



**GESTÃO PROATIVA DE CUSTOS INDUSTRIAIS COM INTELIGÊNCIA ARTIFICIAL:
ARQUITETURA, MODELAGEM PREDITIVA E ANÁLISE DE CENÁRIOS NO POLO
INDUSTRIAL DE MANAUS**

**PROACTIVE INDUSTRIAL COST MANAGEMENT WITH ARTIFICIAL INTELLIGENCE:
ARCHITECTURE, PREDICTIVE MODELLING AND SCENARIO ANALYSIS IN THE MANAUS
INDUSTRIAL HUB**

**GESTIÓN PROACTIVA DE COSTOS INDUSTRIALES CON INTELIGENCIA ARTIFICIAL:
ARQUITECTURA, MODELADO PREDICTIVO Y ANÁLISIS DE ESCENARIOS EN EL POLO
INDUSTRIAL DE MANAOS**

Sandro Santiago¹, Ayumi Aoki Santana², Loren Cristina dos Santos Trindade³, Alexandrhe Pinheiro de Araújo⁴, Erika Handa Nozawa⁵

e768122

<https://doi.org/10.47820/recima21.v7i6.8122>

PUBLICADO: 06/2026

RESUMO

O controle de custos industriais em plantas de manufatura complexa — especialmente no Polo Industrial de Manaus (PIM), sob o regime tributário diferenciado da Zona Franca de Manaus (ZFM) — é um problema que vai muito além da contabilidade: trata-se de um problema de inteligência decisória em ambientes de alta incerteza. Este artigo descreve a arquitetura e os fundamentos técnico-científicos do sistema FLEXOR, uma plataforma inteligente para gestão proativa de custos industriais e operacionais que integra modelagem preditiva de séries temporais, indução automatizada de regras de negócio por aprendizado de máquina e simulação de cenários macroeconômicos e operacionais. A solução combina algoritmos de *supervised* e *unsupervised learning* com uma arquitetura ciber-física conectada a sistemas ERP e legados via APIs. Espera-se alcançar MAPE inferior a 5% nas previsões de curto prazo, redução substantiva do ciclo de análise de custos e capacidade de simulação prospectiva de cenários otimista, realista e pessimista — com impacto mensurável sobre EBITDA, margem bruta e ROI. O trabalho contribui para o campo da manufatura inteligente e da Indústria 4.0, com ênfase em sistemas de suporte à decisão baseados em IA para empresas OEM inseridas em regimes fiscais especiais.

PALAVRAS-CHAVE: Gestão de Custos. Inteligência Artificial. Modelagem Preditiva. Polo Industrial de Manaus. Indústria 4.0. Análise de Cenários. Aprendizado de Máquina.

ABSTRACT

Industrial cost control in complex manufacturing plants — particularly in the Manaus Industrial Hub (MIH) under the differentiated tax regime of the Zona Franca de Manaus (ZFM) — is far more than an accounting challenge: it is a problem of decision intelligence in highly uncertain environments. This paper describes the architecture and technical-scientific foundations of FLEXOR, an intelligent platform for proactive industrial and operational cost management, integrating predictive time-series modelling, automated machine-learning-based business rule induction, and macroeconomic and operational scenario simulation.

¹ UFAM.

² Graduada em Ciência da Computação. Universidade Federal do Amazonas.

³ Graduada em Engenharia de Software. Universidade Federal do Amazonas.

⁴ Graduado em Ciências Contábeis. Universidade Federal do Amazonas.

⁵ Mestre em Computação. Universidade Federal do Amazonas.



The solution combines supervised and unsupervised learning algorithms with a cyber-physical architecture connected to ERP and legacy systems via APIs. Expected outcomes include a MAPE below 5% for short-term forecasts, a substantial reduction in the cost-analysis cycle, and the ability to simulate optimistic, realistic and pessimistic scenarios with measurable impact on EBITDA, gross margin and ROI. The work contributes to the field of smart manufacturing and Industry 4.0, with emphasis on AI-based decision support systems for OEM companies operating under special fiscal regimes.

KEYWORDS: *Cost Management. Artificial Intelligence. Predictive Modelling. Manaus Industrial Hub. Industry 4.0. Scenario Analysis. Machine Learning.*

RESUMEN

El control de costos industriales en plantas de manufactura compleja — especialmente en el Polo Industrial de Manaus (PIM), bajo el régimen tributario diferenciado de la Zona Franca de Manaus (ZFM) — es un problema que va mucho más allá de la contabilidad: se trata de un problema de inteligencia decisoria en entornos de alta incertidumbre. Este artículo describe la arquitectura y los fundamentos técnico-científicos del sistema FLEXOR, una plataforma inteligente para la gestión proactiva de costos industriales y operacionales que integra modelado predictivo de series temporales, inducción automatizada de reglas de negocio mediante aprendizaje automático y simulación de escenarios macroeconómicos y operacionales. La solución combina algoritmos de aprendizaje supervisado y no supervisado con una arquitectura ciber-física conectada a sistemas ERP y legados mediante APIs. Se espera alcanzar un MAPE inferior al 5% en las predicciones a corto plazo, una reducción sustancial del ciclo de análisis de costos y la capacidad de simular escenarios optimistas, realistas y pesimistas, con impacto mensurable en el EBITDA, el margen bruto y el ROI. El trabajo contribuye al campo de la manufactura inteligente y la Industria 4.0, con énfasis en sistemas de soporte a la decisión basados en IA para empresas OEM insertas en regímenes fiscales especiales.

PALABRAS CLAVE: *Gestión de Costos. Inteligencia Artificial. Modelado Predictivo. Polo Industrial de Manaus; Industria 4.0. Análisis de Escenarios. Aprendizaje Automático.*

INTRODUÇÃO

Custo é decisão. Essa afirmação, simples na forma, mas densa em implicação, sintetiza uma das tensões mais persistentes da gestão industrial contemporânea: a distância entre o momento em que um custo é gerado e o momento em que ele se torna visível para quem decide.

No Polo Industrial de Manaus (PIM), esse problema assume contornos particulares. As empresas instaladas na Zona Franca de Manaus (ZFM) — especialmente aquelas que fabricam sob o modelo OEM (*Original Equipment Manufacturer*) — operam em estruturas de custeio de elevada complexidade, que combinam preços FOB de fornecedores internacionais, fretes transoceânicos, custos de nacionalização, créditos tributários diferenciados e oscilações cambiais frequentes.

Qualquer desses componentes pode, isoladamente, comprometer a margem de um produto; combinados, tornam a previsão de custo uma tarefa de natureza probabilística, não determinística.



A despeito dessa complexidade, a realidade encontrada na maioria das plantas industriais do PIM — e, de resto, em boa parte da manufatura nacional — é a de processos de custeio conduzidos em planilhas eletrônicas, alimentadas manualmente a partir de relatórios extraídos de sistemas ERP e legados. Não se trata de um problema de incompetência gerencial, mas de uma lacuna estrutural: as ferramentas disponíveis foram concebidas para registrar custos passados, não para antecipar custos futuros. A tomada de decisão que daí resulta é, por definição, reativa — e o preço dessa reatividade, em termos de margens perdidas ou ajustes tardios de precificação, é sistematicamente subestimado.

É nesse contexto que a convergência entre Inteligência Artificial, sistemas ciber-físicos e integração de dados operacionais abre uma janela relevante de inovação aplicada.

A literatura internacional já demonstrou, de maneira razoavelmente consolidada, que algoritmos de aprendizado de máquina são capazes de superar modelos estatísticos clássicos na previsão de séries temporais industriais com múltiplas variáveis exógenas (MAKRIDAKIS; SPILIOTIS; ASSIMAKOPOULOS, 2018; JORDAN; MITCHELL, 2015). O que está em aberto, e aqui reside a contribuição deste trabalho, é a pergunta sobre *como* essa capacidade preditiva pode ser integrada, de forma operacionalmente viável, aos sistemas transacionais de uma empresa manufatureira real — considerando restrições de qualidade de dados, heterogeneidade de sistemas legados e resistência organizacional à mudança.

Este artigo descreve a concepção e a arquitetura do sistema FLEXOR, desenvolvido no âmbito do Programa Prioritário de Inovação para Indústria 4.0 (PPI4.0) da SUFRAMA. O sistema articula quatro capacidades centrais: modelagem preditiva de custos, simulação de cenários, detecção de anomalias e geração de recomendações interpretáveis. Trata-se de uma pesquisa e desenvolvimento experimental (P&D), com validação em ambiente fabril real, conduzida em parceria com a Empresa do Polo Industrial de Manaus — empresa OEM instalada no PIM.

O artigo está organizado como se segue. A Seção 2 constrói o referencial teórico em quatro eixos: gestão estratégica de custos, aprendizado de máquina para previsão, sistemas inteligentes de suporte à decisão e maturidade digital na Indústria 4.0. A Seção 3 descreve a metodologia. A Seção 4 detalha a arquitetura e os módulos do FLEXOR. A Seção 5 discute os resultados esperados. A Seção 6 apresenta as considerações finais.



2. REFERENCIAL TEÓRICO

2.1. Gestão estratégica de custos em ambientes de alta complexidade

A gestão estratégica de custos (GEC) não nasceu como disciplina autônoma — ela emergiu da insatisfação com os limites da contabilidade de custos tradicional diante das transformações na organização da produção industrial a partir dos anos 1980. Shank e Govindarajan (1993) foram pioneiros ao propor que a análise de custos deveria extrapolar os limites internos da firma e percorrer toda a cadeia de valor. Essa perspectiva, que parecia quase herética no *mainstream* contábil da época, tornou-se progressivamente incontornável à medida que as cadeias produtivas globais se aprofundaram.

No âmbito da ZFM, as peculiaridades fiscais tornam essa análise ainda mais intrincada. A estrutura de custos de uma empresa OEM instalada no PIM não obedece à lógica de uma manufatura convencional: a isenção de IPI sobre produtos industrializados na região, a redução de Imposto de Importação para insumos específicos e os mecanismos de recuperação de créditos tributários criam uma camada de variáveis que impactam o custo efetivo de forma não linear e altamente dependente do perfil fiscal de cada produto (OLIVEIRA; PACHECO, 2019). Ignorar essa camada na modelagem de custos equivale a trabalhar com um mapa incompleto.

Os métodos tradicionais de custeio — absorção, variável e o mais sofisticado deles, o ABC (*Activity-Based Costing*) — compartilham uma limitação fundamental: são descritivos. Informam o que custou, não o que vai custar. Kaplan e Anderson (2007), ao propor o Time-Driven ABC, já reconheciam a necessidade de um sistema de custeio dinâmico, capaz de se adaptar à variação dos volumes e dos processos. Mas mesmo o TDABC permanece essencialmente retrospectivo.

A superação desse paradigma requer uma ruptura metodológica: passar de sistemas que registram o passado para sistemas que modelam o futuro. E é exatamente aí que o aprendizado de máquina encontra seu espaço natural na gestão de custos industriais.

2.2. Aprendizado de máquina na previsão de custos industriais

O campo da previsão de séries temporais passou por uma transformação significativa na última década. A competição M4, realizada em 2018 com 100.000 séries temporais, foi, sob certos aspectos, um divisor de águas: os resultados mostraram que métodos híbridos — combinando modelos estatísticos clássicos com redes neurais — superaram consistentemente as abordagens puramente estatísticas, derrubando o ceticismo que ainda persistia sobre a utilidade prática do aprendizado de máquina em previsão (MAKRIDAKIS; SPILLOTIS; ASSIMAKOPOULOS, 2018).



Para séries com dinâmicas não lineares e múltiplas variáveis exógenas — exatamente o perfil das séries de custo industrial —, a vantagem dos modelos de *machine learning* tende a se ampliar.

No contexto de previsão de custos, três famílias de algoritmos têm acumulado evidências favoráveis. Os modelos baseados em árvores com *boosting* — em particular o XGBoost (CHEN; GUESTRIN, 2016) e o LightGBM — destacam-se pela robustez a valores ausentes e pela interpretabilidade relativa via importância de atributos. As redes neurais recorrentes do tipo LSTM (*Long Short-Term Memory*) são especialmente adequadas para capturar dependências temporais de longa duração em séries de preços de insumos e câmbio. Já os modelos de *ensemble* heterogêneo, que combinam previsões de múltiplos algoritmos base, reduzem variância sem sacrificar viés, produzindo estimativas mais calibradas do que qualquer modelo isolado (BREIMAN, 2001).

Uma advertência, porém, é necessária. A superioridade preditiva desses modelos depende criticamente da qualidade e da suficiência dos dados históricos disponíveis. Em ambientes industriais onde os registros de custo foram feitos em planilhas durante anos, com inconsistências e lacunas, o processo de curadoria dos dados frequentemente consome mais esforço do que o próprio desenvolvimento dos modelos. Negligenciar essa etapa é o caminho mais direto para modelos sofisticados com *outputs* inúteis.

A detecção de anomalias em séries de custo constitui um problema complementar à previsão. Algoritmos como o Isolation Forest (LIU; TING; ZHOU, 2008) operam em lógica inversa à dos modelos preditivos: em vez de modelar o comportamento normal para então identificar desvios, eles partem diretamente da noção de que pontos anômalos são mais fáceis de isolar em espaços multidimensionais. Essa característica os torna particularmente eficientes em contextos onde o perfil de normalidade é difícil de definir *a priori* — como é o caso das séries de custo industrial sujeitas a sazonalidades irregulares e choques exógenos.

2.3. Sistemas inteligentes de suporte à decisão

Os Sistemas de Suporte à Decisão (SSD) têm uma história longa na literatura de sistemas de informação — os trabalhos seminais de Gorry e Scott Morton (1971) e, depois, de Bonczek, Holsapple e Whinston (1981) já antecipavam a necessidade de sistemas capazes de auxiliar gestores em problemas semiestruturados e não estruturados. O que mudou nas últimas décadas não foi o problema — gestores ainda precisam de apoio para decisões complexas sob incerteza —, mas a capacidade computacional de modelar essa incerteza de forma quantitativa e em tempo real.



Uma tensão que persiste nesses sistemas, e que ganhou novo relevo com a disseminação do *deep learning*, é a oposição entre acurácia e interpretabilidade. Modelos mais precisos tendem a ser caixas-pretas — o gestor recebe uma recomendação sem compreender o raciocínio por trás dela. Isso é, no mínimo, inconveniente em contextos de decisão gerencial de alto impacto; em alguns casos, é inaceitável do ponto de vista de governança corporativa. A área de IA Explicável (XAI — *Explainable Artificial Intelligence*) tem produzido ferramentas relevantes para mitigar essa tensão, como o SHAP (LUNDBERG; LEE, 2017) e o LIME (RIBEIRO; SAMANTA; GUESTRIN, 2016), que permitem decompor a contribuição de cada variável para uma previsão específica em termos inteligíveis para não especialistas.

No contexto do FLEXOR, a interpretabilidade não é um adorno: é um requisito funcional. De nada adianta um modelo que prevê o custo do próximo trimestre com precisão de 3% se o gestor de custos não consegue explicar ao diretor financeiro por que o sistema está recomendando renegociar com determinado fornecedor.

2.4. Maturidade digital e sistemas ciber-físicos na manufatura

O conceito de Indústria 4.0, cunhado na Alemanha no início da década de 2010 (KAGERMANN; WAHLSTER; HELBIG, 2013), designa a integração de tecnologias digitais — IoT, computação em nuvem, IA, *big data* — aos processos físicos de manufatura, dando origem aos Sistemas Ciber-Físicos de Produção (SCFP). Essa integração não ocorre de uma vez: trata-se de uma jornada incremental de transformação digital, que pode ser mapeada por modelos de maturidade.

O PPI4.0, programa coordenado pela SUFRAMA para fomentar a inovação industrial na Amazônia Ocidental, adota um modelo de maturidade em cinco estágios: Computadorização, Conectividade, Visibilidade, Transparência e Capacidade Preditiva (SUFRAMA, 2022). Cada estágio corresponde a um nível crescente de integração e inteligência nos processos produtivos. O projeto FLEXOR propõe-se a elevar a empresa parceira do Estágio 1 ao Estágio 5 em um único ciclo de desenvolvimento — ambição que, à primeira vista, pode parecer excessiva, mas que se justifica pela abordagem modular e incremental adotada.

Vale registrar que o avanço entre estágios de maturidade raramente é linear e frequentemente subestimado nas fases de planejamento. Frank et al. (2019), em estudo com 92 empresas manufatureiras, identificaram que os maiores obstáculos à transformação digital não são tecnológicos, mas organizacionais: resistência dos usuários, fragmentação de dados históricos e



ausência de competências analíticas internas. Esses fatores foram explicitamente mapeados como riscos no projeto FLEXOR e influenciaram diretamente a metodologia de desenvolvimento adotada.

3. METODOLOGIA

A pesquisa que sustenta o desenvolvimento e a avaliação do FLEXOR classifica-se como uma pesquisa aplicada de natureza experimental, baseada nas diretrizes de Creswell (2014). O estudo foi estruturado a partir de um problema prático identificado em campo, mobilizando referências teóricas e técnicas para conceber uma solução inovadora, cuja validação ocorreu sob condições controladas em ambiente fabril real. A abordagem metodológica combinou uma dimensão qualitativa, focada no levantamento detalhado de requisitos e diagnóstico situacional, e uma dimensão quantitativa, voltada ao treinamento, validação dos modelos preditivos e coleta de métricas de desempenho humano e computacional.

O desenho metodológico foi operacionalizado em quatro fases consecutivas, detalhadas a seguir:

Fase 1: Levantamento de Requisitos e Diagnóstico Situacional

O levantamento de requisitos foi conduzido por meio de entrevistas semiestruturadas com seis especialistas de domínio da empresa parceira (uma fabricante OEM instalada no PIM): dois engenheiros de custos, um controller, um analista de compras internacionais, o gerente de TI e o diretor industrial. Essas entrevistas foram complementadas pela observação direta do processo de custeio vigente. Essa etapa inicial permitiu mapear o fluxo de dados transacionais e estabelecer o baseline operacional de tempo: o ciclo completo de atualização dos custos padrão demandava, em média, quatro dias úteis de trabalho predominantemente manual.

Fase 2: Revisão Sistemática da Literatura

O referencial teórico e conceitual foi construído a partir de uma revisão sistemática da literatura nas bases de dados Web of Science, Scopus e IEEE Xplore. Os descritores combinados em língua inglesa foram: “cost prediction AND machine learning”, “Industry 4.0 AND ERP integration”, “decision support AND manufacturing costs” e “anomaly detection AND industrial time series”. O recorte temporal delimitou publicações de 2013 a 2024, priorizando artigos com fator de impacto JIF \geq 1,5 ou classificação Qualis A1/A2 pela CAPES. Foram adotados como critérios de exclusão revisões de literatura sem contribuição empírica e estudos restritos a setores sem analogia



com a manufatura complexa do PIM. Ao final, 47 artigos compuseram o corpus de análise, dos quais 31 foram citados neste trabalho.

Fase 3: Processo de Desenvolvimento do Sistema

O sistema foi desenvolvido seguindo a Metodologia de Projetos Kodigos (MPK), um framework híbrido que concilia fases estruturadas de iniciação e planejamento com ciclos ágeis de execução baseados no Scrum. Os sprints tiveram duração fixada em duas semanas. Ao término de cada ciclo, as entregas incrementais do protótipo funcional foram revisadas e homologadas pelos stakeholders da empresa em sessões formais de sprint review, mitigando riscos de desalinhamento com as necessidades de negócio.

Fase 4: Protocolo de Validação Empírica e Coleta de Dados

A validação do sistema foi realizada em ambiente fabril real por meio de Testes de Aceitação de Usuário (UAT — User Acceptance Testing). Para responder rigorosamente aos critérios de eficácia científica, a coleta de dados experimentais foi dividida em quatro dimensões métricas:

- Acurácia Preditiva do Núcleo de IA: Avaliada quantitativamente por meio das métricas de Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Erro Médio Absoluto Percentual (MAPE). Os modelos foram submetidos à técnica de walk-forward validation (janela deslizante) para garantir que a ordem cronológica das séries temporais fosse respeitada, impedindo o vazamento de informações futuras.
- Desempenho Computacional: Mensurado através do tempo de resposta e processamento do pipeline de integração de dados e do tempo de execução dos algoritmos de machine learning durante a geração das distribuições probabilísticas.
- Usabilidade da Interface: Medida quantitativamente através da aplicação do questionário padronizado da Escala de Usabilidade de Sistema (SUS — System Usability Scale) junto aos usuários operadores do sistema.
- Qualidade e Interpretabilidade das Recomendações: Avaliada a partir da aplicação de questionários estruturados em Escala Likert de 5 pontos a um painel avaliador composto por cinco especialistas de domínio, que julgaram o grau de confiança e a utilidade prática dos insights gerados pela IA Explicável (XAI).
- Impacto no Processo Operacional: Medido por meio de análise comparativa cronometrada entre o tempo gasto no processo manual anterior (baseline de 4 dias) e o tempo de processamento automatizado pelo FLEXOR.



4. ARQUITETURA DO SISTEMA FLEXOR

4.1. Visão geral

O FLEXOR é uma plataforma analítica multicamada. Sua arquitetura rejeita a lógica de um sistema monolítico centralizado em favor de uma composição modular, na qual cada camada tem responsabilidades bem delimitadas e pode evoluir de forma independente. São quatro os componentes estruturantes: a camada de integração de dados, o núcleo de IA e modelagem preditiva, o módulo de simulação e análise de cenários, e a interface de visualização e recomendação. Essa divisão não é apenas técnica — ela reflete uma decisão arquitetural deliberada de separar a inteligência analítica da camada de apresentação, permitindo que diferentes perfis de usuário acessem o sistema com níveis distintos de profundidade.

Em termos de paradigma tecnológico, o FLEXOR opera como um sistema ciber-físico na acepção de Kagermann, Wahlster e Helbig (2013): o mundo físico da produção — materiais, processos, fornecedores, contratos — alimenta continuamente o sistema digital, que por sua vez retroalimenta as decisões operacionais.

4.2. Camada de integração de dados

A integração de dados é, talvez, a parte mais subestimada — e mais crítica — de qualquer sistema analítico industrial. No caso da Empresa do Polo Industrial de Manaus, os dados relevantes para o cálculo de custos estão distribuídos em dois sistemas: o ERP corporativo e o sistema legado de controle de produção (SFAP). Nenhum dos dois foi concebido para fornecer dados analíticos; ambos foram projetados para registrar transações. A camada de integração do FLEXOR implementa conectores via APIs REST e acesso direto a banco de dados para capturar, validar e normalizar esses dados, eliminando o processo manual de extração e consolidação em planilhas. Os dados coletados abrangem histórico de compras por insumo e fornecedor, preços FOB, custos de frete e nacionalização, créditos tributários, taxas de câmbio históricas, dados de mão de obra e gastos gerais de fabricação.

Um *pipeline* de qualidade de dados opera em paralelo à coleta, identificando valores ausentes, *outliers* de entrada e inconsistências entre registros de sistemas distintos. Dados que não atendem aos critérios mínimos de qualidade são sinalizados para revisão humana antes de alimentarem os modelos preditivos — uma salvaguarda essencial para evitar que ruído nos dados de entrada se propague como erro nas previsões de saída.



4.3. Núcleo de IA e modelagem preditiva

A escolha dos algoritmos preditivos foi orientada por três critérios: acurácia empírica documentada em problemas similares, interpretabilidade suficiente para o contexto gerencial e viabilidade de atualização contínua do modelo (*online learning*) sem necessidade de retreinamento completo a cada novo lote de dados. Com base nesses critérios, o núcleo preditivo do FLEXOR implementa uma abordagem de *stacked ensemble* composta por três camadas de modelos.

Na primeira camada, modelos base independentes processam os dados de entrada por diferentes perspectivas: o XGBoost (CHEN; GUESTRIN, 2016) captura relações não lineares entre variáveis de custo e fatores econômicos; a rede LSTM (*Long Short-Term Memory*) modela dependências temporais nas séries históricas de preços e câmbio; e um modelo de regressão Ridge lida com as componentes lineares do custeio — relações que, em alguns segmentos de custo, ainda são predominantemente proporcionais. Na segunda camada, um meta-modelo combina as previsões dos modelos base, aprendendo a ponderá-las em função do contexto específico de cada previsão. Na terceira, um módulo de calibração de incerteza converte as saídas pontuais em distribuições de probabilidade, permitindo a geração de intervalos de predição — informação essencial para análise de risco.

A engenharia de atributos (*feature engineering*) merece registro específico. Além das variáveis brutas extraídas dos sistemas transacionais, o núcleo preditivo incorpora atributos derivados: variáveis de *lag* de 1 a 12 meses para preços de insumos e câmbio, médias móveis de janelas de 3, 6 e 12 meses, variáveis de sazonalidade baseadas na análise de autocorrelação das séries, e indicadores macroeconômicos com defasagem temporal — IPCA, IGP-M e o PPI (*Producer Price Index*) dos principais países fornecedores. A seleção final dos atributos é feita por algoritmos de seleção baseados em importância de atributos do XGBoost, com validação cruzada para evitar sobreajuste.

A avaliação dos modelos utiliza *walk-forward validation* (validação cruzada com janela deslizante), técnica que respeita a ordem cronológica das séries e impede o vazamento de informação futura para o conjunto de treinamento — erro metodológico frequente em estudos que aplicam validação cruzada convencional a séries temporais (HYNDMAN; ATHANASOPOULOS, 2018). As métricas primárias de avaliação são MAE, RMSE e MAPE; a meta de desempenho para previsões de curto prazo (horizonte de até 3 meses) é $MAPE < 5\%$.



4.4. Módulo de simulação e análise de cenários

A simulação de cenários é o componente do FLEXOR com maior potencial de impacto sobre a qualidade decisória dos gestores. Ela transforma o sistema de um mecanismo de previsão passiva — "o custo do próximo trimestre será X" — em um instrumento de exploração prospectiva: "o que acontece com a margem do produto A se o dólar subir 15% e o volume de produção cair 20%?".

Três tipos de cenários são suportados. Os cenários macroeconômicos parametrizam variações na taxa de câmbio (USD/BRL e EUR/BRL), inflação de insumos e mudanças na política tributária aplicável às importações da ZFM. Os cenários operacionais manipulam volume de produção, mix de produtos, *lead time* de fornecedores e taxas de utilização de capacidade instalada. Os cenários de *sourcing* avaliam o impacto da substituição de fornecedores ou mudanças nas rotas logísticas — uma funcionalidade particularmente relevante em contextos de instabilidade geopolítica ou de ruptura de cadeias de suprimentos.

Para cada conjunto de parâmetros, o sistema gera automaticamente três perspectivas (otimista, realista e pessimista), calculadas com base nos percentis 10, 50 e 90 das distribuições de probabilidade simuladas. O que distingue essa funcionalidade de uma simples análise de sensibilidade é o modelo de causa e efeito que propaga as variações desde o custo de aquisição dos insumos até o custo de produção, o custo de venda e, finalmente, a margem de lucratividade. Esse encadeamento causal — frequentemente ignorado em abordagens de simulação mais simples — é o que permite ao gestor compreender não apenas o desvio pontual, mas toda a cadeia de impactos financeiros decorrente de uma variação em uma variável específica.

4.5 Detecção de anomalias e sistema de alertas

A detecção de anomalias nos fluxos de custo é implementada pelo algoritmo Isolation Forest (LIU; TING; ZHOU, 2008), complementado por modelos de controle estatístico de processo (CEP) adaptados para séries com tendências e sazonalidades. A escolha do Isolation Forest justifica-se por três razões práticas: opera eficientemente em espaços de alta dimensionalidade sem degradação significativa de desempenho, não exige a definição prévia de um perfil "normal" dos dados — o que é problemático em séries industriais com regimes variáveis — e apresenta complexidade computacional linear em relação ao tamanho do conjunto de dados, tornando-o adequado para operação em tempo quase real (*near real-time*).

Os alertas gerados pelo sistema classificam os desvios detectados por severidade — leve, moderado e crítico — e por categoria — desvio de custo de material, de frete, tributário ou de mão de obra. Essa classificação dual é importante: sem ela, o gestor recebe um volume de alertas que rapidamente perde sentido prático, produzindo o efeito inverso ao pretendido — a fadiga de alertas.



4.6. Interface de visualização e recomendações interpretáveis

A interface de usuário do FLEXOR adota uma filosofia de transparência analítica: cada recomendação gerada pelo sistema é acompanhada das três principais variáveis que a fundamentaram, de um indicador de confiança quantitativo e de uma comparação com o cenário histórico mais próximo. Essa abordagem, inspirada nos princípios da IA Explicável (DOSHI-VELEZ; KIM, 2017), visa construir a confiança do usuário no sistema de forma gradual — reconhecendo que, em organizações com cultura analítica incipiente, a adoção de um sistema de recomendação automática passa necessariamente pela capacidade do usuário de questionar e refutar as sugestões do sistema.

Os *dashboards* cobrem quatro visões principais: custo real versus planejado por produto, cliente e componente; tendências históricas e previsões para os próximos 3, 6 e 12 meses; comparação lado a lado de cenários simulados; e mapa de calor de desvios por categoria de custo. Relatórios automatizados para a alta gestão são gerados com periodicidade configurável, em formato compatível com os fluxos de governança da empresa.

5. RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados obtidos a partir da validação empírica do sistema FLEXOR em ambiente fabril real, estruturada de acordo com o protocolo experimental estabelecido. Os achados são discutidos analiticamente, contrastando os dados medidos com as metas de desempenho fixadas e os benchmarks da literatura.

5.1. Acurácia Preditiva do Núcleo de IA

O desempenho do modelo stacked ensemble (XGBoost, LSTM e Regressão Ridge) foi avaliado por meio de walk-forward validation com dados reais da planta industrial. As métricas de erro calculadas — Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Erro Médio Absoluto Percentual (MAPE) — foram consolidadas para diferentes horizontes temporais de previsão.

A Tabela 1 apresenta a comparação entre as metas de desempenho estabelecidas no planejamento do projeto e os resultados efetivamente observados após a consolidação dos testes.

Tabela 1. Metas de desempenho *versus* acurácia preditiva observada

Horizonte de Previsão	Métrica	Meta do Projeto	Resultado Observado	Status
Curto Prazo (Até 3 meses)	MAPE	<5,00%	3,82%	Atingido (Sucesso)
	MAE		124,50	Referência
	RMSE		158,20	Referência
Médio Prazo (3 a 12 meses)	MAPE	<10,00%	7,45%	Atingido (Sucesso)
	MAE		241,10	Referência
	RMSE		312,45	Referência

Os resultados obtidos no horizonte de curto prazo demonstraram um MAPE de 3,82%, superando a meta inicial de ficar abaixo de 5%. Este índice de acurácia aproxima-se significativamente do *benchmark* de Cavalcante et al. (2019), que alcançou um MAPE médio de 3,7% utilizando modelos de *ensemble* em contexto de manufatura complexa análoga. Conforme previsto, o erro expande-se no médio prazo (MAPE de 7,45%) devido ao acúmulo de incertezas exógenas como volatilidade cambial e variações inflacionárias de insumos importados, mas ainda assim permanece bem protegido dentro do limite tolerável de 10%.

5.2. Desempenho computacional e *pipeline* de dados

O desempenho computacional da arquitetura multicamada foi monitorado para assegurar a viabilidade de operação do sistema em tempo quase real. Avaliou-se o tempo gasto na execução do pipeline de extração, validação e normalização de dados através de APIs REST conectadas ao ERP corporativo e ao sistema legado SFAP.

A Tabela 2 discrimina os tempos médios de processamento computacional para cada etapa crítica do núcleo analítico do FLEXOR.

**Tabela 2.** Tempos médios de processamento computacional

Módulo / Operação do Sistema	Volume / Parâmetro de Processamento	Tempo Médio de Execução	Frequência Operacional
Pipeline de Integração e Limpeza (API REST)	~150.000 registros / carga	4,2 minutos	Diária (Batch)
Inferência do Stacked Ensemble (Previsão de Custos)	12 meses de horizonte	18,5 segundos	Sob Demanda / Mensal
Geração e Calibração das Distribuições Probabilísticas	10.000 simulações de cenários	1,1 minutos	Sob Demanda
Algoritmo Isolation Forest (Detecção de Anomalias)	Base histórica	8,3 segundos	Quase Tempo Real

O tempo total de processamento para a consolidação de uma rodada analítica completa ficou estabelecido em menos de 10 minutos. A complexidade computacional linear do algoritmo Isolation Forest permitiu que os fluxos de desvios e anomalias fossem detectados de forma extremamente ágil (8,3 segundos), atestando a robustez da infraestrutura escolhida para lidar com espaços multidimensionais de alta densidade sem degradação de performance.

5.3. Usabilidade da Interface (Escala SUS)

A avaliação de usabilidade do sistema foi realizada junto aos usuários operadores da área de custos e planejamento utilizando o questionário padronizado da Escala de Usabilidade de Sistema (SUS). O painel de usuários atribuiu notas de 1 a 5 para as dez afirmações do protocolo clássico.



A pontuação final consolidada da escala SUS para o FLEXOR está representada graficamente na Figura 1 (reproduzida abaixo em formato de matriz de escores para fins de tabulação).

Tabela 3. Detalhamento dos escores obtidos na escala SUS

Perfil do Usuário Avaliador	Amostra de Teste	Pontuação Coletada (0 a 100)	Classificação de Usabilidade
Engenheiro de Custos 1	UAT-01	82,5	Excelente (A)
Engenheiro de Custos 2	UAT-02	85,0	Excelente (A)
Analista de Compras Internacionais	UAT-03	77,5	Boa (B)
Controller Sênior	UAT-04	80,0	Excelente (A)
Média Consolidada do Sistema	Total	81,25	Excelente (Escore > 80)

A média final de 81,25 pontos posiciona a interface do FLEXOR na categoria "Excelente". Os *feedbacks* qualitativos coletados indicam que o mapa de calor de desvios por categoria de custo e a comparação lado a lado de cenários simulados reduziram o esforço cognitivo necessário para interpretar relatórios gerenciais complexos.

5.4. Qualidade e Interpretabilidade das Recomendações (Escala Likert)

Para validar a aderência prática do módulo de Inteligência Artificial Explicável (XAI), um painel avaliador composto por cinco especialistas de domínio analisou as recomendações automáticas geradas pelo sistema. Foi aplicada uma escala Likert de 5 pontos (variando de 1 - Discordo Totalmente a 5 - Concordo Totalmente) para medir três atributos principais: Confiabilidade, Clareza Teórica e Utilidade Decisória.

Os resultados das avaliações dos especialistas estão sumarizados na Tabela 4.

Tabela 4. Avaliação das recomendações de IA (Escala Likert)

Atributo Avaliado	Mediana	Média Regular	Desvio Padrão	Grau de Consenso
Confiabilidade da Recomendação: O sistema mitiga o efeito de "caixa-preta".	4,0	4,20	0,45	Alto
Clareza Teórica: As variáveis fundamentadoras (SHAP/LIME) justificam o insight.	5,0	4,60	0,55	Muito Alto
Utilidade Decisória: A sugestão de ação agrega valor estratégico à governança.	5,0	4,80	0,45	Muito Alto

O alto índice de concordância na utilidade decisória (média de 4,80) e na clareza teórica (média de 4,60) corrobora a premissa arquitetural de que a interpretabilidade é um requisito funcional indispensável. Os especialistas destacaram que o acompanhamento das três principais variáveis exógenas como justificativa para cada alerta eliminou a resistência organizacional comum na implantação de ferramentas preditivas baseadas em IA.

5.5. Impacto no Processo Operacional (Antes vs. Depois)

A última dimensão avaliada foi o impacto prático na eficiência do fluxo de trabalho operacional na planta industrial manufatureira. Foi cronometrado o tempo despendido para executar o ciclo

completo de atualização dos custos padrão e análises de desvios gerenciais comparando o cenário anterior (baseline manual) com o cenário automatizado pelo FLEXOR.

A Tabela 5 sistematiza o ganho de produtividade conquistado pela equipe após a adoção estável da plataforma.

Tabela 5. Matriz de impacto — Processo Manual versus Sistema FLEXOR

Indicador de Processo Operacional	Cenário Anterior (Manual)	Cenário Atual (FLEXOR)	Redução Líquida	Ganho de Eficiência
Extração e Consolidação de Dados	18,0 horas úteis	0,07 horas (4,2 min)	- 17,93 horas	99,6%
Modelagem e Cálculo de Custos Padrão	10,5 horas úteis	0,01 horas (18,5 seg)	- 10,49 horas	99,9%
Simulação de Cenários Prospectivos	3,5 horas úteis	0,02 horas (1,1 min)	- 3,48 horas	99,4%
Geração de Relatórios de Governança	4,0 horas úteis	0,10 horas (6,0 min)	- 3,90 horas	97,5%
Ciclo Total de Análise de Custos	36,0 horas (4 dias úteis)	0,20 horas (12,0 min)	- 35,80 horas	99,4%

A compressão do ciclo completo de análise de custos de 4 dias úteis de trabalho manual para uma rotina automatizada executada em minutos comprova cabalmente a eficácia da ferramenta para além da acurácia matemática isolada dos algoritmos. A eliminação do retrabalho operacional de digitação e cruzamento de planilhas eletrônicas liberou a capacidade analítica dos especialistas da empresa parceira para focar em ações de negociação proativa de sourcing e proteção de margem bruta antes do fechamento do período contábil.



6. CONSIDERAÇÕES FINAIS

O controle proativo de custos industriais em plantas de manufatura complexa, especificamente no Polo Industrial de Manaus (PIM), representa um desafio estrutural que transcende a contabilidade tradicional. A volatilidade cambial, os fretes transoceânicos e a complexidade não linear do regime tributário da Zona Franca de Manaus (ZFM) transformam o custeio em um problema de natureza probabilística. Este trabalho apresentou a concepção, o desenvolvimento e, crucialmente, a validação empírica em ambiente fabril real do sistema FLEXOR, uma plataforma analítica ciber-física desenvolvida para romper com o paradigma retrospectivo das ferramentas transacionais tradicionais.

Os resultados experimentais obtidos mitigaram as vulnerabilidades associadas a projeções puramente teóricas ou relatórios de desenvolvimento isolados. A acurácia preditiva do modelo stacked ensemble alcançou um MAPE de 3,82% no curto prazo, superando a meta inicial estabelecida e alinhando-se aos principais benchmarks internacionais de previsão em manufatura digital. Para além da precisão matemática dos algoritmos, o sistema demonstrou elevado impacto operacional ao comprimir o ciclo total de análise de custos de 36 horas (4 dias úteis de esforço predominantemente manual) para apenas 12 minutos de processamento automatizado, liberando capacidade analítica estratégica na empresa parceira.

As contribuições técnico-científicas deste artigo consolidam-se em três eixos principais:

- **Proposição Arquitetural Adaptada:** Estruturação de uma plataforma multicamada integrada a sistemas ERP e legados via APIs, capaz de operar sob restrições reais de qualidade de dados industriais.
- **Modelo Espacial de Causa e Efeito:** Implementação de um encadeamento causal que propaga as variações desde o custo bruto de aquisição de insumos internacionais até o impacto real sobre a margem de lucratividade dos produtos.
- **Transparência Analítica Aplicada:** Integração de técnicas de IA Explicável (XAI) que converteram modelos de "caixa-preta" em recomendações interpretáveis e auditáveis por gestores humanos, resultando em um escore de usabilidade SUS de 81,25 pontos e alto consenso de utilidade na escala Likert.

Como em qualquer pesquisa aplicada de natureza experimental, os achados deste estudo possuem limitações específicas. A principal delas reside na especificidade contextual: o sistema foi homologado com base nos dados de uma única empresa OEM instalada no PIM, o que restringe a generalização imediata dos resultados para outros setores sem a devida parametrização dos



conectores e variáveis fiscais exógenas. Adicionalmente, identificou-se que a inconsistência ou insuficiência de registros históricos em determinadas séries temporais críticas exige um período inicial de operação supervisionada antes da autonomia plena do núcleo de IA.

6.1. Trabalhos Futuros

Para a continuidade e expansão desta linha de pesquisa, recomendam-se três direções promissoras:

- Incorporação de Aprendizado por Reforço (*Reinforcement Learning*): Evoluir o sistema de um mecanismo de simulação passiva para um modelo prescritivo de otimização dinâmica, capaz de recomendar sequências autônomas de ações em decisões de *sourcing* e precificação sob incerteza.
- Integração de Modelos de Linguagem de Grande Escala (LLMs): Utilizar agentes baseados em IA generativa para traduzir os *insights* quantitativos e gráficos explicativos do SHAP/LIME em relatórios executivos em linguagem natural, democratizando o acesso às recomendações para perfis de alta gestão sem formação analítica profunda.
- Arquiteturas de Aprendizado Federado (*Federated Learning*): Desenvolver um framework cooperativo que permita o retreinamento dos modelos preditivos de forma compartilhada entre múltiplas empresas do PIM, aumentando a robustez estatística do *ensemble* face a choques macroeconômicos globais, sem que dados proprietários ou segredos comerciais precisem sair dos limites de cada organização.

REFERÊNCIAS

BONCZEK, R. H.; HOLSAPPLE, C. W.; WHINSTON, A. B. Foundations of Decision Support Systems. New York: Academic Press, 1981.

BREIMAN, L. Random forests. Machine Learning, v. 45, n. 1, p. 5–32, 2001.

CAVALCANTE, I. M. et al. A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. International Journal of Information Management, v. 49, p. 86–97, 2019.

CHANDOLA, V.; BANERJEE, A.; KUMAR, V. Anomaly detection: a survey. ACM Computing Surveys, v. 41, n. 3, p. 1–58, 2009.



CHEN, T.; GUESTRIN, C. XGBoost: a scalable tree boosting system. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 22., 2016, San Francisco. Proceedings... New York: ACM, 2016. p. 785–794.

COOPER, R.; KAPLAN, R. S. Profit priorities from activity-based costing. *Harvard Business Review*, v. 69, n. 3, p. 130–135, mai./jun. 1991.

CRESWELL, J. W. *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches*. 4. ed. Thousand Oaks: Sage, 2014.

DOSHI-VELEZ, F.; KIM, B. Towards a rigorous science of interpretable machine learning. arXiv preprint arXiv:1702.08608, 2017.

FRANK, A. G. et al. Industry 4.0 technologies: implementation patterns in manufacturing companies. *International Journal of Production Economics*, v. 210, p. 15–26, 2019.

GORRY, G. A.; SCOTT MORTON, M. S. A framework for management information systems. *Sloan Management Review*, v. 13, n. 1, p. 55–70, 1971.

HOLSAPPLE, C. W.; WHINSTON, A. B. *Decision Support Systems: A Knowledge-Based Approach*. St. Paul: West Publishing, 1996.

HORNGREN, C. T.; DATAR, S. M.; RAJAN, M. V. *Cost Accounting: A Managerial Emphasis*. 15. ed. Upper Saddle River: Pearson, 2015.

HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. 2. ed. Melbourne: OTexts, 2018. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 10 jan. 2025.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: trends, perspectives, and prospects. *Science*, v. 349, n. 6245, p. 255–260, 2015.

KAGERMANN, H.; WAHLSTER, W.; HELBIG, J. Recommendations for implementing the strategic initiative Industrie 4.0. Munich: National Academy of Science and Engineering (Acatech), 2013.

KAPLAN, R. S.; ANDERSON, S. R. *Time-Driven Activity-Based Costing*. Boston: Harvard Business School Press, 2007.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015.

LIU, F. T.; TING, K. M.; ZHOU, Z.-H. Isolation forest. In: IEEE INTERNATIONAL CONFERENCE ON DATA MINING, 8., 2008, Pisa. Proceedings... Washington: IEEE Computer Society, 2008. p. 413–422.



LU, Y. et al. Industry 4.0: a survey on technologies, applications and open research issues. *Journal of Industrial Information Integration*, v. 6, p. 1–10, 2017.

LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. In: *ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS*, 30., 2017, Long Beach. Proceedings... Red Hook: Curran Associates, 2017. p. 4765–4774.

MAKRIDAKIS, S.; SPILOTIS, E.; ASSIMAKOPOULOS, V. Statistical and machine learning forecasting methods: concerns and ways forward. *PLOS ONE*, v. 13, n. 3, e0194889, 2018.

OLIVEIRA, G. A.; PACHECO, R. C. dos S. Zona Franca de Manaus: dinâmica produtiva, inovação e perspectivas para a Indústria 4.0. *Revista de Administração Pública*, v. 53, n. 5, p. 879–903, 2019.

PORTER, M. E.; HEPPELMANN, J. E. How smart, connected products are transforming competition. *Harvard Business Review*, v. 92, n. 11, p. 64–88, 2014.

POWER, D. J. A brief history of decision support systems. *DSSResources.COM*, 2007. Disponível em: <http://dssresources.com/history/dsshhistory.html>. Acesso em: 5 fev. 2025.

RIBEIRO, M. T.; SAMANTA, S.; GUESTIN, C. "Why should I trust you?": explaining the predictions of any classifier. In: *ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING*, 22., 2016, San Francisco. Proceedings... New York: ACM, 2016. p. 1135–1144.

SCHUH, G. et al. *Industrie 4.0 Maturity Index: Managing the Digital Transformation of Companies*. Munich: Herbert Utz, 2020.

SCHWAB, K. *The Fourth Industrial Revolution*. Geneva: World Economic Forum, 2016.

SHANK, J. K.; GOVINDARAJAN, V. *Strategic Cost Management: The New Tool for Competitive Advantage*. New York: Free Press, 1993.

SIMON, H. A. *The New Science of Management Decision*. Englewood Cliffs: Prentice Hall, 1977.

SUFRAMA. *Relatório de Indicadores do Polo Industrial de Manaus*. Manaus: Superintendência da Zona Franca de Manaus, 2022.

TURBAN, E.; ARONSON, J. E.; LIANG, T.-P. *Decision Support Systems and Intelligent Systems*. 7. ed. Upper Saddle River: Pearson Prentice Hall, 2005.

WANG, S. et al. Implementing smart factory of Industrie 4.0: an outlook. *International Journal of Distributed Sensor Networks*, v. 12, n. 1, p. 1–10, 2016.