

Trilha 2 – métodos, processos, técnicas, práticas e ferramentas;

## **DA MANUTENÇÃO CORRETIVA AO CONHECIMENTO PREDITIVO: MODELO DE GESTÃO DO CONHECIMENTO BASEADO EM IoT PARA MÁQUINAS INDUSTRIAIS LEGADAS**

*FROM CORRECTIVE MAINTENANCE TO PREDICTIVE KNOWLEDGE:  
IOT-BASED KNOWLEDGE MANAGEMENT MODEL FOR LEGACY  
INDUSTRIAL MACHINES*

**Eduardo Alves de Paula**

Pós Graduação Lato Sensu em Gestão Lean 4.0. Universidade Federal do ABC (UFABC) – Brasil.  
e.alves@ufabc.edu.br.

**Rodrigo Gabriel Anelli**

Pós Graduação Lato Sensu em Projeto, Manufatura e Análise de Eng<sup>a</sup>. Universidade Federal do ABC (UFABC) – Brasil.  
r.aneli@ufabc.edu.br.

**Sérgio Ricardo Lourenço**

Doutorado em Engenharia. Universidade Federal do ABC (UFABC) – Brasil.  
sergio.lourenco@ufabc.edu.br.

### **RESUMO**

Máquinas legadas representam um desafio para a gestão de ativos no setor industrial, dada a sua relevância no processo. Avaliar cuidadosamente questões de substituição completa versus implantação de tecnologias para otimização, fomenta com frequência o estudo de soluções nesse segmento. Com o objetivo de elaborar um modelo de implantação das tecnologias habilitadoras da indústria 4.0 em máquinas legadas (*brownfield*), o estudo busca mitigar a problemática da ausência de um método prático, justificado pela necessidade de desenvolvimento de procedimentos para implantação de soluções que transformem dados dispersos em dados de apoio à decisão, amplamente utilizados no setor automotivo. Com foco em abordagem mista (qualitativa e quantitativa), o trabalho analisou o modelo de gestão do conhecimento aplicado na área de manutenção de ativos, observando dados dos custos de manutenção e indicadores de Eficiência Global do Equipamento (OEE), de uma máquina de usinagem, num período de 24 meses, sob as práticas tradicionais de PCM, e 12 meses sob gestão após a digitalização da máquina. A viabilidade da solução implementada foi comprovada por meio da transição da tomada de decisão empírica por um modelo de conhecimento preditivo suportado por dados. Os resultados indicaram o potencial de aumento no intervalo do Tempo Médio Entre Falhas (MTBF) e redução significativa no Tempo Médio de Reparo (MTTR). Ao final, comprovou-se a possibilidade de modernizar ativos industriais legados, por meio de procedimento padronizado, cujo modelo de implantação das tecnologias de manufatura avançada permite uma implantação ágil, organizada e com custo reduzido frente à substituição completa da máquina.

**Palavras-chave:** Gestão do Conhecimento; Manutenção Preditiva; Internet das Coisas; Conhecimento Operacional; OEE.

## ABSTRACT

Legacy machines present a challenge for asset management in the industrial sector due to their significance in the production process. The careful evaluation of complete asset replacement versus the implementation of optimization technologies frequently drives the study of solutions within this sector. Aiming to develop a model for implementing Industry 4.0 enabling technologies in legacy machines (brownfield environments), this study seeks to mitigate the issue of the lack of a practical method. This is justified by the need to develop procedures for deploying solutions that transform dispersed data into decision-support data, which are widely utilized in the automotive sector. Employing a mixed-methods approach (qualitative and quantitative), this work analyzed the knowledge management model applied to asset maintenance. It examined maintenance cost data and Overall Equipment Effectiveness (OEE) indicators of a machining tool over a 24-month period under traditional Maintenance Planning and Control (MPC) practices, followed by a 12-month management period post-digitization. The viability of the implemented solution was demonstrated through the transition from empirical decision-making to a data-driven, predictive knowledge model. The results indicated a potential increase in the Mean Time Between Failures (MTBF) interval and a significant reduction in Mean Time To Repair (MTTR). Ultimately, the study proved the feasibility of modernizing legacy industrial assets through a standardized procedure. This implementation model for advanced manufacturing technologies enables an agile, organized, and cost-effective deployment compared to the complete replacement of the machine.

**KEYWORDS:** Knowledge Management; Predictive Maintenance; Internet of Things; Operational Knowledge; OEE.

## 1. INTRODUÇÃO

O aprimoramento de processos industriais transcende a mera aquisição de maquinário novo ou o desenvolvimento de técnicas inovadoras. Segundo OOI et al. (2020,2022), principalmente nos países em desenvolvimento, a manufatura industrial abriga a coexistência entre máquinas industriais legadas e máquinas modernas, em plantas classificadas como *brownfield*. Muitas dessas máquinas foram concebidas antes do surgimento da indústria 4.0, portanto sem conectividade nativa com sistemas ciberfísicos. ALMEIDA (2019) menciona que a justificativa principal para buscar a otimização do desempenho das máquinas reside na permanência da relevância da operação para os processos produtivos.

Porém, é fundamental atingir o aumento da eficiência (OEE) e da disponibilidade operacional, por meio de intervenções que permitam alcançar resultados significativos, contrapondo a hipótese de uma substituição completa de máquinas, que a depender da peculiaridade de suas operações, pode representar volumes consideráveis de investimentos (CAPEX).

FIROUZI et al. (2026) afirma em seu estudo que a aplicação de tecnologias para conectividade como IoT, Gêmeos Digitais, *Machine Learning*, e Inteligência Artificial para suporte à tomada de decisão baseada em dados, é a solução mais recomendada para plantas do SBGC – Sociedade Brasileira de Gestão do Conhecimento – [sbgc.org.br](http://sbgc.org.br)  
KM Brasil 2026 - 21º Congresso Brasileiro de Gestão do Conhecimento – [kmbrasil.org](http://kmbrasil.org)

tipo *brownfield*, embora enfrentando muitos desafios para a integração entre máquinas e os sistemas ciberfísicos. Nesse contexto, surge uma questão central: a substituição completa de equipamentos legados é sempre necessária, ou esses ativos podem ser adaptados por meio da incorporação de novas tecnologias para geração de inteligência operacional?

Diante dessa questão, a definição formal do problema sintetiza-se no questionamento que segue: Como transformar em conhecimento os dados escassos e dispersos de condições de operação de máquinas legadas para suporte à decisão em ambientes industriais *brownfield*?

O objetivo geral do trabalho é apresentar um modelo de gestão do conhecimento para aplicação de soluções operacionais baseado em IoT para estruturar informações extraídas de uma máquina industrial anterior às tecnologias da indústria 4.0, parte integrante do processo produtivo da usinagem de blocos de motores à diesel, cuja aplicação de soluções de conectividade foram realizadas por meio de um estudo de caso para teste e definição de modelos para apoio à tomada de decisão, com integração do chão de fábrica aos sistemas ciberfísicos corporativos existentes.

## 2. REFERENCIAL TEÓRICO

O termo Indústria 4.0 funde avanços de automação, conectividade e análise de dados massivos, estruturando operações para a inovação acelerada (HERMANN; PENTEK; OTTO, 2016). No cerne deste conceito habitam os Sistemas Ciberfísicos (CPS) e os Gêmeos Digitais, que atuam como construções virtuais informacionais que descrevem o produto físico, amparando a tomada de decisões no ecossistema industrial (GRIEVES; VICKERS, 2017).

Entretanto, o grande desafio na modernização de plantas industriais *brownfield*, reside na gestão inteligente dos processos produtivos e na gestão da manutenção. Em ambientes industriais complexos, a convivência entre o conhecimento tácito e explícito dita o ritmo das operações. O conhecimento tácito, profundo e enraizado na experiência humana, é comumente observado no dia a dia fabril: é o caso do operador de máquina que, apenas por uma sutil alteração no "ruído" da máquina, é capaz de perceber que existe algo errado com a operação, mesmo sem conseguir explicitar tecnicamente a causa da anomalia afirmam NONAKA et al. (1995).

A gestão do conhecimento na manutenção atua justamente na conversão desse saber empírico e individual em conhecimento explícito, documentado e transferível. Ao capturar

dados físicos por meio de tecnologias habilitadoras (vibração, temperatura etc.) e digitalizar indicadores como a Eficiência Global do Equipamento (OEE), elimina-se a falibilidade dos apontamentos manuais e a dependência exclusiva da intuição humana.

Dessa forma, consolida-se a Tomada de Decisão Baseada em Conhecimento (DAVENPORT; PRUSAK, 1998), na qual o gestor deixa de atuar de forma reativa às quebras e passa a basear suas estratégias em um fluxo contínuo de conhecimento estruturado, permitindo o estabelecimento de rotinas de manutenção preditiva orientadas pelas informações baseadas nos dados operacionais extraídos em tempo real.

Porém, para possibilitar a obtenção de dados com confiabilidade assegurada, estudos foram realizados buscando primeiramente compreender o comportamento das máquinas, com a finalidade de identificar os efeitos da operação sobre componentes essenciais para o funcionamento. OOI et al. (2020, 2022), em seu estudo de caso, salienta as dificuldades para a obtenção dos dados de máquinas legadas sem registro histórico, e apresenta uma solução de *retrofitting* associada a um conjunto de parâmetros que possibilita o monitoramento, mesmo sem dados prévios das condições de máquina.

A evolução das tecnologias habilitadoras para a digitalização de processos nos últimos anos, segundo WEN et al. (2024), tem incentivado cada vez mais a integração entre o mundo físico e os sistemas ciberfísicos, proporcionando o desenvolvimento de soluções específicas, como a Internet Industrial das Coisas (em inglês, IIoT) e os Sistemas Industriais Ciberfísicos (em inglês, ICPS). Complementarmente a essas evoluções também surge a Inteligência Artificial como elemento promissor no suporte à tomada de decisão em procedimentos de Manutenção Preditiva.

A convergência das evoluções mais recentes permite a aplicação de soluções avançadas, como por exemplo a Inteligência Artificial Generativa, que se trata de uma ferramenta com capacidade de aprendizado, por meio da obtenção de dados, interpretação das informações, comparação de marcas (*labels* ou referências) e geração de repositório, permitindo a tomada de decisão e a correção de operação em tempo real. Segundo WEN et al. (2024), a IA Generativa tem capacidade para orientar a geração de Gêmeos Digitais com alto nível de acurácia. Essa propriedade garante o desenvolvimento de modelos confiáveis, utilizados como matrizes para a construção de parâmetros que auxiliam no monitoramento do comportamento de máquinas.

Concluindo, a manutenção preditiva suportada a dados apresenta-se como alternativa provável para a digitalização de operações industriais sem conectividade nativa. Porém, OOI et

al. (2022) alerta para as diferenças de propósito entre monitoramento da operação (*tracking*), com foco em OEE, e o monitoramento das condições de operação, com foco na predição de falhas (PdM). Por fim, tanto o monitoramento da eficiência de máquinas (OEE), quanto o monitoramento das condições de operação com a finalidade de suporte às estratégias de manutenção, representam fatores que influenciam diretamente a disponibilidade dos sistemas de produção, impactando diretamente nos resultados, no desempenho do processo, na gestão econômica e na gestão de recursos da corporação.

### 3. METODOLOGIA

A estrutura analítica deste trabalho foi orientada por um plano de pesquisa fundamentado em observação e experimentação industrial (REY, 1993). Segundo a perspectiva de CRESWELL e CLARK (2011), a abordagem mista é a mais assertiva para fenômenos de chão de fábrica complexos, permitindo que a análise do contexto fabril conviva com as métricas sólidas de desempenho mecânico. Nesse sentido, o estudo utiliza elementos qualitativos, como a descrição do contexto fabril, a caracterização das limitações tecnológicas e a construção das soluções com base na realidade da empresa. Em paralelo, incorpora elementos quantitativos, como a coleta e análise de dados técnicos (por exemplo, OEE, custos de manutenção e comparativos de indicadores), possibilitando medir impactos e avaliar a eficácia da intervenção proposta. Essa combinação é a mais adequada quando se busca compreender significados e contextos ao mesmo tempo em que se analisam dados objetivos para fundamentar a tomada de decisões.

A pesquisa por experimentação se justifica pela característica da possibilidade da manipulação de uma ou mais variáveis independentes, com o potencial de influenciar de forma controlada, mensurável e capaz de registro, os efeitos sobre as variáveis dependentes, classificando a presente pesquisa como um estudo de caso, em forma de pesquisa qualitativa e quantitativa, ao considerarmos os resultados esperados, que em resumo objetivam a comprovação numérica das vantagens da intervenção, bem como a construção de conhecimento teórico aplicável para outras máquinas em condição igual ou similar.

A construção do plano de pesquisa iniciou com a investigação da hipótese de problema, com base no histórico de operação de uma máquina de usinagem de materiais metálicos, tomando por referência dados qualitativos, como por exemplo o tipo de máquina, sua origem, ano de fabricação, estrutura básica de construção, fatores esses relevantes para a definição do

objeto de estudo. Também foram considerados dados quantitativos, como horas trabalhadas, horas paradas, quantidade de intervenções em determinados períodos, custos das intervenções e custos da máquina parada. Com base nesses dados foi possível definir a questão problema e elaborar o plano de pesquisa.

A unidade de análise é uma máquina pertencente ao grupo dos centros de usinagem, originalmente concebida antes do surgimento das tecnologias da indústria 4.0 (vide tabela 1), do tipo multiestação, alocada em uma linha de produção automotiva (figura 1). Os dados preliminares foram extraídos do monitoramento operacional e de manutenção, cujos registros históricos de falhas foram preenchidos manualmente, impactando na gestão dos dados.

Tabela 1 – Dados gerais da máquina objeto do estudo.

| Característica       | Descrição                                                |
|----------------------|----------------------------------------------------------|
| Classe de máquina    | Centro de Usinagem                                       |
| Ano de fabricação    | 1999                                                     |
| Fabricante           | Thyssen Hueller                                          |
| Modelo               | Transfer CNC                                             |
| Módulo de comando    | CLP SIEMENS S7-300                                       |
| Linguagem de máquina | STEP7                                                    |
| Rede interna         | Profibus SIEMENS                                         |
| Sistema Gantry       | CNC Liebherr Gantry                                      |
| Quantidade estações  | 5 posições                                               |
| Acionamentos         | Sistemas mecânicos, elétricos, hidráulicos e pneumáticos |
| Dimensões gerais     | C= 20 m / L = 5 m / A = 6 m                              |
| Peso                 | 200 t                                                    |

Fonte: Acervo da empresa – Manual de Máquina




Figura 1 – Planta técnica da máquina multiestação.

Fonte: Imagem gerada por IA (Lourenço, 2026)

As etapas foram constituídas pelo levantamento do referencial teórico, com foco na busca de literatura que orientasse o desenvolvimento de um modelo estruturado para aplicações *brownfield* (vide tabelas na seção Anexo). Foram adotadas palavras-chave com aderência ao tema proposto, resultando no referencial adotado. Em seguida, pelo levantamento dos módulos do equipamento, a apuração dos dados do Tempo Médio Entre Falhas (MTBF) e o Tempo Médio de Reparo (MTTR), e por último, pelo embate técnico e financeiro entre adotar uma solução IoT de mercado padrão ou customizar uma integração interna focada nas particularidades corporativas.

Neste processo, foram aplicadas técnicas empíricas de comparação direta de fatores e características para a avaliação do equipamento, das dificuldades, das relevâncias, conforme os métodos internos de avaliação corporativos vigentes, aprimorando a tomada de decisão estruturada no escopo do projeto.

A organização da estrutura metodológica para a realização do estudo de caso foi dividida em etapas, conforme descrição que segue:

1. Mapeamento técnico: foram identificadas as variáveis operacionais críticas da máquina (tempo de ciclo, falha, temperatura, fluxo de comunicação, tempo de diagnóstico de problemas, mínimo tempo entre falhas, máximo tempo entre reparos e status);
2. Projeto de instrumentação: foram identificados elementos nativos da máquina, compostos por sensores industriais pré-existentes para coleta dos dados relevantes;
3. Integração de dados: os sinais coletados originalmente já enviados a um CLP, responsável por consolidar os blocos de informações, foram extraídos por meio de elementos de conectividade adicionados à arquitetura de controle da máquina, transmitindo as informações via rede Ethernet para o Data Lake da empresa;
4. Configuração de dashboards: as informações foram exibidas em tempo real por meio de uma interface gráfica customizada desenvolvida internamente pela equipe de especialistas da empresa;
5. Avaliação dos impactos: foram medidos os indicadores de manutenção e disponibilidade após a implantação. Esses dados foram comparados aos indicadores constantes no histórico de operação da máquina.
6. Elaboração do modelo de implantação: foi desenvolvido um modelo padrão, roteirizado, para avaliação e implantação de tecnologias para digitalização do processo

produtivo, baseado em extração de dados das condições de operação da máquina, para fim de monitoramento e suporte à estratégia de gestão da produção e dos ativos legados.

## 4. RESULTADOS E DISCUSSÃO

A primeira fase analítica levantou o perfil comportamental de falhas do equipamento. Foi identificado, a título de exemplo, que o 'Módulo 3' da máquina possuía a disponibilidade mais precária, na faixa de 67,87%, ocasionada por um severo MTTR equivalente a 161,27 horas. Estas deficiências culminaram em mais de 5.644 horas paradas globais na base temporal avaliada, no período de registro dos dados, cerca de 2 anos, elevando as restrições produtivas do setor inteiro. A tabela 2 que segue, contém os dados levantados.

Tabela 2 – Dados gerais do histórico de intervenções da máquina.

| Equipamento | MTBF (h) | MTTR (h) | Disponibilidade (h) | Disponibilidade (%) | Horas Paradas | Ordens Manutenção | MOB (h)  |
|-------------|----------|----------|---------------------|---------------------|---------------|-------------------|----------|
| MÓDULO 1    | 547,34   | 1,67     | 17514,72            | 99,7                | 53,28         | 270               | 2087,534 |
| MÓDULO 2    | 834,1    | 2,48     | 17516,01            | 99,7                | 51,99         | 190               | 1295,081 |
| MÓDULO 3    | 340,67   | 161,27   | 11923,61            | 67,87               | 5644,39       | 202               | 1186,432 |
| MÓDULO 4    | 604,57   | 1,22     | 17532,61            | 99,8                | 35,39         | 128               | 860,51   |

Fonte: Registros da empresa período 24 meses (Alves, 2025)

Diante das demandas por conectividade rápida, elaboraram-se dois cenários comparativos. A solução comercial, com aplicação de soluções padronizadas do tipo não invasiva, demonstrou benefícios pela facilidade de implementação, embora trouxesse dependência nociva a infraestruturas de dados de terceiros e rede sem fio instável para maquinário pesado. A equipe avaliadora deliberou, portanto, pela implantação da Solução Interna. Esta via permitiu reaproveitar a confiável arquitetura cabeada já existente na estrutura da empresa, suprimiu alterações mecânicas irreversíveis na máquina, e blindou os dados sigilosos contra vazamentos externos.

O processo estruturou-se na captação de sinais de sensores pré-existent para a medição de vibração e temperatura industriais em motores elétricos (servomotores), rolamentos e eixos cruciais. Os pacotes de telemetria foram encaminhados até um Gateway que integra as redes da Tecnologia Operacional (OT) com a Tecnologia da Informação (TI). Emulando arquiteturas de dados tipo CSV extraídos dos blocos de dados nativos do CLP modelo Siemens S7-300.

Uma projeção simulada do novo escopo digitalizado retratou consideráveis ganhos operacionais e em fôlego preditivo. A título de simulação no 'Módulo 1', registrou-se a elevação

do MTBF das antigas 547,34 horas para excelentes 848,37 horas simuladas. Este alongamento da vida útil do ciclo tem potencial de mitigar em grande escala as ordens frequentes de manutenção e suprimir os altos custos relacionados a paralisações imprevistas e mobilização da mão de obra.

Na mesma direção, o “Módulo 3”, apresentou potencial de otimização significativa, partindo das 340,67 horas e saltando para 528,04 horas para o MTBF. A tabela 3 apresenta os valores gerais obtidos com base em projeções calculadas, considerando parâmetros da consultoria McKinsey para digitalização de ativos legados.

Tabela 3 – Projeção estimada após implantação de conectividade.

| Equipamento | MTBF (h) | MTTR (h) | Disponibilidade (h) | Disponibilidade (%) | Horas Paradas | Ordens Manutenção | MOB (h)  |
|-------------|----------|----------|---------------------|---------------------|---------------|-------------------|----------|
| MÓDULO 1    | 848,377  | 0,668    | 17514,72            | 99,88               | 31,968        | 162               | 1252,52  |
| MÓDULO 2    | 1292,855 | 0,992    | 17516,01            | 99,88               | 31,194        | 114               | 777,0486 |
| MÓDULO 3    | 528,0385 | 64,508   | 11923,61            | 84,52               | 3386,634      | 121,2             | 711,8592 |
| MÓDULO 4    | 937,0835 | 0,488    | 17532,61            | 99,92               | 21,234        | 76,8              | 516,306  |

Fonte: Estimativa da empresa período 24 meses (Alves, 2025)

Superada a etapa das simulações e cálculos de projeção, o estudo seguiu para a fase prática do experimento, por meio da implantação definitiva dos componentes e sistemas para a aplicação efetiva da solução, com base no modelo elaborado. O período de captação de dados compreendeu os 12 meses subsequentes a partir da data de implantação.

Uma vez normalizada a base comparativa, foram levantados os dados reais obtidos através do monitoramento em tempo real e captação remota. A tabela 4 apresenta esses valores registrados no período.

Tabela 4 – Valores captados após 12 meses de conectividade.

| Equipamento | MTBF (h) | MTTR (h) | Disponibilidade (h) | Disponibilidade (%) | Horas Paradas | Ordens Manutenção | MOB (h) |
|-------------|----------|----------|---------------------|---------------------|---------------|-------------------|---------|
| MÓDULO 1    | 334,98   | 1,94     | 8709,45             | 99,42               | 50,55         | 103               | 509,814 |
| MÓDULO 2    | 363,64   | 1,36     | 8727,38             | 99,63               | 32,62         | 80                | 435,97  |
| MÓDULO 3    | 220,71   | 3,91     | 8607,67             | 98,26               | 152,33        | 115               | 812,353 |
| MÓDULO 4    | 315,9    | 1,31     | 7265,76             | 99,59               | 30,24         | 56                | 327,2   |

Fonte: Registro real da empresa (Alves, 2026)

A comparação entre os valores estimados e os valores efetivamente registrados, permitiram concluir que a simulação por estimativa calculada, referenciada pelas projeções baseadas nos percentuais declarados pela consultoria McKinsey, confirmaram o potencial de atingir ganhos com a solução implantada, conforme demonstrado nas tabelas 5 e 6.

SBGC – Sociedade Brasileira de Gestão do Conhecimento – [sbgc.org.br](http://sbgc.org.br)

KM Brasil 2026 - 21º Congresso Brasileiro de Gestão do Conhecimento – [kmbrasil.org](http://kmbrasil.org)

Tabela 5 – Valores teóricos de ganho potencial.

| MTBF<br>(h) | MTTR<br>(h) | Disponibilidade<br>(h) | Disponibilidade<br>(%) | Horas<br>Paradas | Ordens<br>Manutenção | MOB (h) |
|-------------|-------------|------------------------|------------------------|------------------|----------------------|---------|
| +55%        | -60%        | +55%                   | +55%                   | -40%             | -40%                 | -40%    |

Fonte: McKinsey consultoria (Peláez, 2021)

Tabela 6 – Valores reais de ganho em 12 meses Módulo3 (crítico).

| MTBF<br>(h) | MTTR<br>(h) | Disponibilidade<br>(h) | Disponibilidade<br>(%) | Horas<br>Paradas | Ordens<br>Manutenção | MOB (h) |
|-------------|-------------|------------------------|------------------------|------------------|----------------------|---------|
| + 29,57%%   | -95,15%     | +55,62%                | +55,22%                | -94,60%          | -13,86%              | -36,94% |

Fonte: Registro da empresa (Alves, 2026)

Em resumo, os resultados finais indicaram reduções e incrementos potenciais significativos dos indicadores em geral, com destaque para dois deles, bastante importantes, o valor do custo total e o percentual de disponibilidade da máquina. A possibilidade de redução dos custos de manutenção representa uma economia de cerca de 1,2 milhão de reais, com um incremento da disponibilidade na ordem de 35% das horas totais.

Ao final, o modelo estruturado elaborado com base em todo o processo de abordagem permite a aplicação da intervenção em outros ativos da empresa, de maneira estruturada, contemplando os principais aspectos e características da máquina alvo da melhoria, reduzindo principalmente as dificuldades, as dúvidas e barreiras, permitindo uma implantação em menor prazo, com menor custo e permitindo o retorno a curto prazo.

Como produto final do estudo, foram elaborados formulários e procedimentos para guiamento das futuras implantações, adotados como padrão para planejamento, processo e documentação dessas intervenções. A figura 2 representa parte do material elaborado.

**Formulário para Implantação de Tecnologias da Indústria 4.0**

Baseado no guia "Guidelines Tools for Industry 4.0 production" (VDI 5606, Alemanha)

**1. Levantamento de Dados do Objeto**

1.1 Qual dado é relevante ao processo?

1.2 Como posso obter esse dado?

1.3 Em qual dispositivo (CLP ou I/O) ele se encontra?

1.4 Qual a frequência de leitura que preciso ter?

1.5 Quais são os protocolos e formatos de mídia aceitos?

1.6 Como me consumo? essas coisas na minha rede de TI?

**2. Avaliação do Ambiente e Estratégia**

A tecnologia de processo ainda é relevante?

☐ Sim  
☐ Não  
☐ Não se aplica

A máquina tem potencial de modernização para estender a longevidade?

☐ Sim  
☐ Não  
☐ Não se aplica

O plano de substituição será aplicado em até 2 anos?

☐ Sim  
☐ Não  
☐ Não se aplica

Os componentes internos podem ser substituídos por itens modulares?

☐ Sim  
☐ Não  
☐ Não se aplica

A infraestrutura local está preparada para a conectividade da máquina?

☐ Sim  
☐ Não  
☐ Não se aplica

Os dados gerados são compatíveis com os KPIs definidos pela organização?

Figura 2 – Formulário padrão para implantação de tecnologias habilitadoras.

Fonte: Acervo da empresa (Alves, 2025)

## 5. CONSIDERAÇÕES FINAIS E IMPLICAÇÕES

A jornada pela digitalização fabril atestou a aderência do preceito da Gestão do Conhecimento aliado à Indústria 4.0 como alternativa estratégica ao descarte de maquinário legado. Máquinas defasadas reconquistam relevância quando seus dados brutos são transformados em conhecimento analítico e preciso. O modelo implementado consolidou sua aprovação no âmbito da viabilidade executiva, revelando que arquitetar a conectividade IoT de forma customizada reflete expressivas melhorias na transformação do conhecimento tácito da operação em conhecimento explícito para o acompanhamento do OEE, barateando custos recorrentes.

### 5.1 CONTRIBUIÇÃO DO TRABALHO

A contribuição principal deste artigo é propor um modelo de gestão do conhecimento operacional para utilizar dados de manutenção em máquinas legadas (*brownfield*), organizando os registros dispersos em conhecimento útil e estruturado para suportar decisões de manutenção preditiva. A pesquisa reforça que a aplicação de recursos de conectividade transcende a mera atualização de hardware; ela permite uma captação de informações mais aferida e em tempo real, antecipando eventos de falhas através da rápida conversão de dados em conhecimento estratégico para a tomada de decisão.

Adicionalmente a pesquisa reforça a vantagem de aplicação de recursos de tecnologia, que apesar de não exercerem influência direta sobre as tecnologias de processo dessas máquinas legadas, proporciona modelos mais eficientes de monitoramento, permitindo uma captação de dados mais aferida, de forma mais robusta, em tempo real, auxiliando na atuação de maneira preditiva, antecipando eventos de falhas, por meio de interpretação desses dados em prazo mais curto.

### 5.2 IMPLICAÇÕES TEÓRICAS E PRÁTICAS

A aplicação deste estudo em etapas claramente definidas representou uma oportunidade valiosa de ampliação da literatura sobre a transição do conhecimento tácito para o explícito no ambiente industrial. O desafio de integrar o know-how dos operadores experientes à viabilidade técnica e financeira da IoT promoveu um crescimento intelectual sistêmico para os envolvidos e para a corporação, evidenciando o valor prático da gestão do conhecimento no chão de fábrica. O estudo de caso, perpassado pela busca de referencial teórico de outros estudos de caso

SBGC – Sociedade Brasileira de Gestão do Conhecimento – [sbgc.org.br](http://sbgc.org.br)

KM Brasil 2026 - 21º Congresso Brasileiro de Gestão do Conhecimento – [kmbrasil.org](http://kmbrasil.org)

similares, pela estruturação dos passos para a aplicação guiada, pelas intervenções práticas e finalmente pela avaliação dos resultados obtidos, representou a oportunidade de ampliação desse conhecimento acerca das barreiras, dificuldades, requisitos e potenciais, que a implantação dessas tecnologias representa dentro de uma grande corporação.

O desafio para encontrar profissionais com conhecimento teórico e prático, a necessidade de convencimento dos tomadores de decisão quanto aos ganhos potenciais, quanto a viabilidade técnica, quanto a viabilidade financeira, também representou um crescimento primordial para a prática e a visão estratégica da gestão.

### **5.3 IMPLICAÇÕES GERENCIAIS**

Como o estudo gerou impactos diretos sobre a gestão de ativos, comprovados através da economia na ordem de 55% de redução média dos custos gerenciais de manutenção, os resultados instigaram uma profunda mudança cultural na visão da gestão. Os tomadores de decisão deixaram de tratar a manutenção de máquinas legadas sob a ótica reativa, passando a valorizar a aplicação de tecnologias como ferramentas essenciais para a geração de conhecimento preditivo.

Outro reflexo importante da ampliação desse conhecimento foi a decisão da gestão executiva da empresa em replicar o modelo para outros ativos do parque fabril. Os impactos diretos sobre a gestão desses ativos, reforçados pelas estimativas de otimização e redução de custos que o estudo apresentou, inicialmente por meio de cálculo estimativo, e comprovados posteriormente pelos dados reais obtidos, reforçaram a mudança cultural e fomentaram o incentivo à aplicação de tecnologias habilitadoras da indústria 4.0 em máquinas legadas.

### **5.4 LIMITAÇÕES DA PESQUISA E ESTUDOS FUTUROS**

Embora o trabalho tenha alcançado seus objetivos, sugere-se, como limitação, a expansão deste modelo de gestão do conhecimento para uma escala maior de equipamentos ao longo de um período mais extenso. Estudos futuros podem explorar mais profundamente como a introdução dessa inteligência e explicitação do conhecimento impactam diretamente a cultura organizacional e as competências cognitivas dos operadores na linha de frente (NONAKA; TAKEUCHI, 1995). Adicionalmente, investigar o cruzamento desse novo arcabouço de conhecimento com algoritmos avançados de Inteligência Artificial para a tomada de decisão autônoma representa um campo promissor para a literatura de Gestão do Conhecimento

aplicada à Indústria 4.0. O roteiro metodológico estruturado prova-se escalável e serve como referência robusta para fomentar decisões baseadas em conhecimento fidedigno no cenário produtivo.

Os desafios relacionados à segurança cibernética e à proteção de dados em um ambiente de produção cada vez mais conectado também merecem atenção e desenvolvimento de estudos futuros. E a análise do retorno sobre o investimento, com base nos ganhos esperados com a implementação das tecnologias propostas, deve ser considerada outra abordagem relevante para novos trabalhos, estimulando uma investigação e uma avaliação econômica focada nos benefícios da modernização industrial. Por fim, a comparação com outras abordagens de modernização de máquinas originalmente predecessoras à 4ª Revolução Industrial representa uma oportunidade para enriquecer a discussão e oferecer novas perspectivas para o enfrentamento desse desafio.

Ao finalizar este projeto, as perspectivas futuras apontam com nitidez para a replicabilidade integral do sistema. O roteiro metodológico desenhado prova-se escalável e serve como referência robusta para revitalizar ativos que não dispõem de natividade digital, consolidando os Sistemas Ciberfísicos e fomentando decisões baseadas em dados fidedignos no cenário produtivo.

## 6. REFERÊNCIAS

ALMEIDA, C. **História e Evolução da Indústria**. São Paulo: Editora Inovação, 2019.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **NBR 6023: informação e documentação / referências / elaboração**. Rio de Janeiro, 2018.

CRESWELL, J. W.; CLARK, V. L. P. ***Designing and conducting mixed methods research***. 2. ed. California: Thousand Oaks, SAGE Publications, 2011.

FIROUZI, F. et al. Generative IoT: advancing IoT with generative AI and large language models. *Digital Communications and Networks*, v. 12, p. 1–15, 2026.

GRIEVES, M.; VICKERS, J. ***Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems***. In: KROB, D.; LI, M.; YAO, J. (ed.). *Transdisciplinary Perspectives on Complex Systems: New Findings and Approaches*. Cham: Springer, 2017. p. 85-113.

HERMANN, M.; PENTEK, T.; OTTO, B. ***Design Principles for Industrie 4.0 Scenarios***. In: HAWAII INTERNATIONAL CONFERENCE ON SYSTEM SCIENCES (HICSS), 49., 2016, Koloa. Anais [...]. Koloa: IEEE, 2016. p. 3928-3937.

NAKAJIMA, S. Introduction to *TPM: Total Productive Maintenance*. Cambridge: Productivity Press, 1988.

NONAKA, I., & TAKEUCHI, H. *The knowledge-creating company: How Japanese companies create the dynamics of innovation*. New York: Oxford university press, 1995.

OOI, B. Y. et al. Non-Intrusive / Remote Operation Status Tracking for Legacy Machines via Sound Recognition using IoT. IEEE International Conference on Instrumentation and Measurement, Proceedings, 2020/2022.

PELÁEZ, A. **10 benefícios da manutenção preditiva em projetos IoT**. Ubidots, 2021. Disponível em: <https://ubidots.com/blog/iot-predictive-maintenance/>. Acesso em: 30 mar. 2025.

REY, L. *Planejamento e Elaboração de Pesquisas*. Rio de Janeiro: Editora Científica, 1993.

WEN, X. et al. Sustainable Diffusion-based Incentive Mechanism for Generative AI-driven Digital Twins in Industrial Cyber-Physical Systems. arXiv preprint arXiv:2404.XXXX / IEEE Transactions on Industrial Cyber-Physical Systems, 2024–2025.