



**Implementação de Técnica de Identificação de Alarmes de Braços
Ferramentas em Centros de Usinagem de Alta Velocidade em Indústria
Metal Mecânica: aplicação da Engenharia de Dados em um estudo de caso**

Delmo Alves de Moura

Universidade Federal do ABC (UFABC)

e-mail: delmo.moura@ufabc.edu.br

Diego Peixoto

Universidade de São Paulo (USP)

e-mail: psdipe@hotmail.com

Resumo

Iniciativas da engenharia de manutenção, com foco em manutenções preditivas ajudam a estimar quando ocorrerá a falha em equipamentos. Essa previsão nos permite planejar a manutenção com antecedência, reduzir custo, eliminar tempos de paradas não planejados e maximizar a vida útil do equipamento. O uso das tecnologias da Indústria 4.0 (I4.0) e as técnicas da ciência dos dados, permitiram, à engenharia de manutenção, o desenvolvimento de algoritmos inteligentes, que contribuem para a análise, em tempo real, de uma quantidade enorme de dados, transformando-os em informações, para tomada de decisão numa fábrica. Neste trabalho foi implantado um sistema de coleta e análise de dados reais, para identificar os alarmes e a saúde de um sistema de troca de ferramentas de alta velocidade de máquinas de usinagem, de uma linha de cilindros de combustão, de uma indústria metal mecânica. O objetivo do artigo foi estudar a coleta de dados em tempo real de máquinas de usinagem, de uma linha de cilindros de combustão de uma indústria metal mecânica, analisá-los, através da ciência dos dados e transformá-los em informações para tomada de decisão, visando redução de custos operacionais, aumentar vida útil de equipamentos e reduzir parada de máquinas na fábrica.

Palavras-chave: Manutenção, Indústria 4.0, Alarmes, Predição.

Abstract

Maintenance engineering initiatives, focusing on predictive maintenance, help estimate when equipment failure will occur. This forecast allows us to plan maintenance in advance, reduce costs, eliminate unplanned downtime and maximize the useful life of the equipment. The use of Industry 4.0 (I4.0) technologies and data science techniques allowed maintenance engineering to develop intelligent algorithms, which contribute to the analysis, in real time, of a huge amount of data, transforming them into information for decision-making in a factory. In this work, a real data collection and analysis system was implemented to identify the alarms and health of a high-speed tool changing system for machining machines, a line of combustion cylinders, in a metal mechanic industry. The objective of the article was to study the collection of real-time data from machining machines, from a line of combustion cylinders in a metalworking industry, analyze them through data science and transform them into information for decision making. , aiming to reduce operational costs, increase the useful life of equipment and reduce machine downtime in the factory.

Keywords: Maintenance, Industry 4.0, Alarms, Prediction.

1. Introdução.

Em um mercado cada vez mais competitivo e em constante mudança, com as tecnologias da indústria 4.0 (I4.0), o setor produtivo exige uma nova abordagem para o aumento da disponibilidade dos equipamentos, ficando evidente a importância da manutenção de ativos como uma função estratégica dentro de uma organização (KUMARI, SAINI, 2021).

A evolução da manutenção está atrelada ao desenvolvimento das unidades de produção (BRANCO FILHO, 2008). Antes da segunda guerra mundial a indústria era pouco mecanizada, conseqüentemente não era necessária uma manutenção sistematizada, ou seja, a manutenção era fundamentalmente corretiva (BRANCO FILHO, 2008). Na manufatura, os efeitos dos períodos de paralisação foram se agravando pela tendência mundial de utilizar sistemas *just-in-time*, onde estoques reduzidos significavam que pequenas paradas na produção poderiam paralisar a fábrica. Reforçou-se o conceito de manutenção preditiva e a interação entre projeto, fabricação, instalação e manutenção e a disponibilidade/confiabilidade tornou-se mais evidente (KARDEC, NASCIF, 2001).

Com o advento da automação industrial e da transformação digital atrelada a novas tecnologias é fundamental que a manutenção deixe de ser apenas eficiente e se torne cada vez mais eficaz (LAFRAIA, 2001), ou seja, é preciso garantir a disponibilidade e a confiabilidade dos ativos, mas de forma segura, tanto para as pessoas quanto ao meio ambiente, com prazos e custos adequados.

Com isso, a questão de maximizar a eficácia de um ativo durante o seu ciclo de vida, minimizando as falhas e reduzindo perdas, torna-se fator chave na indústria (BRANCO FILHO, 2008). Neste contexto, a manutenção como responsável pelo resultado através do cuidado do ativo físico da empresa, deve assegurar que equipamentos continuem a cumprir com suas funções. Assim, o uso da ciência de dados, cujo desenvolvimento de algoritmos aplicados à manutenção trazem inovações que ajudam a preservar os equipamentos, pode identificar falhas incipientes e proporcionar maior grau de assertividade na programação de intervenções (RAMANI et al., 2016).

Logo, os objetivos de toda estrutura de engenharia de manutenção passam a ser encarados como a aplicação de atividades sistemáticas e coordenadas que contribuem para a análise em tempo real de uma quantidade enorme de dados. E, dessa análise, a decisão do que fazer com o equipamento, onde a função da manutenção deixa de apenas de reconduzir a sua condição original, mas também de garantir a disponibilidade, objetivando alcançar o planejamento estratégico da indústria (SCHMIDT, WANG, 2018).

Desta forma, o presente trabalho visa desenvolver uma metodologia de coleta, processamento e análise de dados que promova o aumento da identificação de falhas em centros de usinagem *High Speed* (de máquinas de usinagem, de uma linha de cilindros de combustão de uma indústria metal mecânica), afim de se potencializar a manutenção preditiva e detectiva, reduzindo a probabilidade de parada de produção não planejada e aumentando a disponibilidade dos equipamentos, o uso de tecnologias da Indústria 4.0, visando redução de custos de manutenção e aumento do desempenho industrial da manufatura de processos de usinagem. O alto custo na implementação da Indústria 4.0, fruto da obsolescência das máquinas na produção, aliadas as dificuldades de acesso à informação, ausência de mão de obra especializada e disponibilização de linhas de investimento são barreiras e dificuldades das empresas (CNI, 2022). Um outro desafio é a obtenção de dados reais na manufatura de uma empresa, para identificar os possíveis problemas nos equipamentos e trabalhar de forma inteligente, para extrair as principais informações, transformando os dados coletados, em planos estratégicos de manutenção.

2. Revisão de literatura.

Nesta seção são abordados os aspectos conceituais relacionados a manutenção, com foco nas tecnologias da Indústria 4.0, para redução de tempo de inatividade e aumento de produtividade industrial.

2.1. A manutenção com foco nas tecnologias da Indústria 4.0.

O Quadro 1 apresenta as principais contribuições dos autores que estudaram os sistemas de manutenção preditiva nas empresas. Ele descreve a evolução ao longo do tempo com o uso de tecnologias da Indústria 4.0, associado a modelos da área de *Data Science and Analytics*. Analisando os artigos relatados neste Quadro, percebe-se a evolução das melhores formas de obtenção de dados em chão de fábrica, transformando-os em informações relevantes, para a tomada de decisão de manutenção preditiva de máquinas.

A revisão da literatura permitiu avaliar o uso das tecnologias da Indústria 4.0 na obtenção de dados. Estes dados, quando bem tratados estatisticamente, podem ser convertidos em informações essenciais, que visam melhorar a produtividade e a vida útil de máquinas e equipamentos, contribuindo assim, com os programas de manutenção das empresas de manufatura.

Quadro 1 – Manutenção preditiva - tecnologias da Indústria 4.0 e ciência dos dados.

Autor (ano)	Contribuição e Pontos Essenciais
Rao e Sarda (2002)	Examinaram a aplicabilidade do processo de manutenção padrão IEEE (Instituto de Engenheiros Eletricistas e Eletrônicos) e concluíram que há necessidade de reorganização dos bancos de dados e melhor gerenciamento de configurações que não são definidas pelo processo de manutenção IEEE.
Kajko-Mattsson (2005)	Analisou o estado da prática de documentação na manutenção corretiva na Suécia e concluiu que os sistemas de softwares não são atualizados continuamente durante as etapas do processo de manutenção corretiva das empresas, possibilitando assim, perdas importantes de dados que poderiam melhorar a manutenção dos equipamentos.
Lechevalier, Narayanan e Rachuri (2014)	Desenvolveram uma estrutura específica para aplicar análises preditivas em aplicativos de manufatura, possibilitando que as empresas de manufatura aproveitassem a análise preditiva para melhorar seu desempenho industrial.
Wu et al. (2016)	Desenvolveu um modelo de prognóstico de máquinas, usando um algoritmo de aprendizado paralelo baseado em nuvem. Os autores aplicaram o modelo de floresta aleatória (<i>Random Forest</i>) para prever desgaste da ferramenta em operações de fresamento a seco.
Ramani et al. (2016)	Desenvolveram um sistema para análise preditiva de automação e otimização de manutenção industrial usando uma rede de sensores inteligentes. O sistema ajudou a área da manutenção de uma empresa, com informações, notificações e relatórios sobre os processos de manutenção necessários.
Jantunen et al. (2017)	Estudaram tecnologias de Manutenção Baseada na Condição (CBM) com sensores microeletromecânico, como Nuvem e <i>Big Data</i> , visando a ampliação de ativos monitorados, permitindo assim, que vários parâmetros sejam mensurados e analisados, com acesso sem fio.
Jose e Zameer (2018)	Desenvolveram um dispositivo baseado em sensor econômico, com o uso dos recursos da arquitetura de computação heterogênea, visando evitar falhas inesperadas da máquina.
Schmidt, Wang (2018)	Definiram uma metodologia para tomada de decisões, relacionada com a manutenção preditiva, fundamentada numa abordagem baseada em nuvem. O foco foi a coleta e a forma de processar dados relacionados à manutenção, num contexto industrial.
Abbasi et al. (2018)	Desenvolveram uma interface analítica de dados de manutenção preditiva, com a implementação da técnica de manutenção preditiva de Regressão Linear Múltipla.
Sadiki et al. (2018)	Investigaram o impacto das políticas de manutenção no desempenho dos sistemas de manufatura. Os autores propuseram a integração de redes de sensores inteligentes para monitorar equipamentos para implementar política de manutenção preditiva.
Balogh et al. (2018)	Abordaram o uso de uma infraestrutura de Internet das Coisas (IoT - <i>Internet of Things</i>) para coleta de uma grande quantidade de dados, que estão disponíveis no chão de fábrica, que devem ser analisados por algoritmos de análise de dados, modelos de manutenção preditiva e de técnicas de previsão, com o intuito de realizar avaliações e previsão da integridade de máquinas e equipamentos, propondo possíveis planos de manutenção, para uma organização.

Polotski, Kenne e Gharbi (2019)	Analisaram o problema de otimização combinada de produção e manutenção corretiva, para um sistema de uma máquina e um produto. Os autores analisaram a situação de reparo mais barato, contra reparo mais caro, com foco no risco de falta de estoque.
Wang et al., 2020	Propuseram um novo método para determinar a disponibilidade em estado estacionário de um sistema multi-estado reparável, visando avaliar a disponibilidade de um sistema de manutenção, sem assumir distribuições exponenciais ou depender de simulação e aproximação de distribuição de probabilidade.
Ton et al. (2020)	Propuseram um modelo que identifica obstáculos a serem enfrentados na área da manutenção. Desta forma, os autores identificaram falta de alinhamento entre as partes envolvidas no processo de manutenção e definiram uma forma estruturada de implantar soluções de manutenção preditiva mais eficientes e eficazes.
Yu et al. (2020)	Desenvolveram uma solução completa para detecção de falhas em manutenção preditiva, em manufatura inteligente baseada em IoT industrial. Os autores analisaram um sistema envolvendo a coleta, armazenamento, processamento e a visualização dos dados de monitoramento da IoT, referente a modelagem preditiva, com o uso de <i>Big Data</i> , num ambiente em tempo real.
Romriell et al. (2020)	Analisaram o uso de técnicas de aprendizado de máquinas para fornecer avisos de possíveis erros em máquinas. Com isto, os autores conseguiram que ações fossem tomadas de forma proativas, para evitar paradas desnecessárias de equipamentos e aumento de rendimentos das máquinas.
Kumari e Saini (2021)	Analisaram o papel da manutenção, com foco na coleta de dados, por meio de sensores, e com isto ter condições reais para tomada de decisões sobre reparos e manutenção de equipamentos. Os autores relataram a necessidade de diagnosticar, com antecedência, a integridade de máquinas, com foco nas causas das falhas, identificando a raiz do problema, através de dados fornecidos pelas máquinas, evitando assim, paradas de equipamentos e com isto melhorando a segurança do processo e aumentando a produtividade das máquinas.
Purnachand et al. (2021)	Abordaram como escolher a melhor técnica de modelagem para problema de manutenção preditiva, levando em consideração o uso diário dos equipamentos e a vida útil das máquinas.
Wellsandt et al. (2021)	Desenvolveram uma nova abordagem para interagir com os sistemas de manutenção preditiva, por meio dos Assistentes Inteligentes Digitais (DIAs). O foco foi a integração do conhecimento humano de forma mais eficiente e eficaz ao processo de manutenção preditiva, visando criar um sistema híbrido de inteligência, seres humanos e computadores se complementam e evoluem juntos.
Canito et al. (2021)	Apresentaram uma arquitetura para manutenção preditiva, baseada em arquiteturas padrão existentes para a Indústria 4.0, que não apenas suportam a implementação de todas as etapas da manutenção preditiva, mas também é flexível o suficiente para ser aplicada em cenários industriais distintos.
Singh, Agrawal e Chakraborty (2021)	Estudaram um modelo multiclassificador, baseado em dados para implementação de manutenção preditiva para reduzir simultaneamente o tempo de inatividade e o tempo ocioso das máquinas em uma fábrica.
Hassan et al. (2021)	Analisaram plataformas de sensores da Internet das Coisas Industrial (IIoT), para monitorar os principais parâmetros do equipamento e desenvolver análises preditivas.
Maqbool, Mahmood e Khattak (2022)	Realizaram uma análise crítica nos trabalhos de detecção de falhas, visando revisar os diferentes algoritmos de <i>Machine Learning</i> e com isto desenvolveram modelos de algoritmos de <i>Deep Learning</i> , que são considerados mais eficientes e eficazes na previsão de séries temporais, reduzindo assim a taxa de erro e o custo computacional.
Mubarak et al. (2022)	Apresentaram uma ideia na implantação de <i>Digital Twin</i> para manutenção preditiva sob arquitetura de sistema aberto. Os autores propuseram uma estrutura de manutenção preditiva otimizada de custo e confiabilidade, voltada para as máquinas da Indústria 4.0, com base em análises qualitativas e quantitativas de dados de monitoramento.
Vinh e Huy (2022)	Desenvolveram um sistema de manutenção preditiva IoT para máquinas industriais. O sistema coleta dados da máquina em análise e também coleta dados específicos, incluindo fabricantes, anos de fabricação e tipos de máquinas. Em seguida, o sistema faz a previsão de manutenção com base nesses dados. A previsão de manutenção usa o algoritmo <i>Random Forest</i> para estimar a vida útil remanescente de máquinas industriais. Com estas informações o sistema

	desenvolvido pode emitir alerta para os gestores realizarem um plano de manutenção mais adequado para os equipamentos.
Asadi, Hashemi e Balakrishnan (2023)	Analisaram alguns modelos de manutenção preditiva para análise de vida útil de sistemas e com isto, desenvolveram comparações entre eles, analisando suas potencialidades para determinar períodos de manutenção.
Yu et al. (2023)	Abordaram o uso do <i>Big Data</i> de IoT completo e otimizado, incorporado em uma arquitetura de três camadas para aplicativos de manutenção preditiva. O foco foi a construção de um sistema de manutenção preditiva monitorando a condição da máquina e avaliando a necessidade de manutenção, por meio de uma técnica de detecção de anomalias e mecanismo de alarme que devem ser capazes de enviarem um alerta de manutenção com antecedência, evitando assim paradas inesperadas na produção.

Fonte: os autores.

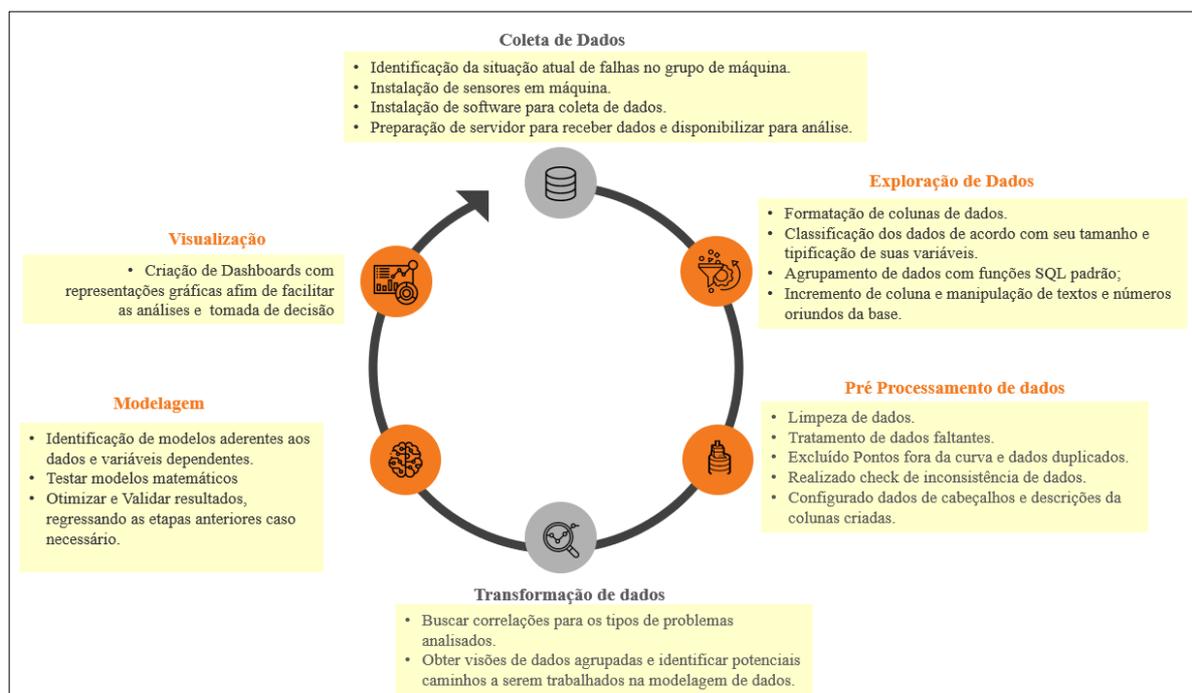
Sensores foram instalados para coleta de dados, num centro de usinagem de cilindros de combustão nesta pesquisa. Os dados foram trabalhados estatisticamente para a obtenção de informações, que foram utilizadas na área de manutenção preditiva, visando a redução de custos anuais elevados de manutenção, de uma empresa.

A revisão da literatura sobre o tema contribuiu para o desenvolvimento deste trabalho e com isto tentar preencher uma lacuna na literatura nacional sobre o tema, com foco no uso de tecnologias da I4.0 aliada com as técnicas de *Data Science and Analytics* para melhorar a manutenção preditiva de máquinas e equipamentos no Brasil.

3. Metodologia.

O Quadro 2 apresenta o fluxograma utilizado para o desenvolvimento metodológico, contendo as etapas realizadas neste trabalho.

Quadro 2 – Fluxograma metodológico das etapas realizadas na pesquisa.



Fonte: os autores.

Os dados utilizados no presente trabalho foram obtidos e extraídos diretamente dos centros de usinagem da marca CHIRON, do parque fabril de uma empresa fabricante de ferramentas motorizadas

localizada no Sul do Brasil. Atualmente, a planta fabril conta com 68 equipamentos da marca CHIRON e cada equipamento possui 20 Braços ferramentas, totalizando 1360 componentes a serem analisados, os quais realizam mais de 136 milhões de ciclo de usinagem por ano. Para este projeto será realizado o piloto inicial em 5 máquinas.

Para realizar a leitura de dados das máquinas foi necessário, no primeiro momento, instalar um sensor VSA005, marca IFM, com range [Hz] 1- 10000, para coletar os níveis de vibração puros de velocidade (mm/s) e aceleração (mg) do eixo motriz da máquina, chamado de *spindle*. Esse sensor é instalado individualmente em cada máquina. Após a instalação dos sensores é instalado e utilizado o software IFM OPC SERVER, fornecido pelo próprio fabricante do sensor, que por sua vez disponibilizará os dados no servidor OPC UA configurado pela área de tecnologia das informações da empresa.

Outra informação necessária que foi preciso obter da máquina foram as mensagens de falhas. Para ler as variáveis do PLC da máquina foi seguido o manual List2 SINUMERIK 840D sl NC *variable and interface signals* do fornecedor SIEMENS, contido na documentação técnica do equipamento. As variáveis já foram definidas e agrupadas conforme endereços apresentados no Quadro 3:

Quadro 3 – Variáveis definidas conforme endereços.

/Plc/Datablock/Byte[c100,52] [número do braço de ferramentas]
 /Plc/Datablock/Bit[c2,201.0] [alarme de ferramenta não acoplada]
 /Plc/Datablock/Bit[c2,201.1] [alarme de ferramenta não acoplada na posição]
 /Plc/Datablock/Bit[c2,203.6] [alarme de ferramenta fixada incorretamente]
 /Plc/Datablock/Bit[c185,4.3] [tentativa de acoplamento de ferramenta]

Fonte: os autores.

As variáveis foram selecionadas baseadas nas informações da saída do PLC do equipamento, onde cada uma nas variáveis representa uma mensagem de erro do programado que por sua vez representa a não conclusão do ciclo e a interrupção do equipamento.

Vale destacar que para garantir comunicação entre a máquina e servidor foi executado redirecionamento de portas, procedimento recomendado pelo fabricante, conforme exemplo em máquina, Figura 1:

N.º	Data	Hora	N.º erro	N.º	Data	Hora	N.º erro
0	01.02.21	01:36:24	700241	10	27.01.21	03:38:16	700238
1	01.02.21	01:36:24	700230	11	26.01.21	20:06:29	700241
2	31.01.21	20:40:01	700241	12	26.01.21	20:06:29	700238
3	31.01.21	20:34:21	700241	13	25.01.21	18:28:33	700241
4	31.01.21	20:34:21	700238	14	25.01.21	18:27:07	700241
5	30.01.21	20:34:56	700241	15	23.01.21	20:20:53	700241
6	30.01.21	20:31:14	700241	16	23.01.21	18:30:25	700241
7	30.01.21	14:43:58	700240	17	23.01.21	12:22:00	700241
8	30.01.21	10:38:56	700238	18	23.01.21	11:52:23	700241
9	27.01.21	03:38:16	700241	19	22.01.21	20:41:35	700241

Figura 1 - Imagem do PLC da máquina com a instalação de software para coleta de dados de processo. Fonte: os autores.

Após realizada a leitura dos dados de máquina coletadas do sensor IFM e do Comando numérico SINUMERIK, foi necessário instalar o *software* EPM Interface Server também na máquina, a fim de conectar com o servidor OPC UA, chamado de EPM server da empresa. Desta forma, os dados coletados e disponibilizados pela máquina no *software* EPM server, desde que configurados e habilitados podem ser descarregados para consulta no servidor OPC UA que centraliza todo gerenciamento de fluxo de dados do sistema, conforme Figura 2. A função do servidor é receber os dados provenientes de todas as fontes, e neste projeto, mais precisamente, as informações dos sensores e do PLC da máquina.

Vale destacar, que o servidor recebe os dados provenientes de diversas fontes, caso dos sensores e do PLC da máquina. Com esses dados o servidor disponibiliza informações em tempo real e também possibilidade comprimir e armazenar as informações.

A necessidade de armazenar dados contínuos vindos das máquinas e em tempo real se fez necessário no contexto deste projeto. Junto a isso a falta de uma interface amigável para historiar dados aliada à baixa capacidade de armazenamento do *software* IFM, fez com que fosse necessário o uso do *software* EPM, que acaba sendo uma solução em termos de processamento e gerenciamento da informação, pois utiliza o *SQL server* para o armazenamento dos dados em um formato otimizado para séries temporais, gerenciando todas as transações com o servidor de banco de dados, de forma a aumentar significativamente o desempenho do sistema.

A Figura 2 resume o fluxo de extração e disponibilização de dados de máquina (SADIKI et al., 2018).

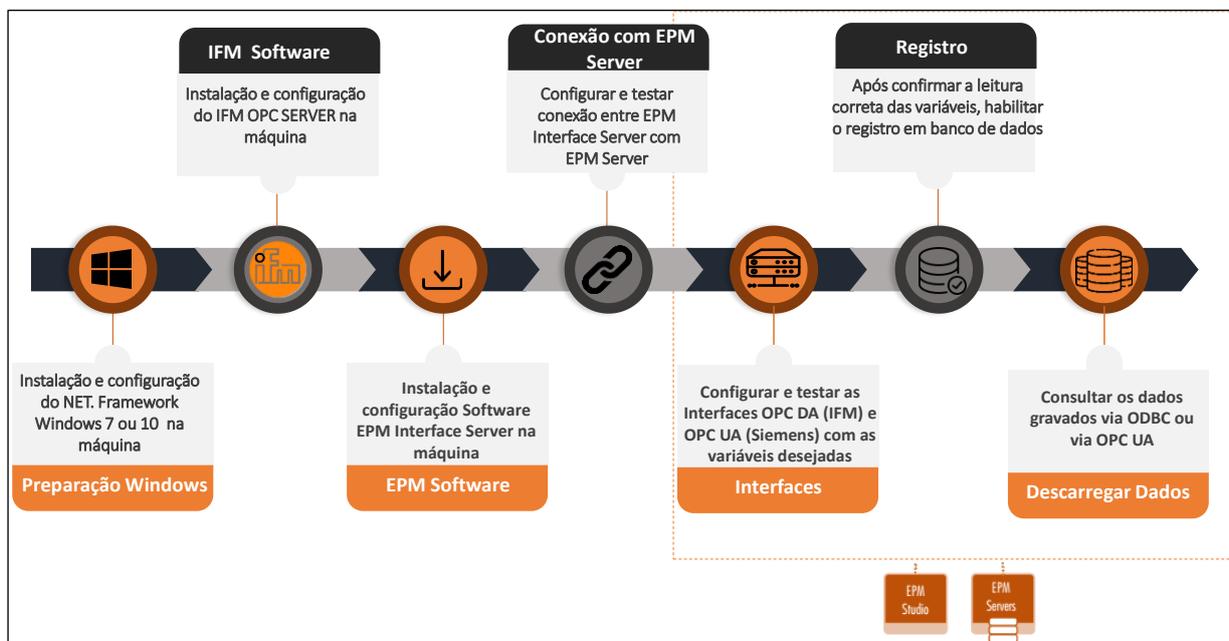


Figura 2 – Framework pós instalação sensor e pré-processamento de dados. Fonte: os autores.

Na exploração os dados de máquinas foram classificados de acordo com seu tamanho e tipificação de suas variáveis, em alguns casos como com a variável tempo, se tornou necessária alterar e adicionar informações já que os dados nativos eram em formato *string* e necessitava-se em formato data e hora.

Tendo a posse das grandezas oriundas do sensor e do PLC, se deu início à função de processamento. Neste momento foi dividido o processo nas seguintes etapas:

- Exploração de dados, pré-processamento de dados e transformação de dados.
- Para aplicação do processamento de dados e modelagem utilizou-se do *software* Visual Studio Code para manipular a linguagem Python
- Foram usadas as seguintes bibliotecas e pacotes: “pandas”, “numpy”, “plotly.express”, “h5py” e “datetime”.

Para a realização das análises no *Visual Studio Code* utilizou-se de dados do tipo tabela (.csv) quando utilizado informações do sistema SAP, com a finalidade de coletar a execução de atividades de

manutenção. Arquivos HDF5 de extensão (.h5), foram utilizados para coleta de dados oriundos do sensor e PLC da máquina, pois é mais fácil processar grande quantidade de dados neste formato do que em dados do tipo (.csv)

Na exploração os dados de máquinas foram classificados de acordo com seu tamanho e tipificação de suas variáveis, além da classificação da variável tempo.

Se tornou necessário adicionar “dias” a variável timestamp nativa do EPM servidor, já que no timestamp gerado não continha esta informação, além de que os dados estavam no formato de *string*. Resultado: YYYY-MM-DDThh:mm:ss

Na segunda etapa, de pré-processamento, se realizou a limpeza de dados (clean data), tratamento de dados faltantes (*missing values*), pontos fora da curva (*outliers*) e dados duplicados. Também foi realizado o check de inconsistências e redundâncias, para evitar nomes despadronizados. Vale destacar, que foram encontrados dados com valores *Null*, os quais foram removidos, além de tabelas adicionais geradas sem valores. Junto a isso, cabe informar que somente foram utilizadas variáveis quantitativas caracterizadas como qualidade, típicas de protocolos OPC UA no caso qualidade igual a 1, isso garante integridade dos dados (ROMRIELL et al., 2020).

Como parte da etapa também foi separado dataframes e configurados cabeçalhos e descrições, todas oriundas do servidor OPC e Sinumerik (PLC) para serem armazenadas no banco de dados SQL utilizando o EPM *Server*. Destes foram criadas as principais variáveis do projeto que estão explicadas na Quadro 4.

Quadro 4 – Conjunto de dados da máquina CEN025.

Variável	Observação	TAG
SE03_SPINDLE_VEFF_PROCESS	Energia de vibração do <i>spindle</i> durante o processo	ifm.VSE.CEN 100.Monitoring.Objects.Object01.Object Value
NUMERO_BRACO	Número do braço	/Plc/Datablock/Byte[c100,52]
ALARME_FERRAMEN TA_NAO_ACOPLADA	Alarme de ferramenta não acoplada	/Plc/Datablock/Bit[c2,201.0]
ALARME_FERRAMEN TA_NAO_ACOPLADA _POSICAO	Alarme de ferramenta não acoplada na posição	/Plc/Datablock/Bit[c2,201.1]
ALARME_FERRAMEN TA_FIXADA_INCORR ETAMENTE	Alarme de ferramenta fixada incorretamente	/Plc/Datablock/Bit[c2,203.6]
TENT_ACOPLA_FERR	Tentativa de acoplamento de ferramenta	/Plc/Datablock/Bit[c2,185.4]

Fonte: os autores.

Na terceira e última etapa do processamento, na transformação de dados se utilizou de técnicas para prever e auxiliar na identificação e entendimento de padrões. Nessa etapa foi tabelado, agrupado, identificado e padronizados os dados, sendo que na Figura 3, consta um exemplo do trabalho (YU et al., 2020).

```

# tratamento dos dados
df = pd.DataFrame()

# para cada uma das tags
for tag in tags:
    df_temp = pd.DataFrame(hdf5['Datasets'][tag][:int(1e12)])
    df_temp = df_temp[df_temp["Quality"] == 0] # seleciona apenas qualidade boa
    # transforma o timestamp para tipo datetime
    df_temp['Timestamp'] = pd.to_datetime(df_temp['Timestamp'], unit='ms') + add_days
    df_temp = df_temp.drop('IsNull', axis=1) # remove colunas com valores Null (remove tabelas adicionais sem valores)

    # retira o número do equipamento da tag
    df_temp['Equipamento'] = tag.split('_')[1]
    # retira o nome da variável da tag
    df_temp['Variável'] = tag[17:]
    # faz com que a coluna Timestamp seja o índice
    df_temp.set_index('Timestamp', inplace=True)

    # concatena a tag atual no Dataframe final
    df = pd.concat((df, df_temp))

# remove a coluna de qualidade
df = df.drop('Quality', axis=1)

```

Figura 3 – Processamento de dados. Fonte: os autores.

Na Tabela 1 consta um exemplo de uma das variáveis para a máquina piloto CEN025 o qual apresentou falha nos dois primeiros horários, valor 1 (evento) e na sequência nenhuma falha, valor 0 (não evento). Para o projeto também foi delimitado o período de análise, neste caso de 2023-01-10 até 2023-01-30. Cabe também observar que a leitura e gravação é feita a cada 3s, caso a máquina esteja em regime de operação. Isso gerou 9848 registros para 1 máquina em 20 dias de leitura (KUMARI, SAINI, 2021).

Tabela 1 – Conjunto de dados da máquina CEN025.

Data	Valor	Equipamento	Variável
2023-01-10 03:51:04	1	CEN025	ALARME_FERRAMENTA_FIXADA_INCORRETAMENTE
2023-01-10 07:39:38	1	CEN025	ALARME_FERRAMENTA_FIXADA_INCORRETAMENTE
2023-01-10 07:43:46	0	CEN025	ALARME_FERRAMENTA_FIXADA_INCORRETAMENTE
2023-01-10 18:39:49	0	CEN025	ALARME_FERRAMENTA_FIXADA_INCORRETAMENTE
2023-01-16 14:26:53	0	CEN025	ALARME_FERRAMENTA_FIXADA_INCORRETAMENTE

Fonte: os autores.

De posse dos dados estruturados, se procurou gerar modelos de identificação de falhas e de tendência de falhas utilizando-se de análise quantitativas, neste caso de alarmes a função soma, capazes de fornecer projeções com maior acurácia para reconhecer os momentos em que ocorra os alarmes, com a finalidade de se comparar os resultados com a situação online do equipamento. Para isso, se criou uma correlação para avaliar se de fato os alarmes na máquina estão precedendo um registro de intervenção no sistema de gerenciamento de produção e manutenção. Na Tabela 2, consta um exemplo da criação da correlação (PURNACHAND et al., 2021).

Tabela 2 – Concatenado de informações de alarmes e parada do equipamento.

Equipamento	Data	Registro de Parada SAP	Registro de Alarme Máquina
CEN025	2023-01-23	True	True
CEN026	2023-01-11	True	True
CEN027	2023-01-12	False	True
	2023-01-13	True	True
	2023-01-20	True	True
	2023-01-21	True	True
	2023-01-22	True	True
	2023-01-23	True	True
	2023-01-24	True	True
	2023-01-25	True	True

Fonte: os autores.

Na Tabela 2 consta uma análise qualitativa em que o código criado para tratamento de dados verifica se um alarme de máquina precede o registro de uma anomalia no ERP da empresa, aberto pela equipe de operação. Essa informação é relevante, pois nos informa a dimensão do nível de maturidade do time operacional quanto a identificação de alarmes e falhas.

Afim de aprimorar o sistema, também foi inserido os dados de vibração lidos pelo sensor localizado no *spindle* (eixo árvore) para identificar possível tendência de alarme, relacionado com aumento vibracional, contido na coluna vibração da Tabela 3 exemplificando as informações.

Tabela 3 – Concatenado de informações de alarmes e vibração do *spindle* equipamento.

Equipamento	Data	Variável	Alarme	Vibração (mms/)
CEN025	2023-01-10	SPINDLE_UNBALANCE_PROCESS	0	1,73129
	2023-01-11	SPINDLE_UNBALANCE_PROCESS	0	1,68571
	2023-01-12	SPINDLE_UNBALANCE_PROCESS	0	2,631535
	2023-01-13	SPINDLE_UNBALANCE_PROCESS	0	1,551712
	2023-01-14	SPINDLE_UNBALANCE_PROCESS	0	1,575612
	2023-01-16	SPINDLE_UNBALANCE_PROCESS	0	1,596629
	2023-01-17	SPINDLE_UNBALANCE_PROCESS	0	1,667298
	2023-01-18	SPINDLE_UNBALANCE_PROCESS	0	1,636039

Fonte: os autores.

4. Resultados.

Com a aplicação dos dados de leitura dos alarmes foi possível conhecer os braços e equipamentos que mais geram falha. Esse indicador mostra um comportamento passado dos dados. Por outro lado, é importante identificar se a tendência para esses alarmes está diminuindo ou aumentando no tempo presente. Dessa forma, é possível identificar se alguma ação está sendo tomada para corrigir o problema. Portanto, um cálculo da tendência foi elaborado, para ser executado no ambiente EPM Processor através de algoritmo em *Python*.

A tendência será a inclinação de uma reta ajustada para o número de alarmes nos últimos 3 dias. Se a tendência tem valor 2, por exemplo, isso indica que para os últimos 3 dias, o número de alarmes aumentou em média em 2 para cada dia. Para o próximo dia, se a tendência se mantém, o número de alarmes será o do dia anterior mais 2. O indicador pode retornar valor negativo, o que indica que a tendência no número de alarmes está diminuindo.

A tendência no número de alarmes é calculada diariamente para cada braço de cada máquina à meia noite. O cálculo do indicador só é executado caso o número de alarmes para o braço nos últimos 3 dias seja pelo menos igual a 1. Se o número de alarmes é menor que 1, a tendência não é salva e nenhum valor é salvo para o braço. Se nenhum dos braços da máquina apresenta pelo menos 1 alarme, então não é salvo valor na variável para aquele dia.

O formato de salvamento é, por exemplo, “2:4.2, 9:-1.4”. Essa *string* indica que, para os últimos 3 dias, a tendência de alarme para o braço 2 é 4,2 e para o braço 9 é -1,4. De forma, a economizar o número de *tags* utilizada no servidor, a resposta é salva na forma de *string*, pois se a tendência fosse salva em uma variável do tipo *float*, por exemplo, seria necessária uma *tag* por braço para cada máquina. Nesse caso, é utilizada apenas uma *tag* por máquina, com a informação de todos os braços.

A contagem de alarmes por dia deverá ser a *array* $y = [1, 2, 3]$ para o número de alarmes e *array* $x = [0, 1, 2]$ para os dias. Essas duas *arrays* são utilizadas como entradas para a função *linregress* da biblioteca *scipy*, que ajusta uma reta utilizando o método de mínimos quadrados ou OLS (do inglês *Ordinary Least Squares*). Sendo assim, se partiu da equação linear de uma reta, sem termo de erro conforme equação abaixo.

$$Y_i = \alpha + \beta \cdot x_i \quad (1)$$

Tem-se um intercepto (α), um coeficiente de inclinação da reta (β) e uma variável explicativa x . Para o cálculo, o resultado da função é a inclinação da reta (β), o intercepto (α). Dessa forma, no estudo a equação para o ajuste linear é dada por:

$$n_{\text{alarmes}_{\text{dia}}} = \beta * \text{dia} + \alpha \quad (2)$$

Após criados as funções e os script, os códigos foram rodados no software EPM Processor, um módulo que possibilita que algoritmos escritos em linguagem *Python* sejam colocados em execução automatizada ou sob demanda de evento. O mesmo possui conexão nativa com o EPM server, na qual é possível fazer inferências relacionados as variáveis de processo coletadas e também prototipar os modelos de aplicação. O uso de ambos os *softwares* foi essencial em todas as etapas apresentadas na metodologia desta pesquisa (HASSAN et al., 2021).

Como etapa subsequente, foram elaborados painéis (*dashboards*), com resumos das análises, para utilização pela equipe de engenheiros e técnicos, afim de definir as ações a serem executadas nos equipamentos e, assim subsidiar os processos de tomada de decisão. Afim de se tornar mais visual estas etapas, foi criado a imagem abaixo, conforme Figura 4, com o fluxo de trabalho e recursos aplicados.

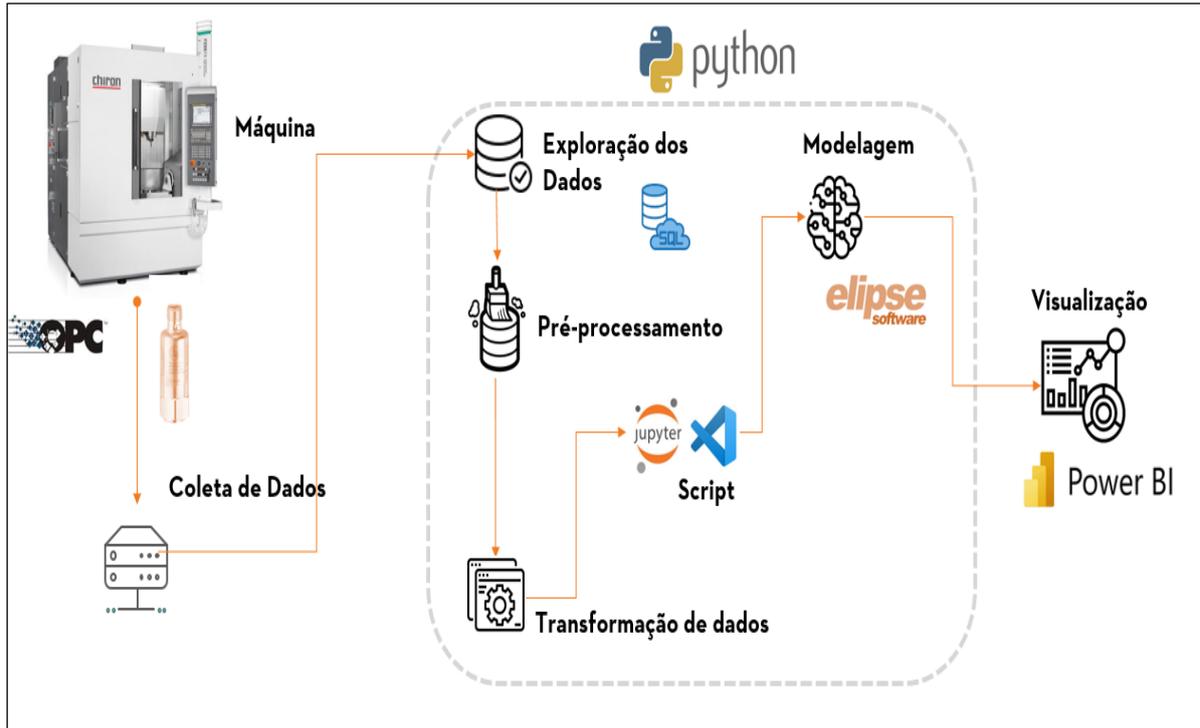


Figura 4 – Fluxo de Trabalho de Monitoramento e Predição CHIRON. Fonte: os autores.

A informação contendo os alarmes de falhas, máquina, dia, hora e braço ferramenta conforme mencionado na seção anterior foram extraídos diretamente dos dados máquinas de 5 equipamentos piloto. São eles: CEN025, CEN026, CEN027, CEN035, CEN036.

Cada máquina de usinagem da fabricante CHIRON de modelo FZ15, com velocidade de rotação de 20.000 rpm e velocidade do posicionamento rápido em X, Y e Z de 75m/min, produz 41 cilindros de alumínio usinado por hora para modelos de motores de combustão de dois tempos, com uma produção anual superior a 7 milhões de cilindros por ano. Desta forma, qualquer interrupção no processo produtivo pode ter um impacto significativo para o negócio da empresa.

Esta atividade culminou com a disponibilização de um banco de dados de conteúdo de 6 meses, com informações diárias e até mesmo a cada hora, para o ano de 2023.

Com os scripts em *Python* rodando no servidor EPM OPC UA, os dados foram coletados automaticamente e de maneira *online* disponibilizado no *software PowerBI*. Dados pertinentes ao status de máquina e falhas no magazine são acessados conforme instrução do SQL no *PowerBI* de acordo com o Quadro 5.

Quadro 5 – Status de máquina e falhas no magazine.

```
SELECT Name, Timestamp, Quality, intval(Value) FROM EpmQueryRawFunction (-3, '2023-01-01
00:01:00','2023-03-31 23:59:00', 0, 1,
SINUMERIK_CEN025_ALARME_FERRAMENTA_NAO_ACOPLADA') UNION
SELECT Name, Timestamp, Quality, intval(Value) FROM EpmQueryRawFunction (-3, '2023-01-01
00:01:00','2023-03-31 23:59:00', 0, 1,
'SINUMERIK_CEN025_ALARME_FERRAMENTA_NAO_ACOPLADA_POSICAO') UNION
SELECT Name, Timestamp, Quality, intval(Value) FROM EpmQueryRawFunction (-3, '2023-01-01
00:01:00','2023-03-31 23:59:00', 0, 1,
'SINUMERIK_CEN025_ALARME_FERRAMENTA_FIXADA_INCORRETAMENTE')
# identifica se houve ou não parada no dia para cada máquina
```

```

df_zu_n_alarmes = deepcopy(df_zu)
df_zu_n_alarmes =
df_zu_n_alarmes.groupby('Equipamento').resample('1D').sum().astype('bool')
df_zu_n_alarmes.head()
# concatena a df das parada com a df dos alarmes
df_alarmes_por_dia_bool =
df_alarmes.groupby('Equipamento').resample('1D').sum().astype('bool')
df_join = df_zu_n_alarmes.join(df_alarmes_por_dia_bool,
how='outer').rename(columns={'Value':'Alarme'}).fillna(False)
df_join.head(10)
# crosstab entre parada e alarmes
pd.crosstab(df_join['ZU'], df_join['Alarme'])

```

Fonte: os autores.

Após importado, a Figura 5 apresenta uma amostra das informações tabeladas de maneira bruta.

	A ^B C name	timestamp	1 ² 3 quality	1 ² 3 intval(Value)
266	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:13:35	0	1
267	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:14:58	0	1
268	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:16:21	0	1
269	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:17:44	0	1
270	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:19:08	0	1
271	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:20:31	0	1
272	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:21:53	0	1
273	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:23:16	0	1
274	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:24:39	0	1
275	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:26:02	0	1
276	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:27:25	0	1
277	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:28:48	0	1
278	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:30:11	0	1
279	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:31:34	0	1
280	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:32:57	0	1
281	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:34:20	0	1
282	SINUMERIK_CEN_025_NUMERO_...	06/01/2023 11:35:42	0	1

Figura 5 – Dados brutos de máquina expostos no PowerBI. Fonte: os autores.

Com a finalidade de facilitar a análise e interpretação visual das informações foram editados os dados brutos no *Power Query*, separando assim as falhas por data, máquina, braço (magazine), além de agrupar os tipos de falhas, pois todas elas possuem o mesmo efeito, no caso a interrupção do equipamento.

Na Figura 6, consta o resultado final da tabela, para ser utilizada como base para montagem dos gráficos.

Tag	Timestamp	Value	Braço	Máquina	Nome Alarme	Data
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	03/03/2023 13:20:00	9	9	CEN_026	CEN_026_BR9	sexta-feira, 3 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	03/03/2023 17:50:00	9	9	CEN_026	CEN_026_BR9	sexta-feira, 3 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	04/03/2023 08:10:00	9	9	CEN_026	CEN_026_BR9	sábado, 4 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	04/03/2023 09:30:00	9	9	CEN_026	CEN_026_BR9	sábado, 4 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	04/03/2023 09:50:00	9	9	CEN_026	CEN_026_BR9	sábado, 4 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	04/03/2023 21:30:00	9	9	CEN_026	CEN_026_BR9	sábado, 4 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	06/03/2023 13:20:00	9	9	CEN_026	CEN_026_BR9	segunda-feira, 6 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	06/03/2023 17:30:00	9	9	CEN_026	CEN_026_BR9	segunda-feira, 6 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	06/03/2023 20:20:00	9	9	CEN_026	CEN_026_BR9	segunda-feira, 6 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	06/03/2023 23:40:00	9	9	CEN_026	CEN_026_BR9	segunda-feira, 6 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	07/03/2023 00:10:00	9	9	CEN_026	CEN_026_BR9	terça-feira, 7 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	07/03/2023 10:10:00	9	9	CEN_026	CEN_026_BR9	terça-feira, 7 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	07/03/2023 17:00:00	9	9	CEN_026	CEN_026_BR9	terça-feira, 7 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	07/03/2023 20:40:00	9	9	CEN_026	CEN_026_BR9	terça-feira, 7 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	08/03/2023 01:40:00	9	9	CEN_026	CEN_026_BR9	quarta-feira, 8 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	08/03/2023 02:50:00	9	9	CEN_026	CEN_026_BR9	quarta-feira, 8 de março de 2023
PROC_LATOS_CEN_026_ALARME_BRACO_DETAILS	08/03/2023 04:20:00	9	9	CEN_026	CEN_026_BR9	quarta-feira, 8 de março de 2023

Figura 6 – Dados prontos para construção dos Dashboards. Fonte: os autores.

Como etapa subsequente se criaram painéis de informações (*Dashboards*) para identificar quais máquinas apresentavam alarme e conseqüente falha no equipamento, exemplificado conforme Figura 7.

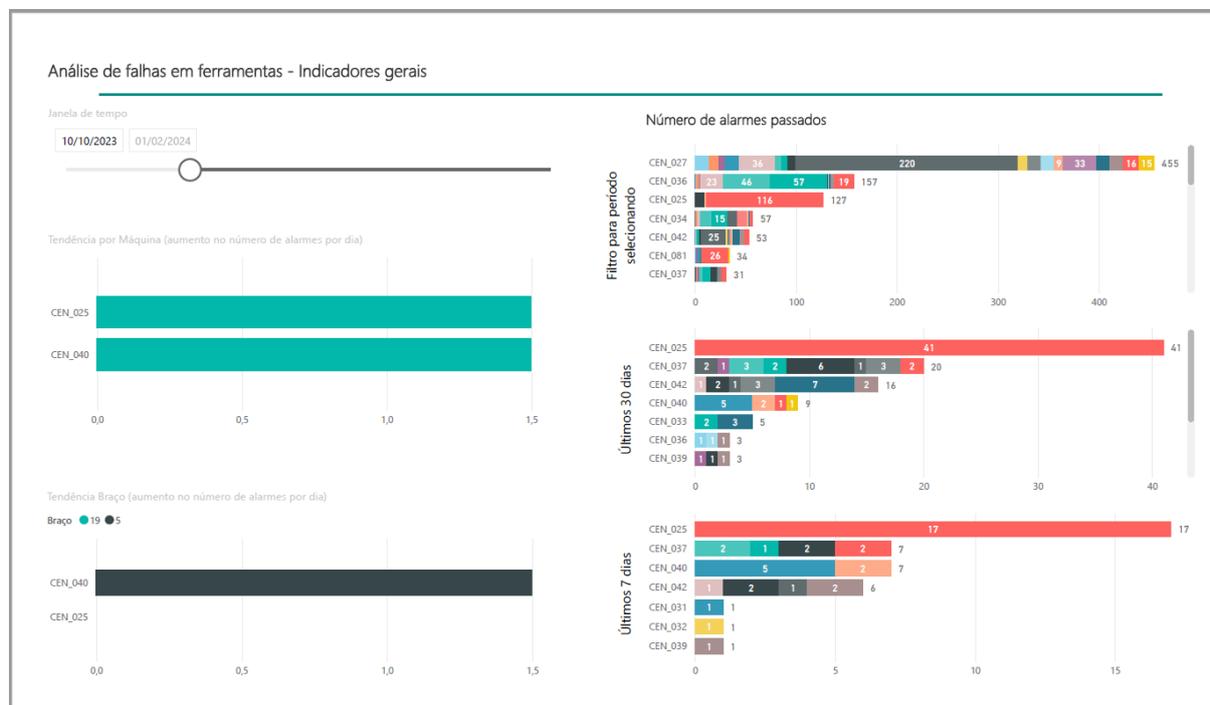


Figura 7 - Dashboards para tomada de decisão. Fonte: os autores.

Para cada alarme é considerado uma interrupção no equipamento, no qual o operador deveria acionar a equipe de técnicos de manutenção para solucionar a causa raiz da falha. No entanto, em muitos casos, a equipe de operação, por motivos variados, acaba por não informar e relatar a falha na máquina,

com isso propiciando aumento da perda de produção e potencializando novas falhas e deterioração dos componentes mecânicos do magazine de ferramentas.

Para ilustrar a situação relatada, se observa na Figura 8 que o centro de usinagem 27, CEN027 apresentava o maior número de falhas, sendo o braço de ferramenta 6 o de maior número de falhas, 13 no total, gerando 13 interrupções de produção em um tempo total de 65 minutos. Isso gerou um impacto de perda de 44 cilindros no dia, reduzindo a capacidade de produção em 5,2% e gerando uma perda financeira de R\$ 22.777,92 no contábil de 2023, além de uma despesa de R\$ 8.932,34 devido ao componente produzir de maneira desregulada.

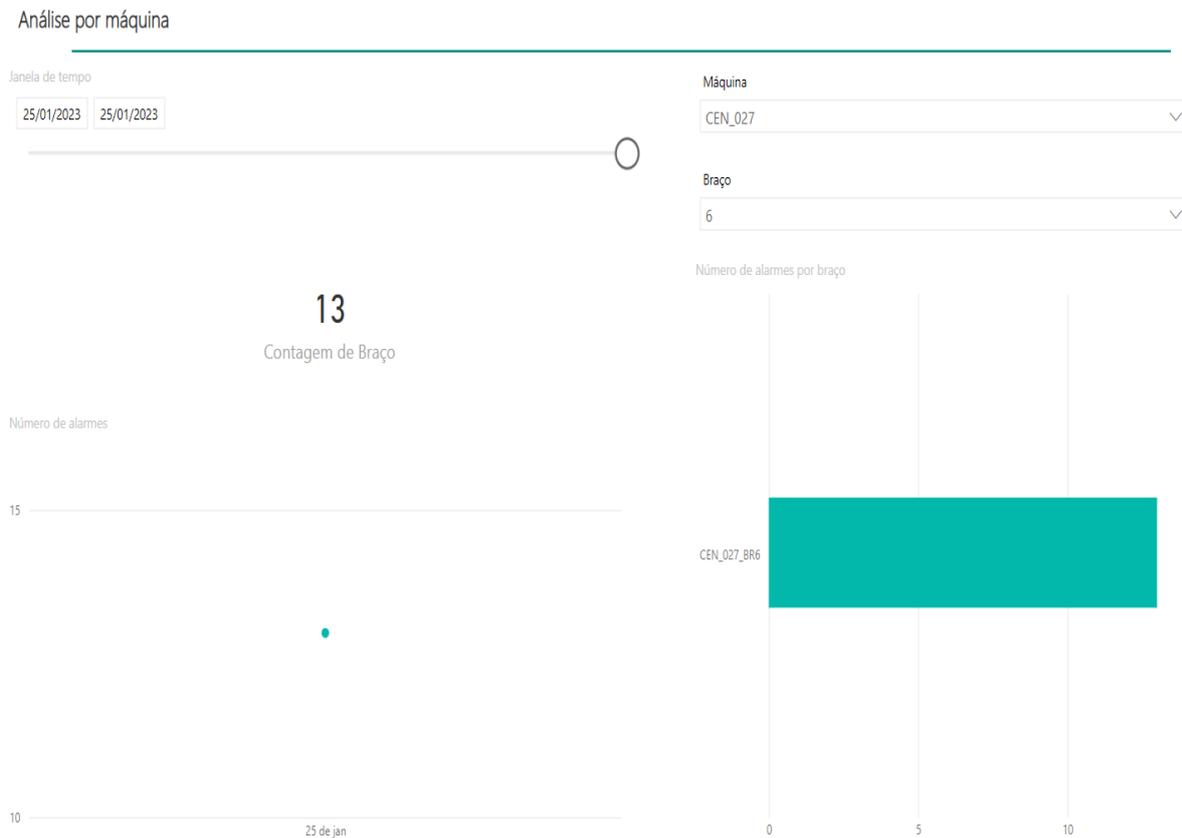


Figura 8 – Painel de Visualização de Falha na máquina CEN027, sendo o braço 6 BR6 com maior número de interrupção. Fonte: os autores.

A falha somente teve registro gerado pela operação, após a décima terceira ocorrência, abrindo uma notificação no sistema de gerenciamento de produção e manutenção, quando as paradas já estavam recorrentes. Desta forma, devido à falta de informação o custo e as perdas foram potencializados.

No dia seguinte, em 26/01/2023 foi acompanhado a tendência de falha, logo quando ocorreu a primeira falha, conforme Figura 9, foi possível direcionar o técnico de manutenção ao equipamento e assim realizar a intervenção para o problema não mais se repetisse, garantindo uma confiabilidade maior e disponibilidade do equipamento.

	TimeStamp	Maquina_Braço	Total
1	26/01/2023 13:30:00	CEN_027_Braço_6	1

Figura 9 – Alarme CEN027 em 26/01/2023. Fonte: os autores.

Na Figura 10 pode-se constatar que a partir da primeira intervenção no dia 26/01/2023 no centro de usinagem CEN027 Braço 6, não foi registrado mais alarme, garantindo assim a eficácia da ação do técnico de manutenção bem como a aplicabilidade do método empregado para identificação.

Análise por máquina

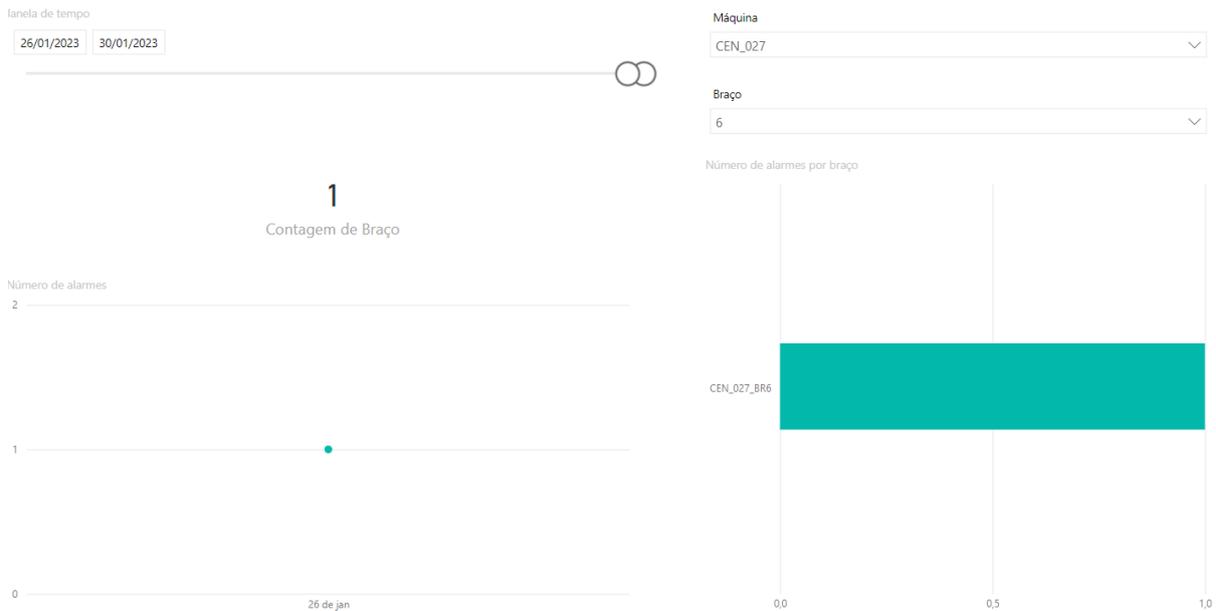


Figura 10 – Painel de Visualização de Alarme CEN027 – Braço 6 - 26/01/2023 até 30/01/2023. Fonte: os autores.

Afim de colaborar com decisão de que a aderência dos alarmes possa ter relação direta com o registro de parada do equipamento, se buscou avaliar a acuracidade dos dados.

Para isso se usou a matriz confusão, que nada mais é do que uma tabela que permite avaliar o desempenho de um algoritmo frente aos seus acertos e erros. Na Tabela 4 abaixo, temos o modelo da matriz.

Tabela 4 – Matriz de Confusão.

		Classe Preditada	
		Classe 1(0)	Classe 2 (1)
Classe Real	Classe 1(0)	Verdadeiro Negativo (False, False - FF)	Falso Positivo (True, False - TF)
	Classe 2 (1)	Falso Negativo (False, True - FT)	Verdadeiro Positivo (True, True - TT)

Fonte: Bruce e Bruce (2019).

- Verdadeiro Positivo [TT]: o resultado é classificado como positivo e é predito corretamente como positivo pelo modelo;
- Verdadeiro Negativo [FF]: o resultado é classificado como negativo e é predito corretamente como negativo pelo modelo;
- Falso positivo [TF]: o resultado é classificado como negativo e é predito incorretamente como positivo
- Falso Negativo [FT]: o resultado é classificado como positivo comparativo e é predito incorretamente como negativo pelo modelo.

Portanto, aplicada a regra desenvolvida, tem-se a Tabela 5 onde consta o número de dias que se teve alarme e o chamado de manutenção (*True, True*), dias em que se teve apenas alarme (*True, False*), dias em que se teve apenas chamado de manutenção (*False, True*) e dias que não se teve nenhum dos dois casos no dia (*False, False*).

A análise é feita para cada uma das máquinas, no exemplo consta apenas da CEN027 conforme a Tabela 5. Quanto mais exemplos existirem na diagonal principal (ambos ou nenhum), maior é a relação entre os alarmes e registros de manutenção.

Tabela 5 – Análise de acurácia de eventos CEN027 em unidades brutas em 15 dias.

Alarme	<i>False</i>	<i>True</i>
Registro de Parada SAP		
<i>False</i>	16	12
<i>True</i>	0	5

Fonte: os autores.

Desta forma, foi também criado uma função no algoritmo para normalizar os valores finais, para que formem a soma de 1 na diagonal, validando a análise e o quanto ele acertou de acordo com a equação a seguir, sendo que seguem a descrição da Tabela 4:

$$Acurácia = \frac{FF+TT}{FF+TT+TF+FT} \quad (3)$$

Com isso, tem-se a fração em cada caso e não apenas na contagem, assim podendo ter a acurácia que é a fração dos exemplos na diagonal principal. Desta forma, o resultado fica com acurácia de 63,6% de acordo com Tabela 6. Sendo que, em 12 ocasiões, registros de alarme foram feitos, ou seja, a máquina parou, mas não foram notificados pela equipe operacional. Caso o problema fosse identificado previamente como realizado no dia 26/01/2023 as paradas não haveriam ocorrido e o custo evitado com troca de peças seria desnecessário.

Tabela 6 – Análise de acurácia de eventos normalizada.

Alarme	<i>False</i>	<i>True</i>
Registro de Parada SAP		
<i>False</i>	0,484	0,363
<i>True</i>	0,000	0,151

Fonte: os autores.

Deste modo, as informações acima colaboram para trabalhar na causa raiz de se evitar a não notificação da parada do equipamento, bem como em atender preventivamente, assim que ocorrer o primeiro alarme, gerando um ganho produtivo e financeiro.

Endossando o trabalho preventivo, no mês de março de 2023, obteve-se o melhor registro de acuracidade, conforme Figura 11, onde somente 2 alarmes não tiveram registro de pronto atendimento, mostrando ainda oportunidades junto com a identificação e solução das falhas, mas demonstrando avanço na eliminação de interrupções e no trabalho preditivo.

```

28 | CEN027
29 | Alarme  False  True
30 | ZU
31 | False    4      2
32 | True     0      24
33 |
34 | Normalizado
35 | Alarme    False    True
36 | ZU
37 | False    0.133333  0.066667
38 | True     0.000000  0.800000
39 |
40 | Acurácia: 0.93

```

Figura 11 – Matriz de Confusão CEN027 criada em *Python* - Março de 2023. Fonte: os autores.

A função para identificação ficou sendo definida conforme demonstrado no Quadro 6:

Quadro 6 – Função para identificação.

```
# identifica se houve ou não parada no dia para cada máquina
df_zu_n_almes = deepcopy(df_zu)
df_zu_n_almes = df_zu_n_almes.groupby('Equipamento').resample('1D').sum().astype('bool')
df_zu_n_almes.head()
# concatena a df da parada com a df dos alarmes
df_almes_por_dia_bool =
df_almes.groupby('Equipamento').resample('1D').sum().astype('bool')
df_join = df_zu_n_almes.join(df_almes_por_dia_bool,
how='outer').rename(columns={'Value':'Alarme'}).fillna(False)
df_join.head(10)
# crosstab entre parada e alarmes
pd.crosstab(df_join['ZU'], df_join['Alarme'])
```

Fonte: os autores.

Com a finalidade de poder gerar e ter uma previsibilidade da saúde do equipamento CEN027, foi aplicado no projeto uma correlação para tentar identificar potencial tendência do aumento de vibração do *spindle* da máquina com o aumento de alarmes. No entanto, conforme Figura 12, não se pode notar uma reta na diagonal do gráfico abaixo, indicando que possa haver uma relação linear, já que o declive da linha reta seria igual a correlação em os eixos X e Y.

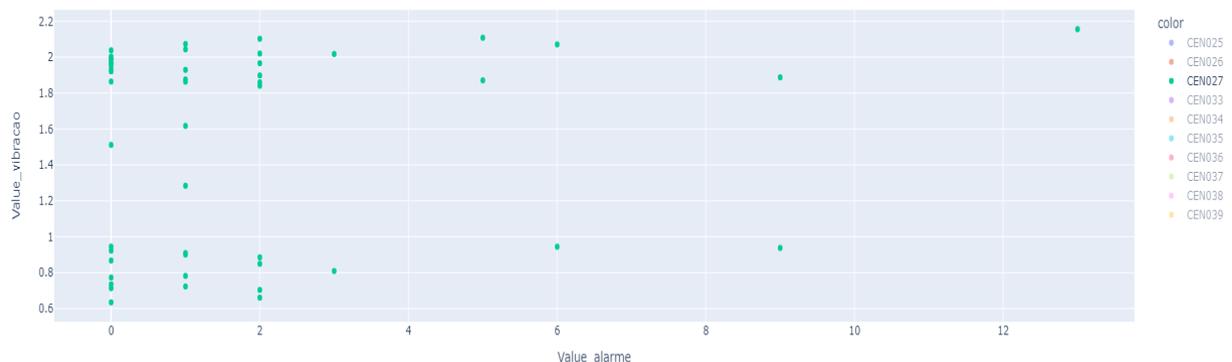


Figura 12 – Análise de Vibração e alarme CEN027. Fonte: os autores.

A mesma avaliação também se aplica quando tenta-se identificar alguma relação entre alarme e alguma variável de vibração em XYZ do sensor, pois não parece haver uma grande diferença entre a variância na imagem dos gráficos de *boxplot* da Figura 13, identificando-se comportamentos distintos de vibração.

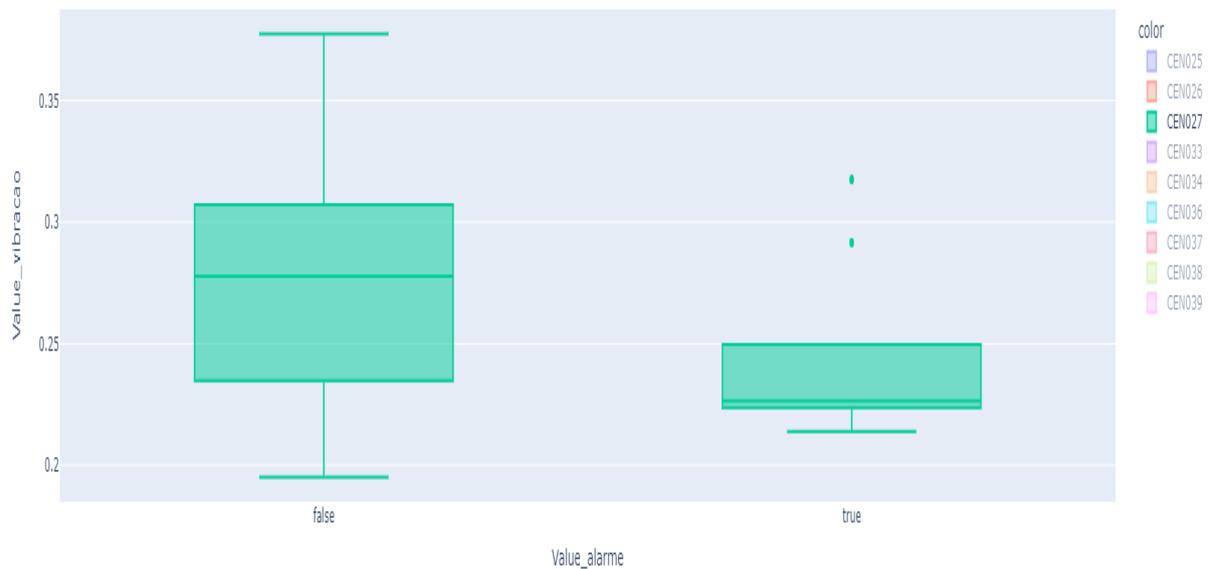


Figura 13 – *Boxplot* Análise de Vibração e alarme CEN027. Fonte: os autores.

Não sendo possível obter relação com aplicação de regressão linear simples com uso de vibração, se optou em criar um algoritmo de regressão linear chamado de TREND, utilizando o evento histórico da ocorrência dos próprios alarmes ao invés da vibração. O algoritmo tem a finalidade de calcular a tendência de falha por dia em cada braço. Na Figura 14 consta parte do script deste algoritmo.

```
def slope_eval(df):
    """ Função que calcula a inclinação no número de alarmes.
    """
    # cria o índice com a data dos últimos dias
    t_index = pd.DatetimeIndex(pd.date_range(start=dia_inicio, end=today, freq="1D"))

    # reamostragem diária para os dados e soma o número de alarmes
    df_resample = df.resample('1D').count().reindex(t_index).fillna(0)
    df_resample.index = df_resample.index.date
    print(df_resample['alarm'][:-1])

    # define x e y para a regressão (são os eixos do gráfico)
    y = df_resample['alarm'].values[:-1]
    x = np.arange(len(y))

    # calcula os parâmetros ajustados para a reta
    slope, intercept, r_value, p_value, std_err = stats.linregress(x, y)

    # retorna a inclinação
    return slope

# inicia a variável que guarda os resultados
res = {}

# define o dia de início dos dados (hoje - days_scan)
dia_inicio = today - dt.timedelta(config['days_scan'])
print(f'Início dos dados: {dia_inicio}\t Fim dos dados: {today}')
```

Figura 14 – Código algoritmo *TREND*. Fonte: os autores.

O Modelo TREND é baseado na função algébrica de regressão linear simples, mas não pode ser usada puramente, devido a necessidade de base histórica. Não sendo possível obter relação com aplicação de regressão linear simples com uso de vibração e demonstrado a falta de correlação, se optou em criar um algoritmo de regressão linear simples chamado de TREND, utilizando o evento histórico da ocorrência dos próprios alarmes, ao invés da vibração. O algoritmo tem a finalidade de calcular a tendência de falha por dia em cada braço usando por base a regressão linear. Dessa forma, é possível identificar se alguma ação foi tomada para corrigir a falha.

A tendência é a inclinação de uma reta ajustada para o número de alarmes nos últimos 3 dias. Se tendência tem valor 2, por exemplo, isso indica que para os últimos 3 dias, o número de alarmes

aumentou em média em 2 alarmes para cada dia. Para o próximo dia, se a tendência se mantém, o número de alarmes será o do dia anterior mais 2. O indicador pode retornar valor negativo, o que indica que a tendência no número de alarmes está diminuindo.

O cálculo do indicador só é executado, caso o número de alarmes para o braço nos últimos 3 dias seja pelo menos igual a 3. Se o número de alarmes é menor que 3, a tendência não é salva e nenhum valor é salvo para o braço. Se nenhum dos braços da máquina apresenta pelo menos 3 alarmes, então não é salvo valor na variável para aquele dia, não calculando a tendência.

O formato de salvamento no banco de dados é, por exemplo, “2:4.2, 9:-1.4”. Essa *string* indica que, para os últimos 3 dias, a tendência de alarme para o braço 2 é 4,2 e para o braço 9 é -1,4.

As regras para o cálculo ficam de acordo com o seguinte exemplo da Tabela 7 e de acordo com a seção material e métodos:

Tabela 7 – *Trend* Positiva.

CEN025 - Braço 8 Data	Horário	Alarmes
25/11/2023	12:00	1
26/11/2023	11:00	1
26/11/2023	12:10	1
26/11/2023	13:40	1
27/11/2023	15:00	1
27/11/2023	15:20	1
27/11/2023	16:00	1
27/11/2023	16:10	1
27/11/2023	16:40	1
Resultado		1

Fonte: os autores.

O valor da tendência será 2, já que o número de alarmes cresce em 2 por dia. O algoritmo conta o número de alarmes por dia e esta contagem gera dois vetores, alarme e dia, esses dois vetores, ou *arrays*, como chamado na função *linregress* da biblioteca *scipy* usada em *Python*, são utilizadas como entrada para utilização no ajuste da reta.

Vale informar que, nem sempre a tendência é tão exata como no caso acima. De forma geral, o algoritmo ajusta uma reta ao número de alarmes. A tendência é a inclinação dessa reta. A tendência pode ser tanto negativa quanto positiva. Abaixo na Tabela 8 o resultado calculado para um equipamento.

Tabela 8 – *Trend* Positiva.

CEN025 - Braço 8 Data	Alarmes
12/01/2023	6
13/01/2023	2
14/01/2023	1
Resultado	-2,5

Fonte: os autores.

No cálculo é utilizado uma tendência considerando 3 dias passados, que no caso foi o período de maior amostragem de repetição de alarmes. O número mínimo de alarmes será de 2, visto que com 1 dado não é possível calcular a inclinação da reta. A amostragem será sempre diária considerando os 3 dias anteriores. O algoritmo sempre conta o número total de alarmes por braço, bem como o número de alarmes por dia.

Para ajudar na validação deste caso se observa a Figura 15 onde se demonstra uma tendência positiva na máquina CEN026 referente ao braço 9 e isso tem correlação quando avaliado com a Figura 16, onde realmente há um aumento de alarmes.

Desta forma, se usado de maneira preventiva, quando não há vários alarmes no mesmo dia, como ocorreu no caso da CEN027 e caso seja observado uma tendência de alarmes negligenciados, pode-se criar uma previsão de falhas para informar o corpo técnico de que o equipamento necessita de

uma correção, para assim se evitar uma interrupção não planejada na produção que gere perda financeira e despesas desnecessárias.

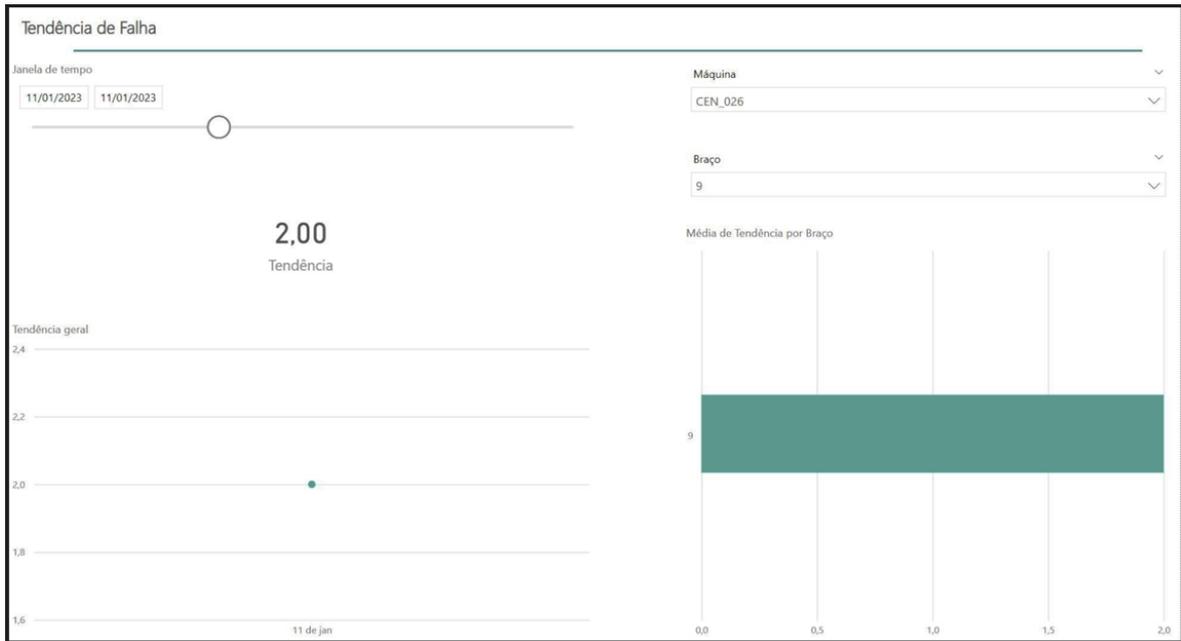


Figura 15 – Painel de Visualização de Tendência de falha positiva - CEN026 Braço 9. Fonte: os autores.

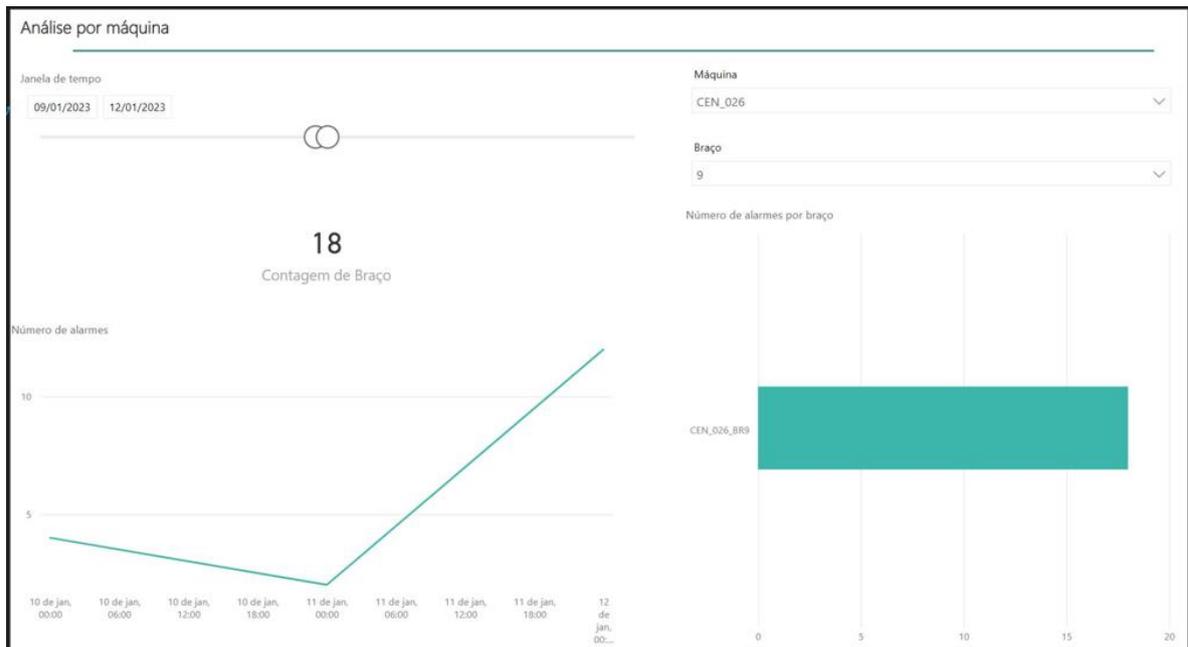


Figura 16 – Painel de Visualização de Alarme de máquina - CEN026 Braço 9. Fonte: os autores.

A Figura 15 mostra visualmente o resultado da tendência e a Figura 16 mostra um outro painel gráfico com dados da quantidade de alarmes de uma determinada máquina em um determinado período de tempo (no caso a mesma máquina). A ideia foi explorar as análises gráficas de diferentes painéis gráficos.

No exemplo abaixo da Figura 17, apresenta-se o alarme ocorrendo na máquina CEN025, braço 8. Quando se observa o gráfico de tendência, vê-se o valor de 2,50, indicando que o algoritmo identificou um aumento de alarmes. Desta forma, indicando a necessidade de intervenção.

No dia 08.03.2023 com base na informação a equipe atuou e solucionou a falha, fazendo então com que o algoritmo iniciasse a regressão até zerar, no dia 11.03.2023 de acordo com Figura 18.

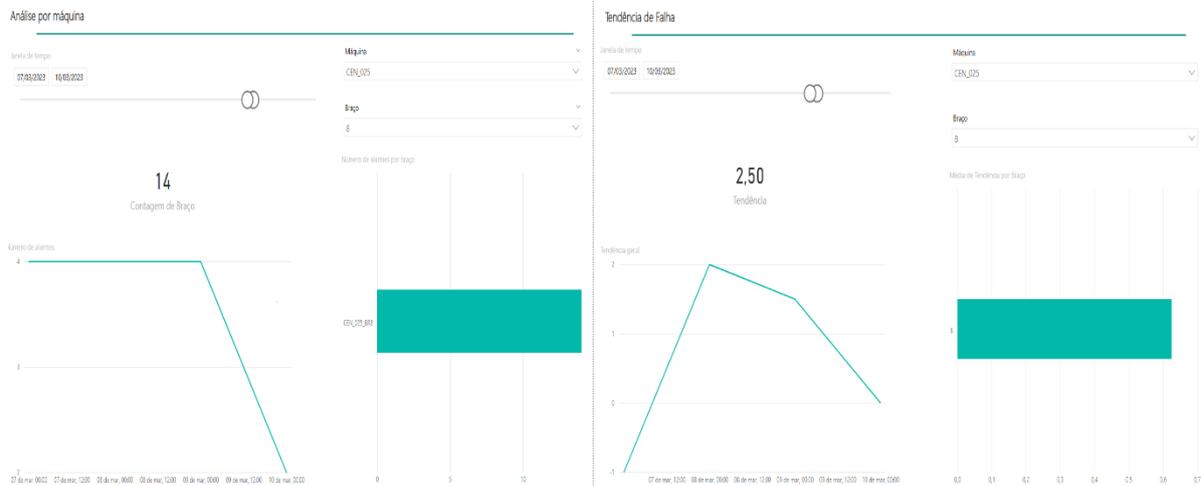


Figura 17 – Alarme máquina CEN025 Braço 8 e Tendência máquina. Fonte: os autores.

```
... Output exceeds the size limit. Open the full output data in a text editor
Início dos dados: 2023-03-09 00:00:00 Fim dos dados: 2023-03-12 00:00:00

Máquina CEN025 Braço 8
Número de alarmes encontrados: 6
2023-03-09 3.0
2023-03-10 3.0
2023-03-11 0.0
Name: alarm, dtype: float64
Slope: -1.5
```

Figura 18 – Regressão na tendência na máquina CEN025 Braço 8. Fonte: os autores.

Frente aos resultados preliminares positivos na geração de alarmes e tendência, procurou-se disponibilizar as informações de alarme e tendência em tempo Real para a oficina de manutenção onde os técnicos atuam, para que assim possam também, de posse da informação, já atuar para realizar as atuações preventiva. No entanto, a solução de visualização dos resultados e *Dashboards*, *PowerBI*, disponibilizada pela empresa é apenas na versão *Desktop*, não contando com um servidor e estrutura dedicada para este fim.

Com isso, se avaliou soluções *opensource* de visualização de dados e se optou pelo Grafana, *software* livre, de fácil instalação e que possui interface SQL que pode se comunicar com o servidor da empresa.

Após instalado e configurado, foi necessário apenas corrigir a consulta ao servidor SQL, conforme Quadro 7 e então elaborar a gestão visual dos gráficos, da mesma forma do que o aplicativo no *PowerBI* e como resultado se tem a Figura 19, identificado os alarmes e tendências.

Quadro 7 – Correção a consulta ao servidor SQL.

```
SELECT TOP 10 Maquina_Braco, COUNT(Maquina_Braco) AS Total FROM [dbo].[fnAlarmesBracoTodasCEN] ($__timeFrom(),$__timeTo()) GROUP BY Maquina_Braco ORDER BY COUNT(Maquina_Braco) DESC
```

Fonte: os autores.

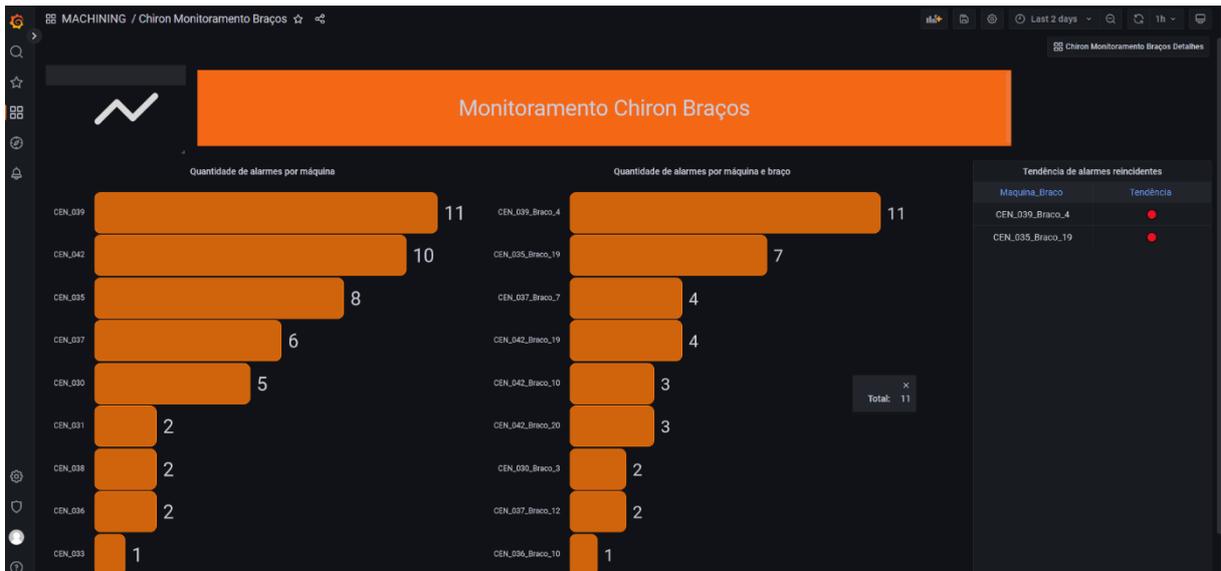


Figura 19 - *Dashboard* desenvolvido no Grafana para gestão *online* da equipe da fábrica.

Fonte: os autores.

5. Discussão.

A transformação digital aplicada na empresa estudada, com os sistemas de automação também digital, veio abrir o campo para a instalação de sensores nas máquinas e em todos os sistemas operacionais. Os dados transmitidos pelas máquinas para bancos de dados de enorme capacidade de armazenamento, e com um sistema de computação baseado em *Machine Learning* e grande capacidade de processamento, propiciaram condições de análise de uma série de variáveis que até então não eram monitoradas e que por sua vez estudados e analisados com ferramentas da ciência de dados, geraram plena condições de prognósticos em tempo real, reduzindo custo, aumentando a disponibilidade de equipamentos e gerando previsibilidade de falhas e de recursos necessários.

As estratégias de manutenção tornaram-se mais claras, pois com o diagnóstico em tempo real a manutenção preventiva por tempo deixa de fazer sentido e abre espaço para manutenção preditiva, baseada em dados e na tendência de falhas, mas principalmente na manutenção prescritiva, onde tem-se a análise avançada de alto volume de dados, que prescrevem as possíveis causas e o que deve ser realizado.

Deve-se ter em mente que este tipo de trabalho, onde se envolva monitoramento *online* de dados de máquina com o objetivo de coletar, periodicamente, de forma automática e remota, parâmetros das máquinas (alarmes, temperatura, vibração, ruído, corrente, tensão etc.) buscando identificar anomalias significativas, vem evoluindo rapidamente com novas tecnologias e ferramentas, como destacado neste trabalho, onde soluções de vanguarda em *hardware* e *software* foram integrados com conhecimento nas melhores práticas de *Data Science and Analytics*.

Assim, foi possível aplicar e analisar *in loco* algumas das tecnologias de vanguarda do mundo real, num complexo de usinagem (manufatura) de uma empresa instalada no Brasil e analisar os dados

coletados, transformando-os em informações essenciais, para a tomada de decisão, como a literatura sobre o tema aborda.

A Figura 20 apresenta uma análise envolvendo o uso de tecnologias da Indústria 4.0, na manufatura, visando melhorar o desempenho da área de manutenção, comparado ao sistema tradicional. A figura visa a comparação de sistema *online* contra um sistema tradicional de manutenção, com necessidade da intervenção de um operador, técnico de manutenção ou de medições *offline*.

Entende-se tradicional com base em elementos, oriundo do TPM (Manutenção Produtiva Total) ou em sistemas com base no RCM (Manutenção Centrada em Confiabilidade).

	
<p style="text-align: center;"><u>Maior Disponibilidade de Máquina</u></p> <p>Quanto menor o tempo de máquina parada, maior o tempo de máquina produzindo e maior a produção. </p> <p style="text-align: center;"><u>Redução dos Custos de Manutenção</u></p> <p>O quanto antes se antecipar às falhas, mais rápido será o atendimento, minimizando ou eliminando qualquer impacto. </p> <p style="text-align: center;"><u>Maior Velocidade na Tomada de Decisão</u></p> <p>O sistema confere rápida análise de dados e em larga escala, evitando dependência de informação da operação. </p> <p style="text-align: center;"><u>Menor Perda por Deslocamento</u></p> <p>Coleta e análise em tempo real, sem exigir deslocamento, e tempo para a tomada de decisão. </p> <p style="text-align: center;"><u>Redução de Falha por Diagnóstico</u></p> <p>Falha prescrita, sem a necessidade de identificar onde está a falha. </p> <p style="text-align: center;"><u>Maior Eficiência nas Análises</u></p> <p>O que for identificado no sistema se enquadra num padrão e as ações para melhorar ou estender a vida útil das máquinas são mais práticas. </p> <p style="text-align: center;"><u>Progresso Científico e Tecnológico</u></p> <p>Nova abordagem de aplicação de redução de falhas para sistema de manufatura. </p>	<p style="text-align: center;"><u>Dependência Excessiva de Tecnologia</u></p> <p>Se houver falhas nos sistemas integrados de Tecnologia da Informação o sistema ficará inativo. </p> <p style="text-align: center;"><u>Maior Infraestrutura de Rede</u></p> <p>Necessidade de recursos de rede para armazenar e estruturar dados. </p> <p style="text-align: center;"><u>Complexidade</u></p> <p>Modelos tradicionais de inspeção e manutenção preditiva são mais simples. Eles já são conceituados no mercado de serviços. </p> <p style="text-align: center;"><u>Falta de Conhecimento Geral</u></p> <p>Maior necessidade de capacitação em informática industrial, análise e ciência de dados. </p>

Figura 20 – Sistema *online* x sistema tradicional. Fonte: os autores.

6. Conclusões.

O tema deste projeto foi desenvolvido pela necessidade de solução de um problema latente que a área de engenharia de manutenção da empresa, identificou para implementar em sua fábrica de cilindros de combustão dois tempos, especificamente na área de usinagem de uma indústria metalmecânica, em conjunto de máquinas específicas de usinagem que representam uma parcela do faturamento do negócio, tendo por finalidade, a redução de perdas financeiras no negócio cilindros.

Como a redução de custos e aumento da produtividade são fatores recorrentes e decisivos para a unidade de negócio, mas também os resultados preliminares deste trabalho tenham se mostrados positivos, confia-se que a proposta de gerar uma metodologia que promova a identificação de falhas e reduza as paradas de máquinas, tenha sido obtida, visto que se obteve a identificação prévia de alarmes que provocavam a interrupção do equipamento bem como a minimização do impacto financeiro na operação.

As análises preliminares se mostraram positivas com o modelo do uso de eventos dos dados passados e o contexto do problema e suas variáveis demonstram aderência aos critérios adotados, bem como aplicação para solução prática no equipamento analisado. Com isso, à busca de maior previsibilidade será o objetivo central máximo do estudo, dado seu potencial de retorno para os para a equipe de manutenção.

A linha de ação evolutiva deste trabalho deve agora focar no aprimoramento da vertente de análise preditiva da tendência, com modelos logísticos lineares generalizados, e suas derivações, como por exemplo adotar logística multinomial ou Poisson e Binomial Negativo.

Por fim, acredita-se que os objetivos do trabalho foram atingidos no que tange a demanda para solução do problema bem como a testagem e aplicação dos códigos criados. Além disso, a experiência de criar e desenvolver um estudo como este, acaba por se tornar uma grande oportunidade de aplicar o conhecimento ao dia a dia da fábrica, onde colocados em prática os conteúdos da Engenharia de Dados, *Data Wrangling*, *Business Intelligence* e Modelos Supervisionados de *Machine Learning*. Foi possível planejar e buscar soluções nunca antes testadas nesta empresa e que por sua vez estimulam ainda mais a área industrial na jornada da digitalização e ciência de dados.

A limitação desta pesquisa foi o recurso tecnológico implementado apenas em uma máquina de uma célula de manufatura para coleta de dados em tempo real. Há necessidade de coleta de mais dados de uma quantidade maior de máquinas, mas para isto, há necessidade de mais investimentos na instalação de mais sensores nos equipamentos industriais, além de investimento em mão de obra especializada na área de *Data Science and Analytics*.

A linha de ação evolutiva deste trabalho deve agora focar no aprimoramento da vertente de análise preditiva da tendência, com modelos logísticos lineares generalizados, e suas derivações como, por exemplo, adotar logística multinomial ou Poisson e Binomial Negativo.

Referências.

ABBASI, T., LIM, K. H., ROSLI, N. S., ISMAIL, I., IBRAHIM, R. **Development of predictive maintenance interface using multiple linear regression**. International Conference on Intelligent and Advanced System (ICIAS). IEEE Xplore, Kuala Lumpur, Malaysia, 2018. DOI:[10.1109/ICIAS.2018.8540602](https://doi.org/10.1109/ICIAS.2018.8540602)

ASADI, M., HASHEMI, M., BALAKRISHNAN, N. An overview of some classical models and discussion of the signature-based models of preventive maintenance. **Applied Stochastic Models in Business and Industry**, Vol. 39, pp. 4–53, 2023. <https://doi.org/10.1002/asmb.2679>

BALOGH, Z., GATIAL, E., BARBOSA, J., LEITÃO, P., MATEJKA, T. **Reference architecture for a collaborative predictive platform for smart maintenance in manufacturing**. IEEE 22nd International Conference on Intelligent Engineering Systems (INES). IEEE Xplore, Las Palmas de Gran Canaria, Spain, 2018. DOI: [10.1109/INES.2018.8523969](https://doi.org/10.1109/INES.2018.8523969)

BRANCO FILHO, G. **A organização, o planejamento e o controle da manutenção**. Rio de Janeiro: Ciência Moderna, 2008.

BRUCE, P.; BRUCE, A. **Estatística Prática para Cientistas de Dados 50 conceitos essenciais**. Rio de Janeiro: Alta Books, 2019.

CANITO, A., FERNANDES, M., MOURINHO, J., TOSUN, S., KAYA, K., TURUPCU, A., LAGARES, A., KARABULUT, H., MARREIROS, G. **Flexible architecture for data-driven predictive maintenance with support for offline and online machine learning techniques**. IECON – 47th Annual Conference of the IEEE Industrial Electronics Society. IEEE Xplore, Toronto, ON, Canada, 2021. DOI: [10.1109/IECON48115.2021.9589230](https://doi.org/10.1109/IECON48115.2021.9589230)

CHIRON. Manual CEM /CMDA Siemens. Manual do Utilizador. Versão 10-12, 2006.

COHEN, J. **Statistical power analysis for the behavioral sciences** (2nd Ed.). New York: Routledge, 1988.

CNI – Confederação Nacional das Indústrias. Indústria 4.0: Cinco anos depois / Confederação Nacional da Indústria, Brasília, Sondagem Especial 83, Ano 21, nº 83 – Brasília, 2022.

ELIPSE. 2022. EPM Disponível em < <https://www.elipse.com.br/produto/elipse-plant-manager/>>. Acesso em: 12 de setembro de 2022.

ELIPSE. 2022. produto disponível em <<https://docs.elipse.com.br/products/epm/>>. Acesso em: 12 de setembro de 2022.

FÁVERO, L. P.; BELFIORE, P. Manual de Análise de Dados. 1ª ed. [reimpressão]. Editora LTC, Rio de Janeiro, RJ, Brasil, 2021.

HASSAN, E., MASTERS, J., JEONG, K., HEYDARIAN, S., ALISA, M. **New industrial Internet of things platform for predictive maintenance in handling heavy equipment**. International Conference on Engineering and Emerging Technologies (ICEET). IEEE Xplore, Istanbul, Turkey, 2021. DOI: [10.1109/ICEET53442.2021.9659568](https://doi.org/10.1109/ICEET53442.2021.9659568)

JANTUNEN, E., CAMPOS, J., SHARMA, P., BAGLEE, D. **Digitalisation of maintenance**. 2nd International Conference on System Reliability and Safety (ICSRS). IEEE Xplore, Milan, Italy 2017. <https://doi.org/10.1109/ICSRS.2017.8272846>

JOSE, T. M., ZAMEER, R. **A novel sensor based approach to predictive maintenance of machines by leveraging heterogeneous computing**. IEEE Xplore Sensors, New Delhi, India, 2018. DOI: [10.1109/ICSENS.2018.8589620](https://doi.org/10.1109/ICSENS.2018.8589620)

KAJKO-MATTSSON, M. A Survey of Documentation Practice within Corrective Maintenance. **Empirical Software Engineering**, Vol. No. 10, pp. 31–55, 2005. <https://doi.org/10.1023/B:LIDA.0000048322.42751.ca>

KARDEC, A. e NASCIF, J.. **Manutenção Função Estratégica**. Rio de Janeiro: Qualitymark, 2001.

KUMARI, R., SAINI, K. **Advanced automobile manufacturing: An Industry 4.0**. 8th International Conference on Computing for Sustainable Global Development (INDIACom). IEEE Xplore. New Delhi, India, 2021. DOI: [10.1109/INDIACom51348.2021.00161](https://doi.org/10.1109/INDIACom51348.2021.00161)

LAFRAIA, J. R. B. **Manual de Confiabilidade, Manutenibilidade e Disponibilidade**. Rio de Janeiro: Qualitymark, 2001.

LECHEVALIER, D., NARAYANAN, A., RACHURI, S. **Towards a domain-specific framework for predictive analytics in manufacturing**. IEEE International Conference on Big Data (Big Data). IEEE Xplore, Washington, DC, USA, 2014. DOI: [10.1109/BigData.2014.7004332](https://doi.org/10.1109/BigData.2014.7004332)

MAQBOOL, F., MAHMOOD, H., KHATTAK, H. A. **An efficient fault-prediction mechanism for improving yield in Industry 5.0**. 24th International Multitopic Conference (INMIC). IEEE Xplore, Islamabad, Pakistan, 2022. DOI: [10.1109/INMIC56986.2022.9972980](https://doi.org/10.1109/INMIC56986.2022.9972980)

MUBARAK, A., ASMELASH, M., AZHARI, A., ALEMU, T., MULUBRHAN, F., SAPTAJI, K. **Digital twin enabled Industry 4.0 predictive maintenance under reliability-centred strategy**. First International Conference on Electrical, Electronics, Information and Communication Technologies (ICEEICT). IEEE Xplore, Trichy, India, 2022. DOI: [10.1109/ICEEICT53079.2022.9768590](https://doi.org/10.1109/ICEEICT53079.2022.9768590)

POLOTSKI, V., KENNE, J.-P. GHARBI, A. Optimal production and corrective maintenance in a failure-prone manufacturing system under variable demand. **Flexible Services and Manufacturing Journal**, Vol. 3, pp. 894–925, 2019. DOI: [10.1007/s10696-019-09337-8](https://doi.org/10.1007/s10696-019-09337-8)

PURNACHAND, K., SHABBEER, Md., SYAMALA RAO, P.N.V. M., BABU, C. M. **Predictive maintenance of machines and industrial equipment.** 10th IEEE International Conference on Communication Systems and Network Technologies (CSNT). IEEE Xplore, Bhopal, India, 2021. DOI: [10.1109/CSNT51715.2021.9509696](https://doi.org/10.1109/CSNT51715.2021.9509696)

RAMANI, B. V., AMITH, C. A., OOMMEN, J. O., BABU, J., PAUL, T., SANKAR, V. **Predictive analysis for industrial maintenance automation and optimization using a smart sensor network.** International Conference on Next Generation Intelligent Systems (ICNGIS). IEEE Xplore, Kottayam, India, 2016. DOI: [10.1109/ICNGIS.2016.7854004](https://doi.org/10.1109/ICNGIS.2016.7854004)

RAMOS, P.; SANTOS, N.; RABELO, R. **Performance of state space and ARIMA models for consumer retail sales forecasting.** Robotics and Computer-Integrated Manufacturing 34, 2015. <https://doi.org/10.1016/j.rcim.2014.12.015>

RAO, B. S., SARDA, N. L. **Applicability of IEEE maintenance process for corrective maintenance outsourcing** - An empirical study. International Conference on Software Maintenance, Proceedings. IEEE Xplore, Montreal, QC, Canada, 2002. DOI: [10.1109/ICSM.2002.1167754](https://doi.org/10.1109/ICSM.2002.1167754)

ROMRIELL, A., NICULESCU, R. S., KESSLER, D., KROLL, T. **Lessons from deploying predictive analytics on manufacturing shop floor.** Annual Reliability and Maintainability Symposium (RAMS). IEEE Xplore, Palm Springs, CA, USA, 2020. DOI: [10.1109/RAMS48030.2020.9153728](https://doi.org/10.1109/RAMS48030.2020.9153728)

SADIKI, S., FACCIO, M., RAMADANY, M., AMGOUZ, D., BOUTAHAR, S. **Impact of intelligent wireless sensor network on predictive maintenance cost.** 4th International Conference on Optimization and Applications (ICOA). IEEE Xplore, Mohammedia, Morocco, 2018. DOI: [10.1109/ICOA.2018.8370573](https://doi.org/10.1109/ICOA.2018.8370573)

SCHMIDT, B., WANG, L. Cloud-enhanced predictive maintenance. **International Journal of Advantage in Manufacturing Technology**, Vol. 99, pp. 5–13, 2018. <https://doi.org/10.1007/s00170-016-8983-8>

SINGH, P., AGRAWAL, S., CHAKRABORTY, A. **Multi-classifier predictive maintenance strategy for a manufacturing plant.** International Conference on Maintenance and Intelligent Asset Management (ICMIAM), IEEE Xplore, Ballarat, Australia, 2021. DOI: [10.1109/ICMIAM54662.2021.9715224](https://doi.org/10.1109/ICMIAM54662.2021.9715224)

TON, B., BASTEN, R., BOLTE, J., BRAAKSMA, J., Di BUCCHIANICO, A., CALSEYDE, P., GROOTEMAN, F., HESKES, T., JANSEN, N., TEEUW, W., TINGA, T., STOELINGA, M. PrimaVera: Synergising predictive maintenance. **Applied Sciences**, 10, 8348, 2020. <https://doi.org/10.3390/app10238348>

VINH, T. Q., HUY, N. T. **Predictive maintenance IoT system for industrial machines using random forest regressor.** International Conference on Advanced Computing and Analytics (ACOMPA). IEEE Xplore, Ho Chi Minh City, Vietnam, 2022. DOI: [10.1109/ACOMPA57018.2022.00020](https://doi.org/10.1109/ACOMPA57018.2022.00020)

WANG, N., JIN, Y. C., MA, L., LIAO, H. A computational method for finding the availability of opportunistically maintained multi-state systems with non-exponential distributions. **IIE Transactions**, Vol. 52, No. 9, pp. 1047–1061, 2020. DOI: [10.1080/24725854.2019.1688897](https://doi.org/10.1080/24725854.2019.1688897)

WELLSANDT, S., KLEIN, K., HRIBERNIK, K., LEWANDOWSKI, M., BOUSDEKIS, A., MENTZAS, G., THOBEN, K.-D. Towards using digital intelligent assistants to put humans in the loop of predictive maintenance systems. ScienceDirect, **IFAC PapersOnLine** 54-1, pp. 49–54, 2021. <https://doi.org/10.1016/j.ifacol.2021.08.005>

WU, D, JENNINGS, C., TERPENNY, J., KUMARA, S. **Cloud-based machine learning for predictive analytics: Tool wear prediction in milling**. IEEE International Conference on Big Data (Big Data). IEEE Xplore, Washington, DC, USA, 2016. DOI: [10.1109/BigData.2016.7840831](https://doi.org/10.1109/BigData.2016.7840831)

YU, W., DILLON, T., MOSTAFA, F., RAHAYU, W., LIU, Y. A global manufacturing Big Data ecosystem for fault Detection in predictive maintenance. **IEEE Transactions on Industrial Informatics**, Vol. 16, No. 1, January, 2020. DOI: [10.1109/TII.2019.2915846](https://doi.org/10.1109/TII.2019.2915846)

YU, W., LIU, Y., DILLON, T., RAHAYU, W. Edge computing-assisted IoT framework with an autoencoder for fault detection in manufacturing predictive maintenance. **IEEE Transactions on Industrial Informatics**, Vol.19, Issue: 4, April, pp. 5701 – 5710, 2023. DOI: [10.1109/TII.2022.3178732](https://doi.org/10.1109/TII.2022.3178732)