



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE AUTOMAÇÃO E SISTEMAS
CURSO DE GRADUAÇÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

Rodrigo Artur Soares Novaes

**Equipamentos IoT em Máquinas Hidráulicas: Monitoramento Inteligente, Análise
e Predição**

Florianópolis
2024

Rodrigo Artur Soares Novaes

Equipamentos IoT em Máquinas Hidráulicas: Monitoramento Inteligente, Análise e Predição

Relatório final da disciplina DAS5511 (Projeto de Fim de Curso) como Trabalho de Conclusão do Curso de Graduação em Engenharia de Controle e Automação da Universidade Federal de Santa Catarina em Florianópolis.

Orientador: Prof. Carlos Barros Montez

Supervisor: Guilherme Cornelli, Eng.

Florianópolis

2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Novaes, Rodrigo Artur Soares
Equipamentos IoT em Máquinas Hidráulicas: Monitoramento
Inteligente, Análise e Predição / Rodrigo Artur Soares
Novaes ; orientador, Carlos Barros Montez, 2024.
80 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia de Controle e Automação,
Florianópolis, 2024.

Inclui referências.

1. Engenharia de Controle e Automação. 2. Manutenção
Preditiva. 3. Internet of Things. 4. Máquinas Hidráulicas.
I. Montez, Carlos Barros. II. Universidade Federal de
Santa Catarina. Graduação em Engenharia de Controle e
Automação. III. Título.

Rodrigo Artur Soares Novaes

Equipamentos IoT em Máquinas Hidráulicas: Monitoramento Inteligente, Análise e Predição

Esta monografia foi julgada no contexto da disciplina DAS5511 (Projeto de Fim de Curso) e aprovada em sua forma final pelo Curso de Graduação em Engenharia de Controle e Automação

Florianópolis, 11 de julho de 2024.

Prof. Marcelo De Lellis Costa de Oliveira
Coordenador do Curso

Banca Examinadora:

Prof. Carlos Barros Montez
Orientador
UFSC/CTC/DAS



Documento assinado digitalmente

Carlos Barros Montez

Data: 30/07/2024 17:23:39-0300

CPF: ***.035.027-**

Verifique as assinaturas em <https://v.ufsc.br>

Guilherme Cornelli, Eng.
Supervisor
Empresa GreyLogix Brasil



Documento assinado digitalmente

GUILHERME CORNELLI SOUZA

Data: 30/07/2024 17:11:18-0300

Verifique em <https://validar.iti.gov.br>

Prof. Leandro Becker
Avaliador
UFSC/CTC/DAS

Prof. Hector Bessa Silveira,
Presidente da Banca
UFSC/CTC/DAS

AGRADECIMENTOS

Gostaria de expressar meus sinceros agradecimentos a todas as pessoas que estiveram ao meu lado durante esta jornada ao longo da graduação e do desenvolvimento deste projeto de fim de curso.

Agradeço à Universidade Federal de Santa Catarina por me proporcionar um ensino de qualidade e diversas experiências, dentro e fora da sala de aula, que levarei para a vida toda. Agradeço a todos os mestres, professores e docentes do Departamento de Automação e Sistemas, em especial ao meu orientador, professor Carlos Barros Montez, por seu apoio, atenção e disponibilidade em todos os momentos de dúvida.

À empresa GreyLogix Brasil e, principalmente, aos amigos do time YoT pelo companheirismo e ajuda ao longo do desenvolvimento do projeto. Em especial, ao meu amigo e mentor na empresa, Guilherme Cornelli, por me incluir no time YoT e por todo o suporte, aprendizado e confiança ao longo do projeto.

À minha família, especialmente meus pais, Artur Novaes e Lucila Novaes, por me apoiarem e proporcionarem uma boa educação, além de confiarem em mim e não medirem esforços para estarem presentes, sempre me acompanhando pelo melhor caminho.

Aos meus avós, Sônia e Tabajara, por seus sábios conselhos e constante apoio, incentivo e cuidado na minha jornada acadêmica e pessoal.

À minha irmã e confidente, Denise Novaes, por me apoiar e estar sempre ao meu lado, nos bons e maus momentos, no Brasil ou fora dele. Também à minha tia, Regina Soares, pela dedicação, incentivo e apoio na minha educação e trajetória desde a minha infância.

À minha namorada e companheira, Maria Eduarda Engel, pelos sempre bons momentos compartilhados, além do constante incentivo e companhia, mesmo nos momentos de intenso estudo e desenvolvimento deste trabalho.


E a todos os meus amigos que compartilharam estes últimos anos de desenvolvimento pessoal e profissional, sejam de Fortaleza-CE, de Florianópolis-SC ou da Alemanha. Suas amizades, companheirismo e momentos de desafios, risos e conquistas foram essenciais para mim.

DECLARAÇÃO DE PUBLICIDADE

Florianópolis, 28 de junho de 2024.

Na condição de representante da GreyLogix Brasil na qual o presente trabalho foi realizado, declaro não haver ressalvas quanto ao aspecto de sigilo ou propriedade intelectual sobre as informações contidas neste documento, que impeçam a sua publicação por parte da Universidade Federal de Santa Catarina (UFSC) para acesso pelo público em geral, incluindo a sua disponibilização *online* no Repositório Institucional da Biblioteca Universitária da UFSC. Além disso, declaro ciência de que o autor, na condição de estudante da UFSC, é obrigado a depositar este documento, por se tratar de um Trabalho de Conclusão de Curso, no referido Repositório Institucional, em atendimento à Resolução Normativa n° 126/2019/CUn.

Por estar de acordo com esses termos, subscrevo-me abaixo.

Documento assinado digitalmente
 **GUILHERME CORNELLI SOUZA**
Data: 30/07/2024 14:35:26-0300
Verifique em <https://validar.iti.gov.br>

Guilherme Cornelli
GreyLogix Brasil

RESUMO

O cenário industrial atual, independentemente da área de atuação, depende significativamente de máquinas para os processos de produção. Nesse contexto, algumas máquinas são essenciais na cadeia produtiva e devem estar sempre disponíveis. No entanto, quando estas máquinas apresentam falhas na sua rotina ou em seus componentes e precisam de manutenção, seja programada ou não, isso pode resultar em gargalos e pausas na linha de produção, gerando grandes custos financeiros e um problema para a organização e o processo de produção da empresa. Assim, as indústrias estão constantemente buscando maneiras de reduzir as manutenções não programadas ou corretivas, principalmente para essas máquinas críticas, as quais estão presentes em processos que necessitam de força, precisão e consistência. Nesse contexto, este trabalho propõe uma transformação da abordagem da manutenção industrial, focando na transição da manutenção corretiva ou preventiva para um modelo preditivo mais eficiente, trazendo análises, projeções e *insights* em um relatório sobre os dados e condição da máquina. Utilizando técnicas de análise e predição de dados em conjunto com o monitoramento contínuo de sensores em máquinas hidráulicas, principalmente focando na metodologia que gira em torno da análise de saúde da máquina por meio de análises no fluido hidráulico (como pressão, temperatura e contaminação por particulados), é possível gerar relatórios detalhados sobre o desgaste das máquinas no tempo passado, visualizar variáveis em tempo real e prever dados futuros. Em conjunto com esses dados em tempo real, a previsibilidade das variáveis permite que as empresas realizem um planejamento eficaz de manutenção, evitando paradas de produção e reduzindo custos inesperados, e impactando diretamente no aumento da produtividade com um menor custo de manutenção.

Palavras-chave: Manutenção Preditiva. Máquinas Hidráulicas. Internet of Things.

ABSTRACT

The current industrial scenario, regardless of the area of activity, relies heavily on machines for production processes. In this context, some machines are essential in the production chain and must always be available. However, when these machines experience routine failures or component issues and require maintenance, whether scheduled or unscheduled, it can result in bottlenecks and production line stoppages, causing significant financial costs and problems for the organization and its production processes. Thus, industries are constantly seeking ways to reduce unscheduled or corrective maintenance, especially for these critical machines, which are present in processes that require strength, precision, and consistency. In this context, this work proposes a transformation of the industrial maintenance approach, focusing on the transition from corrective or preventive maintenance to a more efficient predictive model, providing analyses, projections, and insights in a report on the machine's data and condition. By using data analysis and prediction techniques in conjunction with continuous sensor monitoring on hydraulic machines, primarily focusing on the methodology revolving around machine health analysis through hydraulic fluid assessments (such as pressure, temperature, and particulate contamination), it is possible to generate detailed reports on machine wear over past time, visualize real-time variables, and predict future data. Along with this real-time data, the predictability of variables allows companies to conduct effective maintenance planning, avoiding production stoppages and reducing unexpected costs, directly impacting increased productivity with lower maintenance costs.

Keywords: Predictive Maintenance. Hydraulic Machines. IoT.

LISTA DE FIGURAS

Figura 1 – Diagrama base da Manutenção Preditiva.	15
Figura 2 – Logo da empresa GreyLogix Brasil.	18
Figura 3 – Exemplos de principais simbologias em sistemas hidráulicos.	20
Figura 4 – Tabela de classes da norma ISO4406.	26
Figura 5 – Curva P-F.	28
Figura 6 – Exemplo de resultado para metodologia de análise de dados.	32
Figura 7 – Representação da arquitetura da solução YoT.	33
Figura 8 – Representação do fluxo de dados da solução YoT.	34
Figura 9 – Representação do esquema de armazenamento da solução YoT.	35
Figura 10 – Visão geral e organização dos projetos.	40
Figura 11 – Exemplo de <i>dashboard</i> com diagrama hidráulico.	41
Figura 12 – Exemplo de <i>dashboard</i> com base histórica.	41
Figura 13 – Exemplo de gráfico de pressão do projeto B.	44
Figura 14 – Exemplo de gráfico de pressão do projeto K.	44
Figura 15 – Exemplo de dados do sensor MCS do projeto B.	46
Figura 16 – Exemplo de dados do sensor CS do projeto G.	46
Figura 17 – Exemplo de correlação entre os valores de pressão e temperatura, do projeto B.	47
Figura 18 – Exemplo de correlação entre os sensores de pressão e MCS, do projeto B.	47
Figura 19 – Comparação entre modelos de DF antes e após interpolação de dados.	49
Figura 20 – Comparação entre diferentes formas de interpolação de dados.	50
Figura 21 – Exibição dos períodos de funcionamento da máquina em 3 sensores: pressão, temperatura e MCS (24h).	54
Figura 22 – Comparação entre intervalos de 0 e 5 minutos para limpeza de <i>outliers</i> por tempo.	56
Figura 23 – Exemplo de sazonalidade da temperatura em máquina do projeto G. Imagem feita utilizando o software Visplore.	57
Figura 24 – Exemplo de predição de dados dependendo do tempo de treinamento prévio, em ordem: 1 mês, 2 meses, 6 meses e 12 meses. Dados do sensor de pressão do projeto K.	62
Figura 25 – Exemplo de predição de dados para comparar utilização de diferentes frequências para os dados futuros, em ordem: 1 mês e 30 dias. Dados do sensor de pressão do projeto B.	63

Figura 26 – Exemplo de predição de dados para exibir diferentes resultados dependendo dos dados de entrada (em ordem: filtrados e puros). Em vermelho estão os dados reais do mês, comparados com a predição em azul. Dados do sensor de pressão do projeto B.	64
Figura 27 – Exemplo de predição de dados para exibir aviso gerado quando projeção ultrapassa alarme. Dados do sensor de pressão do projeto B.	64
Figura 28 – Exemplo de parte da página de Dados do Relatório.	66
Figura 29 – Exemplo de estatísticas de sensores da página Sensores e Máquina. Contém sensores com nomes fictícios.	66
Figura 30 – Exemplo de exibição de disponibilidade da máquina da página Sensores e Máquina.	67
Figura 31 – Exemplo de gráfico de sensores da página Sensores e Máquina. Contém 2 variáveis de pressão.	67
Figura 32 – Exemplo de gráfico de sensores da página Sensores e Máquina com limites associados ao desvio padrão. Contém 2 variáveis de pressão e 1 de temperatura.	68
Figura 33 – Exemplo de tabela de alarmes da página de Alarmes. Contém nomes de sensores fictícios. Imagem foi cortada para caber no documento.	69
Figura 34 – Exemplo de tabela de alarmes da página de Alarmes. Contém nomes de sensores fictícios.	70
Figura 35 – Exemplo de gráfico de projeção e dados reais da página de Predição de Dados. Sensores MCS e de pressão, respectivamente.	71
Figura 36 – Exemplo de gráfico de projeção da página de Predição de Dados. Sensor de pressão.	71
Figura 37 – Exemplo de predição de dados entre pressão e temperatura, respectivamente.	73

LISTA DE TABELAS

Tabela 1 – Distribuição das ações de manutenção segundo (REIS; COSTA; ALMEIDA, 2013).	27
Tabela 2 – Comparação de custo, tempo e investimento entre os tipos de manutenção segundo adaptação de (TELES, 2018).	31
Tabela 3 – Formatação padrão dos dados no Banco de Dados.	42
Tabela 4 – Formatação padrão de DF com alarmes dos sensores.	58

LISTA DE ABREVIATURAS E SIGLAS

Alarme LL	<i>Alarme Low Low (Baixo Baixo)</i>
Alarme L	<i>Alarme Low (Baixo)</i>
Alarme H	<i>Alarme High (Alto)</i>
Alarme HH	<i>Alarme High High (Alto Alto)</i>
CSV	<i>Comma-Separated Values (Valores Separados por Vírgula)</i>
DB	<i>Database (banco de dados)</i>
DF	<i>Dataframe (tabela de dados)</i>
DIKW	<i>Data, Information, Knowledge, Wisdom (Dados, Informação, Conhecimento, Sabedoria)</i>
IoT	<i>Internet of Things</i>
IIoT	<i>Industrial Internet of Things</i>
IIIoT	<i>Intelligent Industrial Internet of Things</i>
PLC (CLP)	<i>Programmable Logic Controller (Controlador Lógico Programável)</i>
SCADA	<i>Supervisory Control and Data Acquisition (Supervisão, Controle e Aquisição de Dados)</i>
YoT	<i>Solução de IIoT da empresa GreyLogix</i>
°C	<i>Graus Celsius</i>

SUMÁRIO

1	INTRODUÇÃO	15
1.1	VISÃO GERAL	15
1.2	MOTIVAÇÃO	16
1.3	OBJETIVOS	16
1.4	EMPRESA	17
1.5	ESTRUTURA DO DOCUMENTO	18
2	SISTEMAS HIDRÁULICOS	19
2.1	FLUIDO HIDRÁULICO	19
2.1.1	Conceito de "saúde" de uma máquina hidráulica	19
2.1.2	Verniz	20
2.2	DIAGRAMAS HIDRÁULICOS E SIMBOLOGIA	20
2.3	SENSORES	21
2.3.1	Particulados	21
2.3.1.1	CS - Contamination Sensor	21
2.3.1.2	MCS - Metallic Contamination Sensor	21
2.3.2	Fluxo e Óleo	22
2.3.2.1	HLB - Oil Condition Sensor	22
2.3.2.2	HDA - Pressure Transmitter	22
2.3.3	Outros sensores	22
2.3.3.1	HNS - Level Switch	22
2.4	FALHAS	23
2.4.1	Contaminação do fluido por partículas sólidas, água ou ar	23
2.4.2	Superaquecimento do Fluido	24
2.4.3	Desgaste e falha de componentes	24
2.5	CORRELAÇÕES ENTRE VARIÁVEIS	24
2.5.1	Particulados e pressão	24
2.5.2	Particulados e temperatura	24
2.5.3	Particulados e Umidade	25
2.5.4	Pressão e fluxo	25
2.6	NORMAS	25
2.6.1	Norma ISO4406	25
2.6.2	Norma ISO16232	25
3	TECNOLOGIAS E FERRAMENTAS	27
3.1	FORMAS DE MANUTENÇÃO	27
3.1.1	Curva P-F	27
3.1.2	Manutenção Corretiva	28
3.1.3	Manutenção Preventiva	29

3.1.4	Manutenção Preditiva	30
3.2	METODOLOGIA PARA ANÁLISE DE DADOS DA MÁQUINA	31
3.3	ARQUITETURA E HARDWARE YOT	33
3.3.1	Arquitetura	33
3.3.2	Fluxo de Dados	33
3.3.3	Armazenamento	34
3.3.4	Análises	34
3.3.5	Apresentação	35
3.3.6	Segurança	36
3.4	SOFTWARES	36
3.4.1	Prophet	36
3.4.2	Visplore	37
4	DESENVOLVIMENTO E IMPLEMENTAÇÃO	38
4.1	VISÃO GERAL DO ESTUDO	38
4.2	ANÁLISE PRÉVIA DOS DADOS	41
4.2.1	Dados Iniciais	42
4.2.2	Exploração de dados	43
4.2.3	Correlações entre as variáveis	46
4.3	IMPORTAÇÃO DO BANCO DE DADOS	47
4.3.1	Interpolação dos dados	48
4.4	DEFINIÇÃO DE PARÂMETROS E MÉTODOS	50
4.4.1	Parâmetros de projeto	50
4.4.2	Etapas de funcionamento da máquina	52
4.4.3	Execução e métodos do código	54
4.4.3.1	Detecção de intervalos	55
4.4.3.1.1	<i>Limpeza de outliers por intervalos de tempo</i>	55
4.4.3.2	Moda móvel para temperatura	56
4.4.3.3	Limites de alarmes	57
4.5	ESTATÍSTICAS	58
4.6	ALARMES	59
4.7	PREDIÇÃO	60
4.7.1	Alarmes nos valores estimados	64
5	RELATÓRIO MENSAL AUTOMÁTICO	65
5.1	DADOS DO RELATÓRIO	65
5.2	SENSORES E MÁQUINA	66
5.3	ALARMES	68
5.4	PREDIÇÃO DE DADOS	69
5.5	PARECER TÉCNICO	71
6	RESULTADOS	72

6.1	RESULTADOS DO CÓDIGO E ANÁLISES	72
6.2	RESULTADOS DO RELATÓRIO AUTOMÁTICO	73
7	CONCLUSÃO E PERSPECTIVAS FUTURAS	75
7.1	PERSPECTIVAS PARA FUTUROS TRABALHOS	76
	REFERÊNCIAS	77

1 INTRODUÇÃO

1.1 VISÃO GERAL

O cenário industrial moderno é, cada vez mais, caracterizado pela dependência de máquinas e equipamentos que garantem a eficiência, além de rapidez e precisão, de processos de produção. Como qualquer equipamento, estas máquinas precisam de manutenção e, nesse contexto, esse processo se torna crucial para evitar interrupções na linha de produção que possam causar prejuízos financeiros. Tradicionalmente e de forma menos custosa para ser desenvolvido, as indústrias têm adotado modelos de manutenção corretiva, onde os reparos são feitos após a ocorrência da falha, ou preventiva, onde a manutenção é feita em intervalos regulares, independente da condição real dos equipamentos.

Entretanto, com o avanço da tecnologia e os desenvolvimentos em algoritmos e manuseio de dados, em conjunto com a crescente demanda de uma maior eficiência e uma redução de custos, surge a necessidade de um modelo mais proativo e eficiente: a manutenção preditiva. Este modelo de manutenção tem como foco a utilização e o armazenamento de dados em tempo real e, com base em análises avançadas e num histórico de dados, a prevenção de falhas antes que elas ocorram, permitindo um melhor e mais eficaz planejamento das intervenções de manutenção, caso sejam necessárias.

O presente trabalho visa explorar essa transformação do contexto da manutenção industrial, focando no contexto de máquinas hidráulicas e nos dados de sensores, principalmente, de particulados e utilizando equipamentos IoT (*Internet of Things*) para o monitoramento inteligente e para a análise e predição de falhas.

Figura 1 – Diagrama base da Manutenção Preditiva.



Fonte: Arquivo próprio.

1.2 MOTIVAÇÃO

A motivação para este trabalho está alinhada com a necessidade crescente das indústrias de melhorar a gestão dos custos operacionais e aumentar a eficiência dos processos produtivos por meio de relatórios que contêm análises, *insights* e projeções dos dados das máquinas estudadas. Além disso, há o anseio de facilitar a modificação do cenário industrial atual, o qual os formatos de manutenção corretiva e preventiva predominam nas empresas (levando a pausas inesperadas, altos custos de reparo e substituições prematuras de componentes). Ainda vale ressaltar a utilização de máquinas com funcionamento crítico para toda a cadeia produtiva, as quais são indispensáveis para o processo e devem estar disponíveis na maioria do tempo.

Dessa forma, a adoção da manutenção preditiva promete reduzir custos e paradas de manutenção, além de facilitar a detecção e identificação de problemas, permitindo que as indústrias tenham mais tempo de planejamento e intervenham somente quando necessário com base em dados concretos e projeções sobre a condição da máquina ou componentes. Assim, não somente há uma maior disponibilidade das máquinas, como uma maior vida útil dos equipamentos e de suas partes, contribuindo para uma operação mais sustentável e econômica.

1.3 OBJETIVOS

Dada a contextualização e a motivação do trabalho proposto, este projeto visa a modificação do cenário atual dos modelos de manutenção, tornando a manutenção preditiva mais acessível para máquinas hidráulicas críticas, usando equipamentos IoT para monitorar as suas variáveis, realizar a predição de dados e gerar relatórios sobre a condição da máquina que anteciparão possíveis problemas no processo industrial envolvido.

Dessa forma, o trabalho tem como objetivo principal propor um modelo de relatório das máquinas hidráulicas estudadas a fim de facilitar a modificação do formato de manutenção para a manutenção preditiva. Para isso, devem ser concretizados, como objetivos intermediários:

- Adquirir e organizar os dados históricos e em tempo real da máquina, a fim de facilitar as futuras análises e melhorar a predição de dados.
- Projetar valores futuros das variáveis do processo de forma a observar tendências.
- Apresentar análises, *insights* e predições, focando na condição e disponibilidade da máquina

Por fim, estes relatórios devem facilitar a identificação de padrões, anomalias e problemas, antecipar falhas e informar sobre a disponibilidade e saúde da máquina, de forma que o gestor do processo industrial seja apto a implementar os conceitos de manutenção preditiva, impactando no aumento de produtividade com um menor custo de manutenção na fábrica.

1.4 EMPRESA

A empresa brasileira GreyLogix Brasil, tendo sua origem na Alemanha por meio de uma parceria com a Bilfinger GreyLogix GmbH, nasceu em 2007 seguindo os conceitos de qualidade do grupo alemão. Seus primeiros seis colaboradores treinaram durante dois anos na Alemanha antes mesmo que fosse aberta a operação no Brasil.

Desde então, a empresa vem constantemente recebendo investimentos em treinamentos nas mais modernas tecnologias garantindo soluções de alto padrão para a indústria. A expansão da empresa começou pelo sul do país, dada a influência da cultura alemã, além da proximidade da Universidade Federal de Santa Catarina (UFSC), referência internacional em automação industrial e engenharia mecânica e elétrica.

Hoje, a empresa conta com mais de 250 colaboradores brasileiros, em sua maioria técnicos e engenheiros, com o suporte de mais de 500 colaboradores na Alemanha. Além da matriz em Mafra (SC), a GreyLogix Brasil possui unidades de negócios em diversas cidades dos estados de Santa Catarina, Paraná e São Paulo, como Blumenau, Canoinhas, Curitiba, Florianópolis, Sertãozinho, Londrina, Maringá, Joinville, São Paulo e Rio Negro).

Além da atuação doméstica em todos os estados brasileiros, a GreyLogix Brasil possui projetos concluídos e também em andamento, em mais de 20 países, incluindo diversos países da América Latina, como Chile, Argentina, Venezuela e Uruguai. O time de engenheiros tem capacitação técnica para lidar com as mais variadas características locais de cada país.

A GreyLogix Brasil é uma empresa focada em soluções. Com a missão de evoluir a indústria através de transformação tecnológica, busca na inovação o combustível para se impulsionar a cada novo projeto. Assim como os parceiros da Bilfinger Grey-Logix são referência em soluções de engenharia na Europa, a GreyLogix Brasil busca ser a referência para a América Latina.

Hoje em dia, a empresa é a maior Solution Partner SIEMENS e integrador oficial Rockwell Automation, tornando os engenheiros de Software da GreyLogix especialistas nos principais sistemas de automação do mundo.

Figura 2 – Logo da empresa GreyLogix Brasil.



Fonte: Arquivo próprio.

1.5 ESTRUTURA DO DOCUMENTO

Nos capítulos 2 e 3 será feita uma breve apresentação do contexto do trabalho, além de uma explicação dos conceitos utilizados a fim de criar uma fundamentação teórica do tema. Para o capítulo 2, os conceitos serão direcionados para o contexto de máquinas hidráulicas e conceitos mais relacionados à parte de engenharia mecânica do projeto. Já para o capítulo 3, o contexto é relacionado às tecnologias, metodologias e ferramentas utilizadas no estudo.

No capítulo 4, são mostrados os detalhes e os passos seguidos para a implementação do código principal da análise dos dados dos projetos mencionados. O desenvolvimento é dividido em seções de forma a simplificar o entendimento e dividir as diferentes etapas do processo de análise e de produção do código.

Já como um breve resultado das análises, mas ainda como desenvolvimento do estudo, o capítulo 5 mostra como o material desenvolvido foi aplicado para gerar relatórios automáticos de análise.

No capítulo 6 são apresentadas os resultados gerais acerca do código desenvolvido para análise e dos relatórios criados.

Por fim, o capítulo 7 traz as conclusões deste trabalho e sugestões para pesquisas futuras sobre os tópicos deste estudo.

2 SISTEMAS HIDRÁULICOS

A fim de criar uma base de conhecimento acerca dos futuros temas descritos e das análises desenvolvidas neste trabalho, esta seção tratará dos conceitos necessários sobre os tópicos que envolvem a máquina hidráulica e a parte mecânica do estudo.

Na física, a hidráulica é a área dedicada a entender como os líquidos incompressíveis se comportam, seja para quando estão parados ou em movimento. A palavra "hidráulica" vem do grego, que junta as palavras "hydra", que significa água, e "aulos", que significa condução ou tubos (FIALHO, 2004).

Os sistemas hidráulicos possuem muitas vantagens para os equipamentos a que estão conectados. Enquanto motores elétricos operam em velocidades constantes, as máquinas hidráulicas permitem que a velocidade de funcionamento de um mecanismo seja ajustável. Além disso, uma válvula de alívio protege o sistema hidráulico contra danos causados por sobrecargas de pressão, além de ajustar a máquina para atividades específicas de pressão e força nos equipamentos. A bomba é alimentada por reservatórios que têm limites definidos, de acordo com a força ou torque de saída do sistema. Ademais, os circuitos hidráulicos podem ser interrompidos no meio de uma operação sem causar danos aos componentes e equipamentos (VICKERS, 1983).

2.1 FLUIDO HIDRÁULICO

Como um dos principais componentes de um sistema hidráulico e vital no desenvolvimento deste trabalho, o fluido hidráulico possui diferentes funções no sistema, como lubrificação, transmissão de energia, limpeza e proteção contra a degradação dos componentes internos (THERMAL, 2024).

2.1.1 Conceito de "saúde" de uma máquina hidráulica

O fluido hidráulico pode ser considerado o sangue vital de um sistema hidráulico, pois é responsável por transmitir potência, lubrificar componentes e dissipar calor. A condição do fluido, dessa forma, é um indicador essencial para indicar a condição geral da máquina (BURKE, 2023).

Por se tratar de um elemento essencial num sistema hidráulico, o óleo ou fluido hidráulico deve estar sempre em condições adequadas e, além disso, representa uma condição geral da máquina.

Uma analogia simples feita por profissionais da área sobre a máquina e o fluido hidráulico é uma comparação com o corpo humano e o sangue. Dessa mesma forma, a fim de descobrir o estado da máquina e se ela está funcionando bem, pode-se analisar a condição do fluido hidráulico desta máquina.

Este é o conceito principal deste trabalho: detectar a condição de funcionamento do sistema por meio de análises no fluido hidráulico.

2.1.2 Verniz

Um dos grandes problemas que podem ocorrer num fluido hidráulico é a criação de verniz, que vem junto com a transformação de propriedades do fluido, trazendo enormes danos ao sistema hidráulico e seus componentes. Sua principal causa é a contínua oxidação do óleo, acelerada pela temperatura (LIVINGSTONE, 2023).


Nos últimos anos houve mudanças nos óleos básicos (*base oils*) dos fluidos hidráulicos, tornando-os quimicamente mais puros e termicamente mais estáveis. Atualmente, devido à degradação dos óleos lubrificantes e hidráulicos, são formadas substâncias gelatinosas que levam ao depósito de partículas marrons em partes frias do sistema. Essas partículas afetam válvulas, cilindros e rolamentos por meio do aumento de temperatura devido à fricção, aumento da viscosidade do óleo, vazamento de válvulas e maiores desgastes (HYDAC, 2022).

2.2 DIAGRAMAS HIDRÁULICOS E SIMBOLOGIA

Como neste estudo foram realizadas análises sobre diagramas hidráulicos, foi necessário um breve estudo acerca dos componentes e principais símbolos.

Um resumo de alguns símbolos, seguindo a norma ANSI/ISA-S5. 1 – 1984 (R1992) *Instrumentation Symbols and Identification*, podem ser vistos na figura 3 (GOMES, 2008). Um exemplo de diagrama hidráulico, utilizado neste estudo, que contém alguns destes símbolos está representado na figura 11.

Figura 3 – Exemplos de principais simbologias em sistemas hidráulicos.



Fonte: Arquivo próprio.

2.3 SENSORES

A fim de apontar os principais sensores utilizados neste estudo e explicar brevemente as finalidades, princípios de funcionamento e, para alguns, o formato de resposta enviada, nesta seção haverá categorias para cada tipo de sensor. Essas informações foram retiradas da base de dados de uma das grandes empresas de sensores e equipamentos hidráulicos do mundo, a Hydac, e estão disponíveis nos catálogos e *datasheets* no site da empresa do Brasil (<https://www.hydac.com/shop/pt-br/sensores>).

2.3.1 Particulados

Sensores que monitoram o desgaste de componentes, a presença de contaminantes sólidos e a eficácia do processo de filtragem.

2.3.1.1 CS - Contamination Sensor

- **Função:** detectar e monitorar a presença de partículas sólidas e água em fluidos;
- **Finalidade no estudo:** indicar desgaste de componentes do processo ou impurezas no óleo;
- **Princípio de medição:** através de princípios ópticos, onde as partículas dispersam a luz;
- **Resposta utilizada no estudo:** retorna a classe ISO4406 (a ser explicada na seção 2.6) do tamanho correspondente.

2.3.1.2 MCS - Metallic Contamination Sensor

Classificação de tamanho pela ISO16232

- **Função:** detectar e monitorar a presença de partículas ferrosas ou não ferrosas em fluidos;
- **Finalidade no estudo:** indicar desgaste excessivo de componentes ferrosos do processo ou problemas de funcionamento do equipamento;
- **Princípio de medição:** através de princípios magnéticos, onde as partículas ferrosas presentes no fluido são detectadas por um sensor magnético;
- **Classificação por tamanhos:**
 - A: 70 – 100 μm
 - B: 100 – 150 μm
 - C: 150 μm <

- **Resposta utilizada no estudo:** retorna a quantidade de partículas, dependendo da categoria de tamanho (A, B ou C) e se são ferrosas ou não, que passam pelo sensor.

2.3.2 Fluxo e Óleo

Sensores que monitoram as condições gerais do fluido hidráulico.

2.3.2.1 HLB - Oil Condition Sensor

- **Função:** medir índices de saturação, temperatura, condutividade e constante dielétrica;
- **Finalidade no estudo:** indicar níveis anormais de variáveis que podem trazer problemas aos componentes do sistema hidráulico, como corrosão, oxidação e verniz.
- **Resposta utilizada no estudo:** valores puros principalmente de temperatura e saturação do fluido.

2.3.2.2 HDA - Pressure Transmitter

- **Função:** monitorar a pressão do fluido;
- **Finalidade no estudo:** manter a pressão adequada;
- **Princípio de medição:** através do princípio piezo-resistivo (resistência elétrica muda devido à deformação de uma película), gerando um sinal elétrico proporcional à pressão;
- **Resposta utilizada no estudo:** valores puros de pressão do fluido.

2.3.3 Outros sensores

2.3.3.1 HNS - Level Switch

- **Função:** medir nível de fluido no reservatório;
- **Finalidade no estudo:** manter nível adequado e verificar possível vazamento de fluido;
- **Princípio de medição:** flutuação.

2.4 FALHAS

Máquina hidráulicas possuem muitos componentes e podem ter diversas causas para falhas diferentes. Assim, compreendendo as falhas (suas causas, as relações de medições dos sensores e suas correlações entre eles), é possível compreender melhor os dados e melhorar ainda mais as análises e processos de manutenção preditiva.

A seguir são apresentadas as seguintes falhas mais recorrentes que envolvem o fluido hidráulico (principal componente de pesquisa desse trabalho) e os sensores atrelados, principalmente tendo como exemplo os casos estudados neste trabalho:

- Contaminantes e particulados nos fluidos devido ao desgaste de componentes e/ou contaminação externa; Utiliza-se sensor de particulados (CS ou MCS).
- Vazamento de óleo e problemas de vedação; Utiliza-se sensores de pressão, fluxo e nível.
- Superaquecimento devido a problemas de obstrução, lubrificação inadequada/insuficiente ou mau funcionamento; Utiliza-se, principalmente, sensores de temperatura.
- Vibração excessiva devido a desgaste, desalinhamento e problemas de balanceamento; Utiliza-se sensores de vibração e frequência.

A seguir, as principais falhas no contexto deste trabalho são mais detalhadas de acordo com as suas características, com maior ênfase na contaminação por particulados.

2.4.1 Contaminação do fluido por partículas sólidas, água ou ar

Mais de 75% das falhas em sistemas hidráulicos e de lubrificação são causados pelo excesso de contaminação de partículas. Estes resquícios de sujeira podem fazer com que máquinas caras e grandes falhem (PARKER, 2006).

A contaminação do fluido em um sistema hidráulico é a causa principal de falha dos cilindros hidráulicos. Partículas estranhas contidas no fluido, a partir do ambiente externo, podem arranhar as partes e acelerar o desgaste dos componentes. Contaminantes líquidos, como a água, causam oxidação e corrosão de partes metálicas, principalmente das superfícies cromadas e do cilindro. Vedantes e conexões também podem ser degradados, levando a vazamentos internos e externos, trazendo efeitos ruins ao sistema e diminuindo o desempenho do mesmo (EOOE, 2023).

A contaminação do fluido pode ter várias origens, como: contaminação na instalação ou do ambiente, durante o reabastecimento do fluido de operação, devido a processos de desgaste interno e ao envelhecimento do óleo. E resulta em desgaste abrasivo, aumento de vazamentos, falha de componentes, inexatidões de controle, bloqueio de pistões de controle e curta vida útil do fluido. (HYDAC, 2018).

A cavitação, aeração e a oxidação são problemas gerados pela presença de vapor, água e/ou bolhas de ar no circuito hidráulico. A cavitação gera pequenas implosões de vapor do fluido, causando um maior desgaste nos componentes, principalmente erosão em suas superfícies. Já a aeração é a entrada de bolhas de ar nas cavidades da bomba, diminuindo o rendimento da mesma e aumentando a degradação dos componentes pela formação de espuma. Por último, a oxidação é quando há reações químicas entre o metal e o oxigênio, causando corrosão do material e gerando o enfraquecimento e ferrugem nos componentes (HYDRA, 2018).

2.4.2 Superaquecimento do Fluido

O superaquecimento pode ter influência de vazamentos internos do fluido, fricção excessiva ou passagem bloqueadas do circuito hidráulico, além de incorreta viscosidade do fluido (HYDRA, 2018).

2.4.3 Desgaste e falha de componentes

O desgaste de componentes, como válvulas, bombas, redutores e atuadores, ocorre ao longo do tempo devido à fricção e, como já mencionado, contaminação. Dessa forma, pode-se utilizar sensores para monitorar o desempenho desses componentes, como medições de pressão, temperatura, vibração e vazão (EOOE, 2023).

2.5 CORRELAÇÕES ENTRE VARIÁVEIS

Como pode ser notado pela seção anterior, estas falhas nunca estão isoladas e sempre ocorrem em conjunto com outras falhas as quais as variáveis estão correlacionadas. Alguns exemplos, principalmente no contexto deste trabalho, serão tratadas, de forma resumida, a seguir. (PARKER, 2006) (HYDAC, 2018) (GANNON, 2018)

2.5.1 Particulados e pressão

A alta concentração de partículas no fluido e a falta de limpeza do filtro, podem gerar obstrução deste e elevar a pressão à medida que o fluido é forçado para passar pelos filtros obstruídos.

2.5.2 Particulados e temperatura

Uma maior temperatura no sistema gera um aumento do desgaste de componentes e, logo, maior quantidade de partículas devido ao aumento da pressão interna (devido à expansão térmica), redução da viscosidade (devido a perda de eficiência na lubrificação) e degradação do óleo.

2.5.3 Particulados e Umidade

A maior presença de água no óleo pode acelerar o desgaste de componentes, aumentando a quantidade de partículas. Isso ocorre, como explicado anteriormente, devido a corrosão e oxidação dos metais e a redução da viscosidade do óleo.

2.5.4 Pressão e fluxo

Uma queda na pressão geralmente correlaciona-se com uma redução na taxa de fluxo, indicando potenciais vazamentos ou bloqueios no sistema.

2.6 NORMAS

A seguir, serão comentadas as normas de referência utilizadas neste estudo para as análises dos sensores de contaminação: MCS e CS.

2.6.1 Norma ISO4406

Essa é a norma principal utilizada como referência para o sensor CS.

Esta norma, em resumo, define classes de limpeza com base no número de partículas encontradas em três faixas de tamanho: partículas maiores que 4, 6 e 14 micrômetros. Por exemplo, uma classificação típica na norma ISO 4406 pode ser "18/16/13", onde o primeiro número indica o número de partículas maiores que 4 micrômetros por mililitro de fluido, o segundo número indica o número de partículas maiores que 6 micrômetros, e o terceiro número indica o número de partículas maiores que 14 micrômetros (STANDARDS, 2021).

Assim, a tabela com as classes utilizadas pelo sensor CS neste projeto fica da forma exibida pela figura 4.

2.6.2 Norma ISO16232

Essa é a norma principal utilizada como referência para o sensor MCS.

Esta norma, em resumo, classifica os tamanhos das partículas do fluido, dependendo da categoria (se é ferrosa ou não ferrosa) (ABNT, 2011).

Assim, seguindo o funcionamento do sensor MCS utilizado neste projeto (pois a adequação da norma depende das características do sensor), a categorização fica da seguinte forma:

- **Para partículas ferrosas:**

- Categoria A: 70100 μm
- Categoria B: 100150 μm
- Categoria C: 150 μm

- Para partículas não ferrosas:

- Categoria D: $100\mu m$
- Categoria E: $200\mu m$
- Categoria F: $> 200\mu m$

Figura 4 – Tabela de classes da norma ISO4406.

Classe ISO	Quantidade de partículas/100 ml		Carga de contaminante (ACFTD)
	Mais que	Até inclusive	[mg/l]
0	0,5	1	–
1	1	2	–
2	2	4	–
3	4	8	–
4	8	16	–
5	16	32	–
6	32	64	0,001
7	64	130	–
8	130	250	–
9	250	500	–
10	500	1.000	0,01
11	1.000	2.000	–
12	2.000	4.000	–
13	4.000	8.000	0,1
14	8.000	16.000	–
15	16.000	32.000	0,2
16	32.000	64.000	0,5
17	64.000	130.000	1
18	130.000	250.000	3
19	250.000	500.000	5
20	500.000	1.000.000	7/10
21	1.000.000	2.000.000	20
22	2.000.000	4.000.000	40
23	4.000.000	8.000.000	80
24	8.000.000	16.000.000	–
25	16.000.000	32.000.000	–
26	32.000.000	64.000.000	–
27	64.000.000	130.000.000	–
28	130.000.000	250.000.000	–
> 28	250.000.000		

Fonte: (HYDAC, 2024)

3 TECNOLOGIAS E FERRAMENTAS

Esta seção trata dos conceitos necessários sobre outros tópicos deste estudo, como metodologias, softwares e outros conceitos.

3.1 FORMAS DE MANUTENÇÃO

Como tópico central deste trabalho, é necessário comentar sobre a atual indústria e as formas de manutenção existentes no mercado.

A classificação dos tipos de manutenção é feita de acordo com a forma como é realizada. Apesar de serem diferentes em alguns aspectos, todos os modelos possuem o mesmo objetivo de garantir a disponibilidade e a segurança dos profissionais envolvidos, assim como também para o processo da empresa (OTANI; MACHADO, 2008).

A título de ilustração, em uma pesquisa realizada nas indústrias da Região Metropolitana de Recife, nos diversos ramos de atividade, foi constatada uma diferença significativa entre as porcentagem de uso, quando relacionamos a manutenção preditiva com as demais, como pode ser visto na tabela 1 (REIS; COSTA; ALMEIDA, 2013).

Porte da indústria	Manutenção Corretiva	Manutenção Preventiva	Manutenção Preditiva
Médias Empresas	50%	40%	10%
Grandes Empresas	42%	40%	18%

Tabela 1 – Distribuição das ações de manutenção segundo (REIS; COSTA; ALMEIDA, 2013).

3.1.1 Curva P-F

Para introduzir os 3 principais formatos de manutenção, pode-se utilizar o conceito da Curva PF (Problema Falha).

A curva PF é uma ferramenta crucial na gestão da manutenção de um sistema. Ela exemplifica a dinâmica de uma falha numa máquina, mostrando o intervalo de tempo entre a detecção inicial de um problema (ponto P) e a falha funcional do equipamento (ponto F). A curva evidencia o "período de alerta" durante o qual intervenções de manutenção podem ser programadas para evitar grandes falhas no sistema (IBM, 2022).

Assim, podemos exemplificar esses 3 componentes da curva, vista na figura 5:

- **Detecção do Problema (P):** Este é o ponto onde um problema potencial é identificado. Técnicas de manutenção preditiva, como sensores e análise de dados, podem ser utilizadas para detectar anomalias antes que se tornem falhas graves.
- **Falha Funcional (F):** Este é o ponto onde o equipamento não pode mais executar sua função desejada, resultando em tempo de inatividade.
- **Período P-F:** O tempo entre P e F é crucial para a intervenção de manutenção. Estratégias de manutenção preditiva são eficazes para maximizar este período, permitindo ações corretivas oportunas e evitando falhas inesperadas.

Figura 5 – Curva P-F.



Fonte: Adaptação de (TELES, 2018).

Além disso, como escrito na imagem, as três formas diferentes de manutenção se encaixam, cada uma com o seu momento bem definido, como:

- **Manutenção Preditiva:** ocorre antes da falha potencial ou ponto P;
- **Manutenção Preventiva:** pode ocorrer antes ou depois do ponto P (com um planejamento perfeito, acontece após o ponto);
- **Manutenção Corretiva:** ocorre após a falha funcional ou ponto F.

3.1.2 Manutenção Corretiva

Este tipo de manutenção trata de executar intervenções em máquinas de forma a recolocar em operação, visto que o problema ou falha já aconteceu. “A manutenção

corretiva é a atuação para correção de falha ou do desempenho menor do que o esperado". Ainda conforme o autor, esta forma de manutenção é necessariamente uma intervenção de emergência (KARDEK; NASCIF, 2009).

É uma metodologia reativa, que equivale a não existência de planejamento de manutenção. A manutenção ocorre apenas após a falha de um equipamento, o que a torna a opção mais custosa, ou seja, é realizada intervenção após a avaria ocorrer. Idealmente, deve ocorrer só em equipamentos de menor importância e impacto na operação do sistema (MOBLEY, 2002).

A manutenção corretiva é acionada para consertar problemas e falhas em equipamentos após eles apresentarem defeitos que impedem seu funcionamento. Na prática, isso envolve restaurar peças e equipamentos às suas condições originais, garantindo que a operação seja retomada o mais rápido possível e dentro das especificações. Por ser uma técnica não programada, a manutenção corretiva é considerada de alto risco para as empresas. As paralisações operacionais não planejadas geram custos extras com substituição de peças, mão de obra e podem até resultar em acidentes de trabalho. Além disso, a capacidade produtiva, as entregas e os lucros são significativamente comprometidos (EXATI, 2022).

3.1.3 Manutenção Preventiva

De forma contrária à política de manutenção corretiva, a manutenção preventiva procura evitar a ocorrência de falhas, ou seja, procura prevenir, mas de forma independente dos sintomas e sem uma profunda análise de dados. Em determinados setores, como na aviação, o uso da manutenção preventiva é predominante para determinados componentes, pois o fator segurança se sobrepõe (KARDEK; NASCIF, 2009).

Todas as manutenções são realizadas com base no número de horas operacionais da máquina, em datas pré-estabelecidas, portanto é efetuada de forma periódica (MOBLEY, 2002).

De acordo com o Guia de Boas Práticas do Departamento de Energia dos Estados Unidos, 88% das empresas industriais realizam manutenção preventiva regularmente. Esse alto percentual se deve à natureza preventiva do procedimento, que é realizado mesmo na ausência de danos nos ativos. A manutenção preventiva é programada periodicamente para evitar futuros problemas e garantir a operação contínua e eficiente dos equipamentos. Na prática, isso envolve intervenções e inspeções planejadas que ajudam gestores e equipes de manutenção a reduzir desgastes e problemas em máquinas e equipamentos. Esse procedimento é essencial para evitar prejuízos e interrupções inesperadas no processo operacional, garantindo uma produção mais confiável e segura (EXATI, 2022).

3.1.4 Manutenção Preditiva

O objetivo da manutenção preditiva é prevenir falhas nos equipamentos ou sistemas por meio do monitoramento de parâmetros e componentes, permitindo a operação contínua do equipamento pelo maior tempo possível. Como o nome menciona, o termo 'predição' refere-se adequadamente ao ato de prever as condições dos equipamentos. Ou seja, a Manutenção Preditiva prioriza a disponibilidade da máquina, já que não promove a intervenção nos equipamentos ou sistemas, pois as medições, o monitoramento e as predições são efetuadas enquanto o equipamento está em funcionamento pleno (KARDEK; NASCIF, 2009).

É um sistema de manutenção baseado na condição do equipamento, que se utiliza de meios de monitoramento de condição e técnicas de previsão, acarretando em custos menores. Portanto, é quando são realizadas intervenções caso determinado parâmetro atinja um valor limite, o deixando em certo estado de operação (MOBLEY, 2002).

De acordo com o Guia de Boas Práticas do Departamento de Energia dos Estados Unidos, a manutenção preditiva pode ser cerca de 40% mais econômica que a manutenção corretiva e 12% mais econômica que a preventiva. A principal diferença é que a manutenção preditiva se baseia em dados reais sobre as condições dos ativos, permitindo prever a vida útil de máquinas e equipamentos. Com monitoramento regular e análises de dados, a manutenção preditiva visa reduzir a necessidade de intervenções corretivas e preventivas. Isso ajuda a identificar o momento ideal para reparos, evitando danos, paralisações inesperadas e os altos custos associados à manutenção corretiva. A técnica, portanto, torna a operação mais eficiente e econômica, minimizando interrupções e melhorando a gestão dos ativos (EXATI, 2022).

"A manutenção preditiva também é conhecida como manutenção sob condição ou manutenção com base no estado do equipamento. É baseada na tentativa de definir o estado futuro de um equipamento ou sistema, por meio dos dados coletados ao longo do tempo por uma instrumentação específica, verificando e analisando a tendência de variáveis do equipamento."(TELES, 2018)

Dessa forma, a manutenção preditiva em seu conceito e como utilizada nesse trabalho, tem como principais vantagens e possibilidades:

- **Monitoramento e inspeção contínua:** verificar valores em tempo real (normalmente relacionados a um limite aceitável e alarmes);
- **Análise de dados:** identificar padrões, tendências e anomalias que podem indicar problemas;
- **Diagnóstico por correlação:** correlacionar processos/operações/eventos com mudança de valores;

- **Ganho de tempo:** Poder e maior tempo para realizar agendamentos de manutenção.

Sobre tudo, essas três principais formas de manutenção podem ser resumidas na seguinte tabela comparativa (tabela 2) de custo (valor a pagar para recuperar funcionamento do sistema), tempo (período de interrupção o qual a máquina fica parada) e investimento (valor a pagar para desenvolver método) (TELES, 2018).

Comparação	Manutenção Corretiva	Manutenção Preventiva	Manutenção Preditiva
Custo	⊗ ⊗ ⊗ ⊗ ⊗ ⊗	⊗ ⊗ ⊗ ⊗	⊗
Tempo	⊗ ⊗ ⊗ ⊗ ⊗ ⊗	⊗ ⊗ ⊗ ⊗	⊗ ⊗
Investimento	⊗	⊗ ⊗ ⊗	⊗ ⊗ ⊗ ⊗ ⊗

Tabela 2 – Comparação de custo, tempo e investimento entre os tipos de manutenção segundo adaptação de (TELES, 2018).

3.2 METODOLOGIA PARA ANÁLISE DE DADOS DA MÁQUINA

Como um dos grandes aspectos a ser desenvolvido neste trabalho, está a melhora da análise do sistema por meio da divisão dos estados de funcionamento da máquina hidráulica. Para isso, podemos dividir o período total de funcionamento da máquina em 4 partes: máquina ligando, ligada, desligando e desligada. Ainda, como será utilizado neste trabalho, pode-se considerar o período de máquina ativa como a junção dos períodos de máquina ligando e ligada e o período de máquina em regime permanente (ou ativa) sendo igual ao período de máquina ligada.

Utilizando-se dessa divisão, é possível isolar os períodos mais importantes da máquina, ou seja, quando ela está em funcionamento pleno e estável. Dessa forma, os períodos transitórios do sistema, como quando a máquina está ligando ou desligando, e o período o qual a mesma está desligada, podem ser descartados das análises.

Assim, ao longo prazo, o foco dessa metodologia é facilitar a automatização da análise dos dados por meio da coleta de valores estáveis ao longo do tempo e, relacionando essas variáveis e realizando mais estudos sobre os dados, tornar possível uma predição de dados limpa e direta com tendências e projeções de valores. Vale ressaltar que este é um método genérico para diversos processos e máquinas industriais e, dependendo do cenário de uso, pode sofrer ajustes em sua implementação.

Para isso, foram traçados os seguintes passos no desenvolvimento:

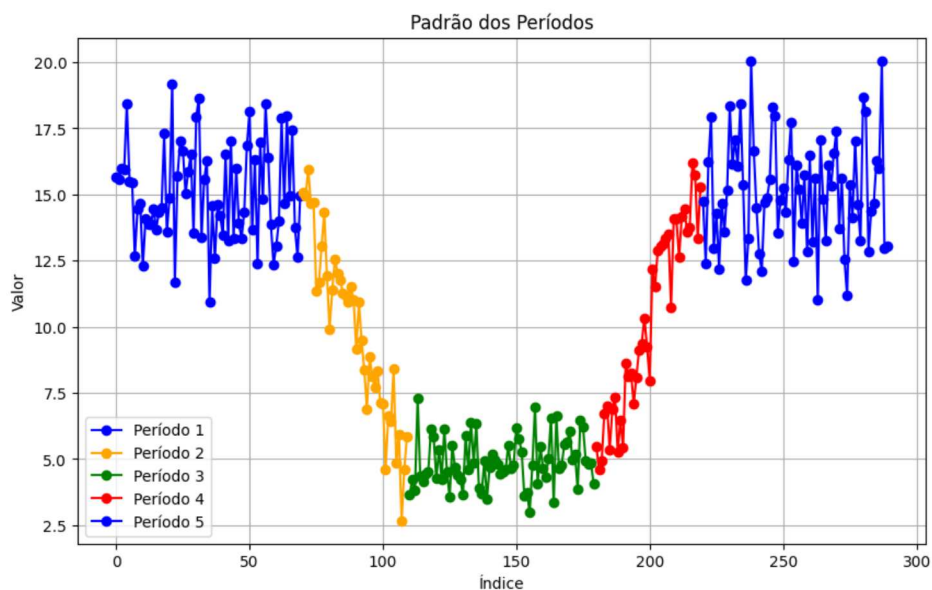
1. Coleta de séries temporais brutas das variáveis desejadas do sistema em questão, os quais os dados são adquiridos, por exemplo, pelos sensores mencionados na seção 2.3;

2. Padronizar e sincronizar temporalmente o conjunto de dados usando métodos previamente definidos de interpolação e até *downsampling*, dependendo do formato dos dados e dos parâmetros (como taxa temporal e método de interpolação) utilizados;
3. Automatização da separação dos estados de funcionamento da máquina (neste estudo os estados serão divididos em máquina ativa, em regime permanente e desligada) a depender de variável (ou conjunto de variáveis) específica;
4. Seguir padrão de variável específica e aplicar filtros temporais para todas as outras variáveis (devido a distorção de padrão, lacunas e interpolação dos dados, podem ocorrer alguns desvios de realidade);
5. Isolar e considerar valores somente do estado de regime permanente da máquina.

Portanto, a ideia desta metodologia de análise de dados é gerar algo semelhante ao visto na figura 6, onde é possível diferenciar e detectar os 4 diferentes estados da máquina. Dessa forma, pode-se encontrar padrões de tendência e comportamentos de regime permanente, além de diferenciar os estados de regime transitório do processo.

Ainda na mesma imagem, o ideal seria, dos 5 períodos exibidos (os quais o período 1 e 5 são correspondentes), isolar e obter somente os períodos em azul (regime permanente em operação 1 e 5) e "descartar" o restante (períodos transitórios 2 e 4 e período de máquina desligada 3).

Figura 6 – Exemplo de resultado para metodologia de análise de dados.



Fonte: Arquivo próprio.

3.3 ARQUITETURA E HARDWARE YOT

Nesta seção haverá a descrição simplificada da arquitetura e hardware da solução IIoT da GreyLogix (GREYLOGIX, 2022).

Intelligent Industrial Internet of Things (IIoT ou YoT) é uma tecnologia implementada pela GreyLogix, a fim de integrar os processos de coleta de dados, armazenamento, análise e apresentação de informação. O conceito geral do produto é possibilitar um conjunto de ferramentas modulares que englobam desde a aquisição de dados dentro da planta industrial até a apresentação final dessas informações para o cliente. Tais ferramentas visam primariamente a integração com outros serviços já existentes, sejam estes de qualquer natureza (APIs, sistemas legados, entre outros).

3.3.1 Arquitetura

O conceito da solução YoT é modular e pode integrar todos os serviços (Aquisição, Armazenamento, Análise e Apresentação, como apresentado na figura 7) em conjunto. Os hardwares fazem a aquisição e pré-tratamento de dados brutos, destinando os dados para aplicações locais ou em armazenamento na nuvem. Estes dados são processados e então são armazenados em estruturas otimizadas de informações, para serem disponibilizados para apresentação em ambientes baseados em Web.

Figura 7 – Representação da arquitetura da solução YoT.



Fonte: Documento YoT - GreyLogix (GREYLOGIX, 2022).

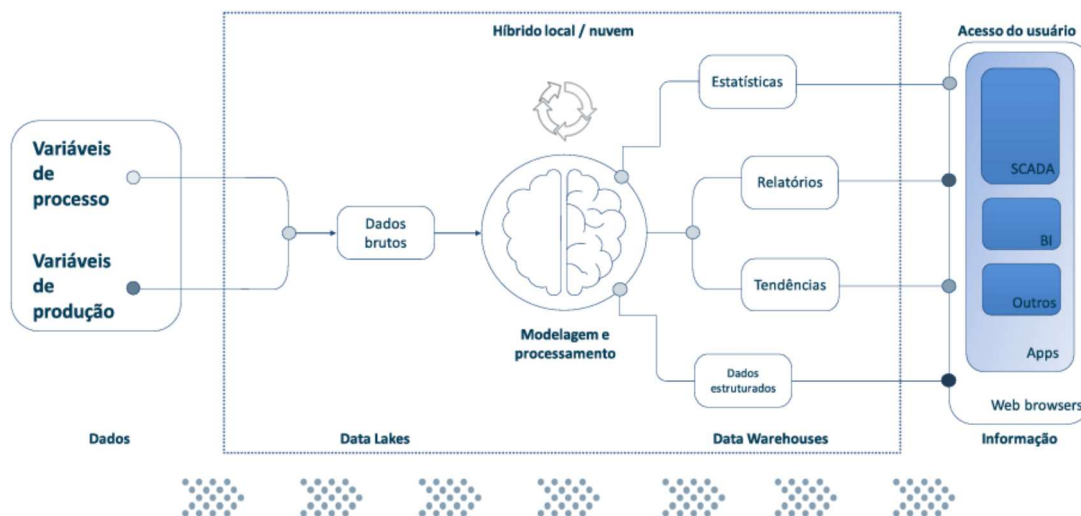
3.3.2 Fluxo de Dados

O fluxo completo dos dados dentro da solução completa (usando os 4 modelos integrados) segue representado pela figura 8.

Inicialmente, os dados brutos coletados são enviados para um data lake, passando por um tratamento (para lidar com informações incorretas e/ou adaptá-las para

uma forma estruturada). O tratamento depende da aplicação e pode ser simples ou até envolver algoritmos de inteligência artificial. Posteriormente, o dado, já transformado em informação, é enviado para *datawarehouses*, as quais são estruturas próprias para providenciar a informação para os sistemas de visualização.

Figura 8 – Representação do fluxo de dados da solução YoT.



Fonte: Documento YoT - GreyLogix (GREYLOGIX, 2022).

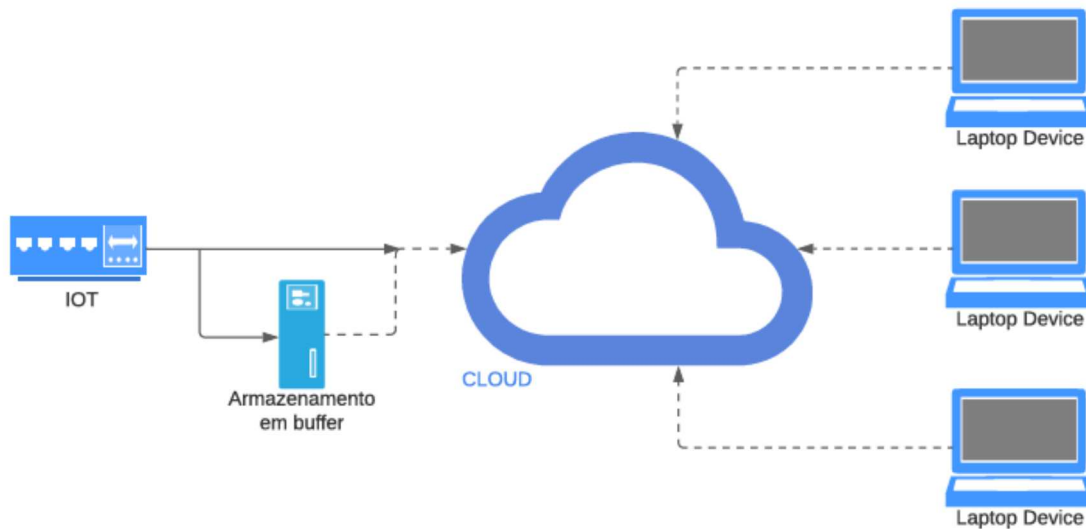
3.3.3 Armazenamento

Sendo o sistema padrão de armazenamento da solução, os dados coletados são enviados para a nuvem, conforme esquema da figura 9. Assim, as informações são armazenadas em um banco de dados relacional na máquina virtual específica da contrante de forma redundante e na estrutura de *datalakes* em serviços em nuvem. A solução conta também com a possibilidade de armazenamento local em um *buffer* temporário. Este é responsável por conter as informações em caso de perda de conexão ou qualquer falha de comunicação. Assim, é possível garantir que nenhum pacote de informação será perdido e, uma vez que a conexão seja reestabelecida, os dados podem ser enviados de maneira correta.

3.3.4 Análises

Seguindo a hierarquia DIKW (Data, Information, Knowledge, Wisdom; em português significa Dados, Informação, Conhecimento, Sabedoria), os dados precisam ser interpretados até chegarem ao nível de análise adequado. De forma resumida, estes são os conceitos da hierarquia:

Figura 9 – Representação do esquema de armazenamento da solução YoT.



Fonte: Documento YoT - GreyLogix (GREYLOGIX, 2022).

- O dados representam o nível mais baixo desta hierarquia e podem ser definidos como um fato isolado sem utilidade (por exemplo: pressão do fluido na máquina em *10bar*);
- A informação é o dado ou conjunto de dados em um contexto (por exemplo: a pressão que antes era de *10bar* aumentou para *15bar* e o sensor de partículas registrou uma contagem alta);
- O conhecimento é gerado fazendo correlações e inferências a partir das informações (por exemplo: se a pressão aumentou de *10bar* para *15bar* e houve um aumento na contagem de partículas, provavelmente houve algum problema no funcionamento da máquina que gerou um desgaste excessivo);
- Por sua vez, a sabedoria são as ações a serem tomadas a partir do conhecimento (por exemplo: como houve um desgaste fora do comum, é necessário verificar a máquina e o seu funcionamento).

Assim, a análise (quarto elemento da pilha de serviços da solução YoT), é responsável por transformar os dados adquiridos e armazenados em um dos outros níveis hierárquicos descritos acima para posterior apresentação ao usuário.

3.3.5 Apresentação

A GreyLogix Brasil implementou um sistema SCADA totalmente em nuvem. A principal vantagem é poder acessar de qualquer local e em qualquer dispositivo com acesso à internet. Para isto, é utilizado um link para o navegador de internet, um login e senha e uma autenticação numérica.

O sistema pode ser dividido em diferentes segmentos, tais como: Interface de usuários; Exibições de gráficos; Alarmes; Escalabilidade; Acesso aos dados; Banco de dados; Rede.

3.3.6 Segurança

A segurança é parte fundamental de qualquer aplicação que lide com informações, e deve sempre ser um ponto de grande atenção, para não criar vulnerabilidades ou causar quaisquer problemas causados por sua falta.

Como mencionado anteriormente, a fim de visualizar os dados, o usuário precisa de algumas barreiras de segurança. Além disso, ainda existem algumas formas de manter a rede lógica isolada e segura, através do balanceador de cargas e do *firewall*.

3.4 SOFTWARES

O código principal de análise foi feito utilizando a linguagem de programação Python (PYTHON, 2024).

Além disso, foi utilizado o *software* Visplore, para explorar e visualizar os dados, e o método de predição de dados Prophet, como uma biblioteca dentro do código principal de análise.

3.4.1 Prophet

"Propomos um modelo de regressão modular com parâmetros interpretáveis, que podem ser ajustados intuitivamente pelos analistas com conhecimento de domínio sobre a série temporal. Nossa implementação está disponível como software de código aberto em Python e R, chamado Prophet."(TAYLOR; LETHAM, 2017)

O Prophet é um modelo robusto e de simples configuração de predição de dados criado pelo Facebook e foi o método escolhido para o uso neste trabalho devido a algumas de suas características principais:

- **Robustez para eventos faltantes:** devido ao método de selecionar somente o período de dados o qual a máquina está em operação em regime permanente, o restante do tempo é desconsiderado e dados ficam vazios.
- **Facilidade em detectar e trabalhar com sazonalidades:** devido à sazonalidades diárias e anuais, principalmente de temperatura, foi necessário que o método tivesse essa habilidade.
- **Dados são séries temporais não estacionárias:** assim como dados que tem sazonalidade, os dados, de forma geral, são dinâmicos e podem ter diferentes regiões de operação ao longo do tempo e, por isso, este também é um atributo importante.

Contudo, o uso do método neste trabalho está detalhado na seção de desenvolvimento da etapa de predição de dados, na seção 4.7.

3.4.2 Visplore

Visplore é um software austríaco de exploração e visualização de dados. Ele oferece uma gama de funcionalidades, estatísticas, gráficos e várias ferramentas voltadas para uma análise visual e interativa de pequenos e grandes conjuntos de dados (VISPLORE, 2024).

O *software* proposto pela empresa, com o intuito de facilitar a exploração e a visualização dos dados, cumpriu todas as exigências para essas etapas, as quais as principais funcionalidades utilizadas nesse trabalho foram:

- filtros temporais ou por valores,
- estatísticas e funções sobre os dados, como médias, derivadas, valores de mínimo e máximo,
- segmentação e *labelling* de dados,
- modificação de valores, como interpolação e rasterização,
- mapas de calor das variáveis e outras ferramentas gráficas e
- identificação de padrões, tendências e anomalias.

4 DESENVOLVIMENTO E IMPLEMENTAÇÃO

Com a base teórica fundamentada nos capítulos anteriores, neste capítulo serão abordados todo o desenvolvimento e a implementação do projeto, colocando em prática os conceitos propostos nos capítulos 2 e 3.

Como apresentado no capítulo 1, este projeto proposto pela empresa GreyLogix, visa a modificação do cenário atual dos modelos de manutenção, tornando a manutenção preditiva mais acessível para as máquinas hidráulicas, monitorando as suas variáveis, usando equipamentos IoT e predição de dados.

Neste projeto, o mesmo estudo e código foram aplicados a cinco projetos de quatro clientes diferentes, os quais cada um possui propriedades e características diferentes a serem explicadas posteriormente. A fim de manter o sigilo dos clientes, os cinco projetos serão referenciados ao longo do documento como projetos B, C, G, K e S.

Contudo, toda máquina hidráulica utiliza os mesmos conceitos básicos e podem ser correlacionadas principalmente sob o ponto de vista de "saúde" da máquina previamente estabelecido e colocando em foco as análises de contaminação do fluido hidráulico. Assim, apesar de algumas dessas máquinas terem algumas especificidades, como alternância de bombas de pressão, usaremos análises parecidas para todos os projetos.

A seguir, a implementação será explicada conforme o desenvolvimento do estudo, de forma que os passos e o contexto geral, seja para qual for o projeto específico, será exemplificado e detalhado.

Além disso, o estudo não irá expor, de forma explícita, o código desenvolvido, mas haverá o detalhamento, a explicação e exemplos da lógica planejada e utilizada ao longo do processo.

4.1 VISÃO GERAL DO ESTUDO

A fim de oferecer uma visão geral do estudo realizado e comentar brevemente sobre cada projeto, a seguir alguns tópicos serão tratados para trazer mais detalhes sobre a execução deste trabalho.

De forma geral, seguindo a metodologia de análise proposta sobre a saúde de uma máquina hidráulica e, apesar de os projetos terem particularidades e sendo inseridos em diferentes setores industriais, este estudo foca a análise em algumas variáveis principais que estão contidas em todos os projetos (e na maioria dos sistemas e circuitos de máquinas hidráulicas), como:

- **Pressão:** um dos principais fatores em uma máquina hidráulica. Indica quando o fluido hidráulico está, de fato, sendo utilizado ou em circulação, ou seja, indica

quando a máquina está ativa. Pode apontar quando há vazamentos ou falhas no sistema. Deve ser controlada para evitar desgastes inadequados nos componentes do sistema.

- **Temperatura:** indica quando o fluido hidráulico está em operação permanente e em normal operação. Pode apontar condições de operação anormais e superaquecimento. Deve ser controlada a fim de evitar degradação excessiva ao fluido hidráulico e componentes do sistema.
- **Umidade:** indica a presença de umidade e/ou ar no fluido hidráulico. Pode apontar vazamentos ou aberturas inadequadas no circuito. Deve ser controlada para evitar corrosão, verniz e degradação do fluido.
- **Contador de Particulados:** conta ou indica a presença de partículas sólidas (sejam ferrosas ou não ferrosas, sejam pequenas ou grandes). Pode apontar desgaste prematuro de componentes ou sujeira proveniente de aberturas indevidas no circuito. Deve ser controlado a fim de monitorar a limpeza e qualidade do fluido.

De qualquer forma, todas estas máquinas analisadas possuem um funcionamento contínuo por horas ou dias e podem funcionar sem um padrão de horário, ou seja, em qualquer hora ou dia da semana.

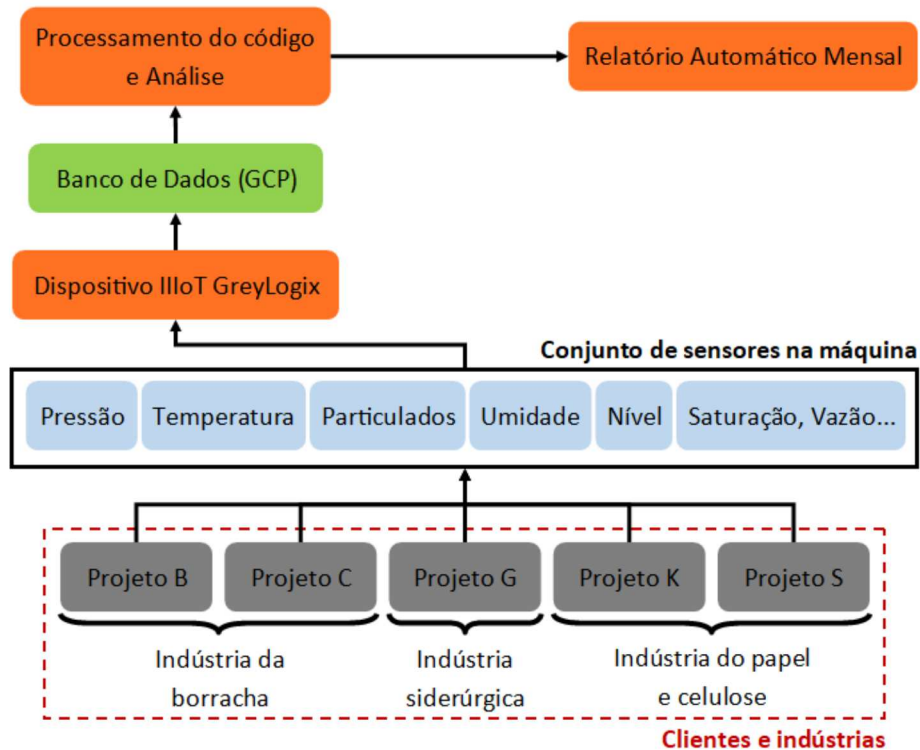
Conforme apresentado, os projetos estão divididos e têm as seguintes características gerais, no que diz respeito ao funcionamento e sensores das máquinas em questão:

- **Projeto B:** está inserido na indústria da borracha. Máquina hidráulica com sensor de pressão, temperatura, umidade do fluido e sensor de contaminação MCS. Funcionamento da máquina sem especificidade.
- **Projeto C:** está inserido na indústria da borracha. Máquina hidráulica com sensor de pressão, temperatura, umidade do fluido, vibração, vazão, nível do tanque e sensor de contaminação MCS. Funcionamento da máquina sem especificidade.
- **Projeto G:** está inserido na indústria siderúrgica. Máquina hidráulica com sensor de pressão, temperatura, umidade do fluido, sensor de saturação de filtro nível do tanque e sensor de contaminação CS. Funcionamento da máquina baseado na alternância de 2 bombas de controle
- **Projeto K:** está inserido na indústria do papel e celulose. Máquina hidráulica com sensor de pressão, temperatura, umidade do fluido e sensor MCS. Funcionamento da máquina sem especificidade.

- **Projeto S:** está inserido na indústria do papel e celulose. Máquina hidráulica com sensor de pressão, temperatura, umidade do fluido, vazão e sensor CS e MCS. Funcionamento da máquina sem especificidade.

Um diagrama contendo a organização dos projetos pode ser visualizada a seguir na figura 10.

Figura 10 – Visão geral e organização dos projetos.

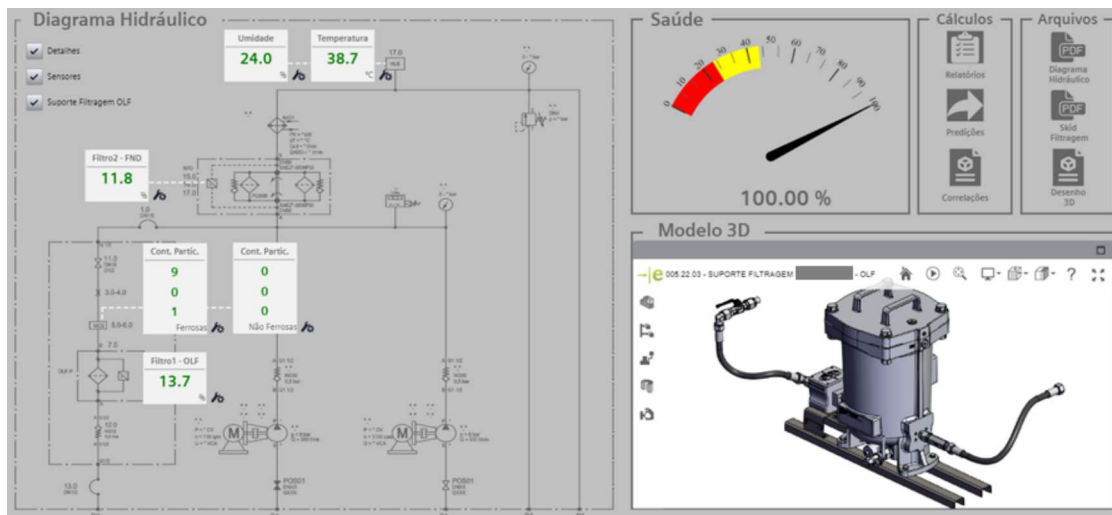


Fonte: Arquivo próprio.

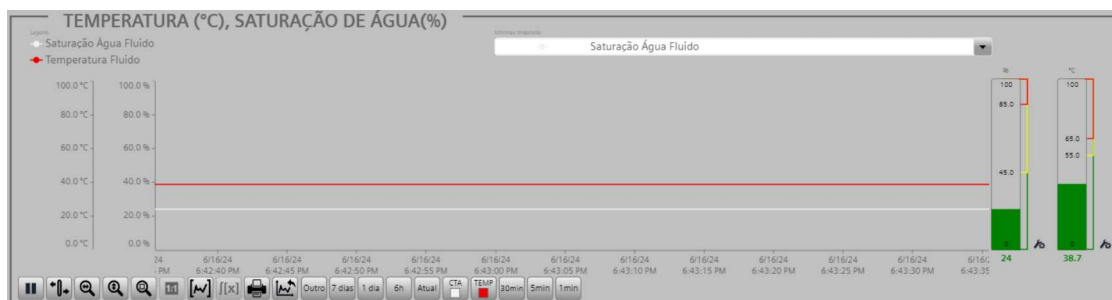
Para cada projeto, há *dashboards* conectadas online com as respectivas máquinas. Essas telas trazem informações sobre a máquina, possibilitando o usuário visualizar valores dos sensores em tempo real ou como base histórica, atribuir e visualizar alarmes, dentre outras funcionalidades. Alguns *prints* dessas telas podem ser vistos a seguir nas figuras 11 e 12.

Na figura 11, é possível ver, conforme explicado previamente no capítulo 2, um diagrama hidráulico o qual representa de forma breve a máquina em questão. Estes diagramas são similares para todos os projetos, mas possuem componentes e circuitos diferentes conforme a máquina. Dessa forma, um profissional da área é capaz de visualizar rapidamente o valor real de um sensor e sua posição no circuito hidráulico.

Para uma análise mais aprofundada ou comparativa, por exemplo, é possível, como na figura 12, visualizar o valor de um sensor em uma base histórica com valores do banco de dados.

Figura 11 – Exemplo de *dashboard* com diagrama hidráulico.

Fonte: Arquivo próprio.

Figura 12 – Exemplo de *dashboard* com base histórica.

Fonte: Arquivo próprio.

Agora, com uma visão geral dos projetos e do funcionamento dos seus sistemas e sensores principais, podemos adentrar nos dados e para entender como funcionam.

4.2 ANÁLISE PRÉVIA DOS DADOS

Para iniciar o projeto, foi necessário entender e ter um panorama de quais são os dados e variáveis, como se comportam e quais são as especificidades de cada projeto/máquina e como esses projetos se relacionam.

Assim, foram feitas análises iniciais e visualizações de todos os projetos, a fim de compreender os dados e adentrar no estudo deste trabalho.

Além disso, é importante ressaltar que os dados analisados e utilizados em todos os projetos são sempre no formato de séries temporais, ou seja, possuem o valor da variável associado ao tempo (no formato *timestamp*) o qual o sensor fez a leitura. De forma padronizada, o banco de dados está organizado no formato que pode ser visualizado na tabela 3.

Tabela 3 – Formatação padrão dos dados no Banco de Dados.

Nome da coluna	timestamp	variavel	valor
Descrição da coluna	Tempo o qual o valor da variável foi acessado.	Variável a qual o valor se refere. Representa o sensor (ou uma partição dele).	Valor da variável.
Exemplo	2024 – 02 – 31 T23 : 59 : 59.000	sensor_pressao_1	23

4.2.1 Dados Iniciais

Apesar de similares, o funcionamento das máquinas dos projetos são ligeiramente diferentes e podem ter diversos formatos e especificidades que dificultam a análise em conjunto de todos os projetos, como, por exemplo:

- funcionam com uma só bomba hidráulica ou com a alternância de duas bombas;
- funcionam por cerca de 10 horas contínuas ou por cerca de 30 minutos;
- período de funcionamento maior ou menor do que período de repouso;
- repousam por dias ou por algumas horas ou minutos;
- possuem pressão estável ou volátil e com picos (até mesmo com valores 300% mais altos do que o valor normal) durante o seu funcionamento;
- regiões de operação diferentes (por exemplo, máquinas que funcionam com 5 bar ou 20 bar.

Além disso, os dados possuem variações, mais consideradas como perturbações nos sistemas, que não são controladas ou previamente definidas e catalogadas, como, por exemplo:

- a sazonalidade de temperatura diária (mais quente durante o dia e mais fria durante a noite);
- a sazonalidade de temperatura anual devido à diferença de temperatura entre as diferentes estações e climas;
- a diferença de temperatura média dependendo da localidade da máquina, como por exemplo no nordeste ou no sul do Brasil;
- pausas e manutenções programadas ou não programadas;

- falhas excepcionais do envio de dados (não ocorreu, mas é importante ressaltar para esse tipo de análise).

Nestes projetos em análise não há um *log* de atividades e eventos, onde deveria ocorrer o registro de eventos relevantes para a análise de dados e para compor o histórico das variáveis e máquinas. Esse registro de eventos é bastante relevante durante os momentos de análise a fim de evitar erros de interpretação. Um exemplo disso pode ser quando o filtro de uma dada máquina é substituído e a máquina entra em estado de repouso por um longo período e, após a troca, os valores de diferencial de pressão antes e depois do filtro, por exemplo, ficam em pontos de operação diferente do filtro antigo, já que o novo filtro está limpo e oferece menos resistência para a passagem do fluido, reduzindo o diferencial de pressão. Outro exemplo é quando há a troca do redutor de pressão e, além da pausa de máquina como no exemplo citado acima, a máquina registra valores anormais de algumas variáveis, como, por exemplo, os contadores de particulados. Isto ocorre porque a máquina, com um novo redutor, está em processo de "amaciamento" (como normalmente definido por profissionais da área), ou seja, a máquina está com desgaste interno acima do normal e, por um curto período de tempo, o fluido aponta uma alta concentração de resíduos e partículas (principalmente ferrosas) nestes sensores.

Outro fator relevante que ocorre nesses dados são os picos de pressão quando a máquina hidráulica é iniciada. Isto acontece devido a alguns fatores, como a pressão de entrada e de pico de carga, que se manifestam no início do processo de funcionamento da máquina e se estabilizam à medida que a máquina entra em estado de operação contínuo; cavitação, que ocorre, de forma mais rara, quando há ar no sistema ou uma mudança rápida de fluxo; e pelo sistema de controle da máquina, que, se mal ajustado, pode enviar uma carga de pressão muito alta para compensar a baixa pressão no momento inicial de funcionamento. Estes picos podem danificar a máquina, dependendo da sua intensidade e frequência, mas é importante identificar seus momentos de atuação, dando maior ênfase para quando acontecem durante o processo de operação contínua, pois isso pode representar uma falha relevante.

Portanto, no estudo deste trabalho, foi necessário analisar cada projeto com as suas particularidades e, para o código final a fim de gerar relatórios e análises automatizadas, foi preciso programar de forma abrangente e com valores e tendências móveis para cada exemplo ou projeto.

4.2.2 Exploração de dados

A fim de explorar e manipular os dados, além de visualizar e conferir os *insights* citados na seção 4.2.1, foi utilizado o *software* Visplore.

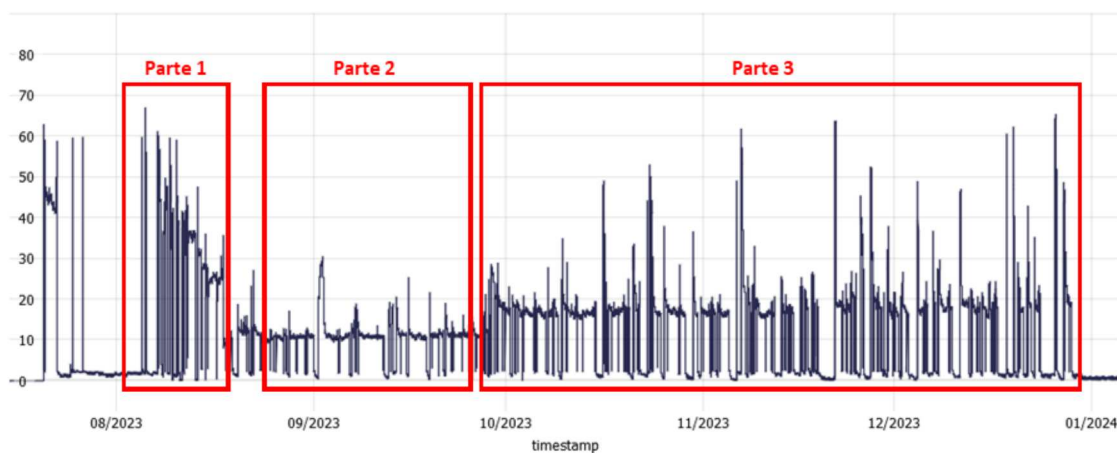
Como mencionado brevemente na fundamentação teórica (seção 3.4.2), esse

software é desenvolvido para ser uma ferramenta de exploração e visualização de dados, além de oferecer ferramentas úteis neste projeto, como estatísticas, seleção e filtros de dados. Dependendo do projeto, o *dataframe* utilizado pode chegar a até 5 milhões de linhas e, por isso, é importante utilizar uma ferramenta que consiga trabalhar com um grande conjunto de dados.

Para analisar cada projeto, os dados presentes no banco de dados foram importados nesta ferramenta e, para uma análise inicial de valores e tendências, os dados foram rasterizados (agrupados, a fim de reduzir a massa de dados e padronizar a frequência de dados, ainda que com uma alta frequência de 1 minuto).


Utilizando sensores de pressão, como exemplo, é possível ver o diferente funcionamento de dois projetos distintos, mostrados nas figuras 13 e 14. A fim de manter os dados seguros, as imagens são simplificadas e não tem os nomes das variáveis.

Figura 13 – Exemplo de gráfico de pressão do projeto B.



Fonte: Arquivo próprio.

Figura 14 – Exemplo de gráfico de pressão do projeto K.



Fonte: Arquivo próprio.

Já que a pressão da máquina aponta quando ela está em operação (por exemplo, quando a máquina está acima de um valor x), na figura 13, é possível notar que a máquina entra em operação e em repouso diversas vezes e de forma contínua por pequenos ciclos de algumas horas. Já para a figura 14, é possível notar que a máquina tem menos ciclos de operação/repouso e esses ciclos de operação demoram mais tempo, como dias ou semanas.

Além disso, no que diz respeito à região de operação da pressão da máquina, a figura 13 pode ser dividida em 3 partes:


- Parte 1 (por volta de agosto de 2023): por meio do contato direto com o cliente, foi descoberto que houve uma troca de redutor de pressão na máquina nesse período, resultando em uma alta pressão inicial que decai com o passar de alguns dias de operação;
- Parte 2 (entre agosto e setembro de 2023): máquina opera com pressão média de 10 bar;
- Parte 3 (entre outubro e dezembro de 2023): máquina opera com pressão média de 18 bar.

Assim, podemos verificar o que foi constatado anteriormente sobre diferentes zonas de operação para um mesmo projeto. Assim como para outras variáveis, isso dificulta o processo de análise automatizada, já que é necessário utilizar diferentes valores para cada período ou projeto em estudo.

Para ilustrar um outro exemplo, pode-se considerar os dois tipos de sensores de particulados estudados nesse documento. Na figura 15, está exibido um exemplo dos dados provenientes do sensor MCS, neste caso, considerando somente as partículas ferrosas do tipo A (como previamente definido na seção 2.3.1.2). Nesta figura, a variável na cor azul mostra a soma diária de partículas que passaram pelo sensor e a na cor vermelho mostra o somatório desde o início. Assim podemos fazer análises diferentes referentes à contaminação do fluido e considerando essas duas condutas, como acontecimentos diários e alarmes, considerando a variável em azul, e tendências ou predições, considerando a variável em vermelho.


Já na figura 16, está exibido um exemplo dos dados provenientes do sensor CS, neste caso, considerando somente as partículas para a norma ISO, no caso 2 (como previamente definido na seção 2.3.1.1). Utilizando esse sensor, podemos também fazer análises referentes à contaminação do fluido, como quando, de repente, há partículas maiores do que o normal passando pelo circuito hidráulico.

Figura 15 – Exemplo de dados do sensor MCS do projeto B.



Fonte: Arquivo próprio.

Figura 16 – Exemplo de dados do sensor CS do projeto G.



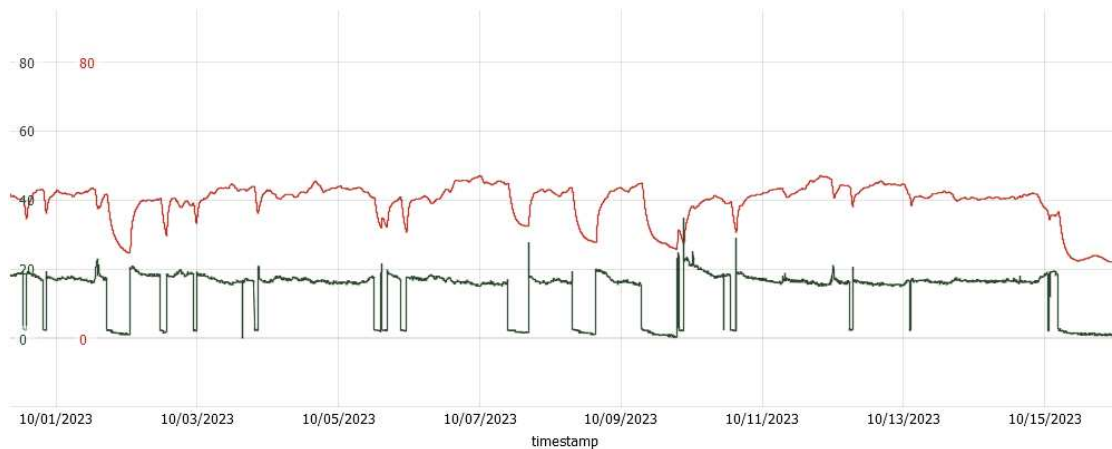
Fonte: Arquivo próprio.

4.2.3 Correlações entre as variáveis

Além das observações feitas anteriormente, é possível correlacionar algumas variáveis distintas do mesmo projeto, como por exemplo a temperatura e a pressão. Neste caso, que pode ser visto na figura 17, pode-se observar que a temperatura (em cor vermelha) diminui quando a pressão (em cor verde) está baixa (máquina desligada) e o oposto quando a pressão está alta (máquina ligada). Além disso, quando a máquina está ligada após um certo tempo, a temperatura aumenta e tende a permanecer num mesmo nível, mesmo com pequenas variações, dependendo, por exemplo, da própria operação ou da sazonalidade diária da temperatura ambiente. Como mencionado, este momento o qual a máquina está ligada e a temperatura, de certa forma, estável é chamado neste projeto de regime permanente da máquina.

Outra correlação interessante para observar é entre o sensor de particulados e o sensor de pressão. Quando há picos de pressão, o contador de particulados indica


Figura 17 – Exemplo de correlação entre os valores de pressão e temperatura, do projeto B.



Fonte: Arquivo próprio.

que há partículas passando no circuito hidráulico. Isso pode ser visto pela figura 18, onde o contador diário de partículas MCS está em azul e a pressão está em verde.

Figura 18 – Exemplo de correlação entre os sensores de pressão e MCS, do projeto B.



Fonte: Arquivo próprio.

Assim, quando os 5 diferentes projetos são colocados lado a lado, é possível confirmar que as principais variáveis possuem as mesmas relações e correlações, como o caso da temperatura e pressão e as relações de funcionamento da máquina.

4.3 IMPORTAÇÃO DO BANCO DE DADOS

Agora, já com uma ideia geral das variáveis e das particularidades de cada projeto, os dados podem ser importados do banco de dados (ou DB -*database*-, do inglês)

da nuvem. Esta pré-visualização dos dados foi importante para tornar a filtragem e manuseio inicial mais diretos, já que agora é possível escolher exatamente os períodos e variáveis desejados, uma vez que já foram visualizados.

No banco de dados, devido ao próprio sistema de exportação de informação dos sensores e do sistema SCADA, os valores são enviados e agrupados por semana e são salvos num formato de arquivo *.parquet*, o qual tem alto rendimento e melhor compressão de dados para altos volumes. Por meio de código em Python, esses agrupamentos são desagrupados e posteriormente formam uma grande massa de dados, que junta todos os arquivos presentes no sistema referente ao dado projeto gera um arquivo final contendo todas essas informações. Este arquivo tem o formato previamente detalhado pela tabela 3.

Assim, a partir desta primeira massa completa de dados presentes na nuvem, podem ser realizados os primeiros filtros e a criação dos primeiros dataframes (DF). A partir deste momento, a fim de obter um melhor desempenho e eficiência e devido a facilidade de uso e manipulação, as informações serão sempre tratadas e manipuladas por meio da utilização de dataframes.

Primeiramente, essa massa de dados é atribuída a um DF inicial. Posteriormente, podem ser realizados filtros temporais, sejam limitadores iniciais e/ou finais. No caso do código da criação automática e mensal de relatórios de análise, que será explicado no capítulo 5, neste momento são utilizados filtros que limitam os dados somente para o mês em questão.

A depender do projeto e da análise, a fim de tornar as próximas etapas do estudo mais eficientes, nesta etapa também podem ser selecionadas somente as informações as quais são de interesse. Dessa forma, *tags* de teste, valores de retorno ou confirmação (como 2 sensores que medem a mesma informação), *buffers* (armazenamentos temporários de dados) e outras variáveis irrelevantes para a análise já são descartadas e não influenciam o restante do estudo. Para ilustração, desses 5 projetos estudados, cerca de 40% das variáveis exportadas no banco de dados estão sendo desconsideradas.

4.3.1 Interpolação dos dados


Além dos manuseios anteriores, ainda visando a eficiência e a padronização dos dados e já que os valores estão sempre no formato de séries temporais, é gerado um novo DF a partir do inicial (o qual sempre deve ser mantido para fins de consulta e obtenção de valores reais), onde todos os dados são agregados ou interpolados conforme uma dada nova frequência. Neste caso, as informações dos sensores são enviadas para a nuvem numa frequência determinada (por exemplo, a cada 30 segundos), mas algumas vezes estes envios sofrem atrasos, os sensores perdem a conexão ou simplesmente estão desligados. Assim, esse novo DF gerado possui uma nova

frequência (neste estudo, a cada 1 minuto) e os dados agregados ou interpolados de todas as variáveis ficam mais fáceis de serem interpretados e acessados, agora organizados e padronizados.

Consequentemente, num processo de manipulação dos dados, principalmente quando eles são modificados ou são realizados cálculos para defini-los, a informação previamente enviada pode se perder ou ser mal interpretada.

Sobre esse aspecto, a figura 19 retrata a diferença de um dado antes e após o processo de interpolação. Nesta figura, em azul está o dado puro e não modificado e em primeiro plano, sobrepondo praticamente todos os dados anteriores, estão os novos valores após a interpolação em laranja. A fim de rápidas análises e algumas detecções, este DF interpolado foi utilizado, mesmo tendo uma pequena margem de erro. Para fins de medições reais e análises críticas, o código é capaz de, utilizando o DF padronizado, buscar o valor real no DF original e não mexido.

Figura 19 – Comparação entre modelos de DF antes e após interpolação de dados.



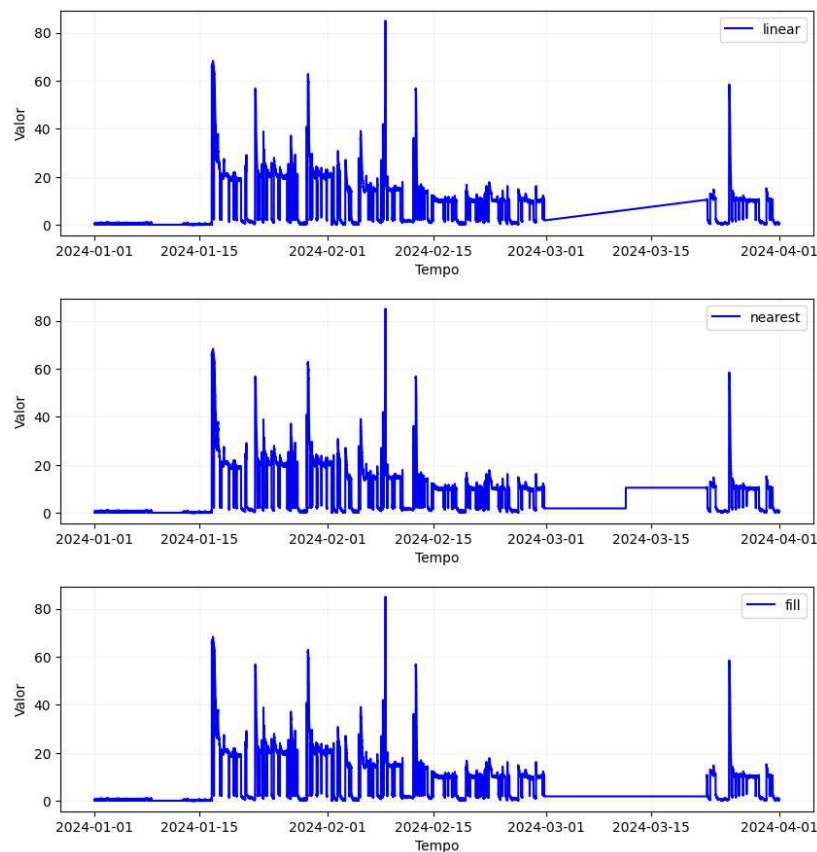
Fonte: Arquivo próprio.

Além disso, a interpolação de dados também exige atenção a depender do formato dos dados. Como no exemplo da figura 20, há um grande período onde a máquina não possui informações, por volta do início ao dia 20 do mês de março de 2024. Utilizando a interpolação, o código vai atribuir algum valor a esse *gap* e é preciso definir o método de interpolação da melhor forma dependendo do processo em questão. A figura mostra o resultado da utilização de 3 dos principais métodos, explicados a seguir.

- Linear: interpola os valores de forma linear entre os pontos vizinhos; ideal para interpolação suave e quando os dados tem uma mudança linear ou gradual.
- Nearest: usa o valor mais próximo para preencher dados faltantes; ideal para medidas binárias ou quando a tendência dos dados não é relevante.
- Fill: preenche os valores faltantes usando o último valor válido; ideal quando valores tem uma tendência estável.

Assim, no código para esse estudo, como estes longos períodos de pausa são associados a manutenções e/ou pausas programadas (como foi o caso), as quais a máquina é desligada previamente, convém utilizar o método fill para a interpolação dos dados, sendo o mais condizente com o período em questão.

Figura 20 – Comparação entre diferentes formas de interpolação de dados.



Fonte: Arquivo próprio.

4.4 DEFINIÇÃO DE PARÂMETROS E MÉTODOS

Seguindo o estudo, é preciso definir algumas informações e relações que são específicas para cada projeto, mas que todos possuem, como por exemplo o sensor de pressão responsável pela caracterização de quando a máquina está em operação.

4.4.1 Parâmetros de projeto

Como são necessários alguns dados relevantes sobre cada projeto, nesta seção são definidos alguns atributos ao sistema, como esses dois tipos de informações:

- Atributos fixos e previamente definidos: informações práticas para a execução da análise e que são necessárias no início do processo, como a lista dos sensores

a serem utilizados nos filtros, datas iniciais e finais de filtros, valores dos alarmes para cada sensor, data inicial limite para treinamento da predição de dados e atributos direcionados para a criação dos relatórios, como quais sensores devem ser utilizados para plotar gráficos, predições e/ou estatísticas.

- Atributos variáveis e definidos via código: informações que são geradas dependendo dos valores presentes e são os resultados dos métodos que serão descritos nas próximas seções, como médias móveis, valores retirados diretamente do DB (como tamanhos de conjunto de dados, primeiro e último *timestamp*, duração de intervalos e *tags* presentes) e estatísticas. Esta categoria, principalmente, será melhor explicada e exemplificada ao longo deste trabalho.

Dentre os atributos fixos, os quais são vitais para o funcionamento do código, vale ressaltar observações sobre os seguintes:

- Sensor de pressão crucial: determinante para diferenciar o momento que a máquina é ligada. Deve acompanhar o valor de corte o qual, quando a máquina registra um número maior do que ele, a máquina deverá ser considerada em operação.
- Sensor de temperatura crucial: determinante para diferenciar o momento que a máquina sai do regime transitório e vai para o permanente, período o qual é mais importante de ser analisado, já que é quando a máquina está mais estável.

Estas informações específicas sobre os sensores de pressão e temperatura (assim como a pré-visualização dos dados e conhecimentos prévios dos projetos) são necessárias devido às variações de sensores e nomenclaturas dos mesmos para cada projeto, além dos diferentes valores de operação, como demonstrado na seção 4.2.2.

Ainda como atributos fixos por projetos, principalmente para a parte do estudo que serão criados os relatórios automáticos, são passados também algumas informações dos clientes e das máquinas para compor o relatório, como contato e registro do cliente em questão e informações sobre a máquina, como número de série, localidade e outras informações não tão relevantes para o estudo, mas necessárias no relatório.

Continuando a definição de parâmetros, nesta etapa também são definidos, de forma manual e não automática, os alarmes para cada variável disponível. Estes alarmes são divididos, assim como padrão na indústria, nas seguintes 4 categorias:

- **Low Low (LL)**: indica o nível mais baixo da variável, valor crítico abaixo do normal;
- **Low (L)**: indica o nível baixo da variável, valor pouco abaixo do normal;
- **High (H)**: indica o nível alto da variável, valor pouco acima do normal;

- **High High (HH):** indica o nível mais alto da variável, valor crítico acima do normal.

Dessa forma, dependendo da variável e do interesse dos clientes, esses valores são passados para o código a fim de, nos próximos passos, serem tratados com o intuito de gerar novas informações no relatório, como quantidade de vezes que o sensor ultrapassou um desses alarmes e até mesmo o tempo total o qual o alarme permaneceu ativo.

A seguir, serão explicados os métodos utilizados ao longo do código para extrair informações importantes do processo realizado pela máquina, já iniciando o processo de análise e manuseio mais importante dos dados.

4.4.2 Etapas de funcionamento da máquina

Como previamente definido na seção 3.2, um passo essencial para o desenvolvimento deste projeto foi a divisão de estados da máquina, compostos por 4 diferentes categorias: máquina ativa, máquina ligando, máquina desligando e máquina desligada.

A fim de executar esta divisão de maneira genérica para todos os projetos, foram criadas algumas funções e o código passa por algumas etapas, além de, como mencionado anteriormente, utilizar alguns parâmetros específicos de cada projeto. Ademais, como mencionado no início do desenvolvimento do projeto, neste estudo, o código não será destrinchado linha por linha, mas sim explicado e exemplificado a fim de deixar clara a lógica e a forma de implementação e execução.

Primeiramente, neste caso do estudo, diferente do mencionado na fundamentação teórica, a parte de máquina desligando será desprezada, já que a máquina simplesmente desliga e não é considerado o período de tempo o qual a mesma está esfriando ou retornando ao estado de desligada. Além disso, o estudo trata como principal, o período que a máquina está em operação contínua, descartando o período transiente. Assim, teremos as 3 diferentes etapas de forma explicada abaixo:

- Máquina ligada (ou em operação): abrange o momento o qual a máquina está ligada até ser desligada (abrangendo os períodos os quais ela está ligando e em regime permanente ou ativa).
 - Está diretamente associada ao sensor de pressão crítica: quando a pressão está ativa (maior do que um valor de corte), a máquina é considerada ligada.
 - Período contido de máquina ligando é evitado nas análises por se tratar de um intervalo onde as variáveis tendem a ser mais instáveis.
- Máquina em regime permanente (operação estável ou regular) ou máquina ativa: momento o qual a máquina esta ligada e, além disso, possui um regime de operação mais estável baseado na temperatura da máquina. É o período considerado

mais relevante para as análises e baseia as estatísticas da operação da máquina (seção 4.5) e todas as principais métricas e gráficos.

- Está associada ao sensor de pressão e ao valor de uma moda móvel da temperatura que depende do período utilizado e será descrita na seção 4.4.3.2.
- Máquina desligada: é o período oposto ao período de máquina ligada.

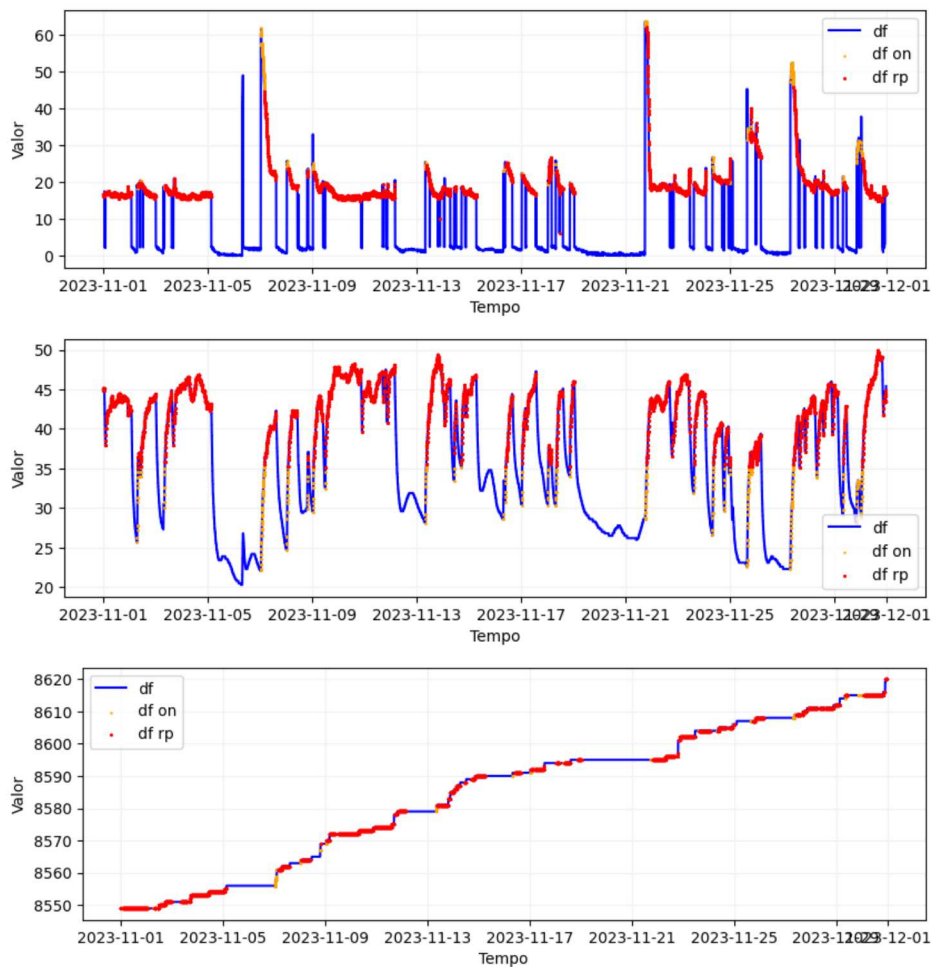
Vale ressaltar que, devido a métodos de moda e outros que dependem de uma visão geral do funcionamento da máquina em um período fechado (intervalo de tempo o qual o início e o fim são limitados), essa categorização é feita somente para quando a máquina já enviou os dados e não durante a operação, de forma "online".

Para ilustrar essa divisão de funcionamento da máquina, pode-se observar a figura 21, onde há a divisão do funcionamento da máquina exibida em 3 variáveis: sensor de pressão, sensor de temperatura e sensor MCS (contador de partículas ferrosas do tipo A). Na imagem, é possível observar as 3 divisões do funcionamento da máquina: em azul no último plano, estão os dados puros; em seguida, sempre sobrepondo os dados em azul, estão os períodos de máquina ligando em laranja e, por último, os períodos de máquina em regime permanente em vermelho.

Ainda sobre a imagem 21, é interessante ressaltar alguns pontos sobre cada um dos gráficos/sensores, principalmente quando se trata de um terceiro sensor não utilizado para realizar esses cálculos de filtros, como no terceiro gráfico:

- Gráfico 1 (sensor de pressão): a máquina só está ligada quando o valor da pressão está acima de um valor de corte. O código rejeita alguns picos curtos de pressão (onde a pressão é alta e logo em seguida vai para zero) e, principalmente, rejeita os picos iniciais, os quais tornam as estatísticas e futuras análises instáveis.
- Gráfico 2 (sensor de temperatura): a máquina só está ligada para valores mais altos de temperatura e só está no modo de operação em regime estável quando está acima de um valor (o qual foi determinado pela moda móvel). Além disso, há pequeno picos de temperatura os quais foram rejeitados para os estados relevantes da máquina.
- Gráfico 3 (sensor MCS): é interessante ver que a maior parte dos períodos onde há uma soma no contador de partículas são os períodos os quais a máquina está ativa. Além disso, vale ressaltar um grande salto na contagem quando houve um pico de pressão por volta do dia 07 de novembro de 2023.

Figura 21 – Exibição dos períodos de funcionamento da máquina em 3 sensores: pressão, temperatura e MCS (24h).



Fonte: Arquivo próprio.

4.4.3 Execução e métodos do código

Para a lógica de processamento, de forma macro, foram feitos alguns passos:

1. Identificação de *timesteps* que pertencem ao estado de máquina ligada dependendo dos parâmetros específicos do projeto em questão e criação de novo DF somente com esses períodos;
2. Criação de intervalo de valores da temperatura, dependendo de moda móvel criada a partir do novo DF criado de máquina ligada;
3. Identificação de períodos os quais fazem parte do estado de máquina ativa, baseando-se na moda móvel, e criação de último DF somente com esses novos períodos.

4.4.3.1 Detecção de intervalos

Para o passo 1 onde foram criados *dataframes* baseados em intervalos, foi utilizada uma função desenvolvida para este fim, chamada de *check_limits*. Esta função precisa de alguns parâmetros:

- DF inicial: o qual é utilizado para puxar os valores, os *timestamp* e as variáveis; Neste caso foi utilizado o DF já filtrado no início com as variáveis e o período de interesse;
- Sensor e limite: variável e valor a ser considerado para checar se foi ultrapassado (sendo maior ou menor) dentro do DF especificado;
- Outros parâmetros temporais, como intervalo mínimo a ser considerado e intervalos de tempo para limpar *outliers* (a ser explicado na seção 4.4.3.1.1) e
- Atributos booleanos para definir se a comparação será para valores maiores (*True*) ou menores (*False*) do que o determinado pelo valor de limite e para definir se o DF será exportado (*True*) ou não (*False*) ao final da execução.

Assim, primeiramente o DF dado é filtrado pela variável passada como parâmetro e os valores são checados pelo limite de corte, facilitando a detecção dos exatos momentos onde há mudanças do resultado da comparação, por exemplo onde o valor do sensor deixou de ser menor para ser maior do que o valor de corte. Obtendo esses tempos exatos, foi possível criar grupos de intervalos precisos onde os valores estão acima ou abaixo do valor de corte, dependendo da definição da variável booleana de parâmetro para este fim. Além disso, os intervalos só são consolidados caso sejam maiores do que o parâmetro temporal de valor mínimo de intervalo em minutos. Utilizando esses intervalos, foram feitos cálculos de duração para cada grupo e a duração total, além da contagem da quantidade desses intervalos. Ainda, baseando-se nesses grupos, foram retirados os *timestamps* não pertencentes para todas as variáveis e foi criado um novo *dataframe* que possui somente os valores, variáveis e *timestamps* desse período de interesse.

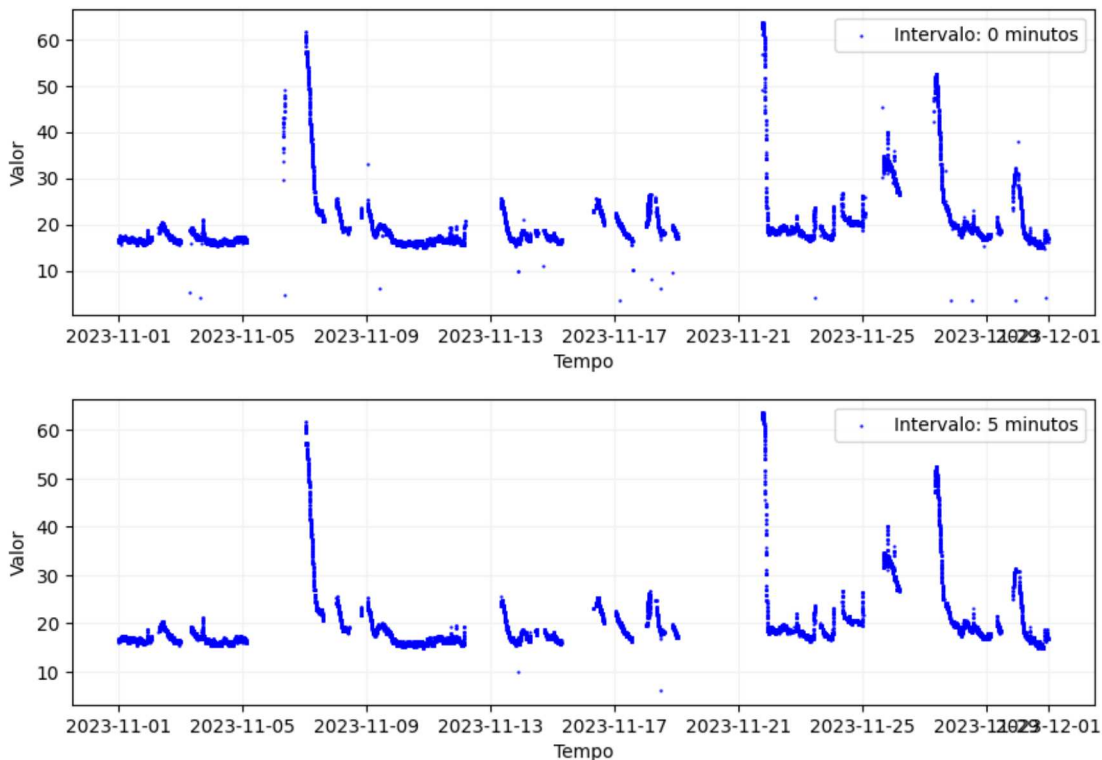
Portanto, a função, ao final, exporta a duração total, os pares (datas iniciais e finais) dos intervalos e a quantidade de pares, além do novo *dataframe* criado baseando-se nos parâmetros passados.

4.4.3.1.1 Limpeza de outliers por intervalos de tempo

Afim de excluir ainda mais os *outliers*, foi usado um período de tempo antes e depois dos pares de intervalos na função previamente definida *check_limits*. Assim, de

acordo com a figura 22, utilizando um intervalo de 5 minutos como exemplo comparativo, pode-se perceber a exclusão de alguns pontos transitórios, desnecessários para as futuras análises.

Figura 22 – Comparação entre intervalos de 0 e 5 minutos para limpeza de *outliers* por tempo.



Fonte: Arquivo próprio.

4.4.3.2 Moda móvel para temperatura

A fim de garantir um valor médio que represente a maior parte de operação da máquina, considerando apenas quando ela estiver ligada, foi criada uma função para determinar uma moda média utilizando alguns parâmetros do projeto. A partir desse resultado, é possível estabelecer uma margem (no caso deste estudo, idealmente estabelecida em 20%) e, com isso, filtrar os dados a fim de gerar um novo conjunto de intervalos contendo somente os períodos os quais a máquina está no período ativo (em regime permanente).

Para este cálculo, foram levadas em conta essas 3 formas de estatísticas:

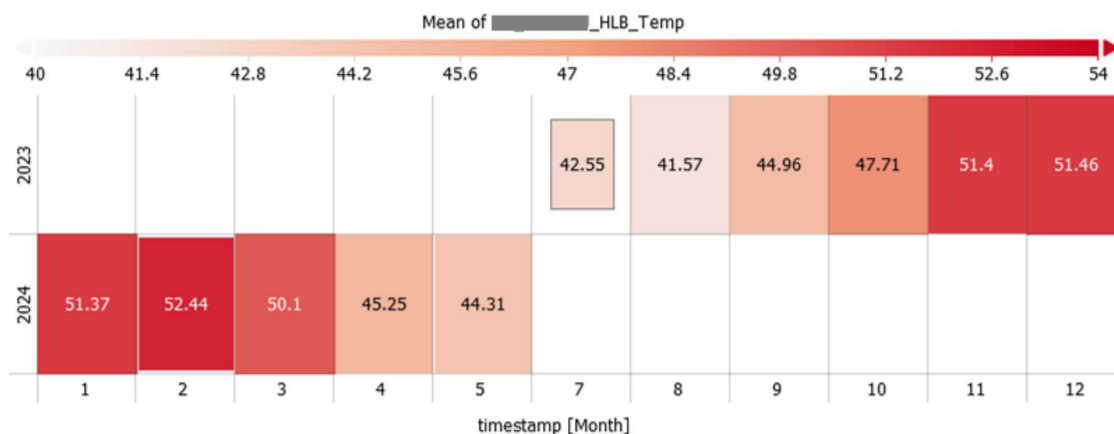
- Média: resultado da soma dos valores dividida pela quantidade de valores; ideal para valores simétricos e onde todos os valores são relevantes, mas não rejeita *outliers*.

- Mediana: valor intermediário quando os dados estão colocados em ordem; ideal para dados com muitos *outliers*, mas considera somente o valor central.
- Moda: valor que aparece com maior frequência em conjunto de dados; ideal para dados categóricos e com *outliers*, mas pode não existir (caso dados não se repitam).

Assim, como os dados possuem outliers e é interessante considerar o máximo de dados, desde que dentro de uma margem, foi utilizada a estatística de moda.

Além disso, como é uma métrica que utiliza diretamente a temperatura, é válido ressaltar que o valor da moda deve ser móvel e diferente para cada conjunto de dados (principalmente no caso dos relatórios mensais) devido à sazonalidade da temperatura durante o ano. Este fator pode ser claramente visto pelo gráfico de calor gerado pelo *software* Visplore na figura 23, onde o eixo x representa os meses do ano (por 2 anos, como descrito no eixo y) e o valor em cada quadrante, assim como a cor, representa a média da temperatura de um dado projeto. Pode-se observar que a temperatura, entre os meses mais frios (durante o meio do ano) e mais quentes (início e final de ano), varia quase 10°C.

Figura 23 – Exemplo de sazonalidade da temperatura em máquina do projeto G. Imagem feita utilizando o software Visplore.



Fonte: Arquivo próprio.

Dessa forma, é essencial que o código seja automatizado para se ajustar conforme o período em questão, por exemplo, seja num mês de inverno ou verão.

4.4.3.3 Limites de alarmes

Ainda sobre os métodos utilizados no estudo, falta o processo para checar os valores de alarmes. Para isso, é necessário, primeiramente, diferenciar se o alarme é do tipo LL/L ou H/HH, detectando se é preciso realizar a comparação do valor para "baixo" ou para "cima".

Para essa nova funcionalidade, a mesma função previamente definida *check_limits* é utilizada, mas, dessa vez, o parâmetro booleano, o qual indica se a comparação será para maior ou menor do que o valor limite, é decisiva para a análise.

No código, os alarmes definidos no início (como demonstrado na seção 4.4.1) estão registrados em um DF, onde as células são baseadas num sistema onde as linhas são os sensores e as colunas são as categorias de alarmes e a coluna de unidades, conforme a tabela 4 de exemplo.

Tabela 4 – Formatação padrão de DF com alarmes dos sensores.

Nome da coluna	Sensor	LL	L	H	HH	Unid
Descrição da coluna	Sensores disponíveis	Valores de alarme por sensor				Unidade do sensor
Exemplo	sensor_temp	10	25	75	85	°C

Assim, dependendo se o alarme é inferior ou superior, a função *check_limits* se ajusta, percorre esses valores de alarmes e retorna, para um novo DF de mesmo formato (linhas e colunas), os resultados para cada célula: duração total, quantidade de intervalos (ou picos) e os pares de intervalos, desconsiderando o DF criado pela própria função (diferente de como foi usado na seção 4.4.3.1, onde o principal dado retornado era esse DF retornado pela função *check_limits*).

Portanto, agora há um DF que, para cada valor limite, seja superior ou inferior, criado para cada sensor, há informações completas sobre os alarmes.

4.5 ESTATÍSTICAS

A fim de trazer mais informações relevantes para as análises, foram feitos cálculos estatísticos e algumas outras análises matemáticas para atribuir mais valor aos dados presentes nos projetos.

Para criar as estatísticas do período mais crítico para as análises, os valores do DF que contém os dados da máquina em operação de regime permanente são agrupados por variável e são feitos os cálculos considerando os seus valores. As estatísticas principais geradas são as seguintes:

- Média: valor médio dos dados;
- Moda: valor mais frequente no conjunto de dados;
- Mínimo: menor valor do conjunto de dados;
- Máximo: maior valor do conjunto de dados;

- Desvio Padrão: medição de dispersão dos dados em relação à média, ou seja, o quanto os valores diferem, em média, da média.

Além disso, são criadas duas novas métricas: a média somada ou subtraída de $1.5 * (\text{desvio padrão})$, métrica utilizada para incluir variações aceitáveis e comuns nos dados. Esses dois valores são gerados a fim de estabelecer uma região de operação média das variáveis e pode ser utilizado em gráficos para facilitar a visualização de outliers e valores abaixo ou acima dessa região de atividade.

Ainda como uma nova métrica, é criado o índice de disponibilidade da máquina. Este valor representa a quantidade total de tempo o qual o sistema esteve ligado, utilizando a mesma função *check_limits* com parâmetros utilizando a pressão crucial da máquina e utilizando somente o primeiro resultado retornado pela função: a duração total. Esta última métrica, em conjunto com uma porcentagem da relação com o período total levado em conta (por exemplo o mês inteiro), é relevante para que o gestor ou técnico do processo, tenha, de forma clara e objetiva, a informação do tempo ativo da máquina e sua disponibilidade operacional, colocando em evidência o contraste com períodos de falhas, manutenções e/ou interrupções voluntárias.

4.6 ALARMES

Essencial em um sistema de monitoramento industrial, os alarmes são utilizados para determinar valores limites para uma dada variável.

Visando a parte do estudo o qual cria relatórios automáticos e, como anteriormente explicado sobre o método de análise de alarmes (seção 4.4.3.3), o código verifica todos os alarmes criados para cada sensor e consegue, com precisão, detectar e exibir as seguintes informações para cada valor:

- Duração total: valor que mostra o período total o qual o sensor permaneceu com um determinado alarme acionado no determinado período; é exibido em dias, horas e minutos.
- Quantidade de picos: valor que mostra a quantidade de vezes o qual o alarme foi acionado, representando a quantidade de intervalos registrados pela função utilizada no método.
- Pares de intervalos: par de *timestamps* que representa o início e fim do intervalo de acionamento do alarme, mostrando com exatidão o período o qual o alerta ficou ativo.

Além de retornar estas informações sobre os alarmes, também foram geradas, por meio de curtos cálculos, informações valiosas e diretas sobre esses dados, como:

- Porcentagem sobre a operação: valor em porcentagem que representa quanto tempo o alarme ficou acionado em relação ao tempo total de operação da máquina, afim de quantificar o quão alarmante está a situação daquele sensor.
- Proporção de alarmes: relação entre todos os alarmes acionados no período, a fim de dimensionar qual sensor ou alarme deve receber mais atenção.

Assim, com esses valores simples e diretos, é possível oferecer uma visão mais clara sobre os alarmes e suas relações com o processo em si, tornando dados valiosos na gestão da indústria.

4.7 PREDIÇÃO

Para a parte de predição de dados, foram feitas algumas pesquisas e testes sobre diferentes métodos para utilizar nesse estudo. De forma breve, esses foram os resultados e observações sobre os métodos pesquisados:

- *Random Forest*: é robusto a *outliers* e ruídos e é bom para múltiplas variáveis, mas não captura dependências temporais e pode ser lento e consumir muita memória para uma grande quantidade de dados.
- *ARIMA (AutoRegressive Integrated Moving Average)*: é bom para séries temporais estacionárias (média e variância são constantes para conjunto de dados), mas não lida bem com dados sazonais e requer diferenciação para dados não estacionários.
- *SARIMA (Seazonal ARIMA)*: corrige os problemas do método *ARIMA*, mas tem difícil ajuste, principalmente para dados complexos ou com múltiplas sazonalidades.
- *LSTM (Long Short-Term Memory)*: é bom para séries temporais e para capturar dependências de longo prazo, mas requer grandes quantidades de dados de treinamento e é de difícil ajuste e alto custo computacional.
- *Prophet*: é fácil de configurar e lida bem com dados sazonais e séries temporais não estacionárias e com lacunas, mas é pouco flexível para ajustes finos e não é tão preciso com outros modelos bem ajustados.

Dessa forma, como os dados são no formato de séries temporais e, principalmente, contém lacunas (devido à categorização do funcionamento da máquina) e padrões sazonais, o método que melhor respondeu foi o *Prophet* e será por meio dele que as seguintes explicações e resultados serão baseados. Além disso, é importante ressaltar que, mesmo quando as variáveis são correlacionadas, as projeções de dados

utilizadas nesse trabalho consideram somente uma variável por vez, de forma que não são análises multivariáveis.

Como definido na seção de fundamentação teórica (seção 3.4.1), o método é de simples configuração para se utilizar em conjunto com o Python e precisa, basicamente, de alguns parâmetros e os dados dispostos em 2 colunas: uma com os timestamps e outra com os valores. Dessa forma, é necessário tratar os dados a fim de obter um DF exatamente como definido pela biblioteca do método e definir os parâmetros de forma clara.

Além disso, é importante ressaltar que, para utilizar qualquer algoritmo de predição de dados, é extremamente relevante usar um banco de dados confiável e com informações reais ao processo, por exemplo, eliminando períodos de testes, fases piloto ou até mesmo testes de aceitação.

Portanto, a maior parte de desenvolvimento nesta seção se deu para definir, da melhor forma, como será o DF utilizado pela biblioteca, principalmente quando o código for criar os relatórios automáticos. Essencialmente, foram tratados alguns tópicos principais que influenciam bastante os resultados finais:

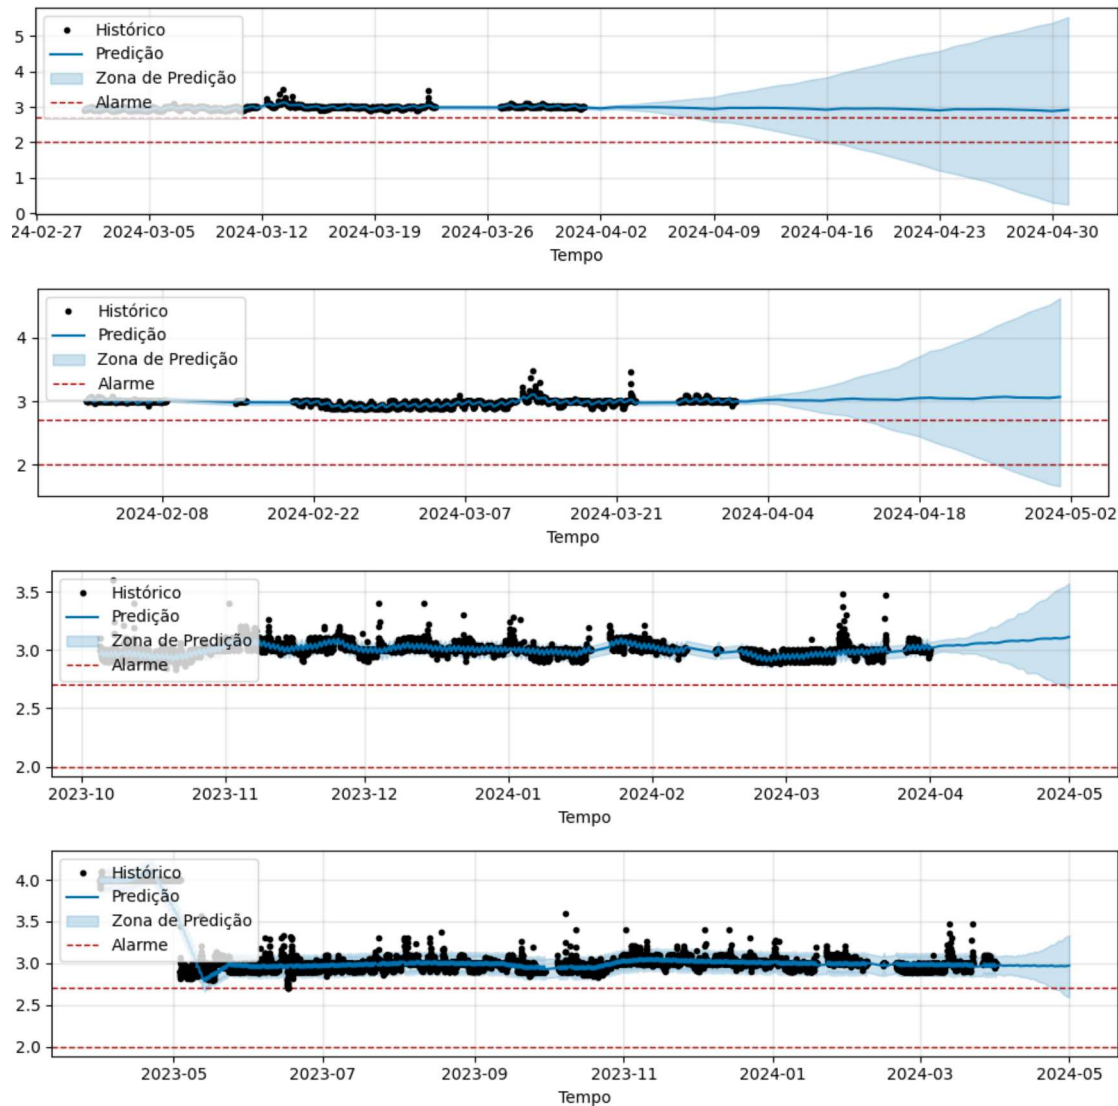
- Período de treinamento prévio;
- Frequência dos dados para futuro;
- Formato dos dados de entrada (completos ou filtrados por funcionamento da máquina).

Como aspecto padrão em métodos de predição de dados e algoritmos de inteligência artificial, um dos fatores que mais influenciam a informação gerada é o treinamento do algoritmo e, com isso, o período completo de dados do conjunto de dados que é utilizado para esse treinamento. Dessa forma, foram testados diferentes períodos de aprendizagem para a mesma base de dados (sensor de pressão do projeto K) e com predição para os mês seguinte, como visto na figura 24, a comparação entre períodos de 1 mês, 2 meses, 6 meses e 12 meses anteriores ao início da projeção. Os resultados parecem similares, mas pode-se notar a diferente tendência para cada um deles: para o exemplo de 1 mês, a tendência da projeção é de diminuir o nível; para os exemplos de 2 e 6 meses, a projeção tende a aumentar de nível; e para o exemplo de 12 meses, tende a ser mais estável.

Baseando-se em testes e na base de dados do estudo, a qual, dependendo do projeto, tem um curto período de dados estáveis para treinamento do algoritmo, o código utiliza por padrão o período de 6 meses anteriores de treinamento do sistema.

Vale ressaltar que, períodos muito grandes acabam perdendo a precisão para projeções próximas (como dos seguintes 30 dias) e também, dependendo do momento do projeto, capturam diferentes estados de operação da máquina.

Figura 24 – Exemplo de previsão de dados dependendo do tempo de treinamento prévio, em ordem: 1 mês, 2 meses, 6 meses e 12 meses. Dados do sensor de pressão do projeto K.




Fonte: Arquivo próprio.

Um outro fator interessante sobre os parâmetros do método Prophet para previsões de dados, é a questão da frequência da projeção. Como é uma abordagem que identifica as sazonalidades dos dados, o formato com o qual definimos o período é bastante relevante. Assim, utilizando 2 formatos diferentes para tratar o mesmo período de 1 mês ou 30 dias, podemos obter diferentes resultados nas projeções, como pode ser visto na figura 25. Ainda na figura, é possível notar que variações curtas ou diárias dos dados têm maior influência quando tratadas em uma abordagem que utiliza a frequência de dias, como no segundo gráfico da figura em questão. Pelo outro lado, quando o formato é em meses, essas variações tem pouca influência e os pontos passam a ser mais lineares.

Portanto, devido às sazonalidades e ao formato dos dados deste estudo, ele adota, por padrão, o formato de dias para a frequência das projeções.

Figura 25 – Exemplo de predição de dados para comparar utilização de diferentes frequências para os dados futuros, em ordem: 1 mês e 30 dias. Dados do sensor de pressão do projeto B.



Fonte: Arquivo próprio.

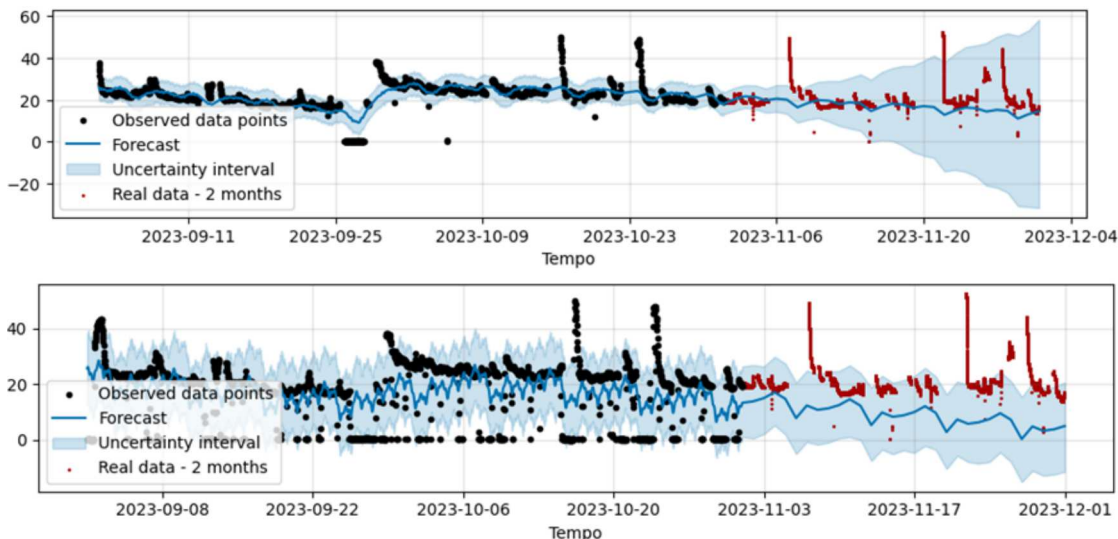
Por último e mais relevante para o estudo desses projetos, está a questão da entrada dos dados, sejam completos ou com lacunas e filtrados.

Conforme debatido ao longo do estudo (principalmente na seção 3.2), foi visto que é importante separar o período de funcionamento crítico da máquina, ou seja, quando ela está em operação e em regime permanente. Esta metodologia, além de conter dados mais fiéis ao processo real, traz menos instabilidade para os pontos e facilita as análises e cálculos, assim como o treinamento do algoritmo de predição de dados, tornando as amostras mais limpas.

Dessa forma, pode-se conferir na figura 26, onde há a comparação entre os dados reais (em vermelho) e a projeção (em azul), que os dados, quando não filtrados (gráfico 2), possuem muitos ruídos e valores que diferem do real processo da máquina, além de apresentar uma tendência equivocada. Por outro lado, quando considerados somente os períodos relevantes da máquina (gráfico 1), além de obter uma melhor visualização, a projeção é mais realista e possui uma tendência condizente com o processo.

Assim, por padrão, os dados utilizados como entrada para a predição de dados, são somente os pertencentes ao período de máquina ativa (ou em regime permanente) para todas as variáveis.

Figura 26 – Exemplo de predição de dados para exibir diferentes resultados dependendo dos dados de entrada (em ordem: filtrados e puros). Em vermelho estão os dados reais do mês, comparados com a predição em azul. Dados do sensor de pressão do projeto B.




Fonte: Arquivo próprio.

4.7.1 Alarmes nos valores estimados

Afim de complementar as análises para a seção da predição de dados e trazer uma melhor visualização, foram implementadas linhas pontilhadas nos gráficos de predição que representam os alarmes atribuídos à determinada variável, conforme visualizado na figura 27.

Dessa forma, a visualização do gráfico, em conjunto com a associação entre a projeção da variável e o limite estabelecido pelo alarme, fica ainda mais evidente e de rápida compreensão. Na figura em questão, fica notório que a variável, neste caso um sensor de pressão do projeto B, ultrapassa o alarme de 25bar. Assim, há mais uma informação que atribui valor à análise do sistema.

Figura 27 – Exemplo de predição de dados para exibir aviso gerado quando projeção ultrapassa alarme. Dados do sensor de pressão do projeto B.



Fonte: Arquivo próprio.

5 RELATÓRIO MENSAL AUTOMÁTICO

Após a fundamentação teórica (capítulos 2 e 3) e o desenvolvimento principal do estudo (capítulo 4), agora, já como forma de resultados iniciais, será tratado especificamente do relatório automático mensal criado pelas análises e métodos criados. Assim, nesta seção será, além de mostrado os últimos trechos desenvolvidos no estudo, serão exibidos alguns trechos dos relatórios, já como resultado do desenvolvimento da análise realizada até então.

Para a criação do relatório, serão utilizados praticamente todo o desenvolvimento e conhecimento até esta seção. Além disso, foi inserida uma nova parte no código que cria um documento de formato Excel, extensão *.xlsx*, além de formatar os valores e resultados em títulos, textos e gráficos.

De forma geral, a ideia da criação desse relatório surge para facilitar a visualização dos dados e estatísticas sobre os sistemas hidráulicos, além de rápidas análises e projeções para o mês seguinte. Dessa forma, o gestor ou técnico pode obter vários *insights* e mais informação sobre o processo, principalmente quando relacionados à manutenção preditiva, já que é possível prever os valores de variáveis e detectar um previsto mal funcionamento, antecipando a ocorrência de possíveis falhas.

A seguir, toda a análise será dividida pelas 5 páginas presentes no relatório: Dados do Relatório, Sensores e Máquinas, Alarmes, Predição de Dados e Parecer Técnico.

Reiterando, os dados que serão exibidos terão os nomes dos clientes e outras informações sigilosas, mas irrelevantes para a análise, ocultados, de forma a manter a segurança destes dados. Além disso, as figuras representam alguns relatórios de exemplo e não estão interligadas (não fazem parte do mesmo relatório).

5.1 DADOS DO RELATÓRIO

Na primeira página do documento, estão algumas informações estáticas, como dados dos clientes, endereços e algumas informações do sistema.

Além disso, como pode ser visto na figura 28, esta página também contém dados voláteis que mudam a cada relatório, como os primeiros e últimos *timestamps* e os nome dos sensores com dados no período.

Para a execução dessa parte, são apresentados os dados fixos já previamente, de forma manual, inseridos no código e rápidos cálculos e manuseios do DF inicial para estes dado dinâmicos.

Figura 28 – Exemplo de parte da página de Dados do Relatório.

Objetivo	Neste relatório serão apresentados os dados do sistema do ultimo mês, além dos alarmes e da previsão das variáveis para os proximos 30 dias.
Período do documento	2024-05-01 00:08:00 - 2024-05-29 23:53:00
Tags do Relatório	______Filtro_1, ______Filtro_2, ______HLB_Saturacao, ______HLB_Temp, ______MCS1000_FEA, ______MCS1000_FEB, ______MCS1000_FEC, ______MCS1000_NFED, ______MCS1000_NFEE, ______MCS1000_NFEF, ______MCS1000_FEA_24h, ______MCS1000_FEB_24h, ______MCS1000_FEC_24h, ______MCS1000_NFED_24h, ______MCS1000_NFEE_24h, ______MCS1000_NFEF_24h

Fonte: Arquivo próprio.

5.2 SENSORES E MÁQUINA

Já na segunda página, as análises são mais profundas e os métodos previamente apresentados são utilizados.

Como visto na figura 29, a primeira parte da página são as estatísticas diretas sobre os dados presentes no DF alterado que mostra somente valores quando a máquina está ativa. Estas métricas são colocadas lado a lado e podem ser ordenadas. Nesta parte é interessante observar os valores e buscar algumas informações chave, como o desvio padrão e valores mínimos ou máximos para variáveis críticas.

Figura 29 – Exemplo de estatísticas de sensores da página Sensores e Máquina. Contém sensores com nomes fictícios.


Sensor	Média	Moda	Mínimo	Máximo	Desvio Padrão	Unid
Sensor1	0,000	0,000	0,0	0,0	0,0	%
Sensor2	28,000	28,000	28,0	28,0	0,0	bar
Sensor3	5,000	5,000	4,0	5,0	0,0	bar
Sensor4	4,000	4,000	4,0	4,0	0,0	bar
Sensor5	27,643	28,000	27,0	28,0	0,5	bar
Sensor6	27,205	27,000	27,0	28,0	0,4	bar
Sensor7	10,735	11,000	8,0	14,0	1,0	%
Sensor8	6,888	7,000	-0,1	7,0	0,9	
Sensor9	8,858	9,000	-0,1	10,2	1,1	
Sensor10	7,872	8,000	-0,1	8,0	1,0	
Sensor11	47,288	46,000	40,8	52,7	2,5	°C
Sensor12	13,406	14,000	11,0	17,0	1,6	%
Sensor13	89,257	89,079	87,9	90,7	0,4	%
Sensor14	1,903	1,900	1,3	2,2	0,1	%
Sensor15	0,000	0,000	0,0	0,0	0,0	bar
Sensor16	29,661	28,600	27,9	31,5	0,8	bar

Fonte: Arquivo próprio.

Em se tratando de uma métrica importante para a máquina como um todo, foi criado um índice de disponibilidade da máquina, que representa o período total, dentro do mês específico, o qual o sistema esteve no modo ligado. Assim, é fácil de visualizar e ter a informação direta de quanto tempo a máquina esteve desligada, seja por opção ou por fatores como manutenção e falhas. O resultado disso, assim como um gráfico

pode ser visto na figura 30.

Figura 30 – Exemplo de exibição de disponibilidade da máquina da página Sensores e Máquina.




Fonte: Arquivo próprio.

Para estes cálculos, foram usados os métodos anteriores para detectar o período completo o qual a máquina esteve ligada e uma relação com o período total de dados recebidos no mês, sendo o intervalo máximo de tempo possível.

Agora, a parte mais visual e voltando para as análises dos sensores, está a exibição dos gráficos das variáveis, como podem ser vistas nas figuras 31 e 32.

Figura 31 – Exemplo de gráfico de sensores da página Sensores e Máquina. Contém 2 variáveis de pressão.




Fonte: Arquivo próprio.

Nas duas figuras em questão, foram utilizados os valores originais para plotar o gráfico e, nos períodos os quais a máquina está em modo ativo (utilizando os métodos de análise descritos anteriormente na seção 4.4.3.1) foi dado uma maior ênfase com o uso de uma linha mais grossa no gráfico.

Além disso, como visto na figura 32, que põe em conjunto o gráfico de temperatura e o gráfico de pressões, há mais uma métrica associada ao gráfico. Como mencio-

Figura 32 – Exemplo de gráfico de sensores da página Sensores e Máquina com limites associados ao desvio padrão. Contém 2 variáveis de pressão e 1 de temperatura.



Fonte: Arquivo próprio.

nado anteriormente na seção 4.5, é criada uma métrica de média $\pm 1.5 * \text{desvio padrão}$ que denota uma região de operação média. Assim, para tornar ainda mais fácil visualizar os pontos *outliers*, esses valores, para cada variável, são plotados como linhas tracejadas no gráfico, evidenciando os pontos acima ou abaixo dessas linhas.

Com isso, é interessante, no exemplo deste último gráfico, verificar e associar os pontos externos a essa região de operação média a fim de verificar a real causa para este efeito ou de observar mais atentamente no futuro.

5.3 ALARMES

Na terceira página, são utilizados os mesmos métodos de análises, mas dessa vez, checando se os alarmes previamente inseridos manualmente no código foram ultrapassados. Assim, como mencionado na descrição do desenvolvimento do método (na seção 4.4.3.3), esta função é capaz de retornar várias informações que foram usadas para criar a tabela vista na figura 33.

Na figura em questão, para cada sensor há um conjunto de informações divididas em colunas, são elas:

- Sensor: contém o nome do sensor (neste caso, um nome fictício).
- Alarme: valor limite atribuído como alarme, seja da categoria LL, L, H ou HH, e sua respectiva unidade. Caso seja L ou H, terá preenchimento de cor amarelo e, caso seja LL ou HH, será vermelho.

Figura 33 – Exemplo de tabela de alarmes da página de Alarmes. Contém nomes de sensores fictícios. Imagem foi cortada para caber no documento.

Sensor	Alarme	Duração total	% Op	Picos	Períodos (dia, hh:mm)
Sensor_1	27.0 bar	12d, 12:41h	76,08%	3	Início 06, 20:13 06, 21:02 12, 05:23
					Fim 06, 20:57 12, 05:12 19, 09:10
Sensor_2	50.0 °C	4d, 18:53h	29,07%	28	Início 01, 00:00 01, 14:50 02, 15:02 03, 15:47 04, 16:54 07, 18:25 12, :
					Fim 01, 01:04 02, 00:54 02, 23:50 04, 01:29 04, 17:05 07, 20:46 12, :
Sensor_3	15.0 bar	4d, 04:09h	25,34%	4	Início 06, 20:49 06, 21:31 08, 03:53 09, 18:41
					Fim 06, 20:57 07, 01:58 09, 16:56 12, 05:12
Sensor_4	27.0 bar	7d, 13:28h	45,92%	885	Início 01, 15:57 01, 16:06 01, 16:15 01, 16:53 01, 17:01 01, 17:29 01, :
					Fim 01, 16:00 01, 16:08 01, 16:17 01, 16:57 01, 17:04 01, 17:31 01, :
Sensor_5	15.0 bar	4d, 06:28h	25,93%	4	Início 06, 20:47 06, 21:02 08, 03:22 09, 17:24
					Fim 06, 20:57 07, 01:58 09, 16:56 12, 05:12
Sensor_6	27.0 bar	14d, 23:20h	90,92%	1510	Início 01, 00:09 01, 00:24 01, 00:32 01, 00:41 01, 00:51 01, 01:03 01, :
					Fim 01, 00:12 01, 00:30 01, 00:34 01, 00:44 01, 00:57 01, 01:13 01, :

Fonte: Arquivo próprio.

- Duração Total: período total, formato em dias, horas e minutos, do tempo o qual o alarme especificado ficou acionado.
- % Op: porcentagem da duração total do alarme sobre o tempo total de operação da máquina ligada.
- Picos: número de vezes o qual o alarme foi acionado e corresponde à quantidade de intervalos registrados.
- Períodos: mostra o *timestamp* inicial e final dos intervalos/picos de alarme acionado.

Dessa forma, é fácil de obter informações gerais sobre os alarmes registrados e, caso seja necessário uma análise mais profunda, tem-se a informação dos *timestamps* iniciais e finais dos intervalos de acionamentos.

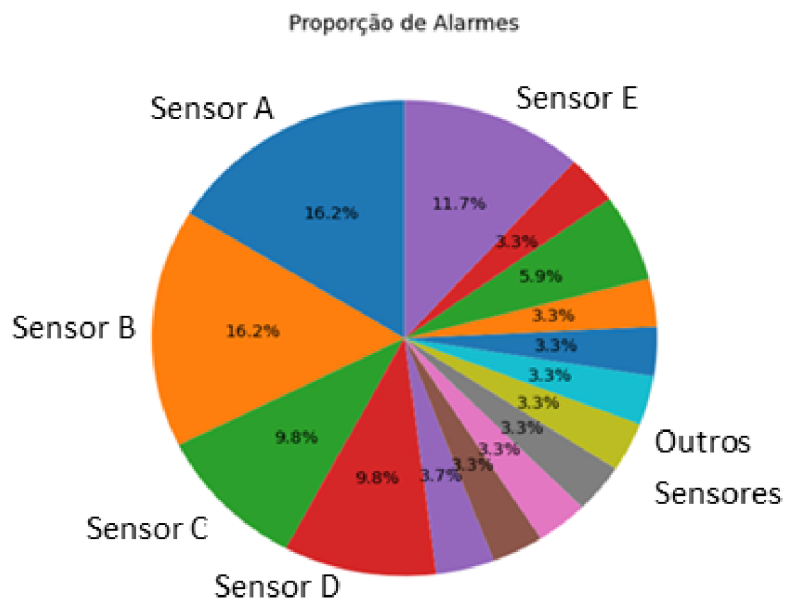
Ainda sobre os alarmes, a fim de oferecer uma ideia de qual sensor está demandando maior atenção, foi gerado uma relação temporal entre todos os alarmes acionados. Dessa forma, é fácil visualizar o sensor o qual possui o alarme que passou mais tempo acionado e precisa ser observado com mais cuidado. O resultado dessa análise pode ser visto na figura 34.

5.4 PREDIÇÃO DE DADOS

Agora, na quarta página, estão as previsões de dados para as variáveis dos projetos. Esta seção é dividida em 2 partes:

- Predição anterior e valores reais: contém gráficos com a projeção dos dados feita no início do mês de referência e os dados reais da variável desse mês (em vermelho). Treinamento do algoritmo foi feito somente até o início do mês. Exemplo de resultado na figura 35.

Figura 34 – Exemplo de tabela de alarmes da página de Alarmes. Contém nomes de sensores fictícios.



Fonte: Arquivo próprio.

- Predição futura: contém gráficos com a projeção dos dados para o mês seguinte. Treinamento do algoritmo foi feito até o final do mês em questão, incluindo os dados recentes. Exemplo de resultado na figura 36.


Para realizar essas análises, foram utilizados somente os períodos de máquina ativa e, novamente, os métodos descritos anteriormente (na seção 4.7).

Dessa forma, para a primeira parte (figura 35), é interessante observar a veracidade das predições e o quanto ela é precisa, mesmo para dados voláteis como temperatura e pressão (como no caso da pressão no segundo gráfico). Ainda sobre a pressão, nota-se que, mesmo com picos e sazonalidade, a predição tem um bom índice de acerto. Além disso, a fim de verificar tendências, é ainda mais válido observar as variáveis de contadores de particulados, já que são mais estáveis.

Agora sobre a segunda parte (figura 36), vale observar se os valores projetados tem a tendência de ultrapassar ou não os alarmes registrados.


Utilizando-se dessa comparação entre dados preditos e dados reais, é notável a facilidade para fazer comparações de quando o valor real está dentro ou fora do planejado e, assim, traçar estratégias para agir acerca desse determinado sensor de forma planejada e prévia.

Figura 35 – Exemplo de gráfico de projeção e dados reais da página de Predição de Dados. Sensores MCS e de pressão, respectivamente.



Fonte: Arquivo próprio.

Figura 36 – Exemplo de gráfico de projeção da página de Predição de Dados. Sensor de pressão.



Fonte: Arquivo próprio.

5.5 PARECER TÉCNICO

Nesta última página do documento, há somente um campo em branco para demais observações específicas do técnico responsável ou gestor acerca do relatório gerado.

6 RESULTADOS

Agora, como uma seção dos resultados gerais do desenvolvimento do estudo, podemos dividir em 2 partes: os resultados obtidos devido à criação do código de análise e devido à criação dos relatórios automáticos.

6.1 RESULTADOS DO CÓDIGO E ANÁLISES


De forma geral as análises desenvolvidas no código principal responderam bem aos dados utilizados. Como resultados prévios e já comentados neste trabalho, no capítulo 5 já foi utilizado grande parte do material desenvolvido anteriormente, no capítulo 4, pois, para desenvolver e gerar os relatórios automáticos, foi necessário carregar toda a análise previamente feita e somente adequar para ser algo automático e com recorrência.

Como o contexto do projeto, desde o começo, demanda uma necessidade de ser um estudo genérico e de se adequar em diferentes contextos (desde que características parecidas, como no caso das máquinas desse estudo), essa capacidade de adaptação é um fator essencial. Como constatado, o código que gera as análises deve ser modular e abstrato, de forma que se adapte em diferentes contextos, já que será usado para várias máquinas diferentes. Dessa forma e sob esse critério de adaptabilidade, como visto no capítulo 5, as análises se comportaram bem para os 5 tipos diferentes de máquinas dos diferentes projetos.

Outro fator muito importante a se analisar nos resultados é a divisão do funcionamento da máquina baseado em algumas variáveis, como pressão e temperatura. No geral, desde que o código receba corretamente as variáveis e valores de corte para cada caso, as funções se comportam bem para os diferentes níveis de operação. Ao longo do estudo, podem ser vistas diferentes figuras com esta correta divisão de funcionamento, independente da variável ou projeto, como das figuras 31 e 21.

Por último, outro fator muito relevante nesse estudo é a predição de dados. Os resultados desse tópico são mais complexos de serem analisados e dependem de muitos fatores. Como visto em várias imagens deste trabalho, quando utilizando o método e parâmetros corretos, grande parte das projeções estão dentro do limite esperado (faixa azul claro) nos gráficos de projeção, como nos gráficos das figuras 35 e 27. Entretanto, este atributo fica difícil de relacionar para certas variáveis em momentos instáveis, como a temperatura em um ciclo de uso da máquina muito diferente do padrão, como pode ser visto no segundo gráfico da figura 37. Por outro lado, na mesma figura, há o primeiro gráfico, que trata da pressão e, mesmo com sazonalidades e picos, a projeção dos dados se comporta muito bem e possui 100% dos dados reais contidos na margem. Além disso, vale ressaltar os picos de pressão existentes nos dados reais e no conjunto projetado para o futuro.

Figura 37 – Exemplo de predição de dados entre pressão e temperatura, respectivamente.



Fonte: Arquivo próprio.

6.2 RESULTADOS DO RELATÓRIO AUTOMÁTICO

Para a criação dos relatórios automáticos, também houve um bom desempenho. Mesmo que com pouco tempo de teste, já foi possível ver que o código consegue gerar informações consistentes, mesmo que com meses diferentes e com contínuas novas entradas de dados.

De forma geral, conforme visto ao longo das explicações do capítulo 5, os gráficos, textos e as tabelas geradas pelo relatório agregam valor aos dados previamente adquiridos. Trazendo um pouco do conceito da hierarquia DIKW (Data, Information, Knowledge, Wisdom; detalhada na seção 3.3.4), o relatório é capaz de transformar o simples dado adquirido do banco de dados em uma informação relevante para o gestor da empresa cliente ou técnico analista do sistema. Essa informação agregada se dá não somente pela evidência de algumas informações mais relevantes, como *insights* e, por exemplo, as estatísticas, os gráficos com ênfase em momentos específicos, gráficos comparativos e até mesmo as predições de dados capazes de alertar o usuário, caso a projeção ultrapasse algum alarme pré-definido.

Pode-se dizer que a presente análise de particulados em correlação com outras variáveis da máquina e a ocorrência de falhas já foi validada por um dos clientes. Em uma das máquinas hidráulicas, foi constatado um pico de particulados em conjunto com uma operação anormal de temperatura. Após alguns dias e após ser acusado pelo sensor de vibração, o redutor de pressão do circuito hidráulico quebrou e a máquina teve que entrar em pausa e em processo de manutenção por alguns dias, até que as peças sejam encomendadas e o conserto executado. Este *case* aconteceu quando o

projeto ainda estava em implementação e não foi dado o devido crédito à informação do sensor de particulados.

Portanto, neste caso, se o projeto já estivesse implementado, o gestor do sistema hidráulico seria capaz de visualizar o funcionamento anormal da máquina e realizar, assim como mencionado no conceito de manutenção preditiva, uma observação mais assertiva e organizar previamente uma manutenção agendada.

Ainda sobre casos de uso, pode-se citar outros dois casos que clientes passaram a observar após a utilização dessas análises:

- foi constatado o travamento de uma válvula hidráulica após o aumento anormal de temperatura e a máquina pode passar por um momento de manutenção agendada e
- foi constatada uma ineficiência do trocador de calor presente em uma máquina hidráulica em estações do ano mais quentes.

Assim, pode-se concluir que a análise e os relatórios automáticos foram facilitadores para a gestão e controle dessas máquinas hidráulicas.

7 CONCLUSÃO E PERSPECTIVAS FUTURAS

O desenvolvimento deste projeto demonstrou a viabilidade e as vantagens da implementação de um sistema de manutenção preditiva em máquinas hidráulicas utilizando o sistema IoT da GreyLogix Brasil. Os resultados, mesmo que iniciais, confirmam que a análise contínua e a predição de dados, se baseando em variáveis críticas, como pressão, temperatura, umidade e contaminação do fluido, permitem uma gestão mais eficiente da manutenção, trazendo uma redução de custos e o aumento da disponibilidade das máquinas.

Outro fator que funcionou e se mostrou relevante com as análises realizadas, foi a classificação e divisão do funcionamento da máquina como critério de seleção para o treinamento do algoritmo de predição de dados e também para a análise mais precisa da condição dos componentes. Mesmo com diferentes cenários de atuação industrial e especificidades das máquinas, o código utilizado foi capaz de realizar a divisão para todas as cinco máquinas distintas.

Além disso, este estudo valida a importância da integração entre sensores e dispositivos IoT na indústria em conjunto com a análise de dados para fins de transformar a abordagem da manutenção industrial e trazer, cada vez mais, informações de valor para os processos industriais.

Embora o projeto ainda esteja sendo desenvolvido e ajustado, de acordo com os resultados preliminares obtidos e comentados na seção anterior, pode-se dizer que utilizando-se dessas análises e desses relatórios em conjunto com os conceitos de manutenção preditiva e da projeção dos dados, houve uma maior facilidade em visualizar e compreender os processos e possíveis futuras falhas. Tendo como comparação indústrias onde existe somente o dado puro do sensor numa tela do chão de fábrica, agora utilizando-se do monitoramento constante e de tendências e projeções, a empresa hoje tem a capacidade de obter a informação referente à necessidade de manutenção de forma prévia e com tempo suficiente para organizar o processo, evitando, assim, períodos maiores e não programados de máquina parada e reduzindo o custo por manutenção.

Dessa forma, pode-se afirmar, para cada objetivo proposto:

- **Adquirir e organizar dados:** os dados, armazenados como séries temporais em formato de base histórica, foram devidamente organizados e manuseados de acordo com a metodologia de análise de funcionamento da máquina proposta. Além disso, o código responsável por essas tarefas, mesmo em diferentes cenários e com algumas especificidades dependendo do projeto, se adequou aos dados.
- **Predição de dados:** as projeções, mesmo que não sendo baseadas em algoritmos de multivariáveis, correspondeu bem aos testes e comparações realizadas.

Vale ressaltar que a resposta obtida não é uma certeza absoluta, mas sim uma indicação de tendência do valor obtido pelos sensores. Além disso, a parte de treinamento sofre grande influência quanto aos dados utilizados, aumentando ainda mais a importância para a etapa anterior de organização dos dados.

- **Apresentação dos dados:** Os relatórios gerados, contendo análises, estatísticas, *insights* e as projeções dos dados, performaram bem e foram capazes de agregar bastante informação e conhecimento a respeito da condição geral da máquina ao longo do período analisado.

7.1 PERSPECTIVAS PARA FUTUROS TRABALHOS

Além do trabalho proposto, ao longo do desenvolvimento foram pensadas novas alternativas e ideias para a continuação e/ou validação de melhorias para o tema apresentado neste estudo, como as seguintes:

- **Integração de log de atividades do funcionamento do sistema:** implementar e anexar, em conjunto com o banco de dados dos sensores já utilizados neste estudo, novas variáveis qualitativas sobre o funcionamento ou estado do sistema, como por exemplo a indicação de uma troca de filtro ou uma indicação de falha em uma válvula.
- **Maior gama de eventos e correlações:** utilizando-se de variáveis qualitativas e de um maior banco de dados com mais eventos distintos, seria possível gerar novas correlações e aumentar a gama de análises possíveis a serem realizadas.
- **Adicionar suporte para falhas:** incluir ações a serem tomadas em momentos ou situações identificadas como fora do padrão ou relevantes, como por exemplo uma solicitação de trocar o filtro de limpeza do fluido após verificar uma crescente tendência ou alarme no valor de saturação do fluido da máquina.
- **Algoritmo multivariável para correlações:** adaptar o Prophet ou utilizar outro algoritmo capaz de interpretar correlações e múltiplas variáveis no treinamento das predições, a fim de validar correlações para as projeções das variáveis.
- **Indicador para comparação:** criar uma variável para servir de comparação entre períodos distintos, correlacionando índices de aumento de valores, como de pressão e de contaminação do fluido, e criando uma métrica que pode ser utilizada para verificar se está mudando ao longo do tempo.

Portanto, o trabalho se encerra com os objetivos alcançados, mesmo que com dados preliminares da execução, mas abre portas para melhorias e novos estudos sobre o tópico estudado.

REFERÊNCIAS

ABNT. **ISO 16232**. [S./], 2011.

BURKE, Rex. **Manutenção de Sistemas Hidráulicos: Um Guia Prático**. [S./], 2023. Disponível em: <https://www.manx-hyd.com.br/post/fluidos-hidr%C3%A1ulicos-%C3%A1gua-e-glicol>. Acesso em: 17 jun. 2024.

EOOE. **Symptoms of Common Hydraulic Problems and Their Root Causes**. [S./], 2023. Disponível em: <https://www.eooehydraulic.com/resources/symptoms-of-common-hydraulic-problems-and-their-root-causes.html>. Acesso em: 18 jun. 2024.

EXATI. **Manutenção corretiva, preventiva e preditiva: diferença e exemplos**. [S./], 2022. Disponível em: <https://blog.exati.com.br/manutencao-corretiva-preventiva-e-preditiva/>. Acesso em: 7 jun. 2024.

FIALHO, Arivelto Bustamante. **Automação Hidráulica: Projetos, Dimensionamento e Análise de Circuitos**. 6. ed. [S./], 2004.

GANNON, Mary. **Hydraulic system contamination: causes and solutions**. [S./], 2018. Disponível em: <https://www.mobilehydraulictips.com/hydraulic-system-contamination-causes-and-solutions/>. Acesso em: 18 jun. 2024.

GOMES, Marcio Rodrigues. **Apostila de Hidráulica**. [S./], 2008.

GREYLOGIX. **Solução YOT: Intelligent Industrial Internet of Things**. [S./], 2022.

HYDAC. **Cartilha de contaminação: Controle de fluidos**. [S./], 2024.

HYDAC. **Fluid Conditioning: All-Round Protection from the Fluid to the System**. [S./], 2018.

HYDAC. **Removing varnish in hydraulic oils efficiently**. [S./], 2022. Disponível em: <https://www.hydac.com/en/removing-varnish-in-hydraulic-oils-efficiently/>. Acesso em: 17 jun. 2024.

- HYDRA. **Common hydraulic problems – symptoms and causes**. [S./], 2018. Disponível em: <https://hydraproducts.co.uk/Blog/common-hydraulic-problems-symptoms-and-causes/>. Acesso em: 18 jun. 2024.
- IBM. **What is predictive maintenance?** [S./], 2022. Disponível em: <https://www.ibm.com/topics/predictive-maintenance>. Acesso em: 17 jun. 2024.
- KARDEK, Alan; NASCIF, Julio. **Manutenção Função Estratégica**. [S./], 2009.
- LIVINGSTONE, Greg. **How Varnish Is Destroying Your Hydraulic System (And How to Stop It)**. [S./], 2023. Disponível em: <https://precisionlubrication.com/articles/hydraulic-system-varnish/>. Acesso em: 17 jun. 2024.
- MOBLEY, R. K. **An introduction to predictive maintenance**. [S./], 2002.
- OTANI, Mario; MACHADO, Waltair V. **A proposta de desenvolvimento de gestão da manutenção industrial na busca da excelência ou classe mundial**. [S./], 2008.
- PARKER. **Tecnologia hidráulica industrial: Fluidos e filtros hidráulicos**. [S./], 2006.
- PYTHON. **About Python**. [S./]. Disponível em: <https://www.python.org/about/>. Acesso em: 17 jun. 2024.
- REIS, Ana Carla Bittencourt; COSTA, Ana Paula Cabral Seixas; ALMEIDA, Adiel Teixeira de. **Diagnóstico da gestão da manutenção em indústrias de médio e grande porte da região metropolitana de Recife**. [S./], 2013.
- STANDARDS, European. **ISO 4406**. [S./], 2021.
- TAYLOR, Sean J.; LETHAM, Benjamin. **Forecasting at Scale**. [S./], 2017.
- TELES, Jhonata. **Tipos de manutenção de acordo com a NBR5462**. [S./], 2018. Disponível em: <https://engeteles.com.br/tipos-de-manutencao/>. Acesso em: 17 jun. 2024.
- THERMAL. **Fluido Hidráulico: Funções, Tipos e Aplicações em Máquinas**. [S./]. Disponível em: <https://www.thermal-engineering.org/pt-br/fluido-hidraulico-funcoes-tipos-e-aplicacoes-em-maquinas/>. Acesso em: 17 jun. 2024.

VICKERS, Sperry. **Manual de Hidráulica Industrial**. 8. ed. [S.l.], 1983.

VISPLORE. **About Visplore**. [S.l.]. Disponível em: <https://visplore.com/company/>. Acesso em: 17 jun. 2024.