ConBRepro
XVI CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO
EVENTO ON-LINE
02 a 04 de dezembro de 2026
Inovação e Transformação Digital como Estratégia Competitiva nas Engenharias

Da Melhoria Contínua à Melhoria Inteligente: Inteligência Artificial como Potencializadora dos Programas de Produtividade na Cadeia de Suprimentos

Petros Augustynczk Samways
Programa de Pós-Graduação em Engenharia de Produção (PPGEP) - Universidade Tecnológica Federal do Paraná (UTFPR), Ponta Grossa - PR
Joao Luiz Kovaleski
Programa de Pós-Graduação em Engenharia de Produção (PPGEP) - Universidade Tecnológica Federal do Paraná (UTFPR), Ponta Grossa - PR

Resumo: A crescente complexidade das cadeias de suprimentos amplia a necessidade de reduzir desperdícios, variabilidade, paradas, estoques e tempos de resposta sem comprometer qualidade e nível de serviço. Programas de produtividade como Lean, Six Sigma, Kaizen, Total Productive Maintenance (TPM), PDCA, Sales and Operations Planning (S&OP) e SCOR oferecem métodos consolidados para melhoria do desempenho, porém frequentemente dependem de análises periódicas, amostras, reuniões e elevada intervenção humana para transformar dados em decisões. Este artigo analisa de que maneira a Inteligência Artificial (IA) pode potencializar esses programas ao adicionar capacidades de detecção contínua, previsão, recomendação, simulação e automação. O objetivo é propor uma síntese comparativa e um framework conceitual que conecte programas tradicionais de produtividade, dados operacionais, capacidades de IA e resultados na cadeia de suprimentos. A pesquisa é qualitativa, exploratória e bibliográfica, combinando literatura clássica sobre produtividade com estudos recentes sobre IA em manufatura e supply chain. Como resultado, apresenta-se uma tabela comparativa contendo, para sete programas, a lógica sem IA, o mecanismo de potencialização, a situação antes e o resultado potencial depois da integração. Propõe-se ainda um ciclo de cinco etapas - programas e dados, camada de IA, decisão e ação, resultado operacional e aprendizagem - que transforma a melhoria contínua em melhoria inteligente orientada por evidências. Conclui-se que a IA não substitui os programas de produtividade; amplia sua velocidade, granularidade e capacidade preventiva, desde que existam dados confiáveis, integração de sistemas, governança e participação humana.

Palavras-chave: Inteligência Artificial, Programas de produtividade, Cadeia de suprimentos, Melhoria contínua, Indústria 4.0.

From Continuous Improvement to Intelligent Improvement: Artificial Intelligence as an Enabler of Productivity Programs in the Supply Chain

Abstract: The growing complexity of supply chains increases the need to reduce waste, variability, downtime, inventories and response times without compromising quality and service levels. Productivity programs such as Lean, Six Sigma, Kaizen, Total Productive Maintenance (TPM), PDCA, Sales and Operations Planning (S&OP) and SCOR provide established methods for performance improvement, but they often depend on periodic analyses, samples, meetings and substantial human effort to convert data into decisions. This paper analyzes how Artificial Intelligence (AI) can enhance these programs by adding continuous detection, prediction, recommendation, simulation and automation capabilities. The objective is to propose a comparative synthesis and a

conceptual framework linking traditional productivity programs, operational data, AI capabilities and supply chain outcomes. The study adopts a qualitative, exploratory and bibliographic approach, combining classic productivity literature with recent research on AI in manufacturing and supply chains. As a result, a comparative table is presented for seven productivity programs, showing the non-AI logic, the AI enhancement mechanism, the before condition and the potential after condition. A five-stage cycle is also proposed - programs and data, AI layer, decision and action, operational results and learning - to transform continuous improvement into evidence-driven intelligent improvement. The study concludes that AI does not replace productivity programs; it increases their speed, granularity and preventive capacity, provided that reliable data, system integration, governance and human participation are available.

Keywords: Artificial Intelligence, Productivity programs, Supply chain, Continuous improvement, Industry 4.0.

1. Introdução

As cadeias de suprimentos contemporâneas precisam conciliar objetivos que frequentemente competem entre si: menor custo, maior disponibilidade, qualidade, rapidez, flexibilidade, sustentabilidade e resiliência. A expansão das redes globais, a volatilidade da demanda, os riscos logísticos e a crescente quantidade de dados operacionais tornam a gestão da produtividade um problema cada vez mais dependente de informação e velocidade decisória. O material que motivou este estudo sintetiza esse desafio ao relacionar globalização, demanda instável, riscos logísticos, sustentabilidade, estoques, transporte e produção como fontes simultâneas de complexidade na supply chain.

Historicamente, empresas respondem a esse desafio por meio de programas e metodologias de produtividade. Lean busca eliminar desperdícios e aumentar fluxo; Six Sigma concentra-se na redução da variabilidade e de defeitos; Kaizen estrutura a melhoria contínua; Total Productive Maintenance (TPM) procura maximizar a eficiência dos ativos; PDCA disciplina ciclos de planejamento, execução, verificação e ação; S&OP integra demanda, suprimento e capacidade; e o modelo SCOR organiza processos e indicadores de desempenho da cadeia. Apesar das diferenças, essas abordagens compartilham um princípio: desempenho superior depende de identificar desvios, compreender causas e agir sobre o processo.

O problema é que o ambiente de dados mudou mais rapidamente do que muitas rotinas de melhoria. Sensores, ERP, WMS, TMS, sistemas de compras, plataformas de fornecedores, dados de clientes e fontes externas passaram a produzir volumes e velocidades de informação que excedem a capacidade de análise manual. Em muitos contextos, o gargalo deixou de ser a simples coleta de dados e passou a ser a capacidade de transformá-los em sinais, previsões, prioridades e decisões acionáveis em tempo adequado. Essa situação abre espaço para a Inteligência Artificial (IA) como uma camada analítica capaz de complementar os programas existentes.

A literatura recente indica que a IA em supply chain e manufatura abrange previsão, classificação, reconhecimento de padrões, detecção de anomalias, otimização, processamento de linguagem natural e sistemas de suporte a decisão. Culot, Podrecca e Nassimbeni (2024), ao revisarem estudos empíricos de IA em supply chain, destacam requisitos de dados e sistemas, processos de implantação, integração interorganizacional e implicações de desempenho. Gao et al. (2024) mostram que, na manufatura, aplicações de IA se estendem do projeto e planejamento de sistemas a controle de qualidade, manutenção e otimização. Assim, a questão relevante não é apenas se a IA melhora produtividade, mas como ela modifica a forma pela qual programas tradicionais identificam problemas e executam a melhoria.

Este artigo parte da proposição de que a IA atua como potencializadora, e não como substituta, dos programas de produtividade. Os princípios metodológicos permanecem

relevantes, mas ganham uma nova camada de capacidade analítica: o Lean pode identificar desperdícios continuamente; o Six Sigma pode antecipar defeitos; o Kaizen pode receber oportunidades sugeridas por dados; o TPM pode evoluir da manutenção preventiva para preditiva; o PDCA pode reduzir o tempo entre observar e agir; o S&OP pode incorporar previsões e simulações; e o SCOR pode combinar mensuração de desempenho com diagnóstico prospectivo.

Diante disso, o objetivo do artigo é analisar como a IA pode potencializar os principais programas de produtividade aplicados à cadeia de suprimentos e propor um framework conceitual para essa integração. A pergunta de pesquisa é: de que forma capacidades de IA alteram a lógica de funcionamento dos programas de produtividade e quais resultados operacionais podem ser potencializados na supply chain? Como contribuição, apresenta-se uma tabela comparativa de "antes e depois" para sete programas e um ciclo conceitual que conecta dados, IA, decisão, resultados e aprendizagem.

O artigo está estruturado em cinco seções. A primeira contextualiza o problema e o objetivo. A segunda apresenta o método. A terceira revisa os fundamentos dos programas de produtividade e as capacidades de IA relevantes. A quarta apresenta os resultados da síntese, a tabela comparativa, o framework proposto e uma ilustração empírica de metas de desempenho. A quinta seção discute conclusões, limitações e oportunidades de pesquisa futura.

2. Metodologia

A pesquisa caracteriza-se como qualitativa, exploratória e bibliográfica, com finalidade de síntese conceitual. A escolha desse desenho decorre do objetivo de aproximar duas correntes de literatura que muitas vezes aparecem separadas: programas tradicionais de produtividade e estudos sobre Inteligência Artificial aplicada à manufatura e cadeia de suprimentos. O trabalho não pretende medir causalmente o efeito de uma tecnologia específica nem apresentar resultados experimentais próprios; busca construir uma estrutura comparativa fundamentada para orientar pesquisa e aplicação gerencial.

O procedimento de revisão foi organizado em três blocos. O primeiro reuniu referências clássicas associadas aos programas abordados: sistema Toyota/Lean, Kaizen, TPM, ciclo PDCA, S&OP e mensuração de desempenho da supply chain. O segundo reuniu literatura recente sobre IA em supply chain, manufatura inteligente, previsão, manutenção, compras e desempenho. O terceiro bloco concentrou estudos que mostram integração entre tecnologias digitais e metodologias de melhoria, bem como evidências de que algoritmos podem apoiar previsão, monitoramento e decisão.

A análise foi conduzida por comparação temática. Para cada programa, foram identificados: a) o objetivo primário; b) a forma tradicional de observar o processo; c) a decisão típica gerada pelo programa; d) a capacidade de IA potencialmente complementar; e) o efeito esperado sobre velocidade, antecipação ou precisão; e f) indicadores de supply chain relacionados. A partir dessa comparação, foi construída uma matriz de "sem IA" e "com IA". Os resultados descritos como "depois" representam direções potenciais de melhoria fundamentadas na literatura e não devem ser interpretados como percentuais universais garantidos.

Como etapa final, os mecanismos recorrentes foram consolidados em um framework de cinco etapas: programas e dados; camada de IA; decisão e ação; resultado operacional; e aprendizagem. O framework possui natureza prescritiva-conceitual. Sua função é explicar como os princípios de produtividade podem permanecer como sistema de gestão enquanto a IA acrescenta capacidade de analisar maior volume de informações, reconhecer padrões, prever desvios e recomendar respostas. A validação quantitativa do framework fica como etapa posterior.

Tabela 1 - Eixos utilizados na síntese conceitual

Eixo	Questão de análise	Exemplos de referências
Programas de produtividade	Qual princípio, problema e indicador cada programa organiza?	Ohno (1988); Imai (1986); Nakajima (1988); Deming (1986); Thomé et al. (2012)
Capacidades de IA	Que capacidades analíticas alteram observação, previsão e decisão?	Gao et al. (2024); Culot, Podrecca e Nassimbeni (2024)
Supply chain digital	Como dados e integração afetam resposta e desempenho?	Zhao, Hong e Lau (2023); Spreitzenbarth, Bode e Stuckenschmidt (2024)
Desempenho e aplicação	Como conectar IA a indicadores e resultados operacionais?	Lima-Junior e Carpinetti (2019); Walter (2023)

Fonte: Elaborado pelos autores (2026)

3. Referencial teórico

3.1 Programas de produtividade e sua lógica de melhoria

O conceito de produtividade, em Engenharia de Produção, está associado à relação entre resultados obtidos e recursos empregados, mas os programas de produtividade ampliam essa visão ao incluir qualidade, fluxo, confiabilidade e capacidade de aprendizado. No Lean, a busca por valor e a eliminação sistemática de desperdícios orientam o redesenho do fluxo. Ohno (1988) descreve o Sistema Toyota de Produção a partir da redução de desperdícios e da criação de fluxo puxado, enquanto Womack e Jones (1996) sistematizam princípios como valor, fluxo de valor, fluxo contínuo, puxar e perfeição.

O Six Sigma acrescenta uma disciplina estatística para reduzir variabilidade e defeitos, geralmente estruturada por ciclos como DMAIC. Em sua forma tradicional, grande parte do diagnóstico depende de amostragem, análise estatística e projetos conduzidos por especialistas. Essa lógica continua relevante, mas a disponibilidade de dados em alta frequência permite ampliar a capacidade de detecção de padrões e de causas complexas, especialmente quando variáveis interagem de forma não linear.

O Kaizen, associado a Imai (1986), enfatiza melhoria incremental e participação sistemática das pessoas. Seu valor não reside apenas em grandes projetos, mas na capacidade de transformar problemas cotidianos em oportunidades de melhoria. A IA pode apoiar esse mecanismo sem substituir o conhecimento tácito: dados de processo, textos de ocorrências, históricos de manutenção e desvios podem ser agrupados e resumidos para sugerir temas prioritários, enquanto operadores validam contexto e viabilidade.

O TPM, consolidado por Nakajima (1988), busca maximizar a efetividade dos equipamentos e envolver diferentes funções na prevenção de perdas. Indicadores como Overall Equipment Effectiveness (OEE), falhas, microparadas e tempos de setup conectam manutenção e produtividade. A evolução para manutenção preditiva ocorre quando sensores e algoritmos estimam a probabilidade de falha ou degradação antes da parada, permitindo programar intervenções segundo condição e risco, e não apenas segundo calendário.

O ciclo PDCA é uma das estruturas mais disseminadas de gestão da melhoria. A lógica de planejar, executar, verificar e agir permanece atual porque fornece um mecanismo de aprendizagem gerencial. Contudo, quando a etapa "Check" depende de consolidações mensais ou reuniões periódicas, o ciclo pode ser lento em ambientes voláteis. A IA e analytics podem encurtar esse intervalo por meio de monitoramento contínuo, alertas de exceção e recomendações, desde que o responsável pelo processo mantenha critérios de decisão e governança.

O S&OP possui uma natureza distinta: trata-se de um processo de planejamento integrado que conecta vendas, demanda, produção, suprimentos e capacidade em um plano coerente. A síntese de Thomé et al. (2012) destaca seu papel cross-functional e de integração entre planos do negócio. A IA acrescenta capacidade de previsão probabilística, segmentação, detecção de mudança de padrão e simulação de cenários; entretanto, estudos recentes sobre IA em S&OP também indicam tensões entre padronização e flexibilidade, tecnologia e conhecimento humano, reforçando que a qualidade do processo decisório não pode ser reduzida à acurácia de um modelo (JAZAIRY; SHURRAB; CHEDID, 2025).

O SCOR, por sua vez, organiza a gestão da cadeia em processos e métricas que permitem relacionar confiabilidade, responsividade, agilidade, custos e ativos. Uma contribuição relevante para este estudo é a de Lima-Junior e Carpinetti (2019), que utilizaram redes neurais para prever métricas de desempenho baseadas em relações entre indicadores SCOR. A ideia ilustra a transição de uma mensuração predominantemente retrospectiva para uma gestão prospectiva, na qual indicadores antecedentes podem sinalizar resultados futuros e apoiar planos preventivos.

3.2 Inteligência Artificial como camada de potencialização

A principal diferença introduzida pela IA é a possibilidade de migrar de análises descritivas para capacidades diagnósticas, preditivas e prescritivas. Em uma análise descritiva, o sistema mostra o que ocorreu; na diagnóstica, identifica padrões e possíveis causas; na preditiva, estima o que tende a ocorrer; e na prescritiva, sugere a melhor ação diante de objetivos e restrições. A IA generativa adiciona capacidade de interpretar documentos, sintetizar ocorrências e apoiar interação em linguagem natural, enquanto técnicas de otimização e aprendizado por reforço podem apoiar escolhas sob restrições operacionais.

Em supply chain, esse conjunto de capacidades é particularmente valioso porque decisão e informação estão distribuídas. A revisão de Culot, Podrecca e Nassimbeni (2024) mostra que aplicações empíricas de IA dependem tanto da tecnologia quanto de requisitos de dados, sistemas e integração entre organizações. Zhao, Hong e Lau (2023) também associam digitalização da supply chain a resiliência e desempenho, reforçando que visibilidade e conectividade criam as condições para respostas mais rápidas. Em outras palavras, IA sem dados integrados pode produzir modelos tecnicamente sofisticados, mas pouco conectados à rotina de melhoria.

O uso de IA também deve ser avaliado pelo seu efeito sobre o processo, e não apenas pela acurácia do algoritmo. Em compras, por exemplo, Spreitzenbarth, Bode e Stuckenschmidt (2024) identificam diferentes clusters de uso de IA/ML e destacam que valor de negócio e facilidade de implementação variam entre casos. Em planejamento, Walter (2023) apresenta uma arquitetura de IA aplicada a um caso de manufatura que integra dados de produção, estoque e rastreabilidade para apoiar planejamento, monitoramento e ajustes em tempo real. Esses estudos sustentam a ideia de que o maior ganho ocorre quando o modelo analítico é incorporado ao fluxo decisório.

Portanto, a integração entre IA e programas de produtividade pode ser entendida como uma mudança em cinco dimensões: frequência de observação, que passa de periódica para contínua; abrangência de dados, que passa de amostras e sistemas isolados para múltiplas fontes; capacidade de antecipação, que passa de reativa para preditiva; apoio a decisão, que passa de exclusivamente humano para humano-IA; e velocidade de aprendizagem, que passa de ciclos longos para feedback quase em tempo real. Essas dimensões formam a base da síntese apresentada na seção de resultados.

Tabela 2 - Capacidades de IA relevantes aos programas de produtividade

Capacidade	Função	Aplicação de produtividade
Detectiva/diagnóstica	Identifica anomalias, padrões, desperdícios e possíveis causas.	Lean, Six Sigma, Kaizen, PDCA
Preditiva	Estima demanda, falha, atraso, defeito ou deterioração de KPI.	TPM, Six Sigma, S&OP, SCOR
Prescritiva/otimização	Recomenda rotas, planos, prioridades e ajustes sob restrições.	Lean, S&OP, PDCA, SCOR
Generativa/NLP	Resume ocorrências, interpreta textos e apoia criação de alternativas.	Kaizen, PDCA, compras e S&OP
Automação inteligente	Executa ou dispara ações dentro de regras e limites de governança.	Reposição, manutenção, qualidade e logística

Fonte: Elaborado pelos autores (2026), com base em Gao et al. (2024) e Culot, Podrecca e Nassimbeni (2024)

4. Resultados e discussão

4.1 Comparação: programas de produtividade antes e depois da integração com IA

A síntese teórica indica que a IA não elimina os princípios centrais de Lean, Six Sigma, Kaizen, TPM, PDCA, S&OP ou SCOR. O que se altera é a capacidade do programa de observar, interpretar e responder ao processo. Em todos os casos analisados, a potencialização pode ser expressa por uma transição de monitoramento retrospectivo e periódico para um sistema mais contínuo, preditivo e orientado a exceções.

Essa transição é importante porque programas de produtividade dependem de ciclos de feedback. Quanto menor o intervalo entre desvio, detecção, diagnóstico e ação, maior a possibilidade de evitar propagação do problema ao longo da cadeia. A Tabela 3 resume a lógica de potencialização. A coluna "antes" descreve a situação predominante quando o programa depende principalmente de análise manual ou periódica; a coluna "depois" descreve o resultado potencial da integração com IA. Trata-se de uma comparação conceitual, e os efeitos concretos dependem de qualidade de dados, maturidade digital, processo e contexto.

Tabela 3 - Como a IA pode potencializar os programas de produtividade na cadeia de suprimentos

Programa	Sem IA / limitação predominante	IA como potencializadora	Antes -> depois: resultado potencial	Exemplo na supply chain / KPI
Lean	Desperdícios identificados por observação, VSM e análises periódicas.	Process mining, visão computacional e detecção de anomalias apontam esperas, retrabalho e movimentos fora do padrão.	Detecção episódica -> detecção contínua; ação tardia -> resposta mais rápida; potencial de menor lead time e WIP.	Rotas e filas internas; picking; fluxo de pedidos. KPIs: lead time, WIP, custo/pedido.
Six Sigma	Defeitos e variabilidade analisados principalmente após ocorrência, por amostras e projetos.	ML relaciona muitas variáveis, detecta desvios e estima probabilidade de defeito ou não conformidade.	Correção reativa -> prevenção; investigação manual -> priorização de causas; potencial de menor defeito e retrabalho.	Qualidade de fornecedor e processo. KPIs: PPM/DPMO, yield, retrabalho, reclamações.

Programa	Sem IA / limitação predominante	IA como potencializadora	Antes -> depois: resultado potencial	Exemplo na supply chain / KPI
Kaizen	Oportunidades dependem de observação humana, eventos e reuniões de melhoria.	IA agrupa ocorrências, identifica temas repetitivos, resume dados e sugere oportunidades para avaliação das equipes.	Agenda esporádica -> funil contínuo de oportunidades; busca manual -> priorização orientada por evidências.	Gargalos de CD, ocorrências logísticas, ideias de melhoria. KPIs: tempo de ciclo da melhoria, ganhos, recorrência.
TPM	Manutenção preventiva baseada em calendário, horas ou experiência; falhas inesperadas persistem.	Modelos preditivos analisam vibração, temperatura, corrente e histórico para estimar degradação e risco de falha.	Preventiva fixa -> baseada em condição; parada inesperada -> intervenção antecipada; potencial de maior OEE e disponibilidade.	Esteiras, sorters, empilhadeiras e equipamentos de produção. KPIs: OEE, MTBF, MTTR, downtime.
PDCA	KPIs verificados em frequências definidas; problemas podem ser percebidos apenas na reunião seguinte.	Monitoramento contínuo, alertas de exceção, previsão de desvio e recomendações aceleram Check e Act.	Ciclo longo -> ciclo curto; desvio detectado tarde -> alerta antecipado; potencial de menor tempo de resposta.	Lead time, atraso, ruptura, OTIF. KPIs: tempo de resposta, desvio vs. meta, reincidência.
S&OP	Forecast e plano baseados em histórico, premissas e consenso; cenários exigem tempo para consolidação.	ML melhora previsão e segmentação; IA simula cenários e apoia avaliação de trade-offs entre demanda, capacidade e estoque.	Planejamento retrospectivo -> mais prospectivo; cenário manual -> simulação rápida; potencial de melhor equilíbrio serviço-estoque.	Previsão de demanda, capacidade e reposição. KPIs: MAPE/WAPE, nível de serviço, estoque, aderência ao plano.
SCOR	Métricas descrevem desempenho realizado e comparações; planos de melhoria podem ser predominantemente reativos.	Redes neurais e analytics preditivo relacionam indicadores antecedentes e resultados, simulando desempenho futuro.	Medir o passado -> diagnosticar o futuro; plano corretivo -> plano preventivo; maior visibilidade ponta a ponta.	Plan, Source, Make, Deliver e Return. KPIs: perfect order, order fulfillment cycle time, cost to serve, asset turns.

Fonte: Elaborado pelos autores (2026). Os efeitos representam direções potenciais e dependem do contexto de implementação

4.2 Framework de potencialização inteligente

O framework proposto, apresentado na Figura 1, organiza a integração em cinco etapas. A primeira é "Programas e Dados": o método de produtividade define o problema, o indicador e o padrão de trabalho, enquanto dados operacionais fornecem evidências do processo. Essa etapa é fundamental porque a IA não deve iniciar pelo algoritmo, mas pelo problema de produtividade que precisa ser melhorado.

Figura 1 - Framework de potencialização inteligente dos programas de produtividade

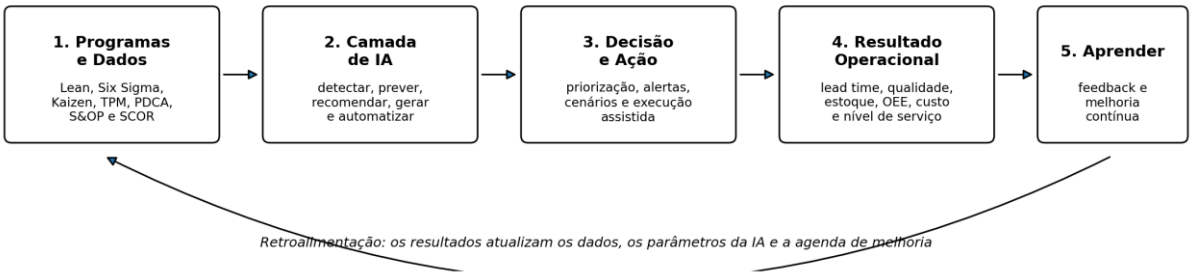

Fonte: Elaborado pelos autores (2026)

A segunda etapa é a "Camada de IA". Nela, modelos são empregados para detectar anomalias, classificar eventos, prever resultados, recomendar alternativas, gerar sínteses e, quando apropriado, automatizar partes da execução. O tipo de IA deve ser escolhido conforme o problema. Previsão de demanda exige modelos diferentes de detecção visual de defeitos; manutenção preditiva depende de sinais de condição; análise de ocorrências pode combinar NLP e modelos generativos.

A terceira etapa é "Decisão e Ação". Esse ponto diferencia analytics de produtividade real: um insight só gera valor quando altera uma decisão ou ação. Alertas precisam ter responsáveis, limites e procedimentos; recomendações precisam considerar restrições; automatizações precisam de regras de exceção e escalonamento. A participação humana permanece crítica para validar contexto, lidar com eventos raros, compreender trade-offs e assumir responsabilidade.

A quarta etapa é "Resultado Operacional", na qual o programa mede se houve redução de lead time, defeitos, variabilidade, estoque, downtime, custo ou aumento de nível de serviço, OEE e confiabilidade. Os indicadores devem permanecer coerentes com a metodologia de produtividade, evitando transformar a IA em um projeto tecnológico sem resultado operacional mensurável.

A quinta etapa é "Aprender". Resultados, erros de previsão, exceções e decisões humanas retroalimentam tanto o programa quanto os modelos. Isso cria um ciclo de melhoria inteligente: o PDCA continua existindo, mas recebe dados e alertas mais rápidos; o Kaizen continua valorizando pessoas, mas utiliza sinais extraídos automaticamente; o Six Sigma continua investigando causa e variação, mas pode trabalhar com maior volume e granularidade; e o Lean continua perseguindo fluxo e valor, agora com visibilidade quase em tempo real.

4.3 Ilustração de resultados e condicionantes de implementação

Um caso descrito por Walter (2023) ajuda a ilustrar como a camada de IA pode ser conectada a indicadores de produtividade. O estudo apresenta uma plataforma para planejamento e monitoramento em uma empresa do setor de laticínios, combinando dados de produção, armazém, rastreabilidade e sensores. O projeto foi concebido para planejar capacidade, identificar restrições, monitorar desvios e ajustar o processo em tempo real. Importante: os percentuais apresentados no estudo são metas de desempenho estabelecidas para o caso e não resultados finais universalizáveis.

As metas incluem reduzir pela metade as horas gastas em planejamento/scheduling e o tempo de resposta para gerar um novo plano com dados em tempo real; aumentar OEE entre 2% e 5%; reduzir homem-hora por tonelada entre 2% e 5%; reduzir downtime e setup por tonelada em 10%; reduzir scrap em 10%; e reduzir o erro de previsão em 10%

(WALTER, 2023). Embora essas metas estejam associadas a uma solução integrada, e não a um único programa, elas mostram como os resultados buscados pela IA se conectam diretamente a indicadores de Lean, TPM, PDCA, S&OP e desempenho da cadeia.

Tabela 4 - Metas de desempenho de um caso de IA aplicada ao planejamento e monitoramento da supply chain

Indicador	Situação de referência	Meta com a solução de IA
Horas de planejamento/scheduling	Processo corrente	Redução média de 50%
Tempo para gerar novo plano	Resposta corrente a mudanças	Redução de 50%
OEE	Desempenho histórico	Aumento de 2% a 5%
Homem-hora por tonelada	Produtividade corrente	Redução de 2% a 5%
Downtime e setup por tonelada	Desempenho corrente	Redução de 10%
Scrap por tonelada	Desempenho corrente	Redução de 10%
Erro de previsão	Erro do processo de previsão corrente	Redução de 10%

Fonte: Adaptado de Walter (2023). Percentuais reportados pelo estudo como metas do caso, não como resultados finais universalizáveis

Esse exemplo também evidencia que a integração deve evitar uma leitura determinística. IA pode acelerar análise e elevar a capacidade de antecipação, mas não corrige automaticamente cadastros inconsistentes, ausência de padronização, processos mal definidos ou conflitos de objetivo. Em S&OP, por exemplo, uma previsão mais acurada não elimina decisões sobre capacidade, nível de serviço, estoques e riscos. Em Lean, detectar desperdício não significa removê-lo sem mudança de processo. Em TPM, prever falha não produz disponibilidade se não houver recursos, planejamento e disciplina de manutenção.

Por isso, quatro condicionantes são propostas para a aplicação do framework: qualidade e governança de dados; integração entre sistemas e processos; competências humanas para interpretar e questionar modelos; e governança de IA, incluindo limites de autonomia, segurança e monitoramento. Esses condicionantes evitam que a tecnologia seja tratada como substituta do sistema de gestão. A organização deve manter os programas como estrutura de problema, método e indicador, utilizando IA como mecanismo de amplificação.

4.4 Discussão

Os resultados sugerem uma evolução dos programas de produtividade em três movimentos. O primeiro é de "ver" para "perceber continuamente": sensores, integração de sistemas e algoritmos reduzem a dependência de observações esporádicas. O segundo é de "corrigir" para "antecipar": modelos preditivos permitem agir antes de falhas, defeitos, rupturas e deterioração de indicadores. O terceiro é de "analisar" para "decidir assistidamente": simulação, recomendação e IA generativa podem reduzir o tempo necessário para consolidar evidências e formular alternativas.

Essa evolução é coerente com a literatura recente de supply chain inteligente. Culot, Podrecca e Nassimbeni (2024) alertam, entretanto, que o campo ainda apresenta distância entre expectativa e evidência empírica e que requisitos de dados, implementação e integração devem receber atenção. Essa ressalva é central para o framework: o termo "potencializadora" foi escolhido exatamente para evitar a ideia de substituição automática. A IA aumenta a capacidade do sistema de produtividade quando encontra um processo minimamente estruturado e uma organização capaz de incorporar o insight na decisão.

Sob a perspectiva gerencial, o framework pode ser utilizado para selecionar casos de uso. Uma empresa não precisa implementar IA simultaneamente nos sete programas. Pode priorizar um problema em que exista dado suficiente, indicador claro e valor operacional: previsão de falha para TPM; forecast para S&OP; detecção de gargalos para Lean; anomalias de qualidade para Six Sigma; ou alertas de desvio para PDCA. O aprendizado desse primeiro ciclo pode então ser replicado para outros programas.

A principal contribuição teórica do trabalho é propor uma lente integradora: em vez de estudar IA como iniciativa tecnológica isolada ou cada programa de produtividade separadamente, a matriz mostra que os mesmos mecanismos de IA - detectar, prever, recomendar, simular e automatizar - podem potencializar diferentes metodologias. A diferença está no objetivo do programa, no indicador de desempenho e no tipo de decisão que será alterado.

5. Conclusões

Este artigo analisou a Inteligência Artificial como potencializadora dos programas de produtividade na cadeia de suprimentos. O objetivo foi compreender de que forma capacidades de IA modificam a lógica operacional de Lean, Six Sigma, Kaizen, TPM, PDCA, S&OP e SCOR e propor uma estrutura simples para conectar metodologia, dados, decisão e resultado.

A pesquisa, de natureza qualitativa, exploratória e bibliográfica, integrou referências clássicas dos programas de produtividade com literatura recente sobre IA em supply chain e manufatura. A síntese demonstrou que a principal contribuição da IA está em ampliar frequência de observação, abrangência dos dados, antecipação, suporte a decisão e velocidade de aprendizagem. Em termos práticos, a transição ocorre de desperdícios identificados periodicamente para detecção contínua; de defeitos analisados após ocorrência para predição; de manutenção programada para manutenção baseada em condição; de KPIs revisados tardiamente para alertas em tempo real; e de planejamento baseado predominantemente em histórico para previsão e simulação.

Como resultado, foi proposta uma tabela de antes e depois para sete programas e um framework em cinco etapas: programas e dados, camada de IA, decisão e ação, resultado operacional e aprendizagem. A mensagem central é que a IA não substitui o método. O Lean continua definindo o que é desperdício; o Six Sigma continua estruturando a redução de variação; o TPM continua organizando confiabilidade; o PDCA continua disciplinando a aprendizagem; o S&OP continua integrando funções; e o SCOR continua estruturando processos e desempenho. A IA potencializa esses mecanismos ao aumentar a capacidade de perceber, prever e responder.

As contribuições práticas concentram-se na seleção de casos de uso orientados a indicadores. Antes de investir em tecnologia, a organização deve definir o problema de produtividade, o indicador, a decisão a ser modificada e a fonte de dados. Somente então deve escolher o tipo de IA. Essa sequência reduz o risco de projetos tecnológicos desconectados de resultados e preserva a governança do sistema de melhoria.

Como limitação, o framework é conceitual e não foi testado empiricamente em uma amostra de empresas. A tabela de antes e depois expressa direções esperadas, e não efeitos quantitativos garantidos. Estudos futuros podem validar o framework por estudos de caso, survey ou pesquisa-ação, comparar maturidade de empresas na integração de IA com programas de produtividade e medir impactos em indicadores como lead time, OEE, forecast accuracy, nível de serviço, custo, desperdício e emissão. Também se recomenda investigar como IA generativa e agentes autônomos alteram papéis de especialistas, operadores e gestores nos ciclos de melhoria.

Referências

CULOT, G.; PODRECCA, M.; NASSIMBENI, G. Artificial intelligence in supply chain management: a systematic literature review of empirical studies and research directions. Computers in Industry, v. 162, 104132, 2024. DOI: 10.1016/j.compind.2024.104132.

DEMING, W. E. Out of the crisis. Cambridge: MIT Press, 1986.

GAO, R. X.; KRÜGER, J.; MERKLEIN, M.; MÖHRING, H.-C.; VÁNCZA, J. Artificial Intelligence in manufacturing: state of the art, perspectives, and future directions. CIRP Annals, v. 73, n. 2, p. 723-749, 2024. DOI: 10.1016/j.cirp.2024.04.101.

IMAI, M. Kaizen: the key to Japan's competitive success. New York: McGraw-Hill, 1986.

JAZAIRY, A.; SHURRAB, H.; CHEDID, F. Impact pathways: walking a tightrope - unveiling the paradoxes of adopting artificial intelligence (AI) in sales and operations planning. International Journal of Operations & Production Management, v. 45, n. 13, p. 1-27, 2025. DOI: 10.1108/IJOPM-07-2024-0582.

LIMA-JUNIOR, F. R.; CARPINETTI, L. C. R. Predicting supply chain performance based on SCOR metrics and multilayer perceptron neural networks. International Journal of Production Economics, v. 212, p. 19-38, 2019.

NAKAJIMA, S. Introduction to TPM: total productive maintenance. Cambridge: Productivity Press, 1988.

OHNO, T. Toyota production system: beyond large-scale production. Portland: Productivity Press, 1988.

SPREITZENBARTH, J. M.; BODE, C.; STUCKENSCHMIDT, H. Artificial intelligence and machine learning in purchasing and supply management: a mixed-methods review of the state-of-the-art in literature and practice. Journal of Purchasing and Supply Management, v. 30, n. 1, 100896, 2024. DOI: 10.1016/j.pursup.2024.100896.

THOMÉ, A. M. T.; SCAVARDA, L. F.; FERNANDEZ, N. S.; SCAVARDA, A. J. Sales and operations planning: a research synthesis. International Journal of Production Economics, v. 138, n. 1, p. 1-13, 2012.

WALTER, S. AI impacts on supply chain performance: a manufacturing use case study. Discover Artificial Intelligence, v. 3, art. 18, 2023. DOI: 10.1007/s44163-023-00061-9.

WOMACK, J. P.; JONES, D. T. Lean thinking: banish waste and create wealth in your corporation. New York: Simon & Schuster, 1996.

ZHAO, N.; HONG, J.; LAU, K. H. Impact of supply chain digitalization on supply chain resilience and performance: a multi-mediation model. International Journal of Production Economics, v. 259, 108817, 2023. DOI: 10.1016/j.ijpe.2023.108817.