

## Desenvolvimento de sistema prescritivo de manutenção industrial: análise de viabilidade técnica e eficácia de algoritmos python na antecipação de falhas

Development of a prescriptive industrial maintenance system: technical feasibility analysis and effectiveness of python algorithms in failure prediction

Elton Ribeiro Bastos<sup>1</sup>  
Ronaldo Gomes Figueira<sup>2</sup>

**Resumo:** Alcançar o estágio da manutenção prescritiva é o objetivo de indústrias que buscam autonomia máxima, onde o sistema não apenas prevê o defeito, mas dita a solução antes mesmo da parada ocorrer. No entanto, um obstáculo real nas fábricas é a falta de registros de medições e históricos de quebras, o que acaba travando o treinamento de modelos de prescrição. Esta pesquisa mostra que essa lacuna pode ser vencida ao utilizar bases sintéticas, como o dataset da Microsoft Azure, para preparar os algoritmos de forma segura e eficaz. O trabalho utiliza o ecossistema Python como uma escolha para análise dos dados, aproveitando as suas ferramentas dedicadas para este fim. A contribuição central é uma proposta de integração de hardware que une controladores Siemens (S7-1200/1500) a gateways Advantech (ECU-1051). Essa estrutura foi pensada para coletar variáveis reais de campo que espelhem o padrão dos dados usados nos testes, garantindo que o algoritmo Ensemble LSCP identifique sinais de desgaste com precisão. Essa escolha permite que a lógica testada em ambiente virtual seja aplicada futuramente em um ambiente real similar ao proposto. Os resultados comprovam que essa união entre equipamentos industriais e software de código aberto é um caminho financeiramente viável para evitar interrupções indesejadas no fluxo produtivo. Ao automatizar as prescrições, o sistema retira o peso do diagnóstico humano e acelera a tomada de decisão do Planejamento e Controle de Manutenção. Conclui-se que o modelo é prático e escalável, oferecendo um roteiro seguro para empresas que desejam elevar sua disponibilidade operacional.

**Palavras-chave:** Manutenção Prescritiva. Indústria 4.0. Python. Dados Sintéticos.

---

<sup>1</sup> Graduando do Curso de Engenharia Elétrica da Universidade de Araraquara- UNIARA. Araraquara-SP. E-mail: erbastos@uniara.edu.br

<sup>2</sup> Orientador. Docente Curso de Engenharia Elétrica da Universidade de Araraquara- UNIARA. Araraquara-SP. E-mail: rfigueira@uniara.edu.br

**Abstract:** Achieving the stage of prescriptive maintenance is the goal of areas seeking maximum autonomy, where the system not only predicts the defect but dictates the solution even before the stoppage occurs. However, a real obstacle in factories is the lack of accurate records and breakdown histories, which ultimately hinders the training of prescriptive models. This research shows that this gap can be overcome by using synthetic datasets, such as the Microsoft Azure dataset, to prepare algorithms safely and effectively. The work uses the Python ecosystem as a choice for data analysis, leveraging its dedicated tools for this purpose. The central contribution is a proposed hardware integration that includes Siemens drivers (S7-1200/1500) and Advantech gateways (ECU-1051). This structure was designed for real-world field variations that express the pattern of the data used in the tests, ensuring that the Ensemble LSCP algorithm accurately identifies signs of wear. This choice allows logic tested in a virtual environment to be applied in the future in a real-world environment similar to the one proposed. The results prove that this combination of industrial equipment and open-source software is a financially viable way to avoid unwanted interruptions in the production flow. By automating prescriptions, the system removes the burden of human diagnosis and accelerates decision-making in Maintenance Planning and Control. It is concluded that the model is practical and scalable, offering a safe roadmap for companies that wish to upgrade their operational availability.

**Keywords:** Prescriptive Maintenance. Industry 4.0. Python. Synthetic Data.

## 1. INTRODUÇÃO

Historicamente, a indústria busca melhorar sua performance produtiva, sendo a manutenção de ativos fundamental nessa estratégia. Essa busca impulsionou a evolução dos métodos que, ao longo das décadas, migraram de ações reativas para sistemas planejados e, atualmente, para sistemas avançados de recomendação: a manutenção prescritiva. Essa abordagem requer o monitoramento constante de variáveis já utilizadas na manutenção preditiva. Nela, a interpretação das informações não depende da avaliação humana, mas de algoritmos treinados que, baseados em custos de parada, quebra e disponibilidade de recursos, indicam a melhor ação, o momento ideal da intervenção e a forma de execução, padronizando o trabalho técnico.

Nessa perspectiva, a gestão de ativos torna-se parte do resultado do negócio. Para (KARDEC e NASCIF, 2022) , a manutenção deixou de ser um "mal necessário" para ser estratégica, unindo gestão e técnica para garantir a confiabilidade da planta. O foco não é apenas a velocidade do reparo, mas o uso

inteligente de dados para evitar perdas. Essa organização de informações sustenta a adoção de modelos analíticos, onde o sistema dita as prioridades de intervenção.

Para que a manutenção se torne prescritiva, esta pesquisa foca no monitoramento de variáveis reais de campo. São dados brutos de vibração, temperatura e corrente elétrica colhidos por sensores em tempo real. Se o padrão de vibração oscila ou a corrente sobe, a falha iniciou, mesmo que imperceptível ao olho humano. Ao disponibilizar esses sinais a algoritmos capazes de filtrar ruídos, o resultado é uma recomendação direta de intervenção. Isso evita o desperdício de peças e elimina paradas de emergência que prejudicam a lucratividade.

Embora infraestruturas de automação possibilitem o monitoramento em tempo real, a coleta de variáveis não garante que a falha será evitada. Frequentemente, falta um histórico de quebras para treinar a inteligência artificial com segurança. O desafio central desta pesquisa é validar a capacidade do algoritmo em prescrever a ação correta antes do dano. Diante dessa incerteza, busca-se responder: de que maneira o desenvolvimento de algoritmos em Python, integrados a sistemas de controle (CLP/Gateway) e validados por bases sintéticas, pode comprovar a eficácia técnica de um modelo de manutenção prescritiva?

A conectividade industrial elevou o patamar do monitoramento, mas dados isolados não previnem paradas. Para (FOGLIATTO e RIBEIRO, 2011), a manutenção ganha eficiência ao aplicar métodos quantitativos sobre o desempenho. A união entre modelos matemáticos e poder computacional permite antecipar falhas antes da interrupção produtiva. O Python justifica-se aqui como ferramenta capaz de processar sinais brutos e devolvê-los como recomendações claras de ação.

Esta investigação testa se modelos prescritivos funcionam integrados aos dispositivos de campo. O ponto de partida é o mapeamento de como os controladores Siemens e gateways Advantech sustentam o tráfego de dados. Com essa base, algoritmos em Python são criados e treinados com bases sintéticas para antecipar quebras. O objetivo é provar que a união entre programação e hardware prescreve correções seguras antes de danos reais.

Este estudo atua como validador para lideranças industriais que hesitam em investir no modelo prescritivo. Ao consolidar uma prova de conceito que une o baixo custo do Python à robustez de equipamentos Siemens e Advantech, a pesquisa oferece segurança para transições tecnológicas baseadas em resultados mensuráveis. Academicamente, o trabalho oferece um roteiro técnico para replicar

arquiteturas de manutenção inteligente, servindo de atalho para novos estudos aplicados.

A metodologia segue um estudo de caso monitorando dados de controladores Siemens e gateways Advantech. Priorizam-se sinais de temperatura, vibração, pressão e dados elétricos. Devido à ausência de histórico real de falhas, adotam-se dados simulados para cobrir lacunas. Essas informações são tratadas em Python para organizar os dados e ajustar os modelos preditivos, validando se o sistema antecipa problemas ao cruzar eventos da planta com simulações de quebra.

O trabalho detalha desde a base teórica até a aplicação prática. Inicialmente, aborda-se a evolução da manutenção com foco no modelo prescritivo. Em seguida, descreve-se a arquitetura de hardware e o papel da comunicação industrial. Os capítulos centrais exploram o desenvolvimento dos algoritmos em Python e a demonstração de sua eficiência. Por fim, apresentam-se as conclusões sobre a viabilidade técnica, resultados e sugestões futuras.

## **2. REVISÃO BIBLIOGRÁFICA**

A gestão da manutenção industrial é pilar estratégico para garantir a funcionalidade, disponibilidade e competitividade em ambientes produtivos. Este trabalho foca no desenvolvimento de sistemas de manutenção prescritiva, analisando a viabilidade técnica de algoritmos Python na antecipação inteligente de falhas. A integração de tecnologias digitais permite que a gestão de ativos evolua da reparação reativa para a autonomia na tomada de decisão. Esta investigação concentra-se no aprendizado de máquina para transformar dados brutos em recomendações que otimizem a produtividade e a segurança operacional, visando eliminar paradas não planejadas e reduzir custos com intervenções desnecessárias.

A complexidade dos ativos e a competitividade global tornam as paradas não planejadas críticas para a rentabilidade, visto que estratégias preventivas e preditivas convencionais muitas vezes falham em oferecer diagnósticos automatizados. Diante dessa lacuna, a pesquisa busca responder: qual a viabilidade e eficácia de algoritmos de aprendizado de máquina em Python para desenvolver um sistema prescritivo capaz de antecipar falhas e recomendar intervenções em ativos críticos?

O levantamento bibliográfico foi conduzido em repositórios como Google Acadêmico, SciELO, Scopus, Web of Science e Portal CAPES. Utilizaram-se palavras-chave como manutenção prescritiva, aprendizado de máquina e algoritmos Python. Destacam-se autores como Alan Kardec, Júlio Nascif e Herbert Viana, além de manuais técnicos da Siemens e Advantech para fundamentar a arquitetura de aquisição de dados e conectividade. A pesquisa priorizou soluções documentadas até 2026, empregando bases de dados sintéticas para treinamento e teste dos modelos. A triagem integrou a gestão estratégica de ativos a métodos de conectividade, pautada por critérios de inclusão de autores consolidados, foco em ferramentas de processamento estável e manuais de referência industrial.

Das centenas de registros iniciais, sessenta e um estudos foram selecionados por apresentarem vínculo direto com a ciência de dados aplicada à indústria. Excluíram-se obras abrangentes sobre máquinas não críticas, estudos voltados à construção civil ou infraestrutura predial, e modelos matemáticos sem aplicação prática demonstrada. Essa filtragem garantiu profundidade sobre a manutenção inteligente e a troca de informações fabris.

A estruturação metodológica integrou práticas tradicionais de manutenção a novas tecnologias de processamento. O foco inicial estabeleceu a base para validar a infraestrutura de monitoramento e a captura automatizada de variáveis preditivas, alinhando-se a (KARDEC e NASCIF, 2022) e (VIANA, 2014). Para a validação prática, selecionou-se o conjunto de dados sintéticos *Microsoft Azure Predictive Maintenance* (2020). Foram analisadas variáveis como tensão, rotação, pressão e vibração. O pré-processamento utilizou Python (Pandas e NumPy) e o método LSCP da biblioteca PyOD (ZHAO, NASRULLAH e LI, 2019) para detecção de anomalias, subsidiando o modelo prescritivo.

Os resultados comprovam que a manutenção evoluiu para um pilar estratégico. Alinhado à literatura, o monitoramento de variáveis como tensão e pressão permite diagnósticos precisos da condição das máquinas, identificando falhas prematuramente. O Python, com as bibliotecas Pandas e NumPy, organiza eficientemente o fluxo de dados dos sensores, enquanto o método LSCP (PyOD) aumenta a confiança nos diagnósticos. Esse modelo inteligente automatiza decisões técnicas, melhora o planejamento do PCM e garante economia direta e confiabilidade dos ativos.

A adoção de estratégias baseadas na condição real consolidou-se como o método de maior retorno sobre o investimento. A transição para modelos prescritivos reduz as paradas não programadas mediante a identificação precoce de sintomas. A manutenção preventiva atende satisfatoriamente apenas 11% dos componentes, gerando custos desnecessários em 89% dos casos de falhas aleatórias (TELES, 2019) Sistemas inteligentes reduzem a inatividade em até 50% e diminuem quebras inesperadas (SOBRINHO, 2022). Segundo a (TELES, 2019), a automação estende a vida útil dos ativos em até 40%. Contudo, a adoção plena enfrenta obstáculos como o custo inicial de modernização e a exigência de grandes volumes de dados (MACHADO, JUNIOR, *et al.*, 2023), além da necessidade de mão de obra qualificada.

Este levantamento reforça que a manutenção inteligente é uma necessidade competitiva. Ferramentas prescritivas convertem dados brutos em decisões úteis, aumentando a vida útil dos ativos e o retorno financeiro. A automação das decisões técnicas reduz a incerteza e os prejuízos de quebras inesperadas. Embora barreiras como a necessidade de dados históricos persistam, o esforço integrado permite uma gestão mais eficiente. Investigações futuras, apoiadas em históricos reais, poderão validar a escalabilidade dos modelos e sua integração total aos sistemas de gestão empresarial.

### **3. CONCEITOS BÁSICOS DE MANUTENÇÃO**

Manutenção é o conjunto de ações e procedimentos técnicos que visam conservar, reparar ou otimizar o funcionamento de equipamentos, máquinas, instalações e sistemas, com o objetivo de prolongar sua vida útil, garantir a segurança operacional e minimizar interrupções em processos produtivos. Para (KARDEC e NASCIF, 2022) a manutenção deve ser vista como uma função estratégica dentro das organizações, impactando diretamente na competitividade e na lucratividade.

De acordo com Associação de Normas Técnicas (ABNT, 1994) a manutenção é “A combinação de todas as ações técnicas e administrativas, incluindo as de

supervisão, destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida” (ABNT, 1994).

Conforme explicado acima, as técnicas de manutenção que também envolvem fatores administrativos, devem ser adequadamente aplicadas com uma visão estratégica impactando diretamente nos negócios e afetando a disponibilidade de equipamentos e processos. Tais técnicas devem ser constantemente revisadas e desenvolvidas conforme surgem novas necessidades e modos mais eficientes de execução.

(FOGLIATTO e RIBEIRO, 2011) em seu livro confiabilidade e manutenção industrial, abordam o tema manutenção centrada na confiabilidade e as técnicas que estão sendo amplamente reconhecidas como a forma mais eficiente para tratar questões de manutenção. "Eles permitem que as empresas alcancem excelência nas atividades de manutenção, ampliando a disponibilidade dos equipamentos e reduzindo custos associados a acidentes, defeitos, reparos e substituições."

Ao mesmo passo que o desenvolvimento tecnológico otimiza os processos industriais automatizados os equipamentos são cada vez mais conectados e interdependentes. fazendo com que, a parada de um dos equipamentos do processo impacte na eficiência geral do processo, desta forma, a rápida atuação da manutenção se torna cada vez mais importante para mitigar problemas de entrega e os custos da manutenção.

### 3.1. TIPOS E DESENVOLVIMENTO HISTÓRICO

A manutenção, ao longo dos anos, evoluiu de uma prática reativa para uma abordagem proativa e estratégica, visando garantir a máxima disponibilidade e confiabilidade dos ativos. Foi a partir do século XX que a manutenção começou a ser vista como uma área de conhecimento específica, com a industrialização em grande escala e a necessidade de garantir a continuidade da produção. Nesse período, os primeiros estudos sobre manutenção começaram a surgir, focando em aspectos práticos como a organização de equipes de manutenção e a definição de procedimentos.

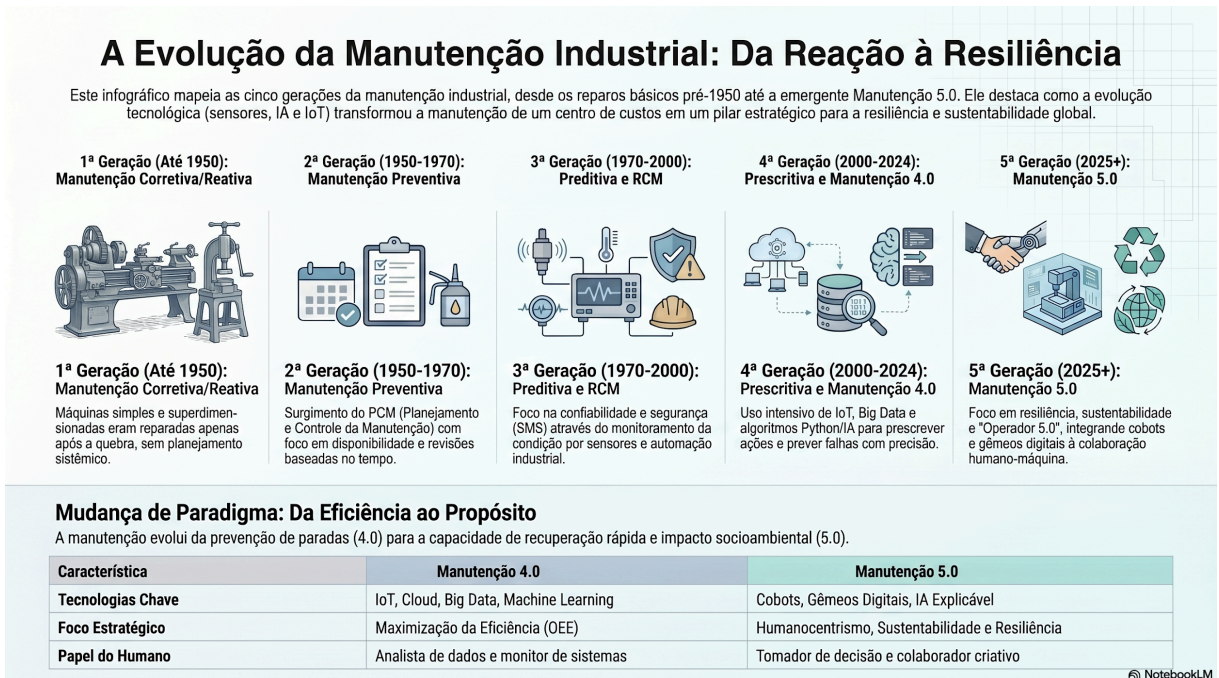
É difícil determinar as origens precisas do conceito de manutenção; no entanto, pode-se afirmar que, concomitantemente com o advento do século XX e a subsequente onda de industrialização, a escalada da demanda produtiva exigiu uma abordagem organizada das atividades de manutenção. Os recentes avanços na tecnologia precipitaram uma aceleração acentuada nos processos evolutivos nas últimas décadas. “Nos últimos 30 anos, a atividade de manutenção sofreu mais mudanças do que qualquer outra atividade” (KARDEC e NASCIF, 2022).

conforme afirmam (KARDEC e NASCIF, 2022), em meados da década de 1950, após a Segunda Guerra Mundial, a indústria começou a articular processos mais eficientes e sustentáveis, caracterizados pela compressão do tempo de manutenção e aumento da produtividade. A implementação da manutenção preventiva durante a década de 1960 foi fundamental para o desenvolvimento de técnicas de diagnóstico e solução de problemas mais eficazes. Essa metodologia inovadora, por sua vez, permitiu um melhor planejamento da manutenção e redução dos custos de produção.

De acordo com (KARDEC e NASCIF, 2022), a progressão das práticas de manutenção pode ser classificada em cinco gerações distintas: a geração inicial ocorre em um período anterior à Segunda Guerra Mundial, a segunda geração se desenvolve durante as décadas de 1950 a 1970, a terceira geração vai da década de 1970 até meados da década de 1990 e a quarta geração se estende da década de 1990 até a era contemporânea.

Na (Figura 1) podemos verificar a evolução da manutenção em gerações e como de forma geral a manutenção era entendida e aplicada. Além disso, é notável que, durante a terceira geração, a incorporação de metodologias de análise de falhas, incluindo Análise de Modos e Efeitos de Falha (FMEA) e Análise de Causa Raiz (RCFA), está começando.

**Figura 1 - A EVOLUÇÃO DA MANUTENÇÃO**



Fonte: Elaborado pelo autor com auxílio de Notebooklm(2026).

De acordo com (KARDEC e NASCIF, 2022), o domínio da manutenção industrial exibe uma trajetória histórica que pode ser categorizada em cinco gerações distintas conforme verificamos na (Figura 2):

Figura 2 - AS GERAÇÕES DA MANUTENÇÃO E SEUS ANOS



Fonte: Elaborado pelo autor com auxílio de Notebooklm (2026).

1º período anterior à Segunda Guerra Mundial:

Ações corretivas após falhas; conjuntos de habilidades voltados para o reparo;

2º Período após a conclusão da Segunda Guerra Mundial:

Manutenção preventiva. Aumento da disponibilidade de equipamentos; Vida útil operacional do equipamento; Aumento nas despesas de manutenção em relação a outros custos operacionais;

3º Período com início na década de 1970:

Manutenção preditiva; Manutenção centrada na confiabilidade (RCM). Implementação de protocolos de monitoramento de condições; Implantação de software para planejamento, supervisão e monitoramento de manutenção; métricas de confiabilidade aprimoradas; Relações de custo-benefício superiores;

4º período iniciado na década de 1990:

Implantação do gerenciamento de ativos; Aumento do uso da manutenção preditiva e monitoramento de condições; Redução das atividades de manutenção corretiva emergencial e preventiva; Implantação de análise de falhas;

5º Período com início nos anos 2000:

Otimização dos ciclos de vida dos ativos; influencia nos resultados do negócio; Aumento do uso da manutenção preditiva e monitoramento de condições on-line e off-line; Envolvimento efetivo no projeto, aquisição, instalação, comissionamento, operação e manutenção de ativos; Implementação de melhorias com o objetivo de mitigar falhas.

Dessa forma podemos dizer que estamos vivenciando a quinta geração da manutenção onde podemos usufruir de diversos aprendizados adquiridos ao longo das gerações anteriores, mas com muitas questões e desafios a serem tratados para que as técnicas de manutenção possam continuar evoluindo e contribuindo para o bom desempenho e a competitividade das empresas.

### 3.2. IMPACTO NO CUSTO DA PRODUÇÃO

A manutenção preventiva, corretiva ou preditiva é fundamental na dinâmica dos custos de produção. Ao garantir o funcionamento otimizado dos ativos, impacta gastos operacionais tanto no investimento em recursos quanto nas paradas não planejadas. Segundo (SIEMENS, 2024) o custo anual de manutenção das 500 maiores empresas mundiais representa 11% de suas receitas, totalizando US\$ 1,4 trilhão equivalente ao PIB da Espanha.

No cenário nacional, a (ABRAMAN, 2022) indica que apenas 38% das empresas apresentam disponibilidade operacional média acima de 95% (ABRAMAN, 2022). Esses dados evidenciam o impacto financeiro direto e indireto da manutenção no custo industrial. Dependendo do método priorizado, esse impacto é maior, especialmente em manutenções não planejadas, onde a somatória de perdas gera prejuízos acentuados aos processos produtivos. (COLEMAN, DAMODARAN e

DEUEL, 2017) apontam que o custo anual do tempo de inatividade não planejado para as indústrias mundiais gira em torno de US\$ 50 bilhões.

A manutenção gera impactos financeiros de duas formas: diretamente, via mão de obra e aquisição de peças, e indiretamente, pela inatividade decorrente de estratégias ineficientes. Apesar da evolução das técnicas preventivas, o custo da inatividade cresceu: "na indústria automotiva, cada hora de inatividade custa o dobro do que custava em 2019 (SIEMENS, 2024, p. 3).

Figura 3 - O ICEBERG DOS CUSTOS NA MANUTENÇÃO



Fonte: Elaborado pelo autor com auxílio de Notebooklm (2026).

Portanto, conforme explicado acima, apesar dos esforços e alocações de capital da indústria internacional para adotar metodologias de manutenção mais eficazes, os gastos com manutenção industrial em escala global permanecem consideráveis e, de fato, estão aumentando, em grande parte atribuíveis à interconexão de máquinas, que normalmente resulta em paradas em mais equipamentos em cascata. Em contraste com os modelos anteriores que, embora menos eficientes, foram capazes de fornecer uma alternativa viável durante a parada

individual de um equipamento específico, por exemplo, quando temos um equipamento com pouca ou nenhuma automatização conectada a outros, é mais fácil realizar a parada e manter a continuidade produtiva em outros processos e até mesmo a realização do processo parado em outro equipamento similar.

#### **4. A MANUTENÇÃO INDUSTRIAL PRESCRITIVA**

A manutenção prescritiva nada mais é do que a evolução da manutenção preditiva, a manutenção preditiva coleta em um intervalo de tempo pré-definido variáveis de um determinado equipamento (pressão, temperatura, vibração, etc.) afim de utilizá-las para diagnosticar o estado funcional do equipamento e identificar anomalias. Já a manutenção prescritiva utiliza das novas tecnologias existentes para monitorar as mesmas e até outras variáveis de máquina de forma contínua e online e através de algoritmos e inteligência identificar as anomalias de forma antecipada e com o desenvolvimento será capaz de prescrever a melhor solução para cada caso específico. Segundo a matéria publicada pelo site a voz da indústria (A VOZ DA INDÚSTRIA, 2020), o entrevistado Marcos Santos afirma que o conceito de manutenção prescritiva permite a indicação de qual procedimento executar, itens a serem trocados e ordem de execução.

Segundo (LOPES, 2025) a manutenção prescritiva é uma combinação da análise da condição do equipamento com o uso da inteligência artificial. Com respostas automatizadas e tomadas de decisão assistidas por sistemas inteligentes com otimização de tempo e precisão de ações.

Conforme explicado acima, a evolução das tecnologias de aquisição de dados para a análise, da possibilidade de armazenamento e aquisição de informações em tempo real e também um maior acesso a sistemas de auxílio de inteligência, posicionam a manutenção prescritiva em vantagem em relação à já efetiva manutenção preditiva. Os dados para a manutenção preditiva são coletados em intervalos de tempos nem sempre curtos podendo não identificar tendências entre esses intervalos.

A manutenção preditiva se baseia na condição real do equipamento. As ações são realizadas conforme a necessidade identificada pelos dados coletados, mas ainda exigem análise e decisão manual por parte da equipe técnica. (LOPES, 2025, p. 26)

Fica evidente a conexão entre a manutenção preditiva e prescritiva, sendo possível imaginar que apesar das informações utilizadas serem basicamente as mesmas, existe uma maior eficiência na forma que elas são tratadas na manutenção prescritiva. E com a implementação de algoritmos de decisão, cálculos de prejuízo em caso de quebra e também de aprendizado, as decisões sobre as ações se tornaram ainda mais efetivas.

A relevância deste estudo reside no fato de que a abordagem prescritiva possui o potencial de transformar radicalmente a forma como as indústrias operam, elevando a disponibilidade dos equipamentos e promovendo uma maior competitividade e sustentabilidade do negócio no panorama da Indústria 4.0. Este trabalho justifica-se ao preencher uma lacuna, oferecendo uma análise aplicada da eficiência das ferramentas de Ciência de Dados (especificamente Python e seus algoritmos) na validação da tomada de decisão prescritiva, em vez de se limitar a uma discussão puramente conceitual. Os resultados visam fornecer direcionamentos práticos para gestores e engenheiros que buscam modernizar seus programas de manutenção.

#### 4.1. BENEFÍCIOS

A manutenção prescritiva estabelece um novo patamar de maturidade na gestão de ativos, superando a simples previsão de falhas ao introduzir a automação da tomada de decisão orientada ao valor do negócio. Diferente da manutenção preditiva convencional, que foca no diagnóstico, a abordagem prescritiva utiliza a inteligência artificial para otimizar intervenções sob incerteza. Conforme afirmam (OROŠNJAK, SARETZKY e KEDZIORA, 2025, p. 2), essa tecnologia reduz a intervenção humana ao "transformar dados históricos e em tempo real em decisões ideais". Dessa maneira, o sistema não apenas alerta sobre o desgaste iminente, mas prescreve a rota de ação mais lucrativa e segura, garantindo que a operação de campo esteja em total sintonia com os objetivos estratégicos da Indústria 4.0.

A manutenção prescritiva representa uma evolução ao utilizar a análise de dados e a inteligência artificial não apenas para prever problemas, mas também para indicar a melhor ação a ser realizada no equipamento. Essa estratégia é

fundamental para aumentar a confiabilidade dos ativos, otimizar processos e reduzir significativamente os custos operacionais (KARDEC e NASCIF, 2022).

A transição da manutenção reativa para modelos mais avançados, como a manutenção prescritiva, não é apenas uma melhoria operacional, mas uma necessidade para o cenário de competitividade atual. Conforme defendem (KARDEC e NASCIF, 2022), a grande vantagem da abordagem prescritiva reside na sua capacidade de ir além do diagnóstico de problemas, utilizando inteligência artificial para recomendar a melhor ação corretiva em tempo hábil, conforme explicado acima. Essa capacidade de tomar decisões otimizadas transforma o setor de manutenção de um setor que é geralmente considerado um gerador de custo em um gerador de valor para o negócio. Ao aumentar drasticamente a confiabilidade e disponibilidade dos ativos, a manutenção prescritiva não só minimiza os tempos de inatividade não planejados, mas também assegura que os recursos e o capital humano sejam direcionados exclusivamente para intervenções cruciais, garantindo a eficiência máxima e a segurança operacional. Em suma, é uma ferramenta indispensável para a gestão moderna que visa a excelência e a longevidade dos equipamentos.

"A manutenção prescritiva vai mais adiante e sugere ações pontuais com base nas possibilidades. Trata-se de um indicador antecipado que mostra o que vai quebrar e como proceder para evitar que isso ocorra. A preditiva faz uma previsão, enquanto a prescritiva oferece recomendações para intervenções futuras, auxiliando diretamente na percepção de um defeito e gerando tratativas para evitá-lo. Isso significa relacionar dados a um nível que somente uma solução digital inteligente pode fazer, já que as causas de uma falha podem ser indiretas, e contar com um levantamento sólido de informações a partir de técnicas preditivas de análise" (OLIVEIRA NETO, 2021, p. 44).

Fica evidente que a essência da manutenção prescritiva é aprimorar drasticamente a tomada de decisão da equipe de manutenção. Indo além do diagnóstico, o sistema prescreve ações pontuais para evitar falhas, relacionando dados a um nível que somente soluções digitais inteligentes podem alcançar. Os benefícios são claros e abrangentes: otimização de processos, maior confiabilidade, segurança elevada e, crucialmente, uma significativa redução de custos

operacionais. Em suma, a manutenção prescritiva é uma ferramenta indispensável que converte a gestão de ativos em um pilar estratégico capaz de gerar valor contínuo e sustentável para o negócio.

#### 4.2. BARREIRAS CULTURAIS E ORGANIZACIONAIS

A Manutenção Prescritiva representa o patamar mais sofisticado da gestão de ativos, diferindo da abordagem preditiva por não apenas antecipar a falha, mas também utilizar algoritmos avançados para prescrever a ação corretiva ideal, o momento exato de intervenção e os recursos necessários. Embora a promessa de otimização tecnológica seja clara, diversos especialistas apontam que a maior complexidade na implantação da MPR não reside nos algoritmos, mas sim no fator humano e estrutural (TRACTIAN, 2026). Este capítulo se propõe a analisar as barreiras culturais e organizacionais que se tornam os obstáculos mais significativos na adoção da Manutenção Prescritiva, argumentando que a resistência à mudança, a falta de confiança em decisões algorítmicas e a rigidez departamental são fatores cruciais que determinam o sucesso ou o fracasso dessa implantação. A seguir, detalharemos a natureza e o impacto desses desafios.

Dentre os entraves não-tecnológicos, a barreira cultural é a mais difícil de ser transposta, pois afeta diretamente o capital humano e o modo de trabalho estabelecido. A migração para o modelo prescritivo exige que técnicos e gestores substituam a prática baseada na experiência e a intervenção manual por um novo modelo operacional onde a confiança nos dados e nos algoritmos é central. Para o sucesso da transição, uma gestão eficaz da mudança é fundamental, pois a implantação de novas práticas, como a gestão da qualidade e as tecnologias avançadas, trata de um processo de mudança de cultura que inevitavelmente gera resistência (KARDEC e NASCIF, 2022, p. 65). Essa perspectiva é crucial, pois a hesitação se manifesta em seguir uma recomendação contrária ao senso comum ou que contradiz o conhecimento técnico tradicional. Tal resistência afeta a área operacional e a gestão, que deve investir e confiar em uma solução complexa.

Esta resistência inerente é um reflexo direto da cultura de intervenção corretiva de emergência, ainda presente em muitas plantas industriais, onde a experiência do técnico em diagnosticar e resolver falhas sob pressão é altamente

valorizada em detrimento de uma abordagem sistemática e baseada em dados. O profissional, acostumado a atuar corretivamente ou sob um modelo preventivo fixo, demonstra aversão em confiar em um algoritmo cuja lógica é, muitas vezes, uma "caixa preta" para ele. Romper essa barreira não é apenas uma questão de treinamento técnico, mas de uma mudança de mentalidade promovida pela alta gestão, conforme explicado acima. A liderança deve, portanto, apoiar a nova metodologia de forma incondicional, demonstrando que a tecnologia é um suporte à tomada de decisão humana, e não um substituto para o conhecimento adquirido, incentivando a adaptação e a confiança no novo processo de trabalho.

A superação das barreiras culturais está ancorada na valorização e desenvolvimento do capital humano. Sem o engajamento da equipe, a Manutenção Prescritiva não gera o retorno esperado. A literatura enfatiza a primazia do elemento humano sobre a tecnologia, princípio crítico na Indústria 4.0. É fundamental compreender o papel das pessoas.

Portanto, as barreiras culturais e organizacionais representam o conjunto de desafios mais complexos na migração para a Manutenção Prescritiva, uma vez que não podem ser resolvidas apenas com investimento financeiro ou implementação de hardware. Estes obstáculos exigem um esforço de gestão da mudança que priorize a substituição da mentalidade reativa pela confiança em sistemas preditivos e prescritivos. Conclui-se que o sucesso do projeto depende do engajamento e da adaptação da equipe, fazendo do capital humano o principal fator crítico na transformação digital da manutenção.

#### 4.3. BARREIRAS TECNOLÓGICAS

A implementação da Manutenção Prescritiva encontra sua primeira e mais concreta resistência na complexidade e nas exigências da infraestrutura tecnológica de coleta e processamento de dados. A exigência fundamental para a eficiência do método é o monitoramento contínuo em tempo real dos ativos, o que demanda investimentos robustos em sensoriamento e dispositivos de Internet das Coisas Industriais, base que (SOBRINHO, 2022) destaca ser o pilar de sustentação do método. O desafio técnico reside na instalação de sensores adequados e na

capacidade da rede industrial de suportar a transmissão de um volume maciço de dados em fluxo contínuo com baixa latência. Além disso, ativos com tecnologia obsoleta, por carecerem de interfaces padronizadas, tornam a adequação e a coleta de dados primários um obstáculo técnico e de capital considerável.

Superada a etapa de coleta, o gargalo se desloca para o processamento e a gestão de grandes volumes de dados complexos. (KARDEC e NASCIF, 2022) salientam que a integração entre os domínios de tecnologia da Informação e tecnologia Operacional é vital, pois a análise completa de um ativo exige dados tanto dos sistemas de gestão quanto do chão de fábrica. A dificuldade é agravada pela persistente separação entre esses ambientes, que trabalham com protocolos distintos, gerando bases segregadas que impedem a visão unificada necessária para a análise de causa-raiz e recomendação de ação. Portanto, sem uma plataforma de dados robusta e integrada, o potencial da manutenção prescritiva limita-se à identificação de falhas, sem alcançar a plena capacidade de otimizar a tomada de decisão.

A partir da base de dados unificada, cuja importância foi ressaltada conforme explicado acima, o desafio técnico final se concentra no desenvolvimento e na sustentação dos algoritmos de Inteligência Artificial. O elemento central da Manutenção Prescritiva reside na capacidade preditiva e na recomendação da melhor ação futura, o que configura um processo naturalmente complexo e exigente. Modelos de Machine Learning e Deep Learning exigem um volume significativo de dados históricos de falhas e de condições operacionais, os quais frequentemente são incompletos ou inexistentes, retardando o processo de treinamento e validação. Esse custo inicial elevado para a aquisição de licenças de software de análise, somado à infraestrutura de cloud computing para o processamento massivo, representa uma barreira técnica e econômica substancial para as organizações.

Além dos custos de infraestrutura e licenciamento de software, a sustentação da Manutenção Prescritiva impõe um desafio contínuo de retenção de talentos. O desenvolvimento, a auditoria e a otimização constante de modelos de Inteligência Artificial demandam capital humano especializado em Ciência de Dados e Machine Learning. Essa profunda transformação exige um planejamento estratégico, como destacam Kardec e Nascif:

A manutenção moderna exige um equilíbrio entre a sofisticação tecnológica e a competência humana. De fato, a experiência mostra que o sucesso de qualquer programa de melhoria não reside na compra de um novo software ou sensor, mas sim na capacidade de envolver e motivar as pessoas para que utilizem a tecnologia de maneira eficaz e sustentável, traduzindo dados em decisões. (KARDEC e NASCIF, 2022, p. 25).

Em suma, as barreiras tecnológicas discutidas revelam que a transição para a Manutenção Prescritiva não depende apenas da aquisição de novas ferramentas, mas de uma reestruturação completa do fluxo de dados industriais. A convergência entre a coleta massiva por sensores e o processamento inteligente via algoritmos demanda uma base sólida de integração entre os sistemas de Tecnologia da Informação e Tecnologia Operacional. Sem o enfrentamento desses desafios de infraestrutura e da escassez de pessoal qualificado, os benefícios da prescrição permanecem inalcançáveis para a realidade fabril brasileira. Dessa forma, conclui-se que a superação desses limites técnicos é a condição primordial para que a organização possa avaliar a viabilidade financeira desta transformação digital. É imperativo que a gestão compreenda que a robustez tecnológica precede o retorno sobre o investimento, estabelecendo um alicerce necessário para a evolução da maturidade industrial.

#### 4.4. BARREIRAS FINANCEIRAS

A viabilização da Manutenção Prescritiva nas organizações esbarra em barreiras financeiras significativas que exigem uma análise criteriosa de custo-benefício para a alta gestão. A implementação deste modelo demanda um aporte de capital elevado, compreendendo desde a aquisição de sensores até o pagamento de licenças de softwares especializados. De acordo com (KARDEC e NASCIF, 2022), o custo da manutenção pode representar uma parcela expressiva do faturamento bruto das empresas, o que torna investimentos em tecnologias de alto custo um processo de decisão complexo. Portanto, a pressão orçamentária e a demora no retorno sobre o investimento configuram obstáculos que muitas vezes impedem a modernização dos ativos industriais.

A alocação de recursos para a manutenção prescritiva exige que a gestão financeira compreenda a transição do custo de reparo para o investimento em confiabilidade operacional. Segundo (LAFRAIA, 2001), a gestão de ativos moderna

demanda um equilíbrio rigoroso entre o desempenho esperado, os riscos envolvidos e os custos totais de propriedade ao longo do ciclo de vida. A barreira financeira se consolida quando os gastos com infraestrutura digital e processamento de dados são imediatos, enquanto os ganhos com a disponibilidade dos ativos surgem de forma diluída no tempo. Dessa maneira, a dificuldade em quantificar o retorno sobre o investimento inicial acaba por retardar a adoção de estratégias prescritivas em ambientes industriais com orçamentos restritos.

Muitas empresas deixam de investir na manutenção prescritiva porque olham apenas para o investimento necessário na implementação, compra de equipamentos e dos sistemas. Conforme explicado acima, é preciso mudar essa visão e entender que o gasto inicial se paga com o tempo, já que a redução de paradas de produção e o aumento da longevidade dos equipamentos argumentam a favor. Nesse sentido, a barreira do dinheiro só deixa de existir quando os gestores percebem que evitar quebras gera um lucro maior do que a economia feita ao não comprar tecnologia. Portanto, a análise financeira deve considerar não apenas o valor que sai do caixa hoje, mas todo o ganho de eficiência que a automação de decisões trará para o dia a dia da produção.

A necessidade de uma mudança na análise financeira para viabilizar novas tecnologias é reforçada pela visão estratégica da gestão de ativos:

A gestão de ativos busca o equilíbrio entre custos, riscos e desempenho. Não se trata apenas de minimizar gastos, mas de otimizar o valor que o ativo entrega à organização ao longo de toda a sua vida útil. Portanto, decisões baseadas apenas no menor preço de aquisição costumam resultar em custos operacionais e de manutenção muito mais elevados no futuro, comprometendo a rentabilidade global do negócio. (LAFRAIA, 2001, p. 42) .

Nesse contexto, a superação das barreiras financeiras para a adoção da manutenção prescritiva depende diretamente da capacidade da organização em reconhecer o valor estratégico da disponibilidade dos seus ativos. Embora o investimento inicial em sensores e inteligência artificial possa parecer proibitivo em um primeiro momento, os ganhos reais aparecem na redução drástica de custos com quebras inesperadas e na otimização dos estoques de peças. Portanto, conclui-se que o sucesso econômico dessa transformação digital não deve ser medido apenas pelo capital gasto na implementação, mas sim pelo retorno gerado pela maior eficiência operacional e pela segurança produtiva conquistada. Assim, a

viabilidade financeira se confirma quando a empresa deixa de enxergar a tecnologia como um gasto isolado e passa a tratá-la como um alicerce para a competitividade no mercado industrial moderno.

## **5. PROPOSTA DE INFRAESTRUTURA PARA AQUISIÇÃO E PROCESSAMENTO DE DADOS**

A proposta de infraestrutura para aquisição de dados visa transformar a manutenção prescritiva em solução prática em ambientes industriais. O capítulo detalha um ecossistema de captura de sinais industriais, integrando hardware e software para garantir a integridade das informações. Segundo análise de (OROŠNJAK, SARETZKY e KEDZIORA, 2025), a eficácia do modelo se dá pela união de dados históricos e em tempo real, minimizando a intervenção humana. A arquitetura envolve hardware, software em Python e bibliotecas para previsão de falhas, cruciais para identificar anomalias. A infraestrutura monitoriza equipamentos críticos, permitindo diagnósticos rápidos, rápidos e o tempo de parada da máquina. Apesar da flexibilidade do Python, desafios como falta de especialistas e segurança cibernética persistem. O uso de linguagens de código aberto representa uma mudança na manutenção moderna, tornando-a mais autônoma e econômica. A criação de uma rede tecnológica para tratar dados industriais é vista como uma mudança significativa na confiabilidade de ativos críticos, com foco em autonomia e eficiência na engenharia de manutenção.

### **5.1. ARQUITETURA DE HARDWARE E CONECTIVIDADE**

Investir em uma arquitetura de hardware e conectividade bem estruturada é o que diferencia os projetos que ficam apenas no campo das ideias daqueles que realmente entregam ganhos de disponibilidade no chão de fábrica. Sem esse cuidado com a robustez do sistema, tentativas de digitalização acabam esbarrando em falhas de comunicação ou perda de integridade dos sinais, o que inviabiliza diagnósticos precisos. De acordo com o Relatório do Estado da Produção Inteligente (AUTOMATION, ROCKWELL, 2025), cerca de 56% dos fabricantes em nível global já se encontram em etapas avançadas de teste ou uso de soluções conectadas para

otimizar a performance de seus ativos. Diante dessa realidade de mercado, analisar estruturas capazes de entregar de forma consistente uma grande quantidade de dados provenientes dos equipamentos torna-se o passo decisivo para garantir que grandes indústrias implementem em suas plantas essas arquiteturas. Neste estudo apresentamos uma proposta que leva como exemplo uma arquitetura já em funcionamento e uso em uma planta real.

Pode-se dizer que a estabilidade física da rede é a única garantia de que os registros coletados reflitam a saúde real do ativo no chão de fábrica. Neste contexto, (OROŠNJAK, SARETZKY e KEDZIORA, 2025) afirmam que essa base tecnológica integrada é o que viabiliza a transição para tomadas de decisão inteligentes e automatizadas em ambiente industrial.

A escolha criteriosa do hardware a ser utilizado é o que assegura que não existam "pontos cegos" na captura de variáveis. No cotidiano de uma indústria a estabilidade desta rede é o que garante que os sinais coletados reflitam a saúde real do ativo, sem latências que possam comprometer a precisão dos diagnósticos. Conforme explicado acima, a infraestrutura integrada é o que viabiliza a transição para tomadas de decisão inteligentes e automatizadas. Assim, a robustez física não é apenas uma preferência técnica, mas a base necessária para que o sistema consiga prever falhas.

A fase inicial da implementação é a sensorização, que se refere ao processo de incorporar sensores específicos em equipamentos e sistemas capazes de detectar e medir determinadas grandezas físicas, para coletar dados e informações sobre o ambiente ou o próprio sistema em tempo real. Esses sensores servem como "olhos e ouvidos" dos ativos, coletando informações precisas sobre seu estado e desempenho. (MACHADO, JUNIOR, *et al.*, 2023, p. 4451)

O autor deixa claro na citação anterior que a sensorização industrial é o pilar para capturar registros em tempo real. Frisar esse ponto é vital, pois a precisão desses componentes físicos elimina falhas humanas e garante diagnósticos técnicos muito confiáveis. Consolidar essa base física integrada é o que efetivamente permite que a inteligência artificial tome decisões operacionais rápidas hoje.

Em resumo, a arquitetura de hardware é o alicerce que retira o sistema prescritivo do campo das ideias e o aplica na prática da manutenção hoje. Essa base

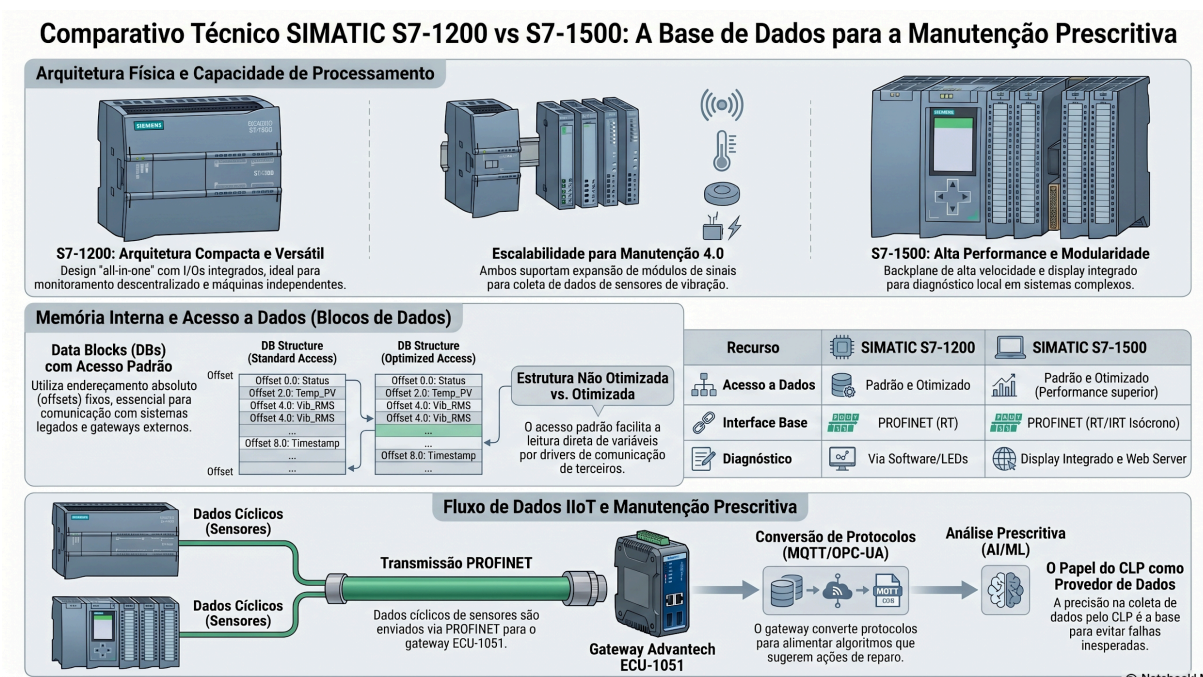
física garante que os sinais coletados sejam precisos, permitindo que as análises antecipem quebras com total agilidade no dia a dia. Conforme explicado acima, uma infraestrutura técnica robusta elimina atrasos de sinal e traz a segurança necessária para as decisões automáticas no chão de fábrica. Assim, o hardware bem estruturado é o que efetivamente sustenta a inteligência industrial proposta neste estudo.

Visando os resultados práticos, a escolha de componentes industriais padrão facilita muito a aplicação desse projeto em diferentes máquinas da planta. A integração entre os sensores e os gateways de comunicação assegura que as informações processadas pelos algoritmos sejam fiéis ao estado real dos equipamentos. Desse modo, após entender a importância dessa base estável, o próximo passo é detalhar o funcionamento dos controladores Siemens S7-1200 e S7-1500 no tópico seguinte. Estes equipamentos funcionam como o núcleo de processamento vital para o sucesso de toda a arquitetura aqui apresentada.

#### **5.1.1. Controladores Siemens s7-1200 e s7-1500**

Os controladores lógicos programáveis da linha Siemens S7-1200 e S7-1500 atuam como o centro nervoso da automação industrial, sendo responsáveis por processar as rotinas lógicas que coordenam o comportamento das máquinas no chão de fábrica. Esses dispositivos recebem sinais de entrada dos sensores, aplicam regras de programação específicas e acionam as saídas correspondentes para que os atuadores executem os movimentos desejados com total precisão. De acordo com (MACHADO, JUNIOR, *et al.*, 2023), essa estrutura de hardware é indispensável para converter grandezas físicas em registros digitais que permitam o monitoramento contínuo dos ativos em tempo real. Na proposta deste projeto, tais controladores organizam essas informações em blocos de dados, as DBs, permitindo que o software do gateway Advantech realize a leitura direta dos registros para o processamento da manutenção prescritiva, conforme a (Figura 4).

Figura 4 - Simatic S7-1200/S7-1500



Fonte: Elaborado pelo autor com auxílio de Notebooklm (2026).

O funcionamento desses controladores baseia-se na execução de um ciclo de varredura constante, onde a CPU processa a lógica de intertravamento e coordena a comunicação sincronizada com os dispositivos de campo. Nas séries S7-1200 e S7-1500, a eficiência na troca de mensagens é garantida pelo protocolo PROFINET, que elimina atrasos críticos no fluxo interno de sinais. Para viabilizar a integração com o gateway Advantech, a configuração das DBs deve obrigatoriamente utilizar o acesso padrão, abdicando da otimização de bloco para permitir o mapeamento de endereços fixos exigido pelo software de comunicação. Conforme apontado por Machado et al. (2025), essa estruturação rigorosa da memória é o que permite que o sistema converta grandezas físicas em registros digitais acessíveis para o monitoramento em tempo real. Portanto, essa base técnica garante que o fluxo de dados entre o hardware Siemens e a camada prescritiva ocorra sem falhas de leitura ou perda de integridade.

A utilização dos controladores Siemens S7-1200 e S7-1500 já presentes nos ativos representa uma vantagem estratégica para a viabilidade do monitoramento prescritivo dos ativos. Embora esses equipamentos não tenham sido adquiridos especificamente para esta nova arquitetura, sua flexibilidade de comunicação

permite uma integração robusta com o gateway Advantech sem a necessidade de substituições. De acordo com (OROŠNJAK, SARETZKY e KEDZIORA, 2025), o sucesso da manutenção inteligente em sistemas ciber físicos depende da capacidade do hardware em disponibilizar dados operacionais para algoritmos de processamento avançado. No entanto, o fato de serem componentes preexistentes não diminui a eficácia técnica do projeto, pois a versatilidade da rede PROFINET facilita a aquisição de sinais de forma imediata e segura. Assim, o aproveitamento desses recursos consolidados garante a integridade dos registros para as análises futuras em Python, conforme explicado acima.

A implementação dos controladores SIMATIC S7-1200 e S7-1500 no chão de fábrica é o que sustenta a transição do monitoramento tradicional para a inteligência de dados sincronizada. Nesse contexto, podemos justificar que a robustez desse hardware é o elemento determinante para que a arquitetura integrada funcione sem interrupções.

Basicamente, a manutenção prescritiva utiliza ferramentas usadas nas técnicas preditivas, como coleta de dados, banco e análise de dados, monitoramento contínuo, e integra algoritmos e modelos matemáticos de previsões de falhas com o aprendizado das máquinas para então sugerir possibilidades de atuações e intervenções para evitar falhas e paradas dos equipamentos (MACHADO, JUNIOR, *et al.*, 2023, p. 4453).

Em síntese, os controladores Siemens S7-1200 e S7-1500 consolidam-se como os provedores fundamentais de dados brutos dentro desta arquitetura, sendo responsáveis por converter as variáveis físicas dos equipamentos em informações digitais estruturadas para o monitoramento. Mais do que meros gerenciadores de lógicas, esses dispositivos garantem a integridade dos registros e os disponibilizam em blocos de dados (DBs) configurados especificamente para alimentar o fluxo de análise prescritiva através da integração com o gateway. Espera-se, portanto, que a robustez tecnológica e a alta capacidade de processamento dessas linhas de hardware viabilizem a antecipação científica de falhas, estabelecendo-as como o alimentador ininterrupto do banco de dados vital para a eficácia deste sistema.

### 5.1.2. Gateway Advantech ECU-1051

O Gateway de Comunicação Advantech ECU-1051 é o elo vital da arquitetura de aquisição de dados, interligando o que ocorre nas máquinas ao local onde os dados são processados. Este equipamento é o canal de envio das informações, possibilitando que os registros brutos dos CLPs Siemens cheguem de maneira segura aos algoritmos de decisão do sistema. Como apontam as especificações da (ADVANTECH), o equipamento é capaz de suportar temperaturas que variam de -40 a 70°C, o que garante a resistência térmica necessária para um monitoramento contínuo dos ativos. Assim, a análise deste hardware irá explorar sua flexibilidade em termos de comunicação e como isso se relaciona com a criação de uma arquitetura de manutenção que se concentra em recomendações automáticas de reparo.

A necessidade de uma base física que suporte o tráfego intenso de variáveis é o que garante a viabilidade das decisões automatizadas dentro da rede industrial hoje. De acordo com (OROŠNJAK, SARETZKY e KEDZIORA, 2025), a implementação de sistemas prescritivos depende da existência de uma infraestrutura técnica que permita a integração de sensores e a comunicação síncrona entre o chão de fábrica e a gerência. Essa conectividade é alcançada através do uso de ferramentas de processamento local e protocolos de troca de dados, como o OPC UA e o MQTT, que organizam as informações brutas para os algoritmos de inteligência artificial. Portanto, a escolha de um dispositivo capaz de gerenciar esses padrões de comunicação é o que assegura que o fluxo informativo seja confiável e imune a falhas de interpretação durante o monitoramento dos ativos físicos.

A aplicação do Gateway Advantech ECU-1051 soluciona o gargalo técnico de integrar a base operacional à inteligência digital do projeto industrial hoje. Este hardware funciona como o ponto de união que estabiliza os sinais dos controladores Siemens para a análise em Python, aproveitando a força do processador ARM para manter o monitoramento estável (ADVANTECH). Para (OROŠNJAK, SARETZKY e KEDZIORA, 2025), essa base física é indispensável para transformar dados brutos em decisões autônomas dentro da planta industrial. No entanto, mesmo que a mistura de tecnologias de diferentes épocas gere desafios de conexão, o processamento local do gateway limpa as informações para assegurar recomendações de manutenção exatas. Dessa forma, o uso desse componente

determina a qualidade do fluxo informativo para a antecipação de falhas, conforme explicado acima.

É importante destacar que a união deste gateway ao sistema vai além da simples troca de sinais, criando um ambiente de dados seguro contra ruídos externos e erros de leitura de protocolos. Percebe-se, assim, que a estabilidade de processamento e a proteção física do módulo são os fundamentos que dão validade científica às sugestões de reparo criadas posteriormente pelos scripts em Python. Por esses motivos, o emprego do ECU-1051 fortalece uma rede de monitoramento muito segura, o que garante o êxito do estudo em diminuir interrupções não planejadas e em proteger a sequência da produção na fábrica. De acordo com (OROŠNJAK, SARETZKY e KEDZIORA, 2025), essa infraestrutura técnica é o requisito que permite a transição de um monitoramento passivo para uma gestão de ativos verdadeiramente inteligente e baseada em dados reais.

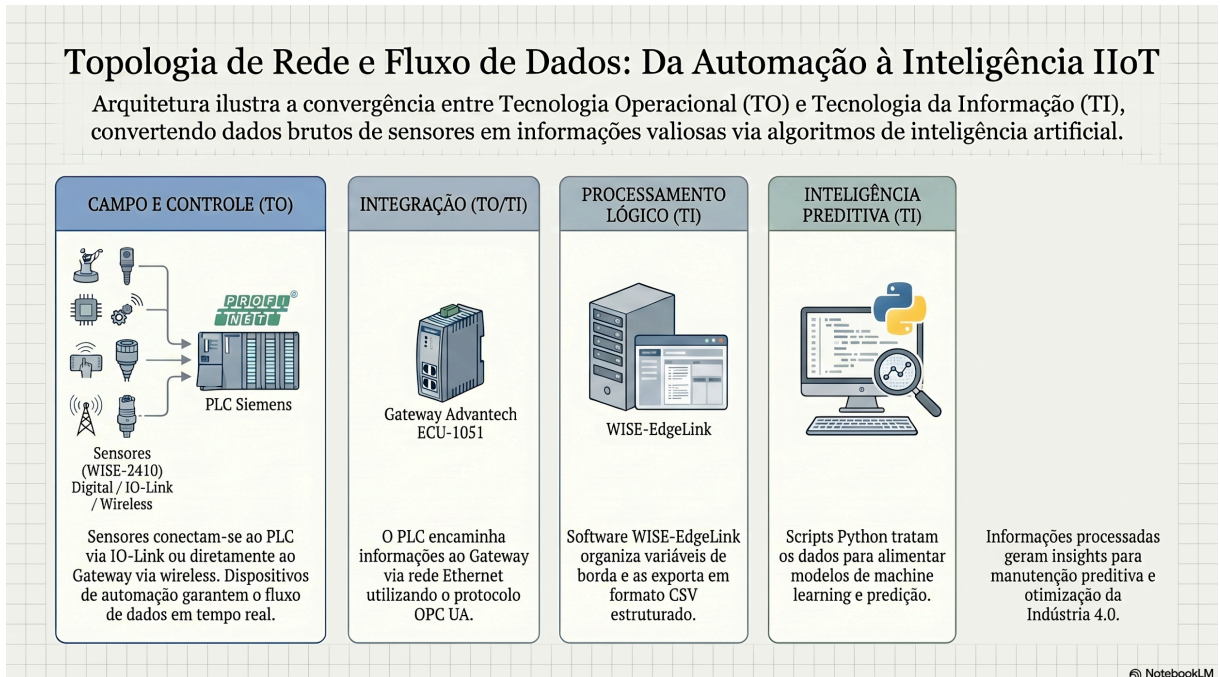
### **5.1.3. Topologia de Rede e Integração dos Dispositivos de Campo**

O planejamento da arquitetura de comunicações funciona como a espinha dorsal que determina o trajeto exato da informação, desde a máquina até o núcleo de processamento. Esse arranjo permite que os dados circulem, impedindo congestionamentos que poderiam atrasar a identificação de uma quebra nos equipamentos. Ao integrar a base operacional com o ambiente Python, a topologia garante que as variáveis de calor e vibração, por exemplo, cheguem sem ruídos para alimentar os modelos de decisão. Segundo explicam (OROŠNJAK, SARETZKY e KEDZIORA, 2025) , a presença de uma infraestrutura técnica sólida é o requisito que permite a união síncrona entre o chão de fábrica e a inteligência de dados em tempo real.

O arranjo físico dos componentes prioriza uma coleta híbrida para garantir que nenhuma variável crítica dos ativos monitorados seja perdida durante a operação industrial. Nesse cenário, os diversos sensores de campo utilizam as entradas digitais e o padrão IO-Link para se comunicarem com os controladores Siemens, enquanto dispositivos inteligentes como o Advantech WISE-2410 enviam dados por conexão sem fio diretamente ao gateway central. Essa diversidade de caminhos elimina a necessidade de cabeamento excessivo em áreas de difícil acesso, o que otimiza o tempo de montagem e a confiabilidade na transmissão das

informações de vibração e temperatura. Portanto, a integração desses diferentes padrões de conectividade consolida a entrada estável de registros no sistema para o processamento avançado, conforme explicado acima.

**Figura 5 - Topologia e fluxo de dados**



O desenho dessa malha comunicativa não serve apenas para interligar peças, mas para garantir que o fluxo de inteligência não sofra com interrupções que invalidariam os cálculos matemáticos do projeto. É essa coordenação entre os protocolos industriais que transforma simples sinais elétricos em pacotes de decisão prontos para serem lidos pela lógica Python, conforme explicado acima. Ao analisarmos a literatura de (OROŠNJAK, SARETZKY e KEDZIORA, 2025), percebemos que a verdadeira inovação não reside no hardware isolado, mas na capacidade de ligar o chão de fábrica diretamente à gestão de ativos de forma automática. Assim, a topologia deixa de ser um detalhe de montagem e passa a ser o filtro que atesta a qualidade da informação necessária para sustentar a manutenção prescritiva em tempo real.

A manutenção deixa de ser um centro de custos para se tornar uma função estratégica vital, onde a disponibilidade e a confiabilidade dos ativos são garantidas pela integração síncrona entre o chão de fábrica e os sistemas de inteligência. A

construção de uma arquitetura de rede que permita a coleta e o processamento de variáveis em tempo real é o requisito fundamental para que as organizações alcancem a excelência operacional e a competitividade exigida pelos novos mercados globais, transformando registros brutos em decisões precisas que elevam a vida útil dos equipamentos e otimizam os recursos humanos e materiais envolvidos nos processos (KARDEC e NASCIF, 2022, p. 25).

Segundo (KARDEC e NASCIF, 2022, p. 25) a manutenção moderna exige a "integração síncrona entre o chão de fábrica e os sistemas de inteligência". Fica evidente, diante desse quadro, que a topologia híbrida apresentada, unindo sensores IO-Link e dispositivos sem fio Advantech, constitui o alicerce indispensável para a captura em tempo real de variáveis críticas. Esta infraestrutura serve para converter registros brutos em arquivos CSV por meio do gateway ECU-1051, eliminando barreiras de comunicação e garantindo que o ambiente Python receba dados íntegros para a antecipação de falhas nos ativos.

## 5.2. ARQUITETURA DE SOFTWARE E PROCESSAMENTO DOS DADOS COM PYTHON

A arquitetura de software e processamento dos dados com Python desempenha o papel crucial, sendo responsável por converter os sinais brutos captados no chão de fábrica em diagnósticos precisos. Diferente de uma simples ferramenta de automação, este ambiente trata todas as informações provenientes dos equipamentos para que os algoritmos de detecção operem sobre uma base de variáveis. O foco deste capítulo será sobre os mecanismos de lógica que permitem a tradução desses registros em ações concretas que impeçam a ocorrência de quebras inesperadas nos ativos monitorados. De acordo com (OROŠNJAK, SARETZKY e KEDZIORA, 2025) , a implementação bem-sucedida da manutenção prescritiva exige que o processamento analítico seja capaz de oferecer recomendações otimizadas, reduzindo a necessidade de intervenção humana constante nos processos decisórios.

A estruturação desse ambiente lógico ganha força com a capacidade que o Python possui de traduzir variáveis complexas vindas diretamente do chão de fábrica. Diferente de sistemas fechados, essa linguagem abre caminho para que as rotinas de limpeza retirem as inconsistências dos sinais antes mesmo da análise

matemática começar. É esse tratamento cuidadoso que garante que o projeto não se limite a guardar dados, mas consiga enxergar os primeiros sinais de desgaste nas máquinas monitoradas, conforme explicado acima. De acordo com Shrivastava et al. (2023), a integração entre a inteligência artificial e os sensores integrados é o que permite à indústria prever estados operacionais com precisão, evitando paradas caras e aumentando a produtividade real.

O uso de bibliotecas específicas Python assegura o rigor matemático necessário para identificar falhas de forma autônoma. Esta estrutura permite que o desenvolvedor organize rotinas de limpeza que preservam a integridade dos sinais captados, conforme explicado acima. Pesquisas de (SHRIVASTAVA, SINGHAL e J., 2023) sustentam que essa integração entre a análise de dados e monitoramento físico é o que eleva a eficiência dos algoritmos. Complementarmente, o uso da biblioteca PyOD, fundamentada por (ZHAO, NASRULLAH e LI, 2019), introduz a robustez essencial para que os algoritmos reconheçam anomalias em grandes volumes de registros. Embora sistemas de código aberto exijam maior especialização técnica do que softwares prontos, sua flexibilidade permite ajustes finos que soluções proprietárias muitas vezes bloqueiam.

A implementação foi realizada com recurso à linguagem de programação Python. Esta linguagem de programação contém numerosas bibliotecas disponíveis [...] que demonstra como estas podem ser aplicadas em projetos de Machine learning. Assim, o Python apresenta-se com uma ótima ferramenta para a aplicação de todos os conceitos apresentados ao longo da dissertação. Não se deve esperar que o Machine Learning resolva todos os problemas da área da manutenção, no entanto, o seu potencial não deve ser desprezado (BARBOSA, 2023, p. 61).

Fica evidente, diante desse quadro, que a arquitetura de software baseada em Python funciona como o cérebro do sistema prescritivo, articulando o processamento lógico para a conversão das medições dos sensores em diagnósticos. permitindo que os algoritmos identifiquem anomalias e emitam recomendações de intervenções exatas antes da ocorrência de quebras nos ativos monitorados. Nesse ritmo, a consolidação desse ambiente digital robusto é o que soluciona o problema central desta pesquisa, sendo de fundamental importância para que a gestão de ativos alcance a eficiência e a autonomia nas decisões.

### **5.2.1. Ecossistema no Contexto Industrial**

Essa hegemonia do Python no setor corporativo decorre de sua habilidade única em integrar prototipagem ágil com sistemas de produção robustos, algo vital para a agilidade exigida pelo mercado atual. Diferente de softwares proprietários que muitas vezes limitam a inovação por meio de licenças onerosas, o ecossistema de código aberto oferece transparência e escalabilidade, permitindo que as organizações gerenciem infraestruturas críticas de forma autônoma. Conforme explicam Müller e Guido (2018), o Python e suas bibliotecas especializadas são amplamente empregados em sistemas de produção de diversas organizações globais, abrangendo desde grandes bancos internacionais até gigantes das redes sociais. Essa confiança depositada por corporações de alta complexidade válida a escolha tecnológica deste trabalho, garantindo que o processamento da telemetria de vibração seja realizado sobre uma base tecnológica de classe mundial, capaz de suportar o rigor exigido pela manutenção prescritiva.

O uso frequente dessa tecnologia em grandes corporações se explica pela combinação do desenvolvimento ágil com a estabilidade que sistemas de alta criticidade demandam. Fugindo do uso de ferramentas proprietárias que restringem a autonomia por meio de licenças onerosas, o código aberto promove inovação e constante evolução técnica. Segundo a Rockwell Automation (2025), as tecnologias emergentes e algoritmos de Inteligência Artificial tornaram-se fundamentais na estrutura produtiva de fabricantes globais, redefinindo o ecossistema de manufatura através da otimização de processos. Essa confiança estabelecida pelo mercado confere ao presente artigo a segurança necessária para processar as medições em uma base confiável, alinhando a arquitetura proposta aos padrões de manutenção prescritiva.

Empresas do setor industrial encontraram no Python a solução para unificar o tratamento de dados e a execução de algoritmos. (SHRIVASTAVA, SINGHAL e J., 2023) exemplificam esse movimento ao demonstrar como a integração de dados de sensores com modelos de aprendizado de máquina fundamenta estratégias robustas de monitoramento para converter sinais de telemetria em informações cruciais para a manutenção. Percebe-se que tal preferência confere versatilidade ao sistema, permitindo que a infraestrutura se adapte rapidamente às variações da telemetria industrial sem os custos elevados de softwares fechados. Esta transição para

ferramentas de código aberto devolve o controle técnico às equipes internas, que passam a contar com uma base estável e escalável para sustentar a autonomia exigida pela manutenção prescritiva.

Python é uma linguagem de programação poderosa e fácil de aprender. Ela possui estruturas de dados eficientes de alto nível e uma abordagem simples mas eficaz para a programação orientada a objetos. A sintaxe elegante de Python e a sua tipagem dinâmica, juntamente com a sua natureza interpretada, tornam-na uma linguagem ideal para *scripting* e desenvolvimento rápido de aplicações em muitas áreas na maioria das plataformas (VAN ROSSUM, 2018, p. 1).

Fica evidente, diante desse quadro, que a consolidação do ecossistema Python no ambiente fabril representa uma excelente opção para a viabilidade da manutenção prescritiva. Essa tecnologia serve para integrar o tratamento de grandes volumes de dados à execução de algoritmos de inteligência artificial, reduzindo as barreiras de custo e rigidez impostas por sistemas fechados. Nesse sentido, a aplicação dessa arquitetura aberta é o que responde ao problema central desta pesquisa, sendo fundamental para garantir a autonomia e flexibilidade nos métodos de indicações de intervenções de manutenção.

### **5.2.2. Bibliotecas para Aquisição, Tratamento e Pré-processamento de Dados**

A criação de um software para a manutenção prescritiva demanda o auxílio de recursos para aquisição, tratamento e pré-processamento de dados que consigam organizar as variáveis dos equipamentos com eficácia. O uso de ferramentas como Pandas, NumPy e Scikit-Learn viabiliza a estruturação das informações e a aplicação de modelos de aprendizado de máquina para antecipar interrupções nos ativos. Müller e Guido (2018) destacam que a união dessas soluções computacionais provê os pilares fundamentais para o desenvolvimento de sistemas analíticos que operem com robustez e escalabilidade. Esse alicerce do sistema assegura que as medições sejam transformadas em diagnósticos confiáveis, permitindo que as ações de intervenção ocorram de forma estratégica.

A estruturação das variáveis dos equipamentos no alicerce do sistema segue uma sequência lógica onde o Pandas e o NumPy atuam como as engrenagens centrais

das etapas iniciais de aquisição e limpeza. Através do recurso de DataFrames, o Pandas unifica registros de sensores de diferentes naturezas em tabelas organizadas, facilitando a manipulação de dados heterogêneos de forma ágil e intuitiva.

Para a maioria das aplicações de análise de dados, as principais áreas de funcionalidade focam em: operações rápidas baseadas em array para tratamento e limpeza de dados [...]; algoritmos comuns de array como ordenação; estatísticas descritivas eficientes e agregação/resumo de dados; alinhamento de dados e manipulações de dados relacionais para mesclar e juntar conjuntos de dados heterogêneos (MCKINNEY, 2022, p. 84).

A análise dessas especificações evidencia que a eficiência do software prescritivo depende da agilidade no processamento de matrizes e na estruturação lógica das informações. Observa-se que o objeto ndarray do NumPy, ao executar cálculos matemáticos por meio de operações vetorizadas, supera as limitações de velocidade inerentes ao processamento sequencial de grandes volumes de dados industriais. Conseqüentemente, a versatilidade do Pandas na manipulação de DataFrames heterogêneos permite uma integração precisa entre as medições de campo e as etapas de normalização do Scikit-Learn, conforme explicado acima. Essa atuação conjunta entre as soluções computacionais assegura que as variáveis dos equipamentos sejam tratadas com o rigor necessário para fundamentar a detecção de anomalias e as futuras ações de manutenção.

A integração entre NumPy, Pandas e Scikit-Learn é responsável pela transformação das variáveis dos equipamentos em informações prontas para a análise prescritiva. O NumPy e o Pandas fornecem a base matricial e tabular necessária para a manipulação ágil de grandes volumes de dados, enquanto o Scikit-Learn aplica as etapas de normalização indispensáveis para garantir a eficiência dos algoritmos:

NumPy, abreviação de Numerical Python, tem sido há muito tempo um pilar da computação numérica em Python. Ele fornece as estruturas de dados, algoritmos e a integração de bibliotecas necessárias para a maioria das aplicações científicas que envolvem dados numéricos em Python. (MCKINNEY, 2022, p. 4).

As funcionalidades técnicas do Pandas, NumPy e Scikit-Learn, permite que o software ultrapasse a simples organização de arquivos para atingir o nível necessário à manutenção prescritiva. Ao solucionar problemas crônicos como a heterogeneidade dos dados de sensores e a interferência de ruídos, o sistema estabelece uma base de informações confiável para alimentar as etapas de detecção de anomalias que serão discutidas adiante. Conclui-se que o rigor aplicado no pré-processamento das variáveis dos equipamentos é o fator determinante que garante a integridade das informações.

### **5.2.3. Bibliotecas para Modelagem e Previsão de Falhas**

Para tirar o sistema prescritivo do papel e viabilizar diagnósticos que façam sentido na rotina industrial, o desenvolvimento do algoritmo foca em ferramentas que dominam o processamento das variáveis dos equipamentos. A peça-chave dessa análise é a biblioteca PyOD, escolhida para ser o motor de modelagem por causa da sua eficiência em rodar algoritmos como LSCP, LODA e IForest, que conseguem flagrar comportamentos atípicos antes de uma quebra real ocorrer. No entanto, o sistema não seria completo se esses dados ficassem restritos ao código; por isso, a Matplotlib assume o papel de dar visibilidade aos resultados. Ela converte o peso matemático da inteligência artificial em gráficos e indicadores que qualquer gestor consegue interpretar para planejar as intervenções. Essa combinação é o que garante que o software não apenas aponte desvios, mas entregue uma interface de visualização robusta para o suporte à decisão na manutenção.

A escolha pela PyOD fundamenta-se na necessidade de uma estrutura capaz de lidar com a complexidade e o volume das informações geradas pelos equipamentos. Essa biblioteca soluciona uma deficiência ao reunir métodos tradicionais e arquiteturas de aprendizado profundo em uma interface única, o que torna a configuração de modelos como o LSCP e o IForest muito mais ágil. Esse padrão permite que o software analise as variáveis dos equipamentos com velocidade, transformando o fluxo de dados em recomendações de intervenção fundamentais. Conforme explicam (ZHAO, NASRULLAH e LI, 2019), a ferramenta disponibiliza algoritmos robustos e escaláveis que foram pensados exclusivamente para a detecção de padrões raros em bases de dados sem rotulação prévia.

A precisão do software aumenta com a união entre os algoritmos LSCP, LODA e IForest, que analisam as variáveis dos equipamentos por diferentes ângulos

matemáticos. O diferencial dessa estratégia é o LSCP atuar como um sintetizador de modelos, funcionando como uma arquitetura de integração que escolhe os melhores detectores para validar o diagnóstico final. Enquanto o IForest foca em isolar anomalias de forma rápida, o LODA mantém a eficiência no processamento de grandes volumes de dados sem perda de velocidade. Essa combinação permite captar sinais de desgaste que um método isolado deixaria passar, essencial para fundamentar as recomendações futuras. Segundo (OROŠNJAK, SARETZKY e KEDZIORA, 2025) o uso de múltiplos algoritmos integrados é o que confere a resiliência necessária para que a manutenção atinja o nível prescritivo com tomada de decisão autônoma e assertiva.

A biblioteca PyOD processa as variáveis dos equipamentos em busca de padrões anômalos, atuando como o motor que aprimora a base de dados antes da visualização gráfica criada pela Matplotlib. Essa etapa não é apenas uma opção de programação, mas uma exigência para que o sistema possa fornecer diagnósticos com precisão, sem erros de leitura, conforme indicado na literatura:

[...] barreiras relacionadas a dados frequentemente inibem a implementação de PsM. Isso sugere que sensores geram dados incompletos, ruidosos ou não rotulados [...]. Aproveitar a detecção de anomalias habilitadas para ponta e estruturas de interoperabilidade semântica oferece um caminho para a adoção de PsM, particularmente em empresas de manufatura menores com infraestrutura digital limitada (OROŠNJAK, SARETZKY e KEDZIORA, 2025, p. 24).

Dessa forma, a escolha desse conjunto de bibliotecas não representa apenas uma solução técnica, mas a criação de uma ponte confiável entre o ambiente industrial e as decisões de manutenção. Ao automatizar o reconhecimento de padrões e a geração de indicadores visuais, o sistema minimiza o risco de diagnósticos imprecisos, garantindo que o software opere com a robustez esperada em ambientes de alta criticidade. Esse ecossistema, agora devidamente estruturado, deixa de ser um aglomerado de códigos para se tornar o motor que sustenta a tomada de decisão autônoma.

## 6. ESTUDO DE CASO: DESENVOLVIMENTO E APLICAÇÃO DOS ALGORITMOS

Promover a integração entre o sinal elétrico captado no sensor e os algoritmos de prescrição representa o pilar central deste estudo de caso, no qual a robustez dos controladores Siemens e gateways Advantech se funde à versatilidade algorítmica da linguagem Python. Diante da dificuldade prática em coletar uma base de dados históricos em ativos durante curtos períodos de observação, a pesquisa utiliza a base de dados Microsoft Azure Predictive Maintenance para fundamentar o aprendizado de máquina. Esse repositório permite simular as flutuações anômalas identificadas nas variáveis preditivas fundamentais como vibração e temperatura, garantindo que o software seja calibrado em ambiente controlado sem colocar em risco a integridade física dos equipamentos em operação. Consequentemente, estrutura-se uma arquitetura modular que permanece plenamente compatível com os registros de campo reais da infraestrutura industrial estabelecida, facilitando uma transição futura ágil entre a simulação e a prática. Conforme apontam (OROŠNJAK, SARETZKY e KEDZIORA, 2025), o aproveitamento de ferramentas analíticas voltadas à detecção de anomalias e o uso de estruturas de interoperabilidade semântica estabelecem o caminho viável para a adoção definitiva da manutenção prescritiva, superando as barreiras de dados e as limitações de infraestrutura digital do parque industrial.

### 6.1. EXEMPLO DE EQUIPAMENTOS E VARIÁVEIS APLICÁVEIS AO SISTEMA

A implantação da arquitetura proposta ganha vida através do monitoramento de perto ativos como prensas mecânicas, tornos e células de montagem. Esse ambiente gerencia a integridade de eixos elétricos e robôs industriais, que hoje representam elementos essenciais da automação. Ao capturar sinais de vibração e rotação, por exemplo, o sistema busca identificar o desgaste mecânico ainda em estágio inicial, enquanto o acompanhamento de flutuações de tensão nos atuadores robóticos previne paradas antes que elas interrompam o fluxo produtivo. Conforme destacam (OROŠNJAK, SARETZKY e KEDZIORA, 2025), essa visão integrada sobre os equipamentos é o que realmente eleva a confiabilidade global da planta, consolidando os pilares da Indústria 4.0.

A modularidade desta arquitetura permite que o monitoramento alcance diversas classes de ativos, abrangendo desde máquinas de grande porte, como prensas mecânicas e tornos CNC, até sistemas auxiliares críticos, como compressores de ar e bombas hidráulicas. Para esses equipamentos, a captura síncrona de dados de pressão e vibração permite que qualquer desvio do padrão nominal denuncie vazamentos ou fadiga mecânica antes de uma parada sistêmica. No caso específico de bombas e compressores, o acompanhamento da rotação e da temperatura funciona como um indicador essencial de integridade, permitindo que o ambiente Python processe se o esforço está superando o limite de projeto. Conforme explicam (MACHADO, JUNIOR, *et al.*, 2023), a incorporação de sensores dedicados a mapear essas grandezas físicas atua como os olhos e ouvidos dos ativos, alimentando algoritmos capazes de sugerir as intervenções exatas para garantir que a planta não pare por falhas imprevistas.

A eficácia desta arquitetura ganha escala conforme o monitoramento é estendido a um número maior de ativos, permitindo que o planejamento da manutenção evolua de uma resposta isolada para uma gestão sistêmica e integrada. Quanto mais equipamentos estiverem conectados ao ecossistema, mais robusta se torna a base de dados para uma tomada de decisão pautada na realidade do chão de fábrica. Esse aumento na visibilidade dos ativos permite que o mecanismo de decisão em Python aplique critérios rigorosos de criticidade, diferenciando falhas que apenas geram alertas daquelas que podem efetivamente interromper o fluxo produtivo. Conforme apontam (OROŠNJAK, SARETZKY e KEDZIORA, 2025), essa visão ampliada garante que as intervenções sejam priorizadas conforme a importância de cada máquina, direcionando os recursos exatamente onde o risco de perda de rentabilidade é maior, o que assegura a continuidade operacional e a eficiência financeira da planta.

Nessa perspectiva, a gestão de ativos deixa de ser encarada apenas como um centro de custos e passa a integrar os resultados estratégicos do negócio. A manutenção deixa o antigo estigma de "mal necessário" para assumir um papel de destaque na organização, unindo a gestão à técnica com o objetivo de assegurar a confiabilidade operacional e evitar paradas indesejadas na planta. O foco principal, portanto, desloca-se da simples velocidade do reparo para o uso inteligente e

direcionado de recursos e dados, mitigando perdas financeiras e operacionais (KARDEC e NASCIF, 2022).

A arquitetura proposta consolida-se como uma ferramenta estratégica que preserva a continuidade operacional e sustenta a rentabilidade do negócio diante dos desafios do chão de fábrica. Esse monitoramento contínuo converte sinais brutos em informações úteis, garantindo que a tomada de decisão técnica seja rápida e precisa. Com a infraestrutura física e os objetivos estratégicos devidamente fundamentados, o estudo atinge a maturidade necessária para discutir a inteligência que processará tais variáveis. Como máquinas de alta performance raramente apresentam quebras em curtos períodos de observação, torna-se indispensável adotar métodos que acelerem o aprendizado do sistema sem colocar o patrimônio em risco. O próximo item detalha, portanto, os critérios e motivações para a seleção da base de dados sintéticos da Microsoft Azure, elemento que servirá como o campo de prova para a calibração final dos algoritmos de prescrição.

## 6.2. MOTIVAÇÃO E CRITÉRIOS PARA A SELEÇÃO DE DADOS SINTÉTICOS

Para consolidar a escolha da base de dados, é necessário confrontá-la com repositórios consagrados no meio acadêmico, como o conjunto NASA C-MAPSS. Embora esse *dataset* seja o padrão-ouro para prever a vida útil de motores turbofan, sua aplicação em um sistema de manutenção para prensas e robôs industriais se torna limitada devido à sua especificidade aeroespacial. Enquanto os dados da NASA focam em ciclos de voo e degradação térmica de turbinas, o presente estudo exige uma base que reflita a intermitência e a variedade de sinais elétricos e mecânicos de uma planta de manufatura diversificada. Conforme explicam (OROŠNJAK, SARETZKY e KEDZIORA, 2025), a eficácia de um sistema prescritivo depende da similaridade entre o padrão de falha treinado e o comportamento real dos ativos que o mecanismo de decisão irá monitorar no dia a dia.

Outra opção frequentemente citada na literatura é o *dataset* AI4I 2020, disponível no Repositório de Machine Learning da UCI. Trata-se de uma base excelente para simular o desgaste em uma fresadora industrial, porém, ela apresenta uma estrutura linear e contida em um único ativo. Em contraste, a arquitetura proposta para este artigo demanda uma análise sistêmica que considere

não apenas o desgaste da ferramenta, mas flutuações de tensão e pressão que afetam diversos equipamentos simultaneamente. Ao optar pela base *Microsoft Azure Predictive Maintenance*, o sistema Python ganha a capacidade de correlacionar cinco tabelas distintas, incluindo registros de erros e trocas de componentes, o que aproxima a simulação da rotina complexa de um Planejamento e Controle de Manutenção (PCM) real. Conforme explicam (MACHADO, JUNIOR, *et al.*, 2023) , o grande trunfo dos sistemas inteligentes na Indústria 4.0 está justamente na habilidade de processar grandes históricos de dados coletados para prever comportamentos e antecipar soluções, transformando dados isolados em uma verdadeira inteligência operacional de prevenção.

A decisão de adotar o repositório Azure como campo de testes blinda a arquitetura contra a escassez de dados históricos, permitindo que o código em Python amadureça diante de cenários de quebra que raramente seriam captados em máquinas novas no curto prazo. Treinar o sistema sob esse estresse simulado é o que traz a segurança necessária para a futura integração física aos controladores Siemens e gateways Advantech instalados na fábrica. Com essa estratégia de dados devidamente validada, o estudo deixa o campo das justificativas para focar no desenvolvimento técnico da lógica prescritiva e no tratamento estatístico das variáveis. A partir daqui o foco reside em como o script transformará esses registros em recomendações capazes de influenciar diretamente a continuidade operacional da planta.

### 6.3. DESENVOLVIMENTO DA LÓGICA PRESCRITIVA EM PYTHON

A construção do mecanismo de análise começa com o processamento dos arquivos em formato .csv. Essa etapa de leitura, embora realizada em rotinas anteriores a esta apresentação, é fundamental, pois organiza as leituras dos sensores e falhas que serviram de insumo para o script. na (Figura 6) vemos a sequência de execução do algoritmo.

Figura 6 – Sequência de execução do algoritmo



Fonte: Elaborado pelo autor com auxílio de Notebooklm (2026).

Com o ambiente estruturado, o código utiliza a classe StandardScaler da biblioteca Scikit-Learn para aplicar a normalização Z-Score. Esse ajuste transforma valores brutos em desvios padrão comparáveis, garantindo que variáveis com escalas distintas, como rotação e tensão, tenham a mesma importância durante o processamento. Esse tratamento inicial é o que impede que o diagnóstico seja distorcido por disparidades numéricas entre os sensores.

```
# Bloco 1: Preparação e Normalização
from sklearn.preprocessing import StandardScaler

# Define os sensores e aplica a normalização Z-Score
colunas = ['volt', 'rotate', 'pressure', 'vibration']
scaler = StandardScaler()
df[colunas] = scaler.fit_transform(df[colunas])
```

Fonte: Autor (2026)

Com os dados uniformizados, o sistema executa o algoritmo Locally Selective Combination of Outlier Ensembles (LSCP), que funciona como o motor de decisão do projeto. A estratégia consiste em coordenar um agrupamento de algoritmos base, como o Isolation Forest (IForest) e o LODA, para detectar anomalias com maior

segurança do que modelos isolados seriam capazes. O modelo estuda o histórico para definir o padrão de operação saudável e atribui um índice individual de desvio (anomaly\_score) a cada nova leitura. Essa abordagem traz a resiliência necessária para identificar falhas em estágio inicial.

```
# Bloco 2: Inteligência Artificial (O Ensemble LSCP)
from pyod.models.lscp import LSCP
from pyod.models.iforest import IForest

# Configura o agrupamento de algoritmos e realiza o
aprendizado
detector_list = [IForest(contamination=0.05),
LODA(contamination=0.05)]
modelo = LSCP(detector_list, contamination=0.05,
random_state=42, n_bins=1)
modelo.fit(df[colunas])

# Extrai o nível de desvio e rotula a anomalia (0 ou 1)
df['anomaly_score'] = modelo.decision_scores_
df['anomalia'] = modelo.labels_
```

Fonte: Autor (2026)

O ponto principal do algoritmo aparece na função que gera as recomendações técnicas, traduzindo o resultado matemático em uma instrução clara. Quando uma anomalia é detectada, o software calcula o desvio absoluto de cada sensor para apontar a variável que mais se afastou do padrão de saúde da máquina. A partir dessa análise, o sistema dispara prescrições automáticas, como a inspeção de rolamentos para vibrações altas ou uma verificação do sistema hidráulico em casos de variações anormais de pressão. Esse mecanismo retira a carga subjetiva da interpretação e entrega à equipe de campo além da possível falha em uma ação ou verificação.

```
# Bloco 3: Lógica Prescritiva (A Tomada de Decisão)
def gerar_prescricao(row):
    if row['anomalia'] == 1:
        desvios = {'Tensão': abs(row['volt']),
'Rotação': abs(row['rotate']),
'Pressão': abs(row['pressure']),
'Vibração': abs(row['vibration'])}

        # Identifica o sensor com maior desvio e
prescreve a ação
        sensor_mestre = max(desvios, key=desvios.get)

        if sensor_mestre == 'Vibração':
```

```

        return "PRESCRITIVO: Alta vibração.
Inspeccionar rolamentos e fixação."
        if sensor_mestre == 'Pressão':
            return "PRESCRITIVO: Oscilação de pressão.
Verificar selos e válvulas."
        if sensor_mestre == 'Tensão':
            return "PRESCRITIVO: Instabilidade de
tensão. Checar painel elétrico."
        return "PRESCRITIVO: Desvio operacional.
Verificar carga do motor."
        return "Operação Normal"

df['prescricao'] = df.apply(gerar_prescricao, axis=1)

```

Fonte: Autor (2026)

Por fim, o software organiza as intervenções através de um ranqueamento de criticidade voltado à gestão de ativos. O script filtra os eventos anômalos e os ordena de forma decrescente pelo nível de risco, isolando os casos mais severos no topo de um painel visual gerado pela biblioteca Matplotlib. Essa priorização garante que o gestor direcione recursos e mão de obra exatamente onde a falha seja iminente ou que o impacto na produção seja maior. Essa camada de visualização transforma o resultado matemático em uma lista de tarefas prática, facilitando o controle do planejamento de manutenção.

```

# Bloco 4: Ranking de Criticidade e Dashboard
# Filtra anomalias e gera o ranking dos 20 casos mais
severos
relatorio_falhas = df[df['anomalia'] == 1]
ranking_critico =
relatorio_falhas.sort_values(by='anomaly_score',
ascending=False).head(20)

# Exporta o Dashboard visual para o Planejamento (PCM)
import matplotlib.pyplot as plt
fig, ax = plt.subplots(figsize=(12, 6))
ax.axis('off')
ax.set_title('PAINEL DE PRIORIDADES - TOP 20 ANOMALIAS',
weight='bold')
plt.savefig('dashboard_manutencao.png', dpi=300)

```

Fonte: Autor (2026)

## 7. ANÁLISE E DISCUSSÃO DOS RESULTADOS

A fase de análise e discussão dos resultados representa o estágio de validação técnica da arquitetura, onde a lógica algorítmica é confrontada com as exigências do monitoramento industrial. É fundamental estabelecer, como premissa desta discussão, que a validação do algoritmo não foi realizada sobre a infraestrutura física em operação real, devido à inexistência de uma base de dados históricos de falhas robustas nos ativos da planta característica comum em equipamentos de alta confiabilidade. Por esse motivo, adotou-se o conjunto de dados Microsoft Azure Predictive Maintenance como campo de prova, permitindo que o sistema fosse calibrado sob estresse simulado para comprovar sua eficácia antes de uma futura integração total.

### 7.1. ANÁLISE DE VIABILIDADE E COMPATIBILIDADE DA ARQUITETURA PROPOSTA

Ao avaliar a viabilidade da solução, percebe-se que a autonomia frente aos sistemas fechados se concretiza na parte lógica, graças à adoção da linguagem Python. Entretanto, levar essa inteligência para a estrutura física exige vencer obstáculos técnicos reais. Ainda que o script dispense o pagamento de royalties, a arquitetura física não abre mão de itens de interface, a exemplo do gateway Advantech ECU-1051, para estabelecer o contato entre o universo digital e o cotidiano da fábrica. Tal exigência se explica pela própria diversidade de um parque fabril típico, onde máquinas de fabricantes e épocas variadas tentam se comunicar através de protocolos diferentes. É preciso um núcleo centralizador que organize esse fluxo de informações e garanta que o dado chegue íntegro para o processamento. Nesse contexto, o gateway assume a função de um intérprete universal, facilitando a integração de equipamentos a nova camada de processamento. Enquanto ativos novos podem possuir comunicação nativa, máquinas mais antigas ou de tecnologias variadas dependem dessa interface para converter sinais elétricos brutos em dados estruturados. Portanto, a viabilidade da arquitetura reside na cooperação entre um hardware industrial robusto para vencer a barreira da conectividade e a flexibilidade do código aberto para manter a autonomia da manutenção prescritiva. Essa abordagem mostra-se eficiente e aplicável ao

cotidiano fabril, pois utiliza componentes de mercado para garantir que os dados cheguem prontos para o processamento.

Ao garantir a comunicação entre diferentes tecnologias, o sistema permite que o monitoramento evolua aproveitando a infraestrutura de automação que a empresa já possui, sem a necessidade de trocar todas as máquinas. Essa estratégia garante que o projeto seja financeiramente sustentável e tecnicamente eficaz, permitindo atualizações constantes conforme a planta industrial cresce. Conclui-se que a solução proposta atende aos requisitos de conectividade modernos, oferecendo um método prático para automatizar diagnósticos e proteger a continuidade da produção com baixo custo de implementação.

## 7.2 DESEMPENHO E EFICÁCIA DOS ALGORITMOS DE ANTECIPAÇÃO

A união entre a sensibilidade do Isolation Forest e a firmeza do LODA permitiu que o sistema filtrasse ruídos com precisão, isolando desvios em variáveis que poderiam passar despercebidos. Essa organização por agrupamento de modelos dá ao projeto a resiliência estatística precisa para enxergar sinais leves de desgaste muito antes de uma falha funcional ocorrer. Com isso, o diagnóstico se torna muito mais seguro para a manutenção prescritiva do que se utilizássemos apenas um algoritmo isolado.

Vale pontuar, no entanto, que essa eficiência técnica foi validada em um cenário controlado, tendo o dataset Microsoft Azure Predictive Maintenance como base principal de testes. A escolha por dados sintéticos foi um passo proposital, servindo para calibrar o software diante de modos de falha complexos que raramente acontecem no dia a dia, dada a alta confiabilidade das máquinas atuais. Como explicam Orošnjak et al. (2025), essa validação por simulação é uma etapa de rigor técnico que protege o patrimônio físico, permitindo que a lógica da solução amadureça em situações de estresse sem expor os ativos reais a riscos desnecessários.

Embora os números da simulação tragam otimismo, a prova final desta arquitetura virá com sua aplicação direta no chão de fábrica, enfrentando a imprevisibilidade do ambiente industrial real. No futuro, integrar o sistema ao

monitoramento de variáveis vindo do gateway Advantech será vital para ajustar como o código reage a interferências externas e oscilações de carga que não aparecem em ambientes virtuais. Essa transição do dado simulado para o acompanhamento físico é o que vai consolidar o software como um auxiliar autônomo, convertendo a robustez matemática vista aqui em ganho real de disponibilidade para a planta.

## **8. CONCLUSÃO**

Esta pesquisa comprovou que a implementação de um sistema de manutenção prescritiva representa o estágio de maior maturidade na gestão de ativos, permitindo que a indústria transite de uma postura reativa para uma autonomia decisória fundamentada em dados. Verificou-se ao longo deste trabalho que o grande gargalo para essa mudança a falta de registros antigos de quebras encontra uma saída viável no treinamento de modelos em ambientes de dados simulados, a exemplo do repositório da Microsoft Azure. Ao encerrar esta análise, nota-se que a meta de criar uma prova de conceito operante foi alcançada, entregando uma estrutura preparada para prever problemas e ditar correções exatas antes que qualquer interrupção trave a linha de produção.

A avaliação da infraestrutura física revelou que a robustez dos controladores Siemens S7-1200/1500, operando em conjunto com o gateway Advantech ECU-1051, forma o "sistema nervoso" indispensável para a captura de variáveis de campo. A pesquisa validou que essa combinação de hardware é eficiente para converter sinais brutos de vibração, temperatura e pressão em registros digitais íntegros e organizados. O papel do gateway como intérprete universal mostrou-se decisivo, pois garante que máquinas de diferentes gerações e tecnologias possam ser integradas à camada de processamento analítico sem a necessidade de substituição dos equipamentos já existentes, tornando o projeto financeiramente sustentável.

No que tange à lógica de inteligência, o uso do agrupamento de algoritmos LSCP (Ensemble) conferiu ao sistema a resiliência estatística necessária para filtrar ruídos e identificar anomalias com alta confiabilidade. A grande contribuição prática

deste trabalho não reside apenas na detecção do desvio, mas na automação da prescrição, que traduz o resultado matemático em instruções claras para a equipe de manutenção, como a inspeção de rolamentos ou válvulas, por exemplo. Essa funcionalidade remove a carga subjetiva do diagnóstico humano e agiliza a resposta, otimizando o planejamento do PCM e assegurando a continuidade da produção com um baixo custo de implementação.

Em síntese, o trabalho avalia que a manutenção prescritiva é tecnicamente aplicável e essencial para a competitividade da Indústria 4.0. Embora os testes tenham ocorrido em ambiente simulado, os resultados provam que a arquitetura proposta está pronta para ser integrada ao monitoramento em tempo real no chão de fábrica. A transição futura para o acompanhamento físico permitirá refinar a sensibilidade do sistema diante das oscilações de carga reais, consolidando o software como um assistente autônomo de decisão. Conclui-se que o modelo desenvolvido oferece um alicerce sólido para proteger a lucratividade industrial, transformando registros de sensores em proteção direta contra paradas inesperadas.

## REFERÊNCIAS

A VOZ DA INDÚSTRIA. Como a manutenção prescritiva ajuda sua indústria. **A voz da indústria**, 2020. Disponível em: <https://avozdaindustria.com.br/artigos/como-manuteno-prescritiva-ajuda-sua-industria/>. Acesso em: 28 set. 2025.

ABNT. **NBR 5462: Confiabilidade e manutenibilidade - Terminologia**. ABNT. Rio de Janeiro. 1994. (NBR 5462).

ABRAMAN. **Documento Nacional 2022: a situação da manutenção e da gestão de ativos nas empresas no Brasil**. Rio De Janeiro. 2022.

ADVANTECH. **ECU-1051TL: Cloud-enabled Intelligent Communication Gateway for IIoT Applications - Startup Manual**. Advantech. [S.l.].

AUTOMATION, ROCKWELL. **Relatório do Estado da Produção Inteligente**. Rockwell Automation. S.l. 2025.

BARBOSA, Jorge D. M. **Manutenção preditiva com recurso a Machine Learning**. Universidade de Coimbra. Coimbra. 2023.

COLEMAN, Chris; DAMODARAN, Satish; DEUEL, Ed. **Unplanned Downtime: Benefits of a Proactive Approach**. ServiceMax (GE Digital). [S.l.]. 2017.

FOGLIATTO, Flávio S.; RIBEIRO, José L. D. **CONFIABILIDADE E MANUTENÇÃO**. 1. ed. Rio de Janeiro: GEN LTC, 2011. ISBN 978-85-352-5188-3.

GILCHRIST, Alasdair. **Industry 4.0: the industrial internet of things**. 1. ed. New York: Apress, 2016.

KARDEC, Alan; NASCIF, Júlio. **Manutenção: Função Estratégica**. 5. ed. Rio de Janeiro: Qualitymark, 2022.

LAFRAIA, João R. B. **Manual de Confiabilidade, Manutenibilidade e Disponibilidade**. 1. ed. ed. Rio de Janeiro: Qualitymark, 2001.

LOPES, Murilo P. **Manutenção Industrial 4.0: Da Oficina ao Nível Estratégico**. 1. ed. [S.l.]: BDM, 2025.

MACHADO, Cristófer O. *et al.* Manutenção Prescritiva: a evolução da manutenção na indústria 4.0. **Revista Ibero-Americana de Humanidades, Ciências e Educação – REASE**, 9, n. 9, 2023. 4444-4458. Disponível em: <https://periodicorease.pro.br/rease/article/view/11476>. Acesso em: 6 abr. 2026.

MCKINNEY, Wes. **Python for Data Analysis: Data Wrangling with pandas, NumPy, and Jupyter**. 3. ed. Sebastopol: O'Reilly Media, Inc., 2022.

MICROSOFT. Microsoft Azure Predictive Maintenance. **KAGGLE**, 2020. Disponível em: <https://www.kaggle.com/datasets/arnabbiswas1/microsoft-azure-predictive-maintenance>. Acesso em: 22 mar. 2026.

MÜLLER, Andreas C.; GUIDO, Sarah. **Introduction to Machine Learning with Python: A Guide for Data Scientists**. 1. ed. [S.l.]: O'Reilly Media, 2016.

OROŠNJAK, Marko; SARETZKY, Felix; KEDZIORA, Slawomir. Prescriptive Maintenance: A Systematic Literature Review and Meta-Analysis. **Applied Sciences**, 15, 2025. Disponível em: <https://doi.org/10.3390/app15158507>.

SHRIVASTAVA, Manish; SINGHAL, Priyank; J., Bhuvana. Integrating sensor data and machine learning for predictive maintenance in industry 4.0. **Proceedings on Engineering Sciences**, 2023. 55-62.

SIEMENS. The True Cost of Downtime 2024. **assets.new.siemens.com**, Alpharetta, 2024. Disponível em: [https://assets.new.siemens.com/siemens/assets/api/uuid:1b43afb5-2d07-47f7-9eb7-893fe7d0bc59/TCOD-2024\\_original.pdf](https://assets.new.siemens.com/siemens/assets/api/uuid:1b43afb5-2d07-47f7-9eb7-893fe7d0bc59/TCOD-2024_original.pdf). Acesso em: 29 mar. 2026.

SILVA, Samuel M. D. LinkedIn. **LinkedIn**, 19 jul. 2017. Disponível em: <https://pt.linkedin.com/pulse/manuten%C3%A7%C3%A3o-fun%C3%A7%C3%A3o-e-strat%C3%A9gica-samuel-medeiros-da-silva>. Acesso em: 28 set. 2024.

SOBRINHO, Edison P. **Projeto Manutenção Prescritiva: A Manutenção da Indústria 4.0**. Instituto Federal Fluminense (IFF). Campos dos Goytacazes. 2022.

TELES, Jhonata. **Bíblia do RCM: O guia completo e definitivo da manutenção centrada na confiabilidade na era da indústria 4.0**. Brasília: ENGETELES, 2019. Disponível em: <https://engeteles.com.br/manutencao-centrada-na-confiabilidade/>. Acesso em: 28 ago. 2024.

TRACTIAN. Manutenção Prescritiva: O que é, benefícios e como implementar, 29 jan. 2026. Disponível em: <https://tractian.com/blog/manutencao-prescritiva-o-que-e-beneficios-e-como-implementar>. Acesso em: 06 abr. 2026.

VAN ROSSUM, Guido. **Python Tutorial: Release 3.7.0**. [S.I.]: Python Software Foundation, 2018.

VIANA, Herbert R. G. **PCM: planejamento e controle da manutenção**. 2. ed. Rio de Janeiro: Qualitymark, 2014.

ZHAO, Yue; NASRULLAH, Zain; LI, Zheng. PyOD: A Python Toolbox for Scalable Outlier Detection. **Journal of Machine Learning Research**, 2019. 1-7.