



Universidade Federal do Paraná

Programa de Pós-Graduação Lato Sensu



Engenharia Industrial 4.0

Jean Carlos Kamradt
Marcos Tulio Costa Turossi

PROPOSTA DE MANUTENÇÃO PREDITIVA ATRAVÉS DA ANÁLISE DE DADOS DE MÁQUINAS E EQUIPAMENTOS

**CURITIBA
2022**

Jean Carlos Kamradt
Marcos Turossi

PROPOSTA DE MANUTENÇÃO PREDITIVA ATRAVÉS DA ANÁLISE DE DADOS DE MÁQUINAS E EQUIPAMENTOS

Monografia apresentada como resultado parcial à obtenção do grau de Especialista em Engenharia Industrial 4.0. Curso de Pós-graduação Lato Sensu, Setor de Tecnologia, Departamento de Engenharia Mecânica, Universidade Federal do Paraná.

Orientador: Prof. Dr. Pablo Deivid Valle

**CURITIBA
2022**

RESUMO

Manutenção preditiva é um termo muito discutido atualmente na indústria principalmente por parte da equipe de manutenção, pelos responsáveis por planejar a manutenção de máquinas e equipamentos, como sendo uma proposta de valor para implementar no conceito de manutenção nas empresas, pois ainda os custos de manutenção corretiva e preventiva são elevados. Há uma lacuna no processo de manutenção considerando o conceito de preditiva, ou seja, predição do que pode ocorrer em um equipamento, a grande parte dos fabricantes de máquinas consideram somente o controle de um processo e não monitoram em grande parte os status dos equipamentos, como vibração, desgaste, torque excessivo etc. existem oportunidades de desenvolvimento e implementação de soluções preditivas em máquinas e equipamentos. Como proposta de criar valor ao ciclo de manutenção podemos implementar sensores que possam medir de forma preventiva as falhas, como vibração, elevação de temperatura, aumento de corrente elétrica, torque os quais são capazes de prever problemas mecânicos de desgaste, aumento de resistência mecânica proveniente de falta de lubrificação, isto influencia na corrente elétrica do motor por exemplo, em consequência teremos maior dissipação de calor etc. Como metodologia e análise precisamos coletar dados do equipamento, criando alertas quando houver falha mecânica, ou elétrica, utilizando recursos como inteligência artificial, análise das informações através de algoritmos de aprendizado de máquina etc. Para avaliar os conceitos e propostas definidas em parceria com as empresas Tigre (Fabricante de produtos plásticos) e Kunume (Startup) escolhemos o equipamento importante para o processo de preparação de matéria prima a Granuladora, onde definidos os principais dados de processo que podem influenciar na qualidade do processo ou gerar falhas no equipamento que causam total parada de produção. A análise de manutenção preditiva baseada em dados de processo e informações de falhas decorrentes do mesmo deve ser uma base de estudo para cada modelo de equipamento e que requer aprendizado constante, como ocorre no aprendizado de máquina (ML).

Palavras-chave: Preventiva. Preditiva. Aprendizado de máquina. Inteligência artificial.

LISTA DE ILUSTRAÇÕES

FIGURA 1 – GRANULADORA	7
FIGURA 2 – DESEMPENHO DA MANUTENÇÃO	11
FIGURA 3 – CURVA CARACTERÍSTICA DA VIDA ÚTIL DE MÁQ. E EQUIPAMENTOS	11
FIGURA 4 – CURVA DE FALHA POTENCIAL	14
FIGURA 5 – FLUXOGRAMA DOS PRINCIPAIS ETAPAS DO TRABALHO	19
FIGURA 6 – MÓDULO GATEWAY 4G	21
FIGURA 7 – TELA IHM COM RESUMO DOS PARAMETROS	21
FIGURA 8 – CLP DA GRANULADORA CONECTADO EM SERVIDOR AZURE	22
FIGURA 9 – CONCENTRAÇÃO DE FALHAS POR CLUSTER	23
FIGURA 10 – ANÁLISE POR PERIODOS	23
FIGURA 11 – IMPACTOS DO MODELO DE SAÍDA CLUSTER 0	24
FIGURA 12 – IMPACTOS DO MODELO DE SAÍDA CLUSTER 1	25
FIGURA 13 – IMPACTOS DO MODELO DE SAÍDA CLUSTER 2	26
FIGURA 14 – CONCENTRAÇÃO DE FALHAS POR CLUSTER	26
FIGURA 15 – IMPACTOS NO MODELO CLUSTER 0	28
FIGURA 16 – IMPACTOS NO MODELO CLUSTER 1	28
FIGURA 17 – IMPACTOS NO MODELO CLUSTER 2	29
FIGURA 18 – FLUXO DE ANÁLISE DE FALHAS	30

LISTA DE TABELAS

TABELA 1 – COMPARAÇÃO ENTRE CLASSIFICAÇÃO EM CLUSTER	Erro!
--	-------

Indicador não definido.

SUMÁRIO

1. INTRODUÇÃO	5
1.1. CONTEXTUALIZAÇÃO	6
1.2. FORMULAÇÃO DO PROBLEMA	6
1.3. JUSTIFICATIVA	7
1.4. HIPÓTESE	7
1.5. OBJETIVO	8
2. REVISÃO DA LITERATURA	9
2.1. INDÚSTRIA 4.0	9
2.2. MANUTENÇÃO	9
2.3. INDICADORES DE MANUTENÇÃO	9
2.3.1. Confiabilidade	9
2.3.2. Disponibilidade	9
2.3.3. Manutenibilidade	9
2.3.4. Tipos de falhas	9
2.4. MANUTENÇÃO PREDITIVA	14
2.5. APRENDIZADO DE MÁQUINA	14
2.6. CLUSTERS	14
2.7. ALGORITMOS BASEADOS EM DISTÂNCIA	14
3. METODOLOGIA	19
3.1. REQUISITOS DE PROJETO	20
3.2. HARDWARE E CONFIGURAÇÕES NECESSÁRIAS DE SOFTWARE	21
3.3. MODELO DE COMUNICAÇÃO	23
4. RESULTADOS DO PROJETO	24
4.1.1. Detalhando o Cluster 0, faca de corte	25
4.1.2. Detalhando o Cluster 1, faca de corte	26
4.1.5. Detalhando o Cluster 0, no alimentador	29
4.1.6. Detalhando o Cluster 1, no alimentador	30
4.1.7. Detalhando o Cluster 2, no alimentador	31
5. CONCLUSÕES	33
5.1.1. Sugestões de trabalhos futuros	34
6. REFERÊNCIAS	33

1.INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO

Com o advento da indústria 4.0, a demanda por sistemas mais seguros e confiáveis vem aumentando e junto a ela a necessidade de adequação das tecnologias de controle de sistemas dinâmicos, que sejam capazes de atender os novos requisitos, como identificar ou prever o algum evento não desejado que pode ocasionar algum tipo de problema ou falha, e que mesmo com este mal comportamento o sistema ainda possa ser controlável.

O termo indústria 4.0 foi utilizado pela primeira vez em 2011 pela Communications Promoters Group da Industry - Science Research Alliance, que descreve a utilização da informação integrada e tecnologias de comunicação na indústria, e o potencial para gerar valor a indústria manufatureira, o qual segundo o autor na Alemanha estima-se que seja capaz de gerar algo em torno de 70 a 140 bilhões de euros no período de 2011 até 2025 (SCHUH et al 2020).

Com a evolução industrial e automatização surgiram também novos métodos de comunicação e controle para as máquinas, como integração entre equipamentos através de redes Ethernet, Profinet, Profibus, IO-Link, entre outros. Com o surgimento desses novos protocolos de comunicação industrial, e habilitamos um novo conceito de IOT (internet industrial das coisas). Com estas tecnologias é possível avançar em relação a indústria 4.0 reunindo todas essas informações e disponibilizando em bancos de dados.

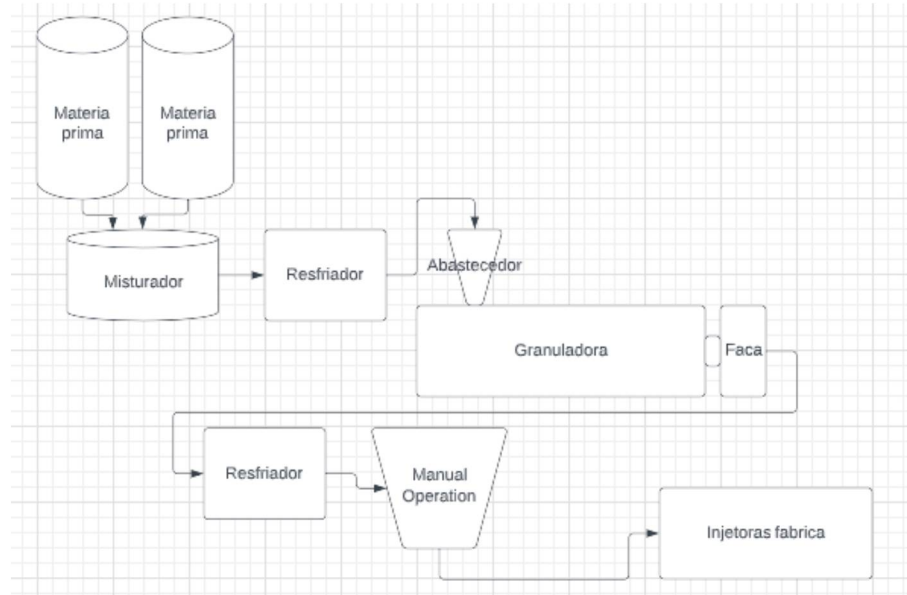
Após conhecer bem um processo e coletar os dados, precisamos realizar a extração, transformação e carga dos dados que precisamos para análise. Para extração utilizamos hoje diversos recursos, como equipamentos que conseguem ler as variáveis utilizadas nos equipamentos, variáveis de processo, parâmetros do equipamento, como corrente do motor, temperatura, pressão etc. Já na transformação também conhecida como mineração de dados, os dados são selecionados e organizados para posteriormente utilizar no processo de aprendizado de máquina, ou inteligência artificial

1.2. FORMULAÇÃO DO PROBLEMA

Como base de estudo e avaliação dos conceitos de aprendizado de máquina escolhemos a Granuladora para avaliar as principais falhas que ocorrem no equipamento tanto de processo como de funcionamento de motores, sistemas de aquecimento e componentes eletrônicos, baseados em dados de processo e interligar com estas falhas. Através destes dados podemos de forma preditiva definir o que pode quebrar ou parar o equipamento durante sua operação.

A Granuladora é um importante equipamento em uma fábrica de materiais plásticos, ele é quem transforma a matéria prima com outros aditivos em pequenos grãos e estes são utilizados nas injetoras, na figura -1 a seguir seu fluxograma de processo.

FIGURA 1 – GRANULADORA



Fonte - autoria própria.

1.3. JUSTIFICATIVA

A realização de manutenção preventiva é possível trocar peças danificadas ou que geram desgaste previsto pelo fabricante, porém algumas peças podem ser trocadas de forma antecipada gerando maior custo de manutenção do equipamento, algumas peças possuem um valor elevado, criando uma oportunidade de venda de peças e não necessariamente uma real manutenção preventiva;

Os planos são criados com base em informações fornecidas por fabricantes de máquinas e equipamentos, com base na experiência e histórico de falhas ou quebras.

Este estudo tem como finalidade associar as falhas com dados de processo ou manutenção, ter maior visibilidade do que ocorre no equipamento, causas das falhas e definir de forma preditiva uma falha ou necessidade de correção do processo.

1.4. HIPÓTESE

Como parte da solução vamos utilizar sensores que possam medir de forma preventiva as falhas, como vibração, elevação de temperatura, aumento de corrente elétrica, tensão etc. Estes são capazes de prever problemas mecânicos de desgaste, aumento de resistência

mecânica proveniente de falta de lubrificação, isto influencia na corrente elétrica do motor por exemplo, em consequência teremos maior dissipação de calor etc.

Realizar análise precisa dos dados coletados, criando alertas de uma possível falha mecânica, ou elétrica, utilizando recursos como inteligência artificial, análise das informações através de algoritmos de aprendizado de máquina etc.

1.5. OBJETIVO

Gerar confiabilidade no sistema ou equipamento, nas linhas de produção, conhecendo melhor e obtendo informações que auxiliam na manutenção preditiva e preventiva, garantindo assim eficiência e disponibilidade das máquinas.

2. REVISÃO DA LITERATURA

2.1. INDÚSTRIA 4.0

A indústria tem passado por diversas alterações em sua essência, a primeira revolução ocorreu com o surgimento das máquinas a vapor e utilização da forma hidráulica, a segunda revolução ocorreu com o surgimento da energia elétrica e do sistema de produção em massa e a terceira revolução ocorreu por volta da década de 70, com o surgimento da eletrônica e dos sistemas de informação, e com o surgimento do Lean Manufacturing (BORLIDO, 2017).

Segundo Junior e Saltorato (2018) estamos vivenciando uma revolução que está mudando a forma como vivemos, trabalhamos e nos relacionamos, e que a indústria 4.0 é um novo modelo de produção em máquinas, ferramentas e processos que estão interconectados através de internet, e com capacidade para operar e tomar decisões de forma autônoma.

O conceito indústria 4.0 teve início em 2011, e desde então vem recebendo uma atenção especial da sociedade, governantes e universidades, o qual vem nos holofotes de várias áreas da ciência, como engenharias, administração e computação (AIRES E MOREIRA 2017).

Uma das tecnologias com forte impacto é a digitalização, que já está presente de diversas formas na vida das pessoas, como ebooks, aplicativos entre outros. A tecnologia da informação mostra-se uma importante aliada para melhorar alguns problemas nacionais, tais como mobilidade urbana (AIRES E MOREIRA 2017).

O conceito de indústria 4.0 nasceu na Alemanha, mas vem se espalhando de forma rápida em todos os cantos do mundo. Os EUA anunciaram em 2011 a Advanced Manufacturing Partnership (AMP) que é a união entre indústria, universidade e governos para promover investimentos em tecnologias em ascensão no país já a China em 2015 apresentou o Made in China 2025, que se tratar de um programa estratégico que busca atualizar a indústria no país e alguns outros países como Coreia do Sul também tiveram programas semelhantes (JUNIOR E SALTORATO, 2018)

Segundo Schwab 2016, a indústria 4.0 é uma junção de tecnologias aplicadas ao ambiente de produção como Cyber-Physical System (CPS), Internet of Things, impressão 3D, Inteligência Artificial, Big Data e veículos autônomos, e que a

combinação dessas tecnologias emergentes tem a capacidade de criar as fábricas inteligentes.

Segundo os Rüßmann Et Al. (2015) a indústria 4.0 é sustentada por 9 pilares tecnológicos que são:

1. Big Data e Data Analytics: que são uma grande quantidade de dados obtido de equipamentos, processos, clientes, gestão etc.
2. Robôs Autônomos: Robôs capazes de trabalhar lado a lado com o ser humano de forma segura.
3. Simulação: Tomada de decisões baseadas em simulações, como por exemplo os gêmeos digitais.
4. Integração de Sistemas: Os sistemas estarão interconectados entre companhias.
5. Segurança da Informação: A segurança da informação é a base para suportar o aumento da conectividade.
6. Internet das Coisas: A interação entre os diversos equipamentos
7. Nuvem: A computação em nuvem é uma ótima solução para o aumento do poder computacional por um determinado tempo e redução de custos.
8. Fabricação de Aditivos: fabricação de produtos customizados e de forma descentralizada.
9. Realidade aumentada/virtual: tomada de decisão, treinamentos e outros procedimentos.

A Quarta Revolução Industrial, pela primeira vez na história, está sendo estudada ao mesmo tempo em que está ocorrendo, e trata de uma revolução dos processos manufatureiros com auxílio das diversas tecnologias aplicadas dentro dos sistemas produtivos (PEREIRA E SIMONETTO 2018).

2.2. MANUTENÇÃO

A manutenção tem como objetivo maximizar a disponibilidade dos equipamentos, manter o equipamento funcional, com bom desempenho e seguro, mantendo as condições originais de operação ao qual o equipamento foi projetado (BALDISSARELLI e FABRO 2019).

Apesar da quarta revolução industrial, as abordagens mais utilizadas pela indústria ainda são a manutenção corretiva e preventiva em grande parte o qual ainda é predominante em indústrias como óleo e gás, transporte, mineração, construção civil etc. (ZHE et al 2020).

O aumento da demanda por equipamentos mais robustos, de fácil manutenção, com alta disponibilidade e segurança, as formas tradicionais de manutenção tem ficado obsoleta, demandando novas tecnologias e estratégias para atender às novas demandas de mercado, que agora tem disponíveis sensores e sistemas de monitoramento em tempo real para auxiliar na tomada de decisão (KHANH & KAAMEDJAK 2019).

Segundo Wang et al (2019) cerca de 80% do tempo parado de máquina são causados por falhas mecânicas, e a manutenção preditiva é um caminho para reduzir os custos incorridos e máquinas paradas, também reduzir os desperdícios financeiros ocasionados pela manutenção preventiva.

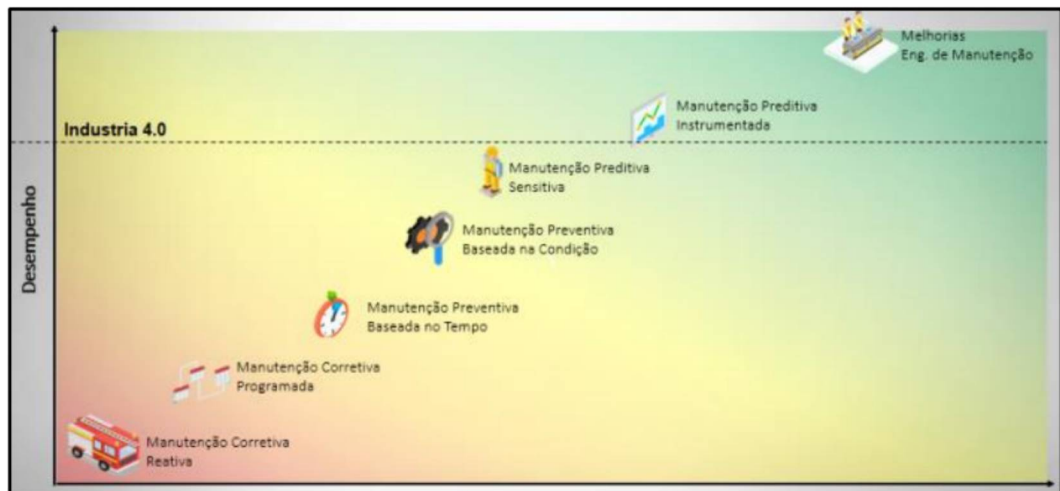
Segundo Baldissarelli e Fabro (2019), o tipo de manutenção é usualmente dividida de acordo com a forma de programação e o objetivo das tarefas a serem executadas. A manutenção pode ser dividida em programada e não programada, quando classificada em relação a programação, a manutenção programada é executada em um período pré-determinado, já a não programada acontece a qualquer momento, quando surge a demanda. Na classificação por objetivos temos

- Corretiva ou reativa: voltada a correção da falha após o acontecimento
- Preventiva: objetiva substituição em após um determinado tempo
- Preditiva: é realizada através da alteração dos parâmetros ou condições de desempenho do equipamento

Segundo o Patriota (2014), uma falha pode ser definida como uma alteração na capacidade ou interrupção de um determinado bem, que prejudique o desempenho da função ao qual foi projetado.

Já a NBR 5462 define a falha como o término da capacidade de um determinado bem ou equipamento de realizar a função requerida. E a Pane como um a incapacidade de desempenhar uma função, exceto pelas paradas programadas, e a pane pode ser ocasionado por uma falha, mas pode existir sem uma antecessora.

FIGURA 2 - DESEMPENHO DA MANUTENÇÃO



Fonte: BALDISSARELLI e FABRO 2019.


2.3. INDICADORES DE MANUTENÇÃO

2.3.1. Confiabilidade

O indicador de confiabilidade teve sua origem na década de 50, nos Estados Unidos, e desde então é amplamente utilizado na indústria, e pode ser definido como a capacidade de um equipamento desempenhar uma função específica durante um intervalo de tempo (NBR 5462-1994).

O comportamento característico das falhas em máquinas e equipamentos é também conhecido como a curva da banheira, representada na figura 3, sendo válida para equipamentos elétricos, mecânicos e sistemas (KARDEC; NASCIF, 2009).

FIGURA 3 – CURVA CARACTERÍSTICA DA VIDA ÚTIL DE MÁQUINAS E EQUIPAMENTOS



Fonte: Kardec e Nascif, 2009

A curva banheira, representada na Figura 3, é dividida em três partes no seu eixo horizontal, sendo elas a mortalidade infantil o qual apresenta uma taxa de falhas elevadas, o qual pode ser por problemas na instalação, defeitos de fabricação, já no meio da curva é conhecida como vida útil do equipamento, é o período em que existem uma taxa menor de falhas no equipamento, e com o envelhecimento a quantidade de falhas começa a aumentar, como pode ser visto na última parte do gráfico.

2.3.2. Disponibilidade

A disponibilidade é a "capacidade de um item estar em condições de executar certa função em um dado instante ou durante um intervalo de tempo determinado" (NBR 5462-1994).

2.3.3. Manutenibilidade

A manutenibilidade é a probabilidade de restabelecer o funcionamento de um sistema após uma falha, dentro de um período desejado de tempo, ou seja, quando a manutenção é executada dentro dos parâmetros pré-estabelecidos para o mesmo. (MONCHY 1989).

2.3.4. Tipos de falhas

De acordo com a NBR 5462 (ABNT) as falhas podem ser classificadas em 4 tipos distintos:

- Falha Gradual – falhas que podem ser detectadas a partir de uma análise prévia
- Falha Parcial – quando há desvio de características dos produtos, o qual extrapola os limites de especificação.
- Falha por Defeito – são falhas graduais e simultâneas podendo ao longo do tempo se tornar piores.
- Falha Completa – quando um item/equipamento deixa de desempenhar a função ao qual foi projetado.

2.4. MANUTENÇÃO PREDITIVA

A ideia de manutenção preditiva é planejar a manutenção de acordo com a condição de atual do equipamento e da condição futura, com a chegada das tecnologias da indústria 4.0, como IIOT (*industrial internet of things*) e a computação em nuvem fazem da manutenção preditiva mais atrativa, não só em locais de alta complexidade e risco, como aviação (JUNIOR 2022).


O conceito de manutenção preditiva está vinculado à intervenção de acordo com o estado atual do equipamento, esta avaliação é usualmente feita através de medições e monitoramento dos parâmetros do equipamento, com o passar do tempo e os avanços tecnológicos as tecnologias de monitoramento estão cada vez mais acessíveis (BALDISSARELLI e FABRO 2019).

Um dos desafios encontrados na utilização da manutenção preditiva é o diagnóstico precoce da falha, e que é possível identificar as falhas por desgaste e a degradação da saúde do equipamento, através do monitoramento dos sinais a longo prazo, como por exemplo sinais de vibrações, consumo de energia, ruídos entre outros (WANG et al 2019). Existem alguns casos de sucesso na utilização dos sinais de vibrações, acústica para a identificar falhas (LI et. al. 2018).

O conceito de Indústria 4.0, o qual todos os processos vêm passando por digitalização associado a automação da produção tem modificado a forma de trabalho, os sistemas cyber-físicos são capazes de compartilhar um grande volume de dados e auxiliar na tomada decisão possibilitando a utilização de ferramentas de auxílio à decisão (STODOLA e STODOLA 2019).

Uma abordagem conveniente para a manutenção preditiva (*data-driven*) é utilizar uma quantidade suficiente para prever o residual *useful lifetime* (RUL) sem qualquer conhecimento da natureza física do equipamento, é possível descrever qual o nível de degradação atual do equipamento, utilizando análise de sinais e algumas técnicas de engenharia. Alguns estudos recentes apontam que algoritmos de Deep Learning são os mais populares na utilização de diagnósticos e prognósticos baseados em dados, o qual é possível sem qualquer conhecimento em processamento de sinais (KHANH & KAAMEDJAK 2019).

FIGURA 4 – CURVA DE FALHA POTENCIAL



Fonte: BALDISSARELLI e FABRO 2019.

A curva de falha potencial (Figura-4), segundo Baldissarelli e Fabro (2019) mostra a vantagem da utilização da manutenção preditiva em relação aos demais tipos de manutenção, antes mesmo da perda de performance do equipamento e de acordo com gráfico a falha é detectada ainda e tempo de atuação e possibilita a programar a parada para a manutenção do equipamento.

2.5. APRENDIZADO DE MÁQUINA

O aprendizado de máquina, no uso de algoritmos matemáticos para encontrar padrões dentro de um banco de dados, ou dividi-los em clusters ou identificar informações através de uma determinada saída, sendo ele um aprendizado automático através de um conjunto de dados (JONES et al 2021).

Com o advento de novas técnicas de aprendizado e máquina, a análise preditiva surge como um ótimo método para identificar anomalias em grande escala de dados, e auxiliando suprir as demandas geradas pela manutenção de máquinas e equipamentos (ALEXOPOLUS et al 2021).

Este capítulo tem como objetivo fazer uma breve introdução ao aprendizado de máquina em séries temporais, e como ela pode ser utilizada para fazer previsões de falhas em equipamentos. Os algoritmos de aprendizado podem ser classificados com o seu tipo de aprendizado, podendo ser supervisionado, não supervisionado e semi-

supervisionado, em relação ao paradigma do aprendizado, que podem ser do tipo classificativo ou preditivo.

Em tarefas de previsão o objetivo é um modelo, o qual a partir dos dados de entrada seja possível prever acontecimentos futuros, já em tarefas de classificação o objetivo é encontrar padrões e classificar o conjunto de acordo com as suas semelhanças, e como não tem nenhum atributo de saída, esses algoritmos são essencialmente de aprendizagem não supervisionados (CARVALHO et al 2011).

Para Segaran 2007, o aprendizado de máquina é um subconjunto da Inteligência Artificial, que é capaz encontrar padrões e generalizar informações dentro de um conjunto de dados.

Segundo Ehlers 2007 uma série temporal é um conjunto de observações que são feitas sequencialmente ao longo de um período de tempo, e que tem como principais características a dependência da observação vizinha. Sendo assim fica evidente que para analisarmos a deterioração e previsão das falhas em equipamentos, devemos ter um conjunto de dados do tipo série temporal.

O aprendizado de máquina precisa de dados para tomar decisões e muitos fatores relacionados aos dados têm influência direta na qualidade dos resultados, e a qual o método deve ser adotado de acordo com o tipo de conjunto de dados, tipo dos valores (MARWALA, 2019).

Para o Mohri et. al. 2018, aprendizado de máquina pode ser definido como um método computacional, que utiliza a experiência (informações obtidas dos dados) para melhorar ou fazer previsões com grande assertividade. O aprendizado pode ser através de dados pré-classificados por humanos, ou através de interações com o ambiente.

Segundo Marwala 2019 o domínio ao qual os dados estão dispostos tem uma grande importância no resultado obtido utilizando técnicas de aprendizado e máquinas. Alguns dados têm desempenhos melhores quando estão no domínio da frequência, enquanto outros têm melhores resultados quando dispostos no domínio do tempo.

O sucesso na utilização dos algoritmos de aprendizado, dependem dos dados usados, e os algoritmos estão diretamente ligados à análise de dados e estatística, de uma forma mais genérica combinam alguns conceitos de ciência da computação, com ideias de estatística, probabilidade e otimização (MOHRI et al 2019).

Existem três tipos principais de aprendizado de máquina: o aprendizado supervisionado, o aprendizado não supervisionado, e o aprendizado semi-supervisionado, e podem existir combinações entre eles (CAMPESATO 2020).

- O aprendizado supervisionado significa que o conjunto de dados já está classificado previamente.
- O aprendizado não supervisionado envolve dados que não foram classificados ainda, e geralmente esses algoritmos de aprendizado tem como objetivo de agrupar os dados, também chamados de algoritmos de clustering.
- Aprendizado semi-supervisionado é a combinação dos dois, onde parte dos dados já estão classificados, e a outra parte ainda não.

Segundo Mohri 2018, existem algumas tarefas que são muito estudadas para aplicação de aprendizado de máquina.

- Regressão: é um problema o qual é necessário prever quantidades numéricas, por exemplo preços na bolsa de valores.
- Classificação: é um problema o qual tem como objetivo prever a classificação de alguma entidade.
- Clusterização: é um problema no qual o algoritmo agrupa os dados por atributos familiares com os outros.
- Ranqueamento: é um problema que consiste em aprender a organizar os itens de acordo com algum critério, um exemplo comum é retornar as páginas mais relevantes de uma pesquisa da web.
- Redução de Dimensionalidade: esse problema consiste em reduzir a representação de um dado para uma dimensão menor, um exemplo comum é o processamento de imagens.

Atualmente existem algumas técnicas o qual as manutenções são previamente treinadas por um classificador empírico, o qual é capaz de identificar se a intervenção fez as correções necessárias, e as informações obtidas da operação e também das falhas são utilizadas para criar um modelo de múltiplas instâncias de aprendizado, o qual é capaz de prever as falhas dos equipamentos (ZEH et. al. 2020).

Segundo Langone 2015, a utilização do método de clusterização dos sinais de vibração coletados por acelerômetros é barata, devido a acessibilidade dos sensores. Mas por outro lado essa técnica não é capaz de prever diretamente a deterioração de equipamentos, mas ela pode servir como um indicativo.

2.6. CLUSTERS

Informalmente quando se fala de clusters, significa encontrar grupos de informações, a classificação de Aristóteles sobre coisas da vida, foi o primeiro clusters conhecido, como um cluster hierárquico, as clusters e classificação são amplamente utilizadas nas ciências, alguns exemplos são; classificações de grupos de animais na biologia; na medicina classificação de tumores e doenças, entre outros (HENNING et. al. 2016).

Clusterização é frequentemente uma tarefa exploratória, isso significa que se utiliza sobre um conjunto de dados para entender melhor os o conjunto sem ter um objetivo formal, já a classificação é uma tarefa preditiva, o qual as categorias são conhecidas, e o objetivo é classificar os dados. Em muitos casos no processo de análise de dados, clusters precedem a classificação (HENNING et. al. 2016).

TABELA 1 – COMPARAÇÃO ENTRE CLASSIFICAÇÃO EM CLUSTERS

Comparação entre Classificação em Clusters		
	Classificação	Clusterização
Meta	Previsão de saída y dado um x	Exploração, informação, organização
Supervisão	Supervisionado	Não Supervisionado
Função Custo	Erro de Classificação ou um erro	Muitas funções loss, não todas probabilísticas
Classes/Clusters	Conhecido	Desconhecido

Fonte: HENNING et al 2016

2.7. ALGORITMOS BASEADOS EM DISTÂNCIA

Algoritmos baseados de acordo com os autores Aggarwal e Reddy (2014) em distância são extremamente desejáveis pela sua simplicidade e facilidade de implementação e geralmente são divididos em dois tipos:

- *Flat*: O conjunto de dados é dividido em muitos clusters, com as escolhas de particionamento por representatividade e em função da distância é essencial para o funcionamento do algoritmo. Alguns exemplos de algoritmos são: k-means; k-medians; k-medoids.
- Hierárquicos: Neste caso os clusters são tem uma representatividade hierárquica, variando grau de granularidade, e depende como está dividida a hierarquia, alguns algoritmos comumente utilizados são; aglomerativo, e divisível.

Muitos algoritmos de clusterização têm sido desenvolvidos nos últimos anos, entre eles o K-means é uns dos mais antigos e também um dos mais utilizados atualmente, apesar de ser muito utilizado, ele tem algumas características indesejadas, como a grande sensibilidade aos outliers (GAN e NG 2017).

O método K-Means conhecido ao final dos anos 60, depois que os primeiros resultados teóricos foram provados, no trabalho de MacQueen em 1967. O método hoje está presente nos maiores pacotes de estatística. O algoritmo K-means é atraente por ser computacionalmente eficiente, rápido e um consumo eficiente de memória (HENNING et al 2016).

Segundo Jones et al (2021) o algoritmo K-means é algoritmo muito utilizado no mercado, onde o número de clusters pode ser conhecido, presumido ou mesmo indicado antecipadamente. O centroide de cada clusters é iniciado randomicamente, ou o primeiro clusters é iniciado de forma randômica e os demais são escolhidos o mais dispersos possível. O segundo passo do algoritmo é recalcular os centróides de cada cluster, com o objetivo de minimizar a soma quadrática Euclidiana da localização dos dados até o centroide.

3.METODOLOGIA

A metodologia do trabalho consiste na assimilação do método científico à realidade de cada projeto para que assim seja possível a experimentação de técnicas

- Velocidade do alimentador;
- Velocidade da faca;
- Velocidade do fuso;

Com estes dados podemos avaliar as características preditivas do equipamento através de análise de ML e IA.

Resumidamente, as etapas envolvem o processo de análise e interpretação dos dados, preparação, aplicação de filtros e das corretas ferramentas:

- Análise de dados - validação dos dados recebidos, tratamento de lacunas e dados faltantes e pré-processamento para preparar os dados para as etapas seguintes.

- Engenharia de “features” - os parâmetros monitorados foram segmentados em janelas de 1 dia; na sequência, foram extraídos atributos, ou features, dos dados dia a dia, gerando um vetor de features que representa o comportamento da máquina em cada dia, tais “features” são parâmetros estatísticos, como desvio padrão, amplitude, assimetria e curtose, e outras informações, como número de picos e nível de ruído.

- Clusterização - Na etapa seguinte, o vetor de “features” gerado na etapa anterior é utilizado como entrada do modelo de clusterização, que tem como objetivo agrupar dados com características em comum; como resultado temos grupos com pontos (ou dias, no caso) de comportamento semelhante da máquina.

- Explicação do processo: finalmente, aplicando a técnica de aplicabilidade SHAP, conseguimos interpretar o modelo, entendendo como as “features” impactam na definição do cluster que o dia analisado pertence; aqui também conseguimos relacionar o cluster que agrupa o maior número de dias com falhas com o comportamento dos parâmetros neste cluster, trazendo um entendimento dos fatores mais associados a susceptibilidade a falhas.

3.2. HADWARE E CONFIGURAÇÕES NECESSÁRIAS DE SOFTWARE

Foi necessário a instalação de Gateway 4G para coleta de dados do PLC, este equipamento foi instalado e configurado pela empresa Tudo Remoto (<https://www.tudoremoto.com/>), as várias são lidas do CLP e enviadas para o servidor

“Data lake do Azure”, as variáveis utilizadas são as principais já monitoradas no processo e disponibilizadas na IHM e foram listadas anteriormente.

FIGURA 6 – MÓDULO GATWAY 4G.



Fonte - autoria própria

Na IHM os principais dados ou parâmetros monitorados pelo equipamento são apresentados na tela principal, estes mesmos dados são dispostos no servidor, para o funcionamento correto do equipamento é necessário ajustar as temperaturas e velocidade.

FIGURA 7 – TELA IHM COM RESUMO DOS PARAMETROS.




Fonte - autoria própria.

3.3. MODELO DE COMUNICAÇÃO

A Granuladora foi conectada no servidor do Azure através de Gateway da empresa dá “TudoRemoto”, ele é capaz de ler variáveis ou dados do CLP, através do protocolo de comunicação TCP-IP, a empresa cobra por quantidade de dados trafegados pelo servidor e transfere os dados para o Data Lake da Azure.

Na figura a seguir apresentamos como está conectado o equipamento a nuvem:

FIGURA 8 - CLP DA GRANULADORA CONECTADO EM SERVIDOR AZURE.



Fonte – Tigre (2022)

4.RESULTADOS DO PROJETO

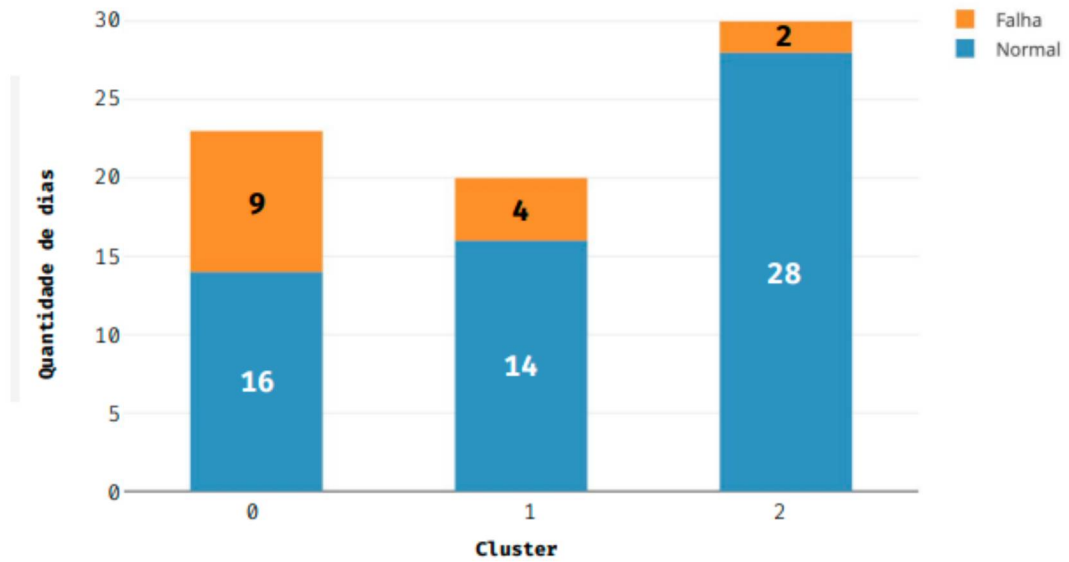
Os resultados foram obtidos foram analisados pela empresa Kunumi em parceria com a Tigre e engenheiros envolvidos nos trabalhos de coleta de dados.

Foram encontrados 3 principais clusters de comportamento para a granuladora quando analisamos a falha nas facas de corte. Os parâmetros considerados para estar na primeira análise são:

- Corrente da faca;
- Velocidade da faca;
- Pressão de massa;
- Temperatura de massa;

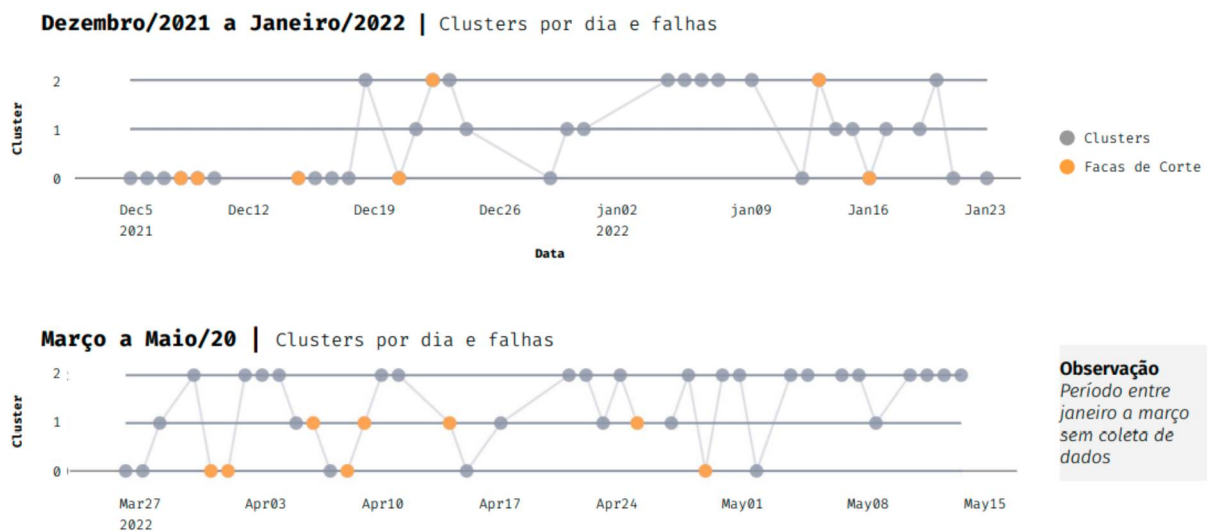
No Cluster 0, estão concentradas as principais falhas.

FIGURA 9 – CONCENTRAÇÃO DE FALHAS POR CLUSTER



Fonte - Kunumi (2022).

FIGURA 10 – ANÁLISE POR PERIODOS.



Fonte - Kunumi (2022).


4.1.1. Detalhando o Cluster 0, faca de corte

Estão concentradas 60% das falhas na faca de corte:

- ↓ **Assimetria ao longo do dia da pressão da massa:** variações negativas puxam a média da pressão da massa para baixo;
- ↑ **Amplitude média da corrente da faca:** valores altos;

- ↓ **Curtose ao longo do dia da pressão da massa**: valores dispersos de pressão da massa;

FIGURA 11 – IMPACTOS NO MODELO CLUSTER 0.



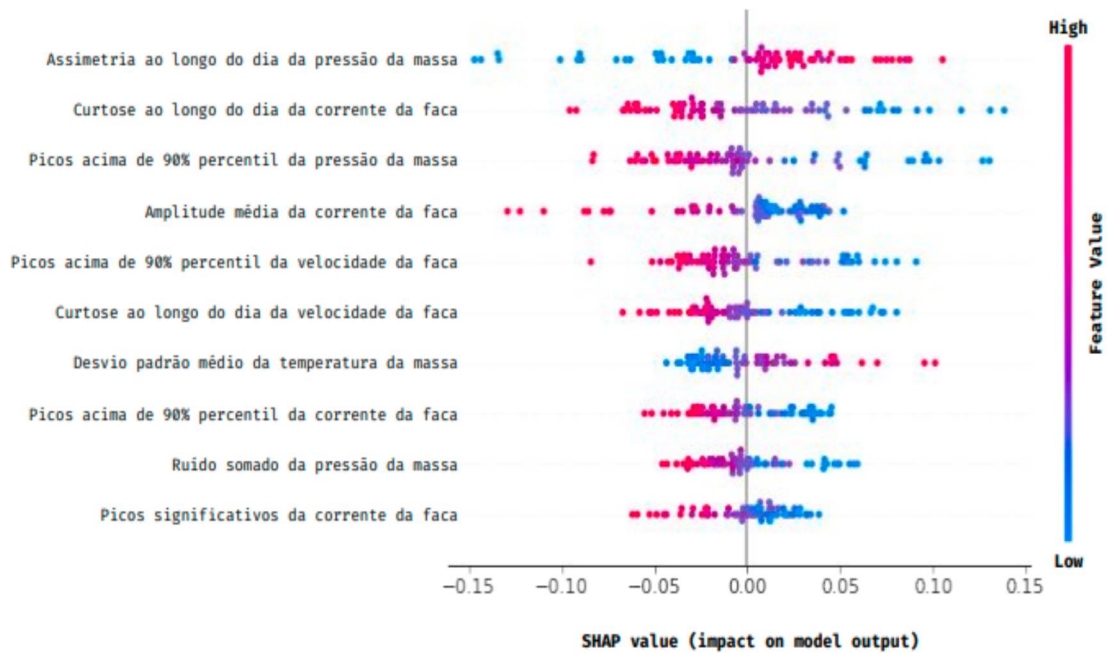
Fonte - Kunumi (2022).

4.1.2. Detalhando o Cluster 1, faca de corte

Agora vamos avaliar o Cluster 1 no projeto:

- ↑ **Assimetria ao longo do dia da pressão da massa**: variações negativas puxam a média da pressão da massa para baixo;
- ↓ **Curtose a longo do dia da corrente da faca**: valores dispersos da corrente da faca;
- ↓ **Picos acima de 90% da corrente da faca**: pressão da massa menos ruidosa;

FIGURA 12 – IMPACTOS NO MODELO CLUSTER 1.



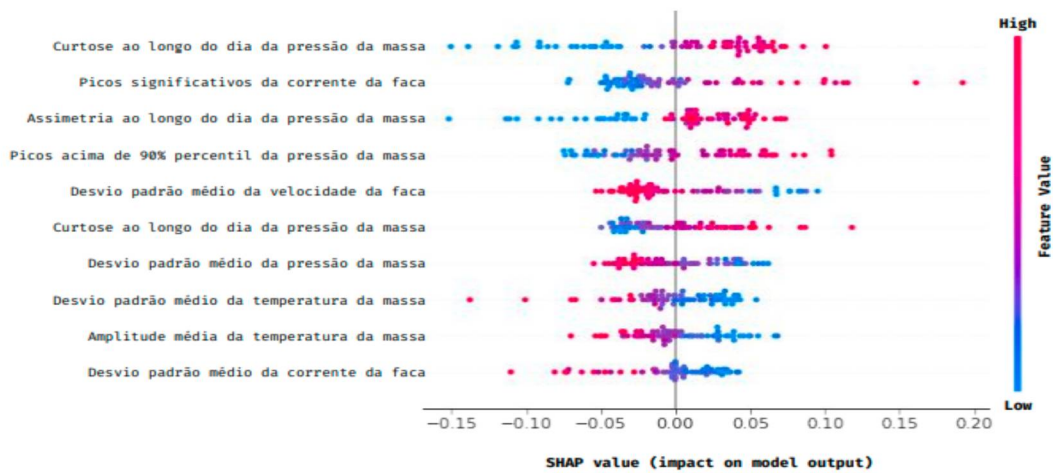
Fonte - Kunumi (2022).

4.1.3. Detalhando o Cluster 2, faca de corte

Agora vamos avaliar o Cluster 2 no projeto:

- ↑ **Curtose ao longo do dia da pressão da massa**: valores bem concentrados;
- ↑ **Picos significativos da corrente da faca**: variações bruscas da corrente da faca;
- ↓ **Assimetria ao longo do dia da pressão da massa**: variações negativas puxam a média da pressão da massa para baixo;

FIGURA 13 – IMPACTOS NO MODELO CLUSTER 2.



Fonte - Kunumi (2022)


4.1.4. Alimentador da Granuladora

Também são 3 os clusters de comportamento para a granuladora quando analisamos as falhas do alimentador. No cluster 2, estão concentradas todas as falhas.

Parâmetros considerados:

- Corrente do alimentador;
- Velocidade do alimentador;

FIGURA 14 – CONCENTRAÇÃO DE FALHAS POR CLUSTER.



Fonte - Kunumi (2022).

Resumo dos Clusters do alimentador:

Cluster 0:

- ↓ **Desvio padrão médio da corrente do alimentador:** corrente do alimentador com pouca variação;
- ↑ **Picos significativos da velocidade do alimentador:** aparecem variações bruscas na velocidade do alimentador;
- ↑ **Picos significativos da corrente do alimentador:** aparecem variações bruscas na corrente do alimentador;

Cluster 1:

- ↑ **Desvio padrão médio da corrente do alimentador:** corrente do alimentador com variação alta;
- ↓ **Picos significativos da velocidade do alimentador:** variações bruscas da velocidade do alimentador;

Cluster 2:

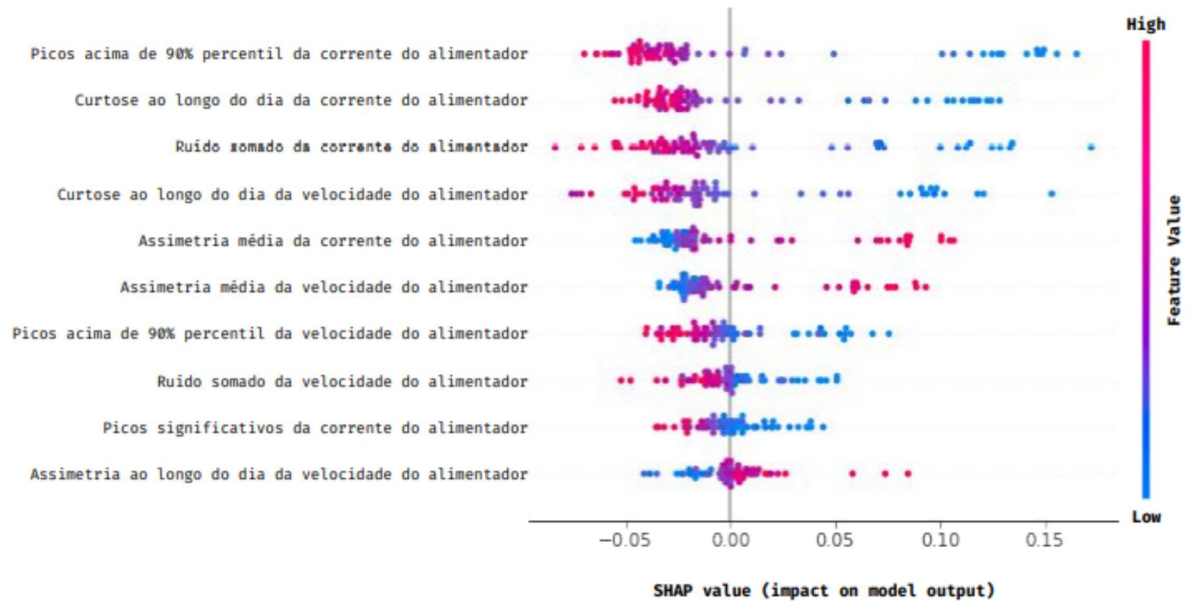
- ↓ **Picos acima de 90% percentil da corrente do alimentador:** corrente do alimentador menos ruidosa;
- ↓ **Curtose ao longo do dia da corrente do alimentador:** valores dispersos da corrente do alimentador;
- ↓ **Ruído somado da corrente do alimentador:** corrente do alimentador menos ruidosa;

4.1.5. Detalhando o Cluster 0, no alimentador

Agora vamos avaliar o Cluster 0 no projeto:

- ↓ **Assimetria ao longo do dia da pressão da massa:** variações negativas puxam a média da pressão da massa para baixo;
- ↑ **Amplitude média da corrente da faca:** valores altos;
- ↓ **Curtose ao longo do dia da pressão da massa:** valores dispersos de pressão da massa;

FIGURA 15 – IMPACTOS NO MODELO CLUSTER 0.



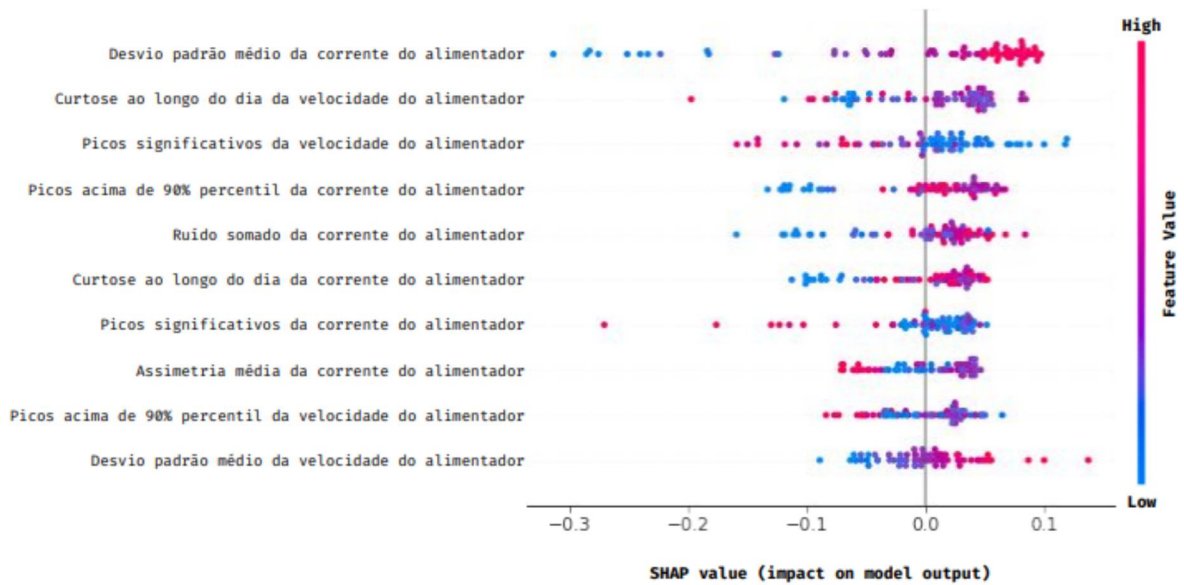
Fonte - Kunumi (2022).

4.1.6. Detalhando o Cluster 1, no alimentador

Agora vamos avaliar o Cluster 1 no projeto:

- ↑ **Desvio padrão médio da corrente do alimentador**: corrente do alimentador com variação alta;
- ↓ **Picos significativos da velocidade do alimentador**: variações bruscas da velocidade do alimentador;

FIGURA 16 – IMPACTOS NO MODELO DE CLUSTER 1.



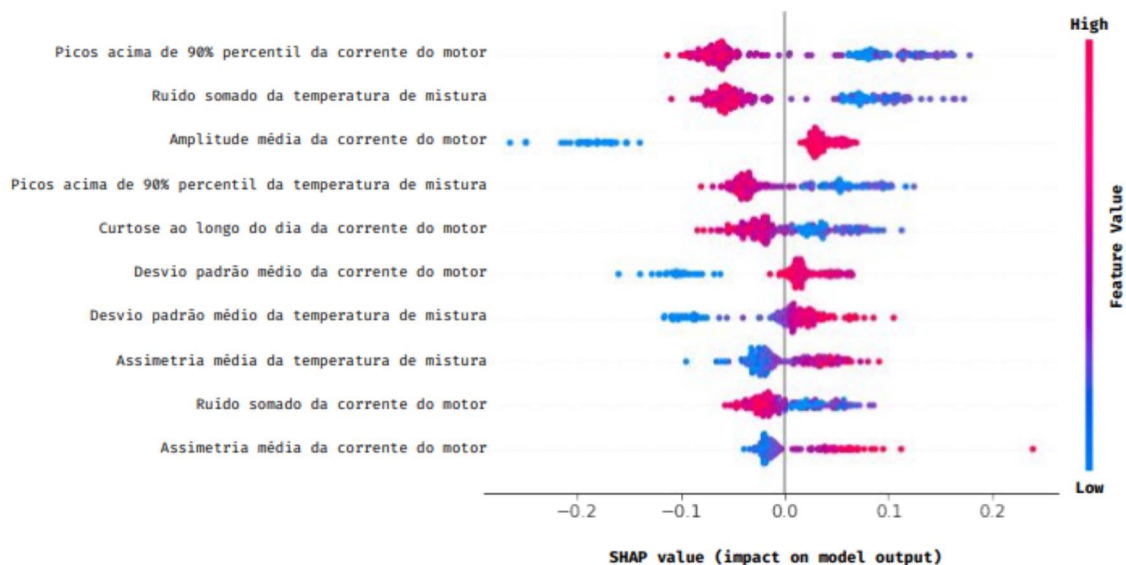
Fonte - Kunumi (2022).

4.1.7. Detalhando o Cluster 2, no alimentador

Agora vamos avaliar o Cluster 2 no projeto:

- ↓ **Picos acima de 90% percentil da corrente do motor:** corrente do motor menos ruidosa;
- ↓ **Ruído somado da temperatura de mistura:** temperatura de mistura menos ruidosa;
- ↑ **Amplitude média da corrente do motor:** corrente do motor tem amplitude mais elevada.

FIGURA 17 – IMPACTOS NO MODELO CLUSTER 2.



Fonte - Kunumi (2022).

5.CONCLUSÕES

Quanto mais parâmetros de máquina e dados de processo obter melhor será o diagnóstico preditivo, algumas variações de processos precisam de maior tempo de aprendizado para se obter um resultado que traz confiança ou segurança.

Uma relação encontrada na análise da Granuladora, foi o vínculo da corrente elétrica do motor com a pressão de massa, quanto maior a corrente elétrica do motor da faca, significa que a pressão de massa está mais elevada.

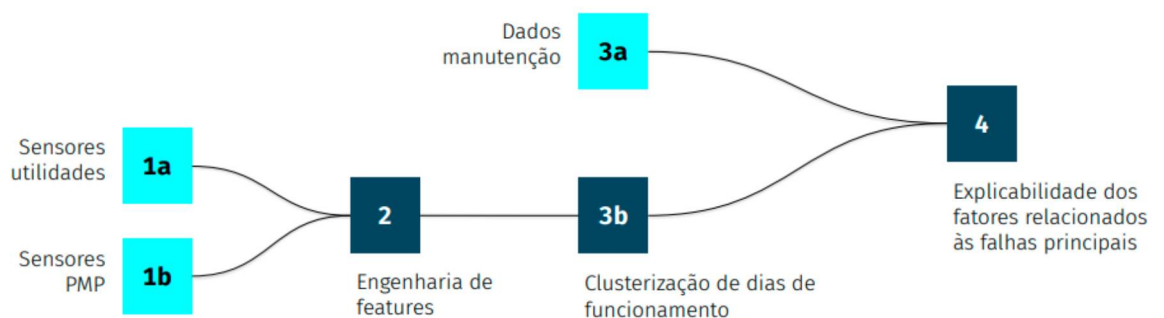
Uma medição não monitorada é o corte da faca, não tem sensor que determine se a faca está na hora de trocar, este impute de preditiva deverá estar relacionado com o aprendizado do sistema, observando o processo quando as variações de corrente elétrica do motor e outros fatores indicam que a faca necessita ser trocada por problema de corte.

O cenário desejado para obter melhor conclusão está ligado com os dados adequados para o trabalho de Machine Learning. Através destes dados podemos obter:

- Designar os parâmetros que indicam a falha em questão;
- Delimitar valores máx e/ou mín de funcionamento da máquina por parâmetro;
- Antecipar falhas e possíveis paradas de máquinas;

A metodologia utilizada poderia ser propagada para as demais máquinas e suas falhas, que possuíssem histórico suficiente, seguindo o fluxograma sugerido na figura a seguir:

FIGURA 18 – FLUXO DE ANÁLISE DE FALHAS.



Fonte - Kunumi (2022).

5.1.1. Sugestões de trabalhos futuros

Durante a análise e discussão dos resultados surgiram alguns questionamentos que não puderam ser confirmados neste trabalho, mas que serviram para apontar sugestões para a continuidade dos estudos. Essas sugestões são listadas na sequência:

- Revisar estratégia de sensoriamento das máquinas focando em sensoriamento de parâmetros mais relacionados às falhas que aos processos.

Exemplos: Vibração, sinais elétricos (Corrente e tensão), temperatura em diversos pontos da máquina e pressão de vácuo.

- Aumento do histórico de dados de sensores.

6. REFERÊNCIAS

AGGARWAL, C., C e REDDY C. K; **Data Clustering: Algorithms and Applications** Taylos & Francis Group LLC Minneapolis 2014.

AIRES, R. W, A; MOREIRA, F, K FREIRE, P, "**Industria 4.0: Competências Requeridas aos profissionais da quarta revolução industrial**" Congresso Internacional de Conhecimento e Inovação, Foz do Iguaçu, 2017.

Associação das Normas Técnicas, NBR 5462, "**Confiabilidade e Manutenibilidade**", ABNT, Rio de Janeiro, 1994.

BAMPOULA, X.; SIATERLIS, G.; NIKOLAKIS, N.; ALEXOPOULOS, K. A **Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems Using LSTM Autoencoders.** *Sensors* 2021, 21, 972. <https://doi.org/10.3390/s21030972>.

BORLIDO D. J. A., "**Indústria 4.0 - Aplicação a Sistemas de Manutenção**", Universidade do Porto 2017.

BALDISSARELLI. L, FABRO E. "**Manutenção Preditiva Na Indústria 4.0.**" *Scientia Cum Industria* 7.2 (2019): 12-22. Web.

LUO, B. et. al , "**Early Fault Detection of Machine Tools Based on Deep Learning and Dynamic Identification,**" in *IEEE Transactions on Industrial Electronics*, vol. 66, no. 1, pp. 509-518, Jan. 2019, doi: 10.1109/TIE.2018.2807414. Disponível em <https://ieeexplore-ieee-org.ez74.periodicos.capes.gov.br/stamp/stamp.jsp?tp=&arnumber=8294247> acesso em 23/06/2022.

CAMPESATO, O. **Artificial Intelligence, Machine Learning and Deep Learning**, Boston, Massachusetts: Mercury Learning and Information 2020.

CARVALHO, A. C. P. d. L. F. d. et al. **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina.** [S.I.]: LTC, 2011.

Gan, G., e Ng, M., K., "**K-means Clustering with Outlier Removal.**" *Pattern Recognition Letters* 90 (2017): 8-14. Web.

HENNING, C.; MEILA, M.; FIONN, M.; ROCCI, R.; **Handbook of Cluster Analysis**, CRC PRESS, BOSTON, 2016.

SIQUEIRA, I. P, "**Manutenção centrada na confiabilidade**" Rio de Janeiro: qualitymark Editora, 3 edição, 2014.

JUNIOR, G, T e SALTORATO, P "**Os impactos da Indústria 4.0 na Organização do Trabalho uma Revisão Sistemática da Literatura**" Produção Online Revista Científica Eletrônica de Engenharia de Produção ABEPRO 2018.

JONES, P. J, CATT M, DAVIES M. J, EDWARDSON C. L, MIRKES E. M, KHUNTI K, YATES T, AND ROWLANDS A. V. "**Feature Selection for Unsupervised Machine Learning of Accelerometer Data Physical Activity Clusters – A Systematic Review.**" *Gait & Posture* 90 (2021): 120-28. Web.

JUNIOR, R, RIBEIRO F., et al. "**Fault Detection and Diagnosis in Electric Motors Using 1d Convolutional Neural Networks with Multi-Channel Vibration Signals.**" *Measurement : Journal of the International Measurement Confederation*, vol. 190, 2022, p. 1. disponível em: [https://www-sciencedirect.ez74.periodicos.capes.gov.br/science/article/pii/S0263224122000616?via%3Dihub](https://www.sciencedirect.ez74.periodicos.capes.gov.br/science/article/pii/S0263224122000616?via%3Dihub), acesso em: 23/06/2022.

KARDEC, Alan; NASCIF, Júlio. *Manutenção: função estratégica*. 3.ed. Rio de Janeiro: Ed. Qualitymark, p. 384, 2009.

KHANH T.P. NGUYEN, KAAMEDJAL MHER. "**A new dynamic predictive maintenance framework using deep learning for failure prognostics**", *Reliability Engineering & System Safety*, Volume 188, 2019, Pages 251-262, ISSN 0951-8320," disponível em <https://www.sciencedirect.com/science/article/pii/S0951832018311050> acesso em: 23/06/2022.

LASI, H.; FETTKE, P.; KEMPER, H.-G.; FELD, T.; HOFFMANN, M. *Industry 4.0. Business & Information Systems Engineering*, Springer, v. 6, n. 4, p. 239–242, 2014.

LI, X., ZHANG, W., DING, Q. *et al.* **Intelligent rotating machinery fault diagnosis based on deep learning using data augmentation.** *J Intell Manuf* 31, 433–452 (2020). <https://doi-org.ez74.periodicos.capes.gov.br/10.1007/s10845-018-1456-1>

BALDISSARELLI L. E FABRO E. "**Manutenção Preditiva na indústria 4.0**", SCIENTIA CUM INDUSTRIA, V. 7, N. 2, PP. 12 — 22, 2019, disponível em: <http://www.ucs.br/etc/revistas/index.php/scientiacumindustria/article/view/6835/pdf>

MARWALA, T. **Handbook of Machine Learning Volume 1: Foundation of Artificial Intelligence**. Nova Jersey. World Scientific Publishing Co. Pte. Ltd. 2019.

MOHRI, M; ROSTAMIZADEH, A; TALWALKAR, A. **Foundations of Machine Learning**, Second Edition, Massachusetts: Francis Bach, 2018.

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

RÜßMANN, M.; LORENZ, M.; GERBERT, P.; WALDNER, M.; JUSTUS, J.; ENGEL, P.; HARNISCH, M. Industry 4.0: The future of productivity and growth in manufacturing industries. Boston Consulting Group, v. 9, 2015

Stodola, P.; Stodola, J. **Model of Predictive Maintenance of Machines and Equipment**. *Appl. Sci.* **2020**, *10*, 213. <https://doi.org/10.3390/app10010213>

ROCCO LANGONE, CARLOS ALZATE, BART DE KETELAERE, JONAS VLASSELAER, WANNES MEERT, JOHAN A.K. SUYKENS, **LS-SVM based spectral clustering and regression for predicting maintenance of industrial machines**, Engineering Applications of Artificial Intelligence, Volume 37, 2015, Pages 268-278, ISSN 0952-1976, <https://doi.org/10.1016/j.engappai.2014.09.008>. (<https://www.sciencedirect.com/science/article/pii/S095219761400222X>).

SCHUH, G. et al. **Industrie 4.0 Maturity Index. Managing the Digital Transformation of Companies**, ACATECH, 22 abril 2020.

ZHE YANG, PIERO BARALDI, ENRICO ZIO, **A novel method for maintenance record clustering and its application to a case study of maintenance optimization**, Reliability Engineering & System Safety, Volume 203, 2020, 107103, ISSN 0951-8320, <https://doi.org/10.1016/j.ress.2020.107103>.