOLVIMENTO DE SISTEMA PARA MANUTENÇÃO PREDITIVA 4.0

CASE STUDY OF SYSTEM DEVELOPMENT FOR PREDICTIVE MAINTENANCE 4.0

Eduardo Marcio Zaro* E-mail: eduardozaro@gmail.com

Carine Getrudles Webber* E-mail: cqwebber@ucs.br

*Universidade de Caxias do Sul (UCS), Rio Grande do Sul, RS, Brasil.

Resumo: A quarta revolução industrial apresenta diversas tecnologias para o desenvolvimento da sociedade e especialmente para o ramo de manufatura. Inserido nesse novo mundo, o estudo de caso vem com objetivo de explorar conceitos de manutenção preditiva com análises e prevenção de falhas para equipamentos que operam com vibração. Analisando conceitos de manutenção preditiva 4.0 já implementados no mercado e incorporando novas tecnologias, tende-se a obter resultados de tempo de inatividade através desses conceitos explorados no trabalho. Com a análise dos dados coletados através de ferramentas em nuvem e sensores IoT, conseguimos determinar parâmetros e o comportamento do equipamento. Com essa prevenção dos fatos, foi possível a implantação de alertas em tempo real de qualquer fator que possa vir tornar-se uma falha, dessa forma predizendo uma ação corretiva no equipamento. Trabalhado dessa forma, foi possível obter redução de 24% no tempo de inatividade do equipamento, trazendo ganhos para empresa e redução de custos ao produto final. A manutenção preditiva, juntamente com outras tecnologias da indústria 4.0 tem grande potencial para estudos e melhorias, incorporando cada vez mais aprendizagem de máquina e inteligência artificial, tornando cada vez mais os equipamentos inteligentes e tomadores próprios de suas decisões.

Palavras-chave: Indústria 4.0. Manutenção Preditiva. MindSphere. Vibração. Manufatura.

Abstract: The fourth industrial revolution presents several technologies for the development of society and especially for the manufacturing sector. Inserted in this new world, the case study aims to explore concepts of predictive maintenance with analysis and failure prevention for equipment that operate with vibration. Analyzing predictive maintenance 4.0 concepts already implemented in the market and incorporating new technologies, we tend to obtain downtime results through these concepts explored in the work. By analyzing the data collected through cloud tools and IoT sensors, we were able to determine parameters and the behavior of the equipment. With this prevention of the facts, it was possible to implement real-time alerts of any factor that could become a failure, thus predicting corrective action in the equipment. Working in this way, it was possible to obtain a 24% reduction in equipment downtime, bringing gains to the company and cost reductions for the final product. Predictive maintenance, along with other technologies from industry 4.0, has great potential for studies and improvements, incorporating more and more machine learning and artificial intelligence, making more and more intelligent equipment and decision makers themselves.

Keywords: Industry 4.0. Predictive Maintenance. MindSphere. Vibration. Manufacturing.

1 INTRODUÇÃO

As empresas de manufatura buscam cada dia mais serem efetivas em seus processos a fim de garantir qualidade e menos custo em seus produtos, obtendo maiores lucros. Para contribuir com esse avanço, a revolução tecnológica, conhecida como indústria 4.0, impulsiona estes objetivos, beneficiando a indústria de manufatura (MOYA, 2004). Com a implantação massiva de máquinas e automação de processos, as indústrias se tornam dependentes de recursos tecnológicos que precisam estar disponíveis, operacionais e produtivos. A saúde das máquinas se torna então um fator que deve ser monitorado de forma a prever e prevenir paradas e perdas na produtividade. Tal problema se estende a todas as áreas fabris que empregam máquinas e robôs, sendo portanto amplamente pesquisado.

Neste contexto, esse artigo tem como objetivo apresentar um estudo exploratório desenvolvido no âmbito de manutenção preditiva de uma empresa localizada no Rio Grande do Sul. O estudo irá limitar-se ao caso do equipamento denominado espiraladeira, responsável pela confecção de tranças de fio de nylon. A máquina apresenta em média 35 horas mensais de inatividade causados pela sensibilidade na vibração do equipamento. A escolha de aplicação de conceitos e tecnologias de manutenção preditiva neste caso, é devido às oportunidades possíveis de redução do tempo de inatividade, devido a efeitos de vibração gerados durante o processo.

Devido a complexidade das aplicações industriais, a manutenção preditiva acabou sendo um dos pilares da Indústria 4.0, representando uma tendência mundial em todas as áreas de atuação. Todas as técnicas utilizadas na manutenção preditiva tem como finalidade indicar as reais condições de funcionamento e do desempenho das máquinas, e por meio do acompanhamento de parâmetros, consegue-se identificar o desgaste ou a degradação de componentes. A manutenção preditiva contribui diretamente para a eficiência operacional do chão de fábrica, reduzindo custos, erros e atrasos no fluxo produtivo, tendo um papel determinante na continuidade das operações de manufatura.

O objetivo do estudo exploratório é obter indicações e previsões de futuras falhas que o equipamento poderá apresentar, através da coleta e análise dos dados futuros. Com isso, deseja-se avaliar a possibilidade de prever e reduzir o tempo de

inatividade do equipamento, aumentando os ganhos com paradas inesperadas, conforme indicado por (SUSTO *et al.*, 2015).

2 REFERENCIAL TEÓRICO

Esta seção apresenta o referencial teórico da análise e estudo exploratório sobre o tema tratado.

2.1 Indústria 4.0

O mundo da indústria vem sofrendo diversas mudanças e evoluções. Por meio de revoluções industriais, os processos foram se modernizando e incorporando novas tecnologias ao dia a dia, desde o marco da máquina a vapor. Nos dias atuais a revolução que estamos vivenciando é denominada de Indústria 4.0 (KAGERMANN *et al.*, 2013).

A Indústria 4.0 foi criada em 2011 por uma iniciativa do governo alemão com universidades e empresas privadas. Era um programa estratégico para desenvolver sistemas avançados de produção com o objetivo de aumentar a produtividade e eficiência da indústria nacional (KAGERMANN *et al.*, 2013). Este conceito representa uma nova etapa industrial dos sistemas de manufatura ao integrar um conjunto de tecnologias emergentes e convergentes que agregam valor ao produto ao cliente (FRANK, 2019). A nova revolução industrial exige uma evolução sociotécnica do papel humano nos sistemas de produção, em que todas as atividades humanas de valor serão realizadas com abordagens e fundamentos em tecnologias de informação e comunicação (BASCO, 2018).

A Indústria 4.0 é um conceito que representa a automação industrial e a integração de diferentes tecnologias como inteligência artificial, robótica, internet das coisas e computação em nuvem. Entre os objetivos visados está a digitalização das atividades industriais, melhorando os processos e aumentando a produtividade (PEREIRA, 2018).

Outro importante objetivo desta recente revolução é automatizar o processo de manufatura, incluindo aquisição e armazenamento de dados, visando o aumento global da eficiência. Toda ferramenta, máquina, sensor, peça ou computador adquire a capacidade de trocar dados entre si. Com os dados coletados, o processo e seus

derivados, os sistemas podem tomar decisões em tempo real, tornando um mundo físico e virtual único (WOLLSCHLAEGER *et al.*, 2014).

Sensores embarcados permitem a conectividade de produtos em uma rede com outros objetos e sistemas de manufatura. Os sensores e dispositivos eletrônicos podem fornecer capacidade de monitoramento em estruturas físicas, permitindo que os clientes/usuários conheçam a melhor condição dos equipamentos e os parâmetros de uso. Maquinários, com software integrado conectado a serviços em nuvem, podem ser controlados por meio de interfaces remotas digitais (PEREIRA, 2018).

A figura 1 apresenta os pilares da indústria 4.0 a fim de mostrar os principais pontos que essa nova revolução apresenta para a indústria de manufatura. Neste contexto destaca-se os seguintes pilares: realidade aumentada, big data, robôs autônomos, simulações, manufatura aditiva, computação em nuvem, Internet das Coisas e a Segurança da Informação (LEE *et al.*, 2014).

Figura 1 – Pilares da indústria 4.0



Fonte: Adaptado de SSMAQ, 2018.

Com o avanço da tecnologia e computação em nuvem, surge a estrutura de Sistemas Ciber-Físicos (CPS). Com ela, a indústria futura será capaz de alcançar um sistema de informação de toda a cadeia da manufatura que ajudará aos equipamentos serem autoconscientes e identificar a si próprios possíveis problemas (LEE, 2014). Um sistema autoconsciente é aquele capaz de reconhecer seu estado interno, estabelecer objetivos e metas e auto-avaliar-se. Um dos benefícios diretos desta capacidade está associado à percepção do seu desempenho, saúde e nível de degradação. Tais autoavaliações são importantes, e até mesmo fundamentais, para

que um sistema exiba inteligência em nível local. Em nível ciber, dados são integrados, analisados e produzem resultados úteis para uso posterior em decisões de manutenções inteligentes futuras e para evitar problemas no processo (SEZER *et al.*, 2018).

Para um sistema mecânico, autoconsciência significa ser capaz de avaliar a condição atual ou passada de um equipamento e reagir para produzir o resultado da avaliação desejada. Essa avaliação de saúde da máquina pode ser realizada usando um algoritmo baseado em dados/informações coletadas da máquina em questão e seu meio ambiente inserido. A condição do equipamento em tempo real pode ser realimentada para o controlador da máquina para controle adaptativo e gerentes de máquina para manutenção em tempo real (LEE *et al.*, 2014).

2.2 Sistema de Manutenção Preditiva

Esta seção apresenta os conceitos de manutenção em equipamentos de manufatura, compreendendo os conceitos de manutenção preventiva e preditiva. Os nomes são parecidos, mas o objetivo de cada uma delas é distinto.

2.2.1 Manutenção Preventiva

A manutenção preventiva é a atuação realizada de forma a reduzir ou evitar a falha ou diminuição do desempenho, obedecendo a um plano preventivamente elaborado, baseado em intervalos de tempos definidos. Como o próprio nome sugere, procura prevenir a fim de evitar a ocorrência de falhas de um determinado equipamento (SEZER, *et al.*, 2018). A vantagem do uso da manutenção preventiva no lugar da manutenção corretiva (falha já ocorreu), é diminuir as interrupções inesperadas de produção. Ou seja, se considerarmos o custo total, em várias situações a manutenção preventiva acaba sendo mais barata que a manutenção corretiva, pelo fato de se ter domínio das paradas dos equipamentos, ao invés de se ficar sujeito às paradas inesperadas por falhas nos equipamentos. A manutenção preventiva permite um bom gerenciamento das atividades, nivelamento dos recursos, além de previsibilidade do consumo de materiais e sobressalentes com antecedência, conseguindo otimizar custos e menos tempo de inatividade de equipamentos (KARDEC *et al.*, 2009).

2.2.1 Manutenção Preditiva

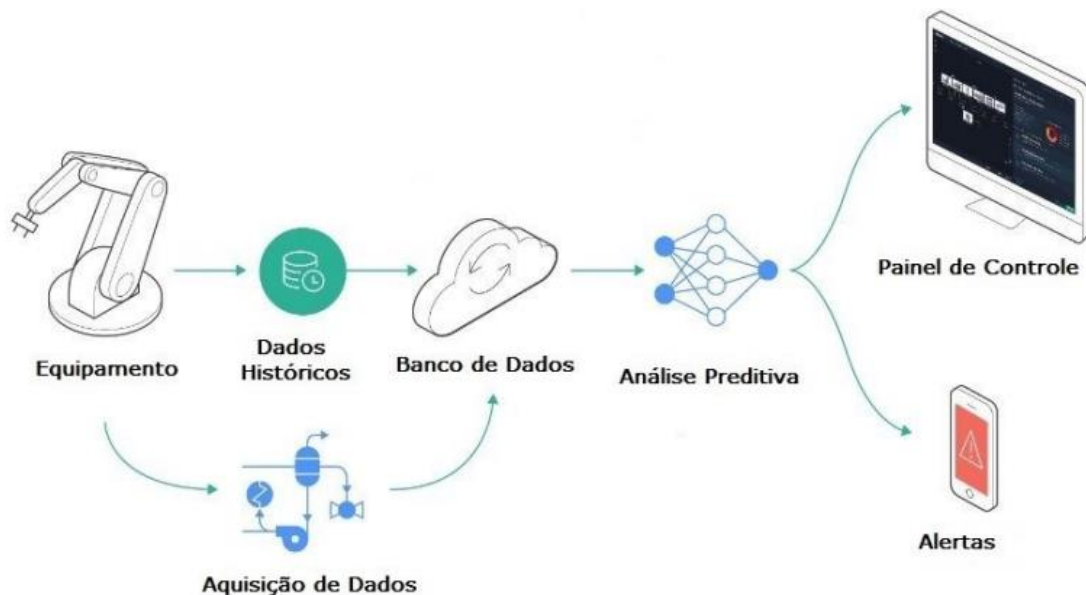
Com a competitividade em alta no cenário atual, as organizações almejam reduzir custos nos processos, elevar a disponibilidade de seus ativos e agregar valor ao seu produto. Para suprir essas demandas do cenário atual, as organizações buscam reduzir o tempo de inatividade dos equipamentos, reduzir custos de mão de obra e prolongar a vida útil dos ativos. Para atingir esses objetivos, as organizações avistaram a Indústria 4.0 (MOYA, 2004). Objetivos estes que vão ao encontro dos benefícios entregues pela Manutenção Preditiva ou agora conhecida também como Manutenção Preditiva 4.0. São apresentadas técnicas de Machine Learning utilizadas para a análise preditiva, além dos benefícios gerados e estratégias necessárias para implementação do sistema (SUSTO *et al.*, 2015).

A possibilidade da coleta instantânea de grandes conjuntos de dados de diferentes ativos, além da aplicação da análise de Big Data para fornecer informações preditivas de manutenção (DILMEGANI, 2018). Portanto, não é uma surpresa que a Manutenção Preditiva tenha emergido rapidamente como um dos principais casos de uso da Indústria 4.0. A sua implementação possibilita monitorar a integridade dos ativos, otimizar os cronogramas de manutenção e obter alertas em tempo real dos riscos operacionais, benefícios estes que vão ao encontro das necessidades atuais das organizações (SUSTO *et al.*, 2015).

Existem diversas divisões e classificação de manutenção preditiva, mas trataremos o conceito neste artigo apenas de duas. A Manutenção Preditiva baseada na condição conta com a instalação de sensores que coletam continuamente dados sobre os ativos. Através de regras pré-definidas, o sistema envia alertas quando algum limite estabelecido é atingido (SEEBÓ, 2018). Embora este tipo de manutenção forneça algum nível de manutenção preditiva automatizada, ela ainda depende da compreensão da equipe de manutenção sobre quais variáveis elétricas ou ambientais precisam ser medidas, bem como de sua capacidade de prever o que pode quebrar (SEEBÓ, 2018). A Manutenção Preditiva baseada em *Machine Learning* (em português, aprendizado de máquina) necessita de sensores coletando dados em tempo real. Mas além disso, também faz uso de conjuntos de dados históricos dos ativos monitorados. Estes dados, combinados com algoritmos personalizados de aprendizado de máquina, executam diferentes cenários e podem prever o que vai dar

errado e quando gerar alertas. Por ser este o tipo de manutenção que está impulsionando a Indústria 4.0 (SEEBO, 2018).

Figura 2 – Estrutura da manutenção preditiva 4.0



Fonte: Adaptado de Seebo, 2018.

2.2.2 Manutenção Preditiva na indústria manufatura

Para aplicar a manutenção preditiva a indústria de manufatura se faz também necessário outros conceitos da indústria 4.0 para ser incorporada. A predição trabalha com o conceito de prever o futuro, mas para isso precisamos usar conceitos de Machine Learning, do inglês aprendizagem de máquina, para agregar conhecimento na tomada de decisão do equipamento (SUSTO *et al.*, 2015).

Hoje em dia, as máquinas estão cada vez mais autônomas. Desse modo, através de algoritmos e softwares específicos, já é possível fazer com que o equipamento não só analise os dados coletados, mas também aja de forma autônoma, realizando ações pré-programadas capazes de evitar e até mesmo resolver problemas.

Outro ponto fundamental são as etapas de coleta e análise de dados. Elas são as responsáveis por armazenar e relacionar esses dados. Sem dúvida, informações como o histórico de falhas, manutenções, reparos e performance do equipamento,

são valiosíssimas. Na manutenção preditiva esses dados são muito úteis para identificar, por exemplo, a hora certa de substituir algum componente. Da mesma forma, essas informações podem ser utilizadas em conjunto com o *Machine Learning*, para programar determinadas ações do equipamento (AMIR *et al.*, 2015).

A análise de dados tem um potencial quando aproveitado para conduzir a tomada de decisão. Para permitir essa tomada de decisão baseada em fatos, as empresas precisam de processos eficientes para transformar grandes volumes de dados diversos e de rápida movimentação em ações que agregam para a empresa. O gerenciamento de dados envolve processos e tecnologias de suporte para adquirir e armazenar dados e prepará-los e recuperá-los para análise. Análise de dados, por outro lado, baseia-se em técnicas usadas para analisar e adquirir conhecimento, padrões e modelos por meio de grandes volumes de dados (AMIR *et al.*, 2015).

A análise preditiva compreende uma variedade de técnicas que preveem resultados futuros com base em dados históricos e atuais. Na prática, a análise preditiva de dados pode ser aplicada a quase todas as disciplinas - desde prever a falha de motores com o fluxo de dados de milhares de sensores, até prever os próximos movimentos dos clientes com base no que compram, quando compram e até mesmo o que eles dizem nas redes sociais (BAGHERI *et al.*, 2013).

Em sua essência, a análise preditiva busca descobrir padrões e capturar relacionamentos nos dados. As técnicas de análise preditiva são subdivididas em dois grupos. Algumas técnicas, como médias móveis, tentam descobrir os padrões históricos nas variáveis de resultado e extrapolá-los para o futuro. Outros, como a regressão linear, visam capturar as interdependências entre as variáveis de resultado e variáveis explicativas e explorá-las para fazer previsões. Com base na metodologia subjacente, as técnicas também podem ser categorizadas em dois grupos: técnicas de e técnicas de aprendizado de máquina. Outra classificação é baseada no tipo de variáveis de resultado: técnicas como regressão linear abordam variáveis de resultado contínuas, como por exemplo, preço de venda de casas.

As técnicas de análise preditiva são baseadas principalmente em métodos estatísticos. Vários fatores exigem o desenvolvimento de novos métodos estatísticos para *Big Data*. Em primeiro lugar, os métodos estatísticos convencionais estão enraizados na significância estatística: uma pequena amostra é obtida da população e o resultado é comparado com o acaso para examinar a significância de uma relação

particular. A conclusão é então generalizada para toda a população. Em contraste, as amostras de *Big Data* são enormes e representam a maioria, senão toda a população. Como resultado, a noção de significância estatística não é a única medida a ser usada. Em segundo lugar, em termos de eficiência computacional, muitos métodos convencionais para pequenas amostras não se adaptam a grandes volumes de dados (LIU, 2014).

3 ESTUDO DE CASO

Nesta seção é apresentado o estudo de caso em uma empresa no ramo metalúrgico com objetivo de identificar análise de vibração com objetivo de diminuir a inatividade da linha de produção ou equipamento pela falha.

3.1 Apresentação da organização

A aplicação do estudo e análise foi realizada na empresa Tramontina Multi, unidade pertencente ao grupo Tramontina, localizada na cidade de Carlos Barbosa-RS. Empresa com mais de 100 anos de atividades pelo mundo, vem investindo e apoiando o crescimento para a modernização de seus processos, trazendo melhorias e tecnologias aos seus produtos a fim de entregar cada vez mais produtos com qualidade e menor preço.

A Tramontina Multi é uma empresa que possui em seu mix de produtos as seguintes linhas: ferramentas para agricultura, construção civil e jardinagem. Por mais que seu produto seja de baixo valor agregado, a empresa após na evolução de processos produtivos para cada vez mais ser competitivo no mercado que está inserido.

3.2 Problema de manutenção preditiva

O problema em estudo é explorar os conceitos e analisar na prática no ambiente industrial princípios da manutenção preditiva. Conceitos que vem para auxiliar as empresas a evitar paradas inesperadas e prever com antecedência possível a inatividade de um equipamento que poderá trazer enormes prejuízos para a empresa em questão avaliada.

O estudo de caso será aplicado no setor de mangueiras para jardim, localizado na fábrica 8 da empresa Tramontina Multi. A empresa possui diversas linhas de produção do mesmo produto, mas o estudo de caso consiste na aplicação apenas na linha número 6.

O equipamento denominado de espirradeira é capaz de realizar tranças de fio de nylon no produto, que operam em rotações acima de 1500 RPM. Devido ao seu processo de fabricação, o equipamento apresenta desbalanceamento e gera vibrações na máquina. Com a vibração agindo diretamente na máquina, a sensibilidade que qualquer ação é gerada, torna-se fundamental para uma falha futura ser gerada. Com essas dificuldades, se incorporam conceitos de manutenção preditiva, utilizando tecnologias da indústria 4.0 para diminuir o tempo de inatividade e correções de desbalanceamento e taxas de vibração do equipamento.

3.3 Método de pesquisa

3.3.1 Projeto piloto

O projeto piloto consiste em aplicar os conceitos de manutenção preditiva e introduzir esse conceito na empresa em análise. A organização já aplica métodos de manutenção preventiva e a partir desse estudo de caso, busca-se aplicá-lo a produção de mangueiras. O equipamento específico a ser implantado no projeto é a espiraladeira, responsável por fazer a segunda camada da mangueira de jardim, que é composta por fios de nylon.

O objetivo desse projeto piloto é abrir portas para novas demandas necessárias na planta da empresa. A ferramenta adquirida para processamento em nuvem permite obter dados e analisar de uma forma simples e em tempo real. Através desses softwares consegue-se analisar e prever uma ação futura. Tal recurso é uma demanda da indústria 4.0 em favor das empresas para incorporar novas tecnologias e obter lucros.

Neste projeto prevê-se a instalação de dois sensores de vibração com interface IO-Link da IFM, modelo VV, que permite coletar dados importantes como: v-RMS, a-RMS, a-Peak e o valor de crista. Estes sensores serão capazes de coletar dados de vibração do equipamento. O dispositivo é responsável em fazer as tranças das

mangueiras onde trabalham em uma rotação de 1600 rpm. A figura 3 apresenta o equipamento em operação de trabalho.

Figura 3 - Espiraladeira em estudo de caso de manutenção preditiva



Fonte: Elaborado pelo autor.

Uma das razões para o presente estudo está na complexidade da linha de fabricação das mangueiras, pois utilizam equipamentos que trabalham 24 horas diárias, com sistemas operando em alta velocidade. Qualquer problema na linha pode causar uma parada de horas ou até mesmo dias, dependendo da falha. O custo de uma linha dessas além de afetar diretamente atrasos na entrega de produto ao cliente, podendo gerar um prejuízo para empresa, e até mesmo sendo necessária aquisição de peças para repor a manutenção da linha.

3.3.2 Etapas do projeto

O projeto está planejado nas seguintes etapas:

1. Estudo exploratório da análise vibração em equipamentos;
2. Estudo sobre conceitos de manutenção preditiva;
3. Estudo sobre sensoriamento de vibração;
4. Instalação no equipamento Espiraladeira (figura 4);
5. Coleta dos dados dos sensores axial e radial em nuvem;
6. Análise dos dados na plataforma MindSphere;
7. Definição de limites e análise preditiva baseado no equipamento em específico.
8. Análise e conclusão dos ganhos com análise preditiva x preventiva.

3.3.3 Dados em análise

Os dados em análise de vibração são: v-RMS, a-RMS, a-Peak e Fator de crista. A seguir segue a definição de cada componente a ser analisada na força axial e radial do equipamento, obtendo assim o melhor resultado para o estudo de caso.

O v-RMS (valor efetivo da velocidade de vibração) mede a carga total de uma máquina em rotação. Os tipos mais comuns de sobrecarga (desbalanceamento, desalinhamento, etc.) são refletidos no v-RMS. Uma carga alta pode danificar a máquina a longo prazo (fadiga, resistência à fadiga) ou, em casos extremos, destruí-la em pouco tempo.

O a-RMS (valor efetivo de aceleração) detecta contatos mecânicos de componentes da máquina. Este contato ocorre normalmente devido ao desgaste (rolamento defeituoso, engrenagens gastas, entre outros) ou problemas de lubrificação (graxa contaminada, água no óleo, entre outros).

O a-Peak monitora o valor máximo da aceleração. Impactos na aceleração podem ocorrer uma vez ou periodicamente, como no caso de uma colisão, por exemplo, em caso de um dano no rolamento. a-Peak é uma medida das forças que ocorrem na máquina.

O fator de crista é um valor característico descrito na análise de sinal. É definido como a relação entre o valor máximo e o valor efetivo (peak/RMS). No monitoramento de condições, o valor característico é usado para avaliar a condição de rolamento. Os sinais de alta frequência com curta duração de pulso de um rolamento danificado produzem valores de pico maiores em relação ao valor efetivo. Esta relação pode ser lida no fator de crista.

3.4 Modelamento na ferramenta de software EasyDash Siemens

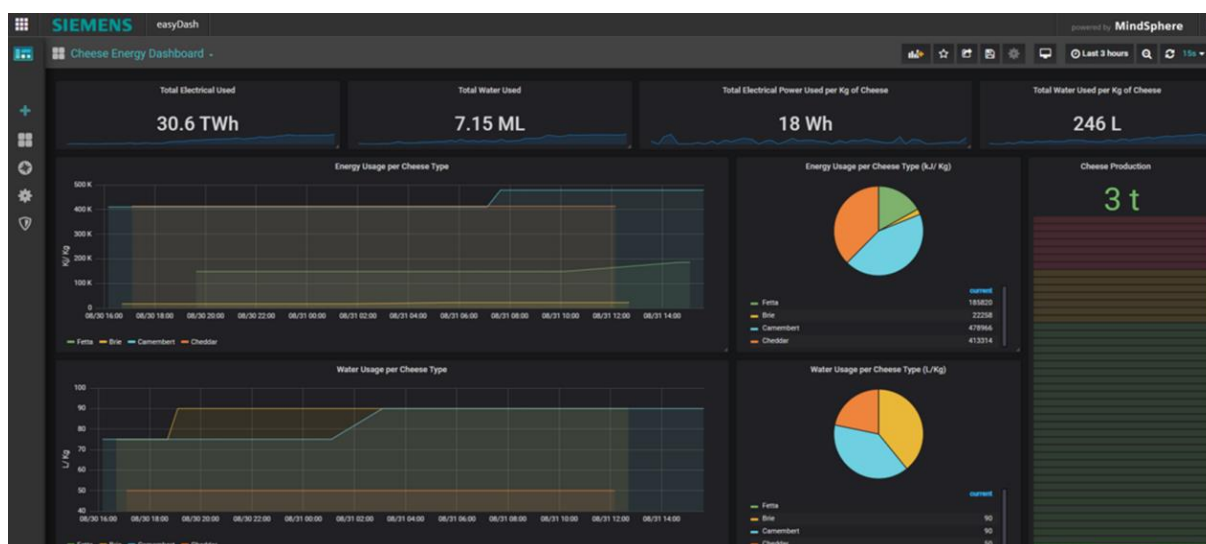
A coleta de dados será realizada através da tecnologia incorporada no sensor que possui conexão através da tecnologia IoT. Esses dados serão armazenados em nuvem através da plataforma em nuvem da Siemens MindSphere. A coleta é realizada minuto a minuto para identificar todas as falhas e possíveis alterações nos parâmetros em análise.

A visualização e análise dos dados em questão serão realizados através do aplicativo dentro da plataforma MindSphere denominada Easy Dash. Através deste

aplicativo será possível fazer análise preditiva do equipamento, a fim de emitir alertas de possível falha futura.

Existem diversos aplicativos dentro da plataforma em nuvem para análise preditiva de equipamentos. Alguns modelos fazem análise e cálculos automaticamente dentro do aplicativo, utilizando algoritmos de machine learning e inteligência artificial. No trabalho exploratório aqui apresentado, será apresentado de uma forma simples e visual essa análise, comprovando que dependendo do equipamento, não se faz necessário aquisição de software de alta análise. A figura 4 apresenta um modelo de exemplo do aplicativo EasyDash.

Figura 4 – Exemplo de dashboard do aplicativo EasyDash na plataforma MindSphere



Fonte: Siemens, 2021.

3.5 Métricas de Avaliação

3.5.1 Avaliação de Dados

O estudo de caso tem como objetivo trazer ganhos de manutenção preditiva utilizando análise simples, a fim de obter resultados equivalentes a sistemas que operam com machine learning ou inteligência artificial. A importância dessa análise é verificar qual o melhor método a ser utilizado, isso podendo ser modificado dependendo do equipamento e análise. Na maioria dos casos o problema pode ser resolvido de forma simples, não dependendo de grandes algoritmos para obtermos o

mesmo resultado. Esse será o foco do estudo exploratório, obtendo resultados satisfatórios através de métodos e análises simples de manutenção preditiva.

A avaliação dos dados é dada através do monitoramento do comportamento do equipamento no período de 60 dias. Através deste período, todos dados coletados serão armazenados na nuvem e depois exibidos em Dashboard dentro da plataforma MindSphere. Será necessário dados complementares ao estudo em questão para a análise realizada, como: velocidade da extrusão, velocidade da espiraladeira, temperatura, pressão, Esses dados complementares já estão disponíveis no equipamento, que também passarão a ser enviados para a plataforma em nuvem.

Os dados serão avaliados e criados limites que sinalizem a falha que irá ocorrer em um futuro. Baseado no histórico criado, conseguiremos ver e prever o que poderá acontecer num futuro próximo, a fim de evitar uma parada de linha e inatividade do equipamento.

3.5.2 Análise das falhas e paradas de linha por manutenção

A instalação de sensores de vibração nos equipamentos, tem por objetivo alertar o operador de situações ou sinais que o equipamento vem apresentando, a fim de evitar uma parada. Através de notificações, operadores e gestores poderão agir antes de uma falha ocorrer ou organizar uma parada prevista para realização de manutenção do equipamento.

Para mensurar e verificar tal necessidade de instalação de sistemas com atuação em tempo real, trago dados das paradas de linha do equipamento sem a implementação do estudo de caso aqui apresentado.


4 RESULTADOS

Esta seção apresenta os resultados preliminares obtidos por meio do estudo de caso de manutenção preditiva baseado em conceitos da indústria 4.0. Como descrito na base bibliográfica deste estudo, existem diversas formas de análise e algoritmos para incorporarmos os conceitos de manutenção preditiva nos equipamentos da indústria. Esse artigo tem como objetivo identificar todos esse métodos e implementar um método de forma simples para operadores e gestores de produção de uma linha de mangueiras de jardim. Usando softwares e dispositivos sem

algoritmos de alta complexidade conseguiremos apresentar uma melhora nas paradas de linha da linha, apenas com sistemas de monitoramento e alertas prevendo uma inatividade.

A figura 5 apresenta a causa das paradas de linhas da linha de mangueiras de jardim sendo estudada aqui, nos meses de Julho, Agosto e Setembro.

Figura 5 - Principais motivos de paradas de linha na produção de mangueiras



Fonte: Elaborado pelo autor.

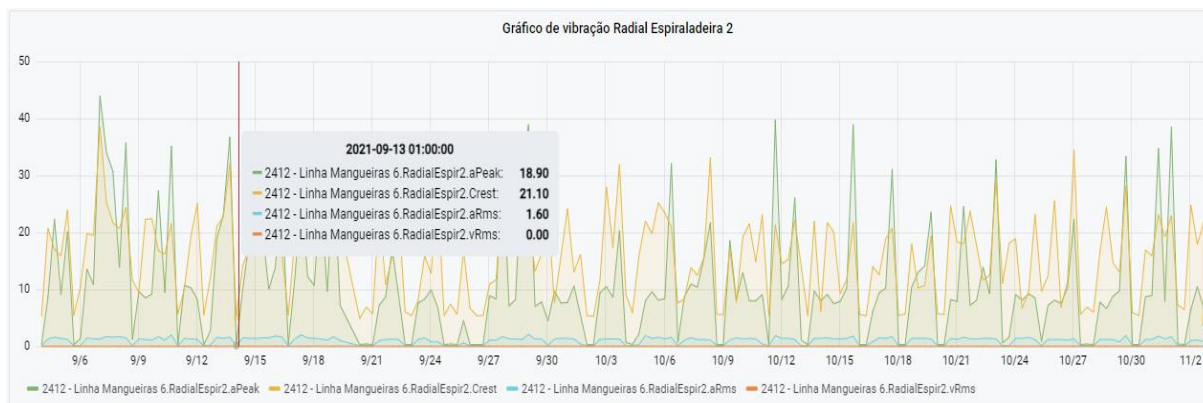
Através das análises das paradas de linhas acima foi possível identificar que as causas mais importantes são a troca de fio e a regulagem de máquinas. Tais paradas são registradas no equipamento em análise no estudo exploratório. Somente esses dois motivos de parada de linhas, significam 107 horas de paradas nos três meses. (Linha em estudo). Isso significa uma perda para a empresa de aproximadamente R\$48.792,00/ano.

Esses valores justificam cada vez mais a implantação de sistemas que possam prever uma falha antes da mesma acontecer, a fim de evitar inatividade dos equipamentos. A indústria 4.0 vem ao encontro dessa necessidade, aplicando tecnologias em tempo real em busca de melhores resultados para a empresa.

Seguindo com esses conceitos, foi realizada a instalação dos sensores de vibração com interface IO-Link da IFM na espirradeira da linha 6 de mangueiras de Jardim. Os sensores são conectados em nuvem através da conectividade junto com CLP da Siemens, alimentando o banco de dados do Mindsphere. A figura 6 apresenta a coleta de dados v-RMS, a-RMS, a-Peak e Fator de crista dos sensores no *dashboard*

criado para visualização na plataforma. A coleta de dados começou a ser realizada em 20/08/2021.

Figura 6 - Dashboard dos dados dos sensores de vibração em tempo real



Fonte: Elaborado pelo autor.

Dados do gráfico:

- Verde: a-Peak
- Laranja Forte: v-RMS
- Laranja : Fator de Crista
- Azul: a-RMS


Com os dados coletados e apresentados em *dashboard*, precisamos cruzar os mesmos e observar comportamentos e comparar com a realidade na linha de produção. Os dados numéricos não significam muito, se não forem atrelados a comportamentos e ações na linha de produção. A primeira etapa é estabelecer os valores limites dos parâmetros a fim de emitir alertas para os operadores. Entendendo bem essa etapa, é possível trabalhar para prevenir uma falha que ocorra e possa realizar uma parada de linha no equipamento.

O parâmetro V-RMS, responsável pelo monitoramento de sobrecarga no equipamento vem apresentando valor nulo no banco de dados, devido ao dispositivo não ter apresentado desbalanceamento no período em análise, e o mesmo será ignorado na análise do estudo de caso. Como esse parâmetro é importante para detecção de falhas graves no equipamento, foi adicionado um alerta para caso o dispositivo passe a apresentar valor superior ou igual a 1. Dessa forma, o dispositivo poderá informar a equipe da manutenção para realizar uma revisão do equipamento, evitando a inatividade da linha.

O parâmetro a-RMS, responsável pela detecção de contatos mecânicos apresentou os seguintes resultados, conforme a figura 7. Realizada a análise do Revista Produção Online. Florianópolis, SC, v. 22, n. 3, p. 3418-3340, 2022

comportamento do a-RMS, foram criadas duas situações de aviso para operadores e equipe de manutenção, sinalizadas como Alerta na cor amarela com valor de 1,2 m/s² e Alerta Crítico na cor vermelha com valor de 1,5 m/s².

Figura 7 - Dados de a-RMS na espirradeira




Fonte: Elaborado pelo autor.

Dados no gráfico em m/s².

Com os alertas e cadastro do envio de notificações para celulares dos responsáveis, passamos a ter o acompanhamento dos ocorridos na linha de produção em tempo real, sendo assim tomando a iniciativa imediata de correção dos parâmetros e ajustes necessários para evitar uma parada de linha. Todos alertas irá ocorrer da mesma forma para demais parâmetros em análise por esse estudo de caso, dentro dos limites encontrados na análise.

O parâmetro a-Peak, responsável em caso de uma colisão e até mesmo desbalanceamento de rolamentos ou do sistema, apresentou os seguintes resultados, conforme a figura 8. Realizada a análise do comportamento do a-Peak, foram criadas duas situações de aviso para operadores e equipe de manutenção, sinalizadas como Alerta na cor amarela com valor de 9 m/s² e Alerta Crítico na cor vermelha com valor de 15 m/s².

Figura 8 - Dados de a-Peak na espirradeira




Fonte: Elaborado pelo autor.

Dados no gráfico em m/s².

O parâmetro fator de Crista, que é o fator entre Peak/RMS responsável para identificar picos e vibrações no sistemas de rolamentos, apresentou os seguintes resultados, conforme a figura 9. Realizada a análise do comportamento do a-Peak, foram criadas duas situações de aviso para operadores e equipe de manutenção, sinalizadas como Alerta na cor amarela com valor de 13 e Alerta Crítico na cor vermelha com valor de 15.

Figura 9 - Dados de Fator de Crista na espirradeira




Fonte: Elaborado pelo autor.

Após apresentar os resultados e análises de cada parâmetro de vibração, chegamos na avaliação pontual do dado que está sendo apresentado de forma online, a fim de termos ganhos efetivos de diminuição de inatividade das linhas. O objetivo

deste estudo de caso é que por meio dos dados e alertas emitidos pelo sistema desenvolvido, possa-se identificar na prática e corrigir antes mesmo de vir a ocorrer algum problema.

Foram analisados diversos casos nesse período em questão. Apresenta-se na figura 10 uma parte da situação em que o sistema implementado foi capaz de identificar o problema em ocorrência. Como pode ser observado na figura, o parâmetro a-Peak sofreu variação e acréscimo em seu dado, onde as 01:10 do dia 07/11 atingiu o alerta identificado na cor amarela no gráfico. Para facilitar o entendimento das causas do sistema, foi incluído a visualização da rotação do equipamento, na parte inferior da imagem. Nesse momento, podemos observar que a rotação do sistema estava em funcionamento normal e constante. Às 06:00 o sistema começou apresentar problemas e falhas, fazendo com o que operador tenha alguma ação no sistema para evitar a parada de linha.

Figura 10 - Análise pontual de falha no equipamento identificado pelo sistema implementado



Fonte: Elaborado pelo autor.

Com o caso apresentado, confirma-se o princípio e a importância de obter-se dados para conseguir agir antes que uma falha aconteça. No caso descrito, como o sistema estava apenas em teste, e o operador não tinha acesso, não foi realizada

nenhuma ação preventiva, ocasionando horas mais tarde problemas e falhas no sistema. Posteriormente, com esse sistema incorporado, o operador será notificado em qualquer variação que atinja os alertas sinalizados e podendo agir de forma imediata antes de ocorrer falhas futuras.

A figura 11 apresenta o modelo de notificação criado e enviado para o operador quando o dado atinge seu limite crítico, conforme apresentado anteriormente.

Figura 11 - Notificação enviada ao operador ao ter atingido limite crítico

Tenant:	tmulti
Asset Name:	2412 - Linha Mangueiras 6
Asset ID:	28ac7eda47544fcca2173e56d7cf7675
Rule ID:	1027000
Severity:	30 - WARNING
Description:	Alerta Crítico a-RMS
Timestamp:	Sun, 07 Nov 2021 16:03:05 UTC <small>(Please note: This time may differ from your local time.)</small>
Variable 1:	AxialEspir2:aRms
Value 1:	2.2
Details in Fleet Manager:	
Browse Events	

Fonte: Elaborado pelo autor.

As paradas de linhas, pelos motivos apresentados, totalizavam em média 35 horas mensais. Após a implantação do sistema e notificações aos operadores, conseguiu-se reduzir o tempo de parada de linha para 27 horas e 10 minutos, ou seja redução de 23%, assumindo uma *baseline* de Novembro/21. Em valores, isso significa uma redução financeira da ordem de R\$11.222,00/ano em paradas de linhas.

5 CONSIDERAÇÕES FINAIS

Empresas em constante evolução e buscando inovar-se em seus processos produtivos, a indústria 4.0 vem ao encontro desse crescimento da era da manufatura que vem ocorrendo nos dias atuais. As empresas precisam entrar cada vez mais

nessa era, buscando competitividade e gerando lucros, sempre pensando no cliente que busca produtos com qualidade e preços competitivos (MOYA, 2004).

Um dos pilares da Indústria 4.0 é a predição de ações e falhas, baseados em dados do passado. Quanto mais a tecnologia conseguir prever uma situação futura e conseguirmos agir antes mesmo dela ocorrer, conseguiremos ter enormes ganhos. Seguindo essa linha, o estudo de caso vem ao encontro disso, trazendo um estudo mais específico de conceitos da Indústria 4.0 e seus diversos modelos de manutenção (SUSTO *et al.*, 2015).

Existem diversos modelos e métodos apresentados por autores de como implantar uma manutenção preditiva nos processos manufaturados. O estudo de caso aplicado em uma indústria metal mecânica, vem com objetivo de aprofundar os conceitos implantados no mercado, mas através de métodos e algoritmos simples, conseguimos atingir o mesmo objetivo final. Ressalvo que deve ser avaliado os processos e analisar qual o melhor método para determinada aplicação.

O estudo de caso contemplou toda a análise dos dados de vibração coletados através do sensoriamento instalado no equipamento, além de todo conceito por trás da manutenção preditiva 4.0. Foi utilizada a plataforma em nuvem Mindsphere da Siemens para coleta dos dados e armazenamento. A predição das falhas do equipamento foi analisada através de ferramentas que a plataforma dispõe para essa finalidade, utilizando conceitos de *Machine Learning*.

Com a implementação do sistema em nuvem e monitoramento dos dados de vibração do equipamento, conseguimos criar dashboards e analisar diversos comportamentos que a máquina viria apresentar. Com todas as análises realizadas históricas, conseguimos de forma simples entender o comportamento do equipamento específico e determinar diversos parâmetros que venham trazer consequências futuras. Com a criação de alertas aos usuários, foi possível identificar irregularidades no processo, antes mesmo de vir causar uma falha ou uma inatividade da linha de produção.

Conclui-se que com sistemas de baixo investimento, conseguimos atingir o objetivo proposto no estudo de caso, obtendo uma redução de tempo de inatividade do equipamento já no primeiro mês em aplicação, com redução de até 24%. Essas reduções são importantes para a indústria de manufatura atual, garantindo cada vez mais produtos de qualidade e preços justos aos seus clientes.

Como oportunidades de melhoria do estudo aqui apresentado, existe a necessidade de testar e aplicar estrutura desenvolvida em outros equipamentos de maior complexidade, a fim de verificar a eficácia da análise dos dados. Em equipamentos, como por exemplo motores, possivelmente será necessário uma coleta e análise de dados com maior período. Falhas em sistemas de maior complexidade, apresentam-se em períodos longos, diferentemente do estudo de caso alvo deste artigo. Deve portanto ser analisada a necessidade de incorporação de *machine learning* nos métodos com equipamentos mais complexos.

REFERÊNCIAS

PEREIRA, E. O. SIMONETTO, Indústria 4.0: Conceitos e Perspectivas para o Brasil, **Revista da Universidade Vale do Rio Verde**, v. 16, 2018. DOI:

<https://doi.org/10.5892/ruvrd.v16i1.4938>

ALEJANDRO, J. K.; DALENOGARE, L. S.; AYALA, N. F. Industry 4.0 technologies: Implementation patterns in manufacturing companies. **International Journal of Production Economics**, v. 210, 15-26 p., 2019. DOI:

<https://doi.org/10.1016/j.ijpe.2019.01.004>

GANDOMI, A.; HAIDER M. Beyond the hype: Big data concepts, methods, and analytics. **International Journal of Information Management**, v. 35, n. 2, 2015, p. 137-144. DOI: <https://doi.org/10.1016/j.ijinfomgt.2014.10.007>

BASCO, A. I. *et al.* **Industria 4.0**: fabricando el futuro. Inter-American Development Bank, 2018.

JUNG, G. Z.; ZHANG M. W., "Vibration Analysis for IoT Enabled Predictive Maintenance". *In*: IEEE 33RD INTERNATIONAL CONFERENCE ON DATA ENGINEERING (ICDE), 2017, pp. 1271-1282. DOI:

<https://doi.org/10.1109/icde.2017.170>

DILMEGANI, C. Predictive Maintenance: In-depth Guide. *In*: AI Multiple., [S.I.], 27 2018. Disponível em: <https://blog.aimultiple.com/predictive-maintenance/>. Acesso em: 8 ago. 2019.

SEZER, E. D.; ROMERO, F.; GUEDEA, M.; MACCHI E. C. Emmanouilidis. industry 4.0-enabled low cost predictive maintenance approach for smes, 2018 IEEE *In*: INTERNATIONAL CONFERENCE ON ENGINEERING, TECHNOLOGY AND INNOVATION (ICE / ITMC), 2018, p. 1-8. DOI: DOI:

<https://doi.org/10.1109/ice.2018.8436307>

SUSTO, G. A.; SCHIRRU, S.; PAMPURI, S.; MCLOONE E. A.; BEGHI. Machine Learning for Predictive Maintenance: A Multiple Classifier Approach. *In*: IEEE

TRANSACTIONS ON INDUSTRIAL INFORMATICS, v. 11, n. 3, p. 812-820, 2015.
DOI: <https://doi.org/10.1109/tii.2014.2349359>

INDUSTRY 4.0. In: IEEE INDUSTRIAL ELECTRONICS MAGAZINE, v. 11, n. 1, p. 17-27, 2017.

JAY LEE; KAO, H.; YANG, S. Service Innovation and Smart Analytics for Industry 4.0 and Big Data Environment. **Procedia CIRP**, v. 16, 2014, p. 3-8. DOI: <https://doi.org/10.1016/j.procir.2014.02.001>

LEE, J.; LAPIRA, E.; BAGHERI, B.; KAO, H. Recent advances and trends in predictive manufacturing systems in big data environment. **Manufacturing Letters**, v. 1, n. 1, 2013, p. 38-41. DOI: <https://doi.org/10.1016/j.mfglet.2013.09.005>

KARDEC, A.; NASCIF, J. **Manutenção**: função estratégica. 3 ed. Rio de Janeiro: Qualitymark: Petrobrás, 2009.

WOLLSCHLAEGER, Martin; SAUTER, Thilo; JASPERNEITE, Juergen. The future of industrial communication: Automation networks in the era of the internet of things and industry 4.0. **IEEE industrial electronics magazine**, v. 11, n. 1, p. 17-27, 2017. DOI: <https://doi.org/10.1109/mie.2017.2649104>

MOYA, M.; CARNERO, C. **O controle da implantação de um programa de manutenção preditiva por meio de um sistema de indicadores**. Omega 32.1, 2004. p. 57-75. DOI: <https://doi.org/10.11606/d.5.2012.tde-28022013-134542>



Artigo recebido em: 25/01/2022 e aceito para publicação em: 10/02/2023
DOI: <https://doi.org/10.14488/1676-1901.v22i3.4557>