

CAPÍTULO 4

TRANSIÇÃO ESTRATÉGICA DA MANUTENÇÃO CORRETIVA PARA A MANUTENÇÃO PREDITIVA COM SUPORTE DE INTELIGÊNCIA ARTIFICIAL: ESTUDO DE CASO APLICADO À FÁBRICA DA COCA-COLA EM MATOLA-GARE.

Matheus Pedroso de Oliveira

Centro Universitário Augusto Motta (UNISUAM), Engenharia de Produção.
matheuspedroso@souunisuam.com.br

Nathalia Nair Dias da Silva

Centro Universitário Augusto Motta (UNISUAM), Engenharia de Produção.
nathalia.dias@souunisuam.com.br

Victor Franco Ferreira

Centro Universitário Augusto Motta (UNISUAM), Engenharia de Produção.
victorfranco@souunisuam.com.br

George Gilberto Gomes Junior

Professor Mestre em Engenharia de Materiais
Centro Universitário Augusto Motta (UNISUAM), unidade Bonsucesso
george.junior@souunisuam.com.br

Leonardo Lopes de Campos

Mestre em Desenvolvimento Local com ênfase em Cadeias Produtivas Sustentáveis
Centro Universitário Augusto Motta (UNISUAM)
leonardolopes@souunisuam.com.br

Everton Rangel Bispo

Professor Doutor em Engenharia de Materiais e Processos Metalúrgicos
Centro Universitário Augusto Motta (UNISUAM), unidade Bonsucesso
evertonbispo@souunisuam.edu.br

RESUMO

Este artigo examina a substituição da ineficiente Manutenção Corretiva pela Manutenção Preditiva potencializada pela Inteligência Artificial (IA). A Manutenção Corretiva, por ser reativa, gera interrupções não planejadas e altos custos emergenciais. Em contraste, a Manutenção Preditiva, utilizando sensores de IoT e algoritmos de IA, processa dados em tempo real (vibração, temperatura) para prever a probabilidade e o momento exato da falha. IA transforma a gestão de ativos de reativa para proativa, permitindo intervenções programadas e otimizadas. As principais vantagens desta abordagem incluem a drástica redução de custos operacionais e de materiais, o aumento da disponibilidade e vida útil dos equipamentos e a melhoria da segurança no trabalho. Conclui-se que a Manutenção Preditiva com IA é uma

prioridade essencial da Indústria 4.0, garantindo maior eficiência operacional e competitividade.

Palavras-Chave: Manutenção Preditiva; Inteligência Artificial; Manutenção Corretiva; Indústria 4.0; Gestão de Ativos; IoT; Redução de Custos.

INTRODUÇÃO

Segundo Higgins, Mobley e Smith (2002) em um cenário industrial de crescente competitividade, a confiabilidade de ativos e a eficiência de processos produtivos emergem como elementos cruciais para a sustentabilidade e o desempenho operacional das organizações. Nesse contexto, a gestão da manutenção desempenha um papel estratégico, com impacto direto na produtividade, segurança e custos operacionais.

A manutenção corretiva é caracterizada por intervenções reativas após a ocorrência de falhas. Contudo, apesar de uma percepção inicial de baixo custo, esse modelo tem se mostrado ineficiente a médio e longo prazo, resultando em paradas não planejadas, perdas de produção e elevados custos associados a emergências técnicas.

Diante desse panorama, o presente estudo propõe uma transição da manutenção corretiva para a manutenção preditiva. A fundamentação dessa proposta se baseia no estudo de caso conduzido por Nunes Fernando Machava (2023) na fábrica da Coca-Cola em Matola-Gare, Moçambique. Esse caso real evidencia, de forma prática, os impactos operacionais negativos da abordagem reativa e as oportunidades de melhoria com a implementação de técnicas preditivas.

Adicionalmente, esta pesquisa expande a proposta original de Machava por meio da integração da inteligência artificial (IA) na estratégia de manutenção preditiva. Essa aliança visa aprimorar a tomada de decisão, permitir a antecipação de falhas críticas e automatizar o gerenciamento de ordens de serviço. A abordagem busca, assim, reposicionar o setor de manutenção para um pilar de vantagem competitiva e excelência operacional.

A partir dessa base teórica e prática, este trabalho busca responder à seguinte questão de pesquisa: "Em que medida a implementação de uma estratégia de manutenção preditiva, suportada por inteligência artificial, pode aumentar a disponibilidade de ativos críticos, reduzir custos e otimizar o desempenho operacional em contextos industriais que ainda se baseiam em modelos reativos?"

Para abordar a questão, são explorados os aspectos técnicos e operacionais da manutenção preditiva. A análise considera tanto os resultados do estudo de caso quanto às inovações propostas. O objetivo final é fornecer um modelo replicável que possa ser implementado em outras organizações industriais que enfrentam desafios similares.

OBJETIVO GERAL

Analisar a viabilidade e os impactos da implementação de uma estratégia de manutenção preditiva, otimizada com o uso de inteligência artificial, em substituição ao modelo corretivo tradicional, com base no estudo de caso da Coca-Cola em Matola-Gare.

Objetivo específico

- a) Identificar os principais prejuízos operacionais decorrentes da manutenção corretiva no sistema de refrigeração da planta analisada;
- b) Apresentar as técnicas utilizadas na manutenção preditiva (análise de vibração, termografia, tribologia e ultrassom);
- c) Investigar os benefícios da integração da inteligência artificial no processo de manutenção preditiva;
- d) Propor um modelo replicável de gestão de manutenção para outras indústrias com desafios similares;

JUSTIFICATIVA

A escolha do tema se justifica pela necessidade crescente das indústrias em aumentar a confiabilidade dos ativos e reduzir custos operacionais, alinhando-se às exigências da Indústria 4.0. A manutenção preditiva, aliada à inteligência artificial, representa uma solução inovadora e eficaz para reduzir riscos, prevenir falhas e melhorar o desempenho produtivo. O estudo contribui para o avanço do conhecimento técnico-científico na área de engenharia de manutenção, além de oferecer um modelo prático e aplicável a diversos contextos industriais que ainda adotam práticas reativas.

ESTUDO DE CASO: CRÍTICA À MANUTENÇÃO CORRETIVA E PROPOSTA DE MANUTENÇÃO PREDITIVA NA COCA-COLA.

O modelo de manutenção corretiva, que se manifesta pela intervenção reativa após a ocorrência de uma falha, tem sido objeto de intensa crítica no âmbito industrial. Essa abordagem, que negligencia a previsibilidade das falhas, acarreta interrupções na produção que afetam a competitividade e resultam em perdas financeiras significativas, uma vez que a correção emergencial de falhas é a abordagem menos econômica (LIMA, 2011).

Um exemplo disso foi o estudo de caso na fábrica da Coca-Cola da Matola-Gare, em Moçambique, que identificou um ponto crítico de vulnerabilidade que reside no sistema de refrigeração *chiller*. Este equipamento é indispensável para o processo de produção, pois garante que a temperatura do xarope seja reduzida e mantida a 14 °C para posterior engarrafamento. A falha inesperada do sistema de refrigeração pode paralisar a produção de refrigerantes, causando consideráveis perdas financeiras e atrasos. Contudo, a dependência da fábrica ao tipo de

manutenção corretiva para os *chillers* resulta em danos significativos (MACHAVA, 2023). A dinâmica da competitividade de mercado exige que as indústrias operem em um estado de prontidão contínua para atender às demandas do consumidor, um esforço que só se sustenta com a eficiência plena de seus equipamentos. A opção por este modelo reativo, portanto, expõe a operação a riscos e custos imprevistos, em clara desvantagem em relação às abordagens proativas.

Ademais, a transição para um novo paradigma de manutenção, focado na prevenção e na predição, é uma alternativa para mitigar os riscos associados ao modelo corretivo. A manutenção preditiva, em particular, utiliza o monitoramento de variáveis para antecipar falhas, reduzindo custos e aumentando a vida útil dos equipamentos (LIMA, 2011). Logo, a implementação de um plano preditivo na Coca-Cola da Matola-Gare, com foco no sistema chiller, tem como objetivo principal otimizar o desempenho, a partir da adoção de técnicas específicas de monitoramento. O estudo de Machava (2023) apresenta uma solução robusta ao propor a implementação de um plano de manutenção preditiva para o sistema de refrigeração *chiller*. Ao contrário da manutenção corretiva, a preditiva se baseia na monitoração constante das condições do equipamento para identificar falhas que vão gradativamente evoluindo para falhas mais graves e antecipar a necessidade de reparos. O autor fundamenta sua proposta em um conjunto de técnicas e equipamentos que, em conjunto, criam um diagnóstico abrangente da saúde do sistema:

- a) **Análise de Vibração:** Essencial para o monitoramento do compressor, um dos componentes mais críticos. A utilização de um monitor como o NK200 permite a identificação de padrões de vibração anormais que sinalizam desgaste ou desalinhamento.
- b) **Termografia:** Destinada à vigilância dos trocadores de calor, como condensador e o evaporador. A medição de anomalias de temperatura com um scanner como o SUPER-DAQ 1586A é fundamental, uma vez que variações térmicas são um dos primeiros indicadores de falhas que comprometem a qualidade do produto.
- c) **Análise de Óleo (Tribologia):** Uma técnica para rastrear o desgaste das peças e a condição do lubrificante. O Minilab 153, por exemplo, permite uma análise completa do óleo, revelando contaminação, viscosidade inadequada e a presença de partículas de desgaste.
- d) **Ultrassom:** Empregado na detecção precoce de vazamentos em tubulações e válvulas. O detector LD 300, proposto no estudo, capta a alta frequência gerada pelo fluxo turbulento em pontos de fuga, algo imperceptível a olho nu.

Apesar do alto investimento inicial para a implementação, Machava (2023) argumenta que o plano se justifica financeiramente a longo prazo, por meio da redução de custos com manutenção, do aumento da vida útil

dos equipamentos e da maximização da produção. A manutenção, nesse contexto, deixa de ser vista como um gasto inesperado e passa a ser considerada uma estratégia de negócio, fundamental para a confiabilidade e eficiência da produção.

A integração de inteligência artificial: Otimizando a preditiva

Embora a proposta anterior seja tecnicamente sólida, ela pode ser aprimorada com a integração da Inteligência Artificial (IA), elevando o conceito de manutenção preditiva para um patamar mais sofisticado e automatizado. A solução, que chamaremos de Manutenção Preditiva Otimizada por IA, não substitui as técnicas de Machava (2023), mas as centraliza e potencializa.

A viabilidade dessa abordagem reside na capacidade da IA de processar grandes volumes de dados de forma contínua e autônoma, superando as limitações da intervenção humana. Com todos os sensores do *chiller* conectados a uma plataforma de IA, os algoritmos de aprendizado de máquina podem analisar dados de vibração, temperatura, qualidade do óleo e pressão em tempo real. Essa análise não se limita a identificar um problema já existente, mas a prever sua ocorrência com base em padrões complexos de dados.

A inteligência artificial pode prever a probabilidade de falha de um componente específico e gerar alertas proativos, permitindo que a equipe de manutenção planeje intervenções antes que o problema cause uma parada na produção. Essa antecipação estratégica não só minimiza os riscos, mas também permite que a empresa realize a manutenção no momento mais economicamente vantajoso. Além disso, a automação na geração de ordens de serviço e na análise de dados reduz a carga de trabalho da equipe, que pode se concentrar em tarefas de maior complexidade. A adoção desse modelo assegura uma disponibilidade quase máxima do equipamento, convertendo o departamento de manutenção de um centro de custo para um pilar estratégico da eficiência operacional. Contudo, enquanto o plano proposto por Machava (2023) se concentra em monitorar variáveis (vibração, temperatura, óleo) para diagnosticar um problema existente, a solução baseada em IA utiliza esses mesmos dados para aprender, prever a probabilidade de falha e estimar o Tempo de Vida Útil Restante (Remaining Useful Life - RUL) do equipamento.

A IA processa volumes massivos de dados multivariados para identificar padrões de falha complexos que um analista humano ou um sistema de regras simples não conseguiria detectar e isso é possível pelos componentes chave e métodos Implementação abaixo:

- a) Camada de Aquisição de Dados (Digitalização - IoT Industrial)

Esta camada é a base e expande a coleta de dados:

Sensores Aprimorados (IIoT - Industrial Internet of Things): Além dos sensores de vibração, termografia, ultrassom e análise de óleo já propostos, seriam adicionados sensores contínuos de pressão, vazão, consumo de energia elétrica, e dados operacionais diretamente do PLC (Controlador Lógico Programável) do chiller.

Exemplo de Dados Coletados: Temperatura do gás de sucção/descarga, pressão do condensador/evaporador, corrente e tensão do compressor, taxa de refrigeração e dados meteorológicos externos.

Gateway e Nuvem/Edge Computing: Os dados em alta frequência (em tempo real ou quase) são enviados para um sistema de armazenamento (nuvem ou servidores locais) para processamento.

b) Camada de Processamento e Modelagem (Machine Learning)

Pré-processamento de Dados: Limpeza, normalização e sincronização dos dados de diferentes sensores.

Desenvolvimento do Modelo de IA: Utilização de modelos de Machine Learning (ML) como:

- I) Redes Neurais Recorrentes (RNN) ou Transformadores: Excelentes para analisar séries temporais e prever o próximo estado do equipamento com base no histórico.
- II) Árvores de Decisão (como XGBoost ou Random Forest): Para identificar quais variáveis são as mais críticas para a falha e em que limiares.
- III) Modelos de Aprendizado Não-Supervisionado (Ex: Autoencoders): Para detecção de anomalias, identificando qualquer desvio do "comportamento normal" do chiller, mesmo que não seja um padrão de falha conhecido.

Treinamento: O modelo é treinado com dados históricos de operação do chiller, incluindo períodos de funcionamento normal e, crucialmente, dados que antecederam falhas passadas (se disponíveis).

c) Camada de Resultado e Ação

O resultado da IA é transformado em ações de negócio:

Geração do RUL e Probabilidade de Falha: O modelo de ML gera continuamente a estimativa do Tempo de Vida Útil Restante (RUL) do compressor e de outros componentes críticos, e a Probabilidade de Falha.

I) Alerta Inteligente: Em vez de alertar apenas sobre uma temperatura alta (como faria um sistema simples), a IA alerta, por exemplo, que "O compressor terá uma falha de rolamento com 85% de probabilidade em 15 dias".

II) Manutenção Preditiva-Prescritiva: O sistema não apenas prevê, mas prescreve a ação ideal.

Exemplo: "Agende a substituição do óleo do compressor e o alinhamento do motor em 14 dias para evitar uma interrupção não programada." Isso permite à fábrica planejar a intervenção para o momento de menor impacto na produção.

Desafios da manutenção inteligente

Apesar das inúmeras vantagens, a adoção da manutenção preditiva baseada em tecnologias da Indústria 4.0 ainda enfrenta alguns desafios. Entre eles, destaca-se a necessidade de garantir a qualidade e a consistência dos dados coletados pelos sensores, pois falhas na coleta podem comprometer toda a análise preditiva. Além disso, a implementação dessas tecnologias requer investimentos iniciais significativos em infraestrutura digital e capacitação técnica da equipe. Outro ponto crítico é a integração dos sistemas de monitoramento com os processos decisórios da empresa, exigindo mudanças culturais e operacionais.

UTILIZAÇÃO DO INDICADOR OEE (OVERALL EQUIPMENT EFFECTIVENESS) NA AVALIAÇÃO DA PROPOSTA DE MELHORIA:

O OEE (Eficácia Global do Equipamento) é um indicador crucial para medir a contribuição dos equipamentos no desempenho industrial, sendo o melhor meio para quantificar sua eficácia durante a operação. O OEE quantifica quanto valor o equipamento agrega ao produto e serve como métrica de melhoria contínua dos equipamentos e processos. Um OEE consistente de 85% é considerado uma referência de "classe mundial". Além disso, ele é um indicador obtido pela multiplicação dos fatores de Disponibilidade, Eficiência e Qualidade (SILVA,2013). O caso do chiller demonstra que a transição da manutenção corretiva para a preditiva com IA impacta diretamente a disponibilidade, que é o fator mais penalizado pelas quebras inesperadas. Diante disso, abaixo está os dados base para o cálculo.

Quadro 1

Parâmetro	Valor Base	Justificativa
Tempo Total Disponível (Planejado)	24.000 minutos (17 dias de 24h)	Base de cálculo para um período de 17 dias de operação contínua.
Tempo de Parada Programada	2.400 minutos	Paradas planejadas (limpeza, setup, inspeções). Equivalente a 10% do Tempo Total.
Tempo de Ciclo Ideal	100 garrafas por minuto	Velocidade máxima nominal de produção da linha de engarrafamento.
Meta de Qualidade (Q)	99,0\%	Padrão alto da indústria de bebidas.
Fórmula OEE	$OEE = D \times P \times Q$	Disponibilidade x Desempenho x Qualidade

3.1 Cenário antes: Manutenção Corretiva

Cálculo da Disponibilidade (D)

Quadro 2

Componente de Tempo	Valor (Minutos)	Impacto da Corretiva
Tempo Operacional Total (A)	24.000 min	Tempo total do período.
Parada Programada (B)	2.400 min	Setup, limpezas.

Parada Não Programada (Falhas do Chiller)	3.600 min (60 horas)	Longas paradas devido à falha inesperada, diagnóstico e espera por peças (característica da Corretiva).
Tempo de Produção Líquido (C)	A - B - (Falhas Chiller) = 24.000 - 2.400 - 3.600	18.000 min

Fórmula: $D = \frac{\text{Tempo de Produção Líquido}}{\text{Tempo Disponível de Produção}} = \frac{C}{A-B}$

$$D = \frac{18.000 \text{ min}}{24.000 \text{ min} - 2.400 \text{ min}} = \frac{18.000}{21.600} \approx 0,8333$$

$$D_{\text{Corretiva}} \approx 83,33\%$$

Cálculo do Desempenho (P):

Quadro 3

Componente de Velocidade	Valor	Justificativa
Produção Real (Boa + Ruim)	1.700.000 garrafas	Produção efetivamente realizada no tempo líquido (C).
Produção Ideal (Teórica)	1.800.000 garrafas	18.000 min x 100/min (Baseado no Tempo de Produção Líquido).

Fórmula: $P = \frac{\text{Produção Real}}{\text{Produção Ideal}}$

$$P = \frac{1.700.000 \text{ garrafas}}{1.800.000 \text{ garrafas}} \approx 0,9444$$

$$P_{\text{Corretiva}} \approx 94,44\%$$

Cálculo da Qualidade (Q)

Quadro

4

Componente de Qualidade	Valor	Justificativa
Produção Total	1.700.000 garrafas	Produção Real.
Garrafas Reprovadas (Refugo)	34.000 garrafas	Refugo de 2% (4% acima do ideal de 99%).
Produção Boa	1.700.000 - 34.000 = 1.666.000\$ garrafas	Produto final conforme as especificações.

Fórmula: $Q = \frac{\text{Produção Boa}}{\text{Produção Real}}$

$$Q = \frac{1.666.000 \text{ garrafas}}{1.700.000 \text{ garrafas}} \approx 0,9800$$

$$Q_{\text{Corretiva}} = 98,00\%$$

OEE final:

$$OEE_{\text{Corretiva}} = D \times P \times Q$$

$$OEE_{\text{Corretiva}} = 0,8333 \times 0,9444 \times 0,9800$$

$$OEE_{\text{Corretiva}} \approx 77,06\%$$

3.2 Cenário após: Manutenção preditiva e IA

Cálculo da Disponibilidade (D)

Quadro 5

Componente de Tempo	Valor (Minutos)	Impacto da MP-IA
Parada Não Programada (Pós-IA)	360 min	Redução drástica das falhas críticas. (10% do tempo de parada anterior).
Tempo de Produção Líquido (C)	24.000 - 2.400 - 360	21.240 min

Fórmula: $D = \frac{\text{Tempo de Produção Líquido}}{\text{Tempo Disponível de Produção}}$

$$D = \frac{21.240 \text{ min}}{21.600 \text{ min}} \approx 0,9833$$

$$D_{\text{MP-IA}} \approx 98,33\%$$

Cálculo do Desempenho (P)

A intervenção preditiva e o monitoramento contínuo da IA garantem que o *chiller* e o compressor operem em condições ótimas.

Previsão de Desempenho: A manutenção preditiva e IA elimina perdas de velocidade e mantém a linha operando muito próxima da capacidade ideal.

$$P_{\text{MP-IA}} = 98,50\%$$

Cálculo da Qualidade (Q)

A IA monitora a termografia e a pressão (parâmetros de qualidade do xarope) continuamente, evitando desvios antes que afetem o produto. A meta é atingir ou superar o padrão de 99%.

$$Q_{\text{MP-IA}} = 99,00\%$$

OEE Final (Preditiva com IA)

$$OEE_{MP-IA} = D \times P \times Q$$

$$OEE_{MP-IA} = 0,9833 \times 0,9850 \times 0,9900$$

$$OEE_{MP-IA} \approx 95,78\%$$

A implementação da Manutenção Preditiva Otimizada por IA no sistema *chiller* supera significativamente de 80% de OEE, levando a planta para o patamar de excelência operacional.

Quadro 6

Fator OEE	Cenário 1: Manutenção Corretiva	Cenário 2: Manutenção Preditiva com IA
Disponibilidade (D)	83,33%	98,33%
Desempenho (P)	94,44%	98,50%
Qualidade (Q)	98,00%	99,00%
OEE Total	77,06%	95,78%

O ganho mais expressivo está na Disponibilidade, que aumenta em 15 pontos percentuais, provando que a eliminação de paradas não planejadas pelo uso da IA é o principal fator de otimização de custo e produção.

METODOLOGIA DE MELHORIA CONTÍNUA APLICADA À MANUTENÇÃO PREDITIVA

A adoção de metodologias de melhoria contínua, como o ciclo PDCA (Plan, Do, Check, Act), tem se mostrado eficaz na identificação e na resolução de problemas, garantindo um modelo de gestão mais direcionado. A gestão da manutenção , por sua vez, se constitui de ações, normas e instruções relacionadas a um sistema estruturado, cujo a finalidade é definir objetivos e metas para obter o melhor aproveitamento de pessoas, equipamentos e materiais (Teixeira, 2015). Todas essas estratégias necessitam de uma ferramenta de gestão que possibilite a correta utilização dos recursos disponíveis e assegure o alcance dos resultados desejados. Nesse contexto, o ciclo PDCA, composto pelas etapas de Planejamento (P), Execução (D), Monitoramento (C) e Ações corretivas (A), mostra-se uma ferramenta ideal

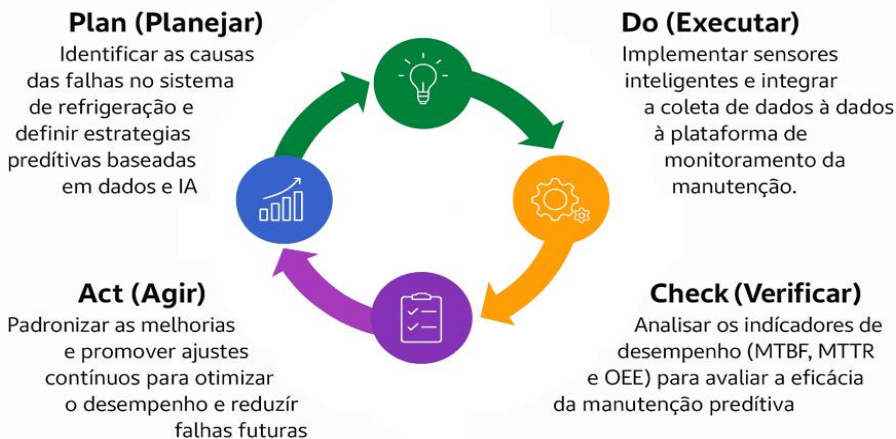
para a gestão da manutenção, devido a sua simplicidade e à promoção da melhoria contínua.

O ponto de partida é o exemplo observado na fábrica da Coca-Cola da Matola-Gare, em Moçambique, onde o sistema de refrigeração (chiller) foi identificado como um ponto crítico de vulnerabilidade devido à dependência da manutenção corretiva. A falha inesperada deste equipamento, indispensável para manter a temperatura do xarope a 14 °C, pode paralisar a produção de refrigerantes e gerar perdas consideráveis, evidenciando a importância de aplicar o PDCA como suporte para uma transição estratégica rumo à manutenção preditiva.

Metodologia (Ciclo PDCA)

PDCA é uma metodologia de gestão voltada para a melhoria contínua de processos, produtos e serviços. É um ciclo contínuo de planejamento, execução, verificação e ação, que busca garantir a eficiência, reduzir falhas e promover a evolução constante nas organizações.

Figura 1



Fonte: De autoria própria (2025)

Plan (Planejar)

O início da transição é estruturado pela etapa Plan do ciclo PDCA, focada em definir o problema e o plano de ação. O problema central é a baixa disponibilidade do chiller devido ao modelo corretivo. Para detalhar as causas, utiliza-se o Diagrama de Ishikawa (Análise da Causa-Raiz). O plano de ação é a implementação da Manutenção Preditiva Otimizada por IA, que integra as técnicas de campo com a análise preditiva dos algoritmos.

Diagrama de Ishikawa

No contexto da gestão da qualidade e da melhoria contínua de processos, o Diagrama de Causa e Efeito também conhecido como Diagrama de Ishikawa ou Espinha de Peixe se destaca como um instrumento tradicional, porém indispensável. Sua função primária reside em auxiliar na identificação e no mapeamento das causas fundamentais (causas-raiz) que levam a um problema ou resultado indesejado (CARVALHO; PALADINI, 2012).

Em termos de estrutura, o Diagrama de Ishikawa é caracterizado por um processo analítico que se apoia em um conjunto de categorias predefinidas, universalmente conhecidas como 6Ms. Tais categorias representam os eixos principais de onde se originam as causas e englobam: Método, Máquina, Medida, Meio Ambiente, Mão de Obra e Material (ALMEIDA *et al.*, 2017). Embora essa seja a estrutura completa, é crucial reconhecer a flexibilidade do modelo: nem sempre todas as seis categorias serão pertinentes ao detalhamento das causas, permitindo que a análise se ajuste à realidade específica do processo em estudo.

Adicionalmente, para que o diagrama seja construído de maneira eficaz, a simples aplicação do modelo dos 6Ms não é suficiente. É fundamental o envolvimento ativo da equipe que executa o processo. A experiência e o conhecimento prático dos colaboradores são insubstituíveis. Por isso, Nascimento (2021) estabelece que o desenvolvimento do diagrama exige a realização de uma sessão consultiva com os responsáveis diretos pela execução. Essa prática é vital para extrair a expertise do grupo, garantindo que as informações utilizadas na montagem do Diagrama de Ishikawa (Figura 2) reflitam a realidade operacional e resultem em um diagnóstico preciso e completo

Figura 2



Fonte: De autoria própria (2025)

Do (Executar)

O OEE (Eficácia Global do Equipamento) é um indicador crucial para medir a contribuição dos equipamentos no desempenho industrial, sendo o melhor meio para quantificar sua eficácia durante a operação. A etapa Do envolve a instalação física dos sensores preditivos no *chiller* e, criticamente, a integração desses dados em tempo real na plataforma de IA. A execução se manifesta na alteração do fluxo de trabalho: as intervenções de manutenção passam a ser disparadas por alertas preditivos da IA (e não pela falha do equipamento), permitindo que a equipe execute o reparo planejado.

Check (Verificar)

A etapa Check valida a eficácia da nova estratégia. O principal indicador de verificação é o OEE (*Overall Equipment Effectiveness*), que mede a eficácia do equipamento combinando Disponibilidade, Performance e Qualidade.

A intervenção preditiva e a automação de processos pela IA devem resultar em um aumento na Disponibilidade (redução do Tempo de Parada Não Planejada) e na Qualidade (redução de perdas e falhas do produto final). A análise dos novos valores do OEE valida o impacto financeiro e operacional da transição.

Act (Agir)

A etapa Act tem como objetivo padronizar e consolidar as melhorias. As ações de manutenção que demonstram eficácia são convertidas em planos de manutenção e procedimentos operacionais padrão.

O modelo de manutenção Preditiva Otimizada por IA é formalizado, com a criação de Dashboards de acompanhamento diário para monitoramento contínuo. O sucesso da intervenção torna o modelo replicável em outras organizações industriais que enfrentam desafios similares.

DISCUSSÃO E CONTRIBUIÇÃO ORIGINAL

Resultados e Implicações (Validando a fase Check)

A etapa de Verificação (Check) do ciclo PDCA é crucial para validar a transição da manutenção corretiva para a preditiva otimizada com IA. A eficácia da nova estratégia é quantificada pelo indicador OEE (*Overall Equipment Effectiveness*).

A) Aumento na Disponibilidade: A intervenção preditiva, planejada com base nos alertas gerados pela Inteligência Artificial, permite uma redução significativa nas paradas não planejadas. Essa antecipação estratégica no ativo crítico (o *chiller*) garante maior disponibilidade e permite que a manutenção seja realizada no momento mais economicamente vantajoso.

B) **Sustentabilidade da Qualidade:** Ao garantir que o equipamento opere dentro das condições ideais por meio de monitoramento contínuo, o processo contribui para a estabilidade e a qualidade do produto final, reduzindo perdas e falhas, conforme refletido no fator Qualidade do OEE.

C) **Validação Metodológica:** O aumento no OEE geral valida o plano de implementação (MP com IA). Embora a parte descritiva (o que foi feito) esteja bem desenvolvida, a implicação é que a abordagem estruturada do PDCA torna a melhoria tangível e mensurável, diferentemente do modelo corretivo.

Contribuição da Inteligência Artificial (Inovação no PLAN)

A integração da IA representa a principal contribuição original deste trabalho. A IA otimiza a Manutenção Preditiva, superando as limitações da intervenção humana, conforme proposto na fase Plan.

A) **Previsão Preditiva Avançada (Inovação Autoral):** A IA não se limita a detectar anomalias (função das técnicas preditivas), mas a prever a probabilidade de falha e estimar o tempo de vida útil remanescente (RUL) por meio da análise de grandes volumes de dados. Isso reforça o que exatamente é a inovação proposta pelos autores e não apenas uma extensão do estudo de Machava.

B) **Automação e Eficiência:** A IA potencializa as ações da fase Do ao automatizar a geração de ordens de serviço e a análise de dados. Essa automação converte o departamento de manutenção de um centro de custo para um pilar estratégico da eficiência operacional.

4.2.3 Implicações e Replicabilidade (Direcionamento da Fase ACT)

A fase Act do PDCA foca na padronização e no aprendizado, garantindo a sustentabilidade e a relevância prática do trabalho.

A) **Replicabilidade do Modelo:** A base teórica, a aplicação do PDCA e o uso do OEE estão bem alinhados com a área, o que confere ao trabalho um valor de replicabilidade em outras plantas industriais. O modelo de MP Otimizada por IA deve ser formalizado para que outras indústrias com desafios similares possam adotá-lo.

B) **Limitações e Desafios:** É crucial discutir as implicações críticas. O sucesso da transição exige o reconhecimento de barreiras de implementação real, incluindo investimentos iniciais significativos em infraestrutura e capacitação técnica da equipe. Além disso, a qualidade e a consistência dos dados coletados pelos sensores são críticas para não comprometer a análise preditiva.

CONCLUSÃO

A transição da manutenção corretiva para a manutenção preditiva com suporte de inteligência artificial representa uma mudança estratégica essencial para o aumento da confiabilidade e da eficiência operacional nas indústrias modernas. O estudo de caso aplicado à fábrica da Coca-Cola em Matola-Gare evidenciou, de forma clara, as limitações do modelo corretivo, responsável por paradas não planejadas, desperdícios de recursos e comprometimento da produtividade. Em contrapartida, a implementação de um plano de manutenção preditiva otimizado pela IA demonstrou ganhos expressivos em disponibilidade, desempenho e qualidade refletidos na elevação do OEE de 77,06% para 95,78%, aproximando a planta dos padrões de classe mundial.

A análise desenvolvida confirmou que o uso de sensores inteligentes, combinados a algoritmos de aprendizado de máquina, permite prever falhas com antecedência, reduzindo custos e tempo de inatividade. A integração da IA amplia a capacidade de decisão, transformando a manutenção em uma atividade estratégica e não apenas corretiva, capaz de gerar vantagem competitiva e sustentabilidade operacional.

O emprego do ciclo PDCA como metodologia de melhoria contínua mostrou-se fundamental para estruturar o processo de mudança, garantindo que cada fase — planejamento, execução, verificação e padronização — fosse conduzida de forma sistemática e mensurável. Tal abordagem consolidou a aplicabilidade do modelo e reforçou seu potencial replicabilidade em outras plantas industriais com desafios semelhantes.

Conclui-se, portanto, que a manutenção preditiva otimizada por inteligência artificial não apenas melhora o desempenho técnico dos equipamentos, mas redefine o papel da manutenção dentro da organização, elevando-a ao patamar de ferramenta estratégica de gestão.

REFERÊNCIAS BIBLIOGRÁFICAS

MACHAVA, Nunes Fernando. Proposta de implementação de um plano de manutenção preditiva para o sistema de refrigeração chiller na Coca-Cola da Matola- Gare. 2023.

MOBLEY, R. Keith. *Maintenance Fundamentals*. 2. ed. New York: Butterworth-Heinemann, 2002.

HIGGINS, Lindley R. *Maintenance Engineering Handbook*. 6. ed. New York: McGraw-Hill, 2002.

DA SILVA LIMA, Leandro. Uma Abordagem Sobre a Manutenção Preventiva Como Meio Para Diminuir a Manutenção Corretiva, Pitágoras 2011

CARVALHO, Marly Monteiro, PALADINI, Edson Pacheco. Gestão da Qualidade: Teoria da Qualidade. Rio de Janeiro: Campos. 2005.

SILVA, M. T.; ALMEIDA, D. R.

Manutenção preditiva com sensores inteligentes: estudo de caso em sistemas de refrigeração da indústria alimentícia. Revista Brasileira de Engenharia de Produção, v. 28, n. 2, p. 77–90, 2013.

BUSO, Christianne Matias; MIYAKE, Dario Ikuo. Análise da aplicação de indicadores alternativos ao Overall Equipment Effectiveness (OEE) na gestão do desempenho global de uma fábrica. Production, v. 23, p. 205-225, 2013.

Teixeira, Matheus; Silva, Sérgio R.; Medeiros, Jailson T. O CICLO PDCA COMO FERRAMENTA PARA ALCANÇAR A EFICIÊNCIA E EFICÁCIA NA GESTÃO DA MANUTENÇÃO (2015)