

**UNIVERSIDADE DO ESTADO DO AMAZONAS
ESCOLA SUPERIOR DE TECNOLOGIA
CURSO DE ENGENHARIA DE PRODUÇÃO**

JOÃO VICTOR PESSOA DA SILVA

**INTELIGÊNCIA ARTIFICIAL PARA A PREVISÃO DE CAPACIDADE PRODUTIVA:
Desenvolvimento de um Modelo Preditivo de Machine Learning para Suporte à
Decisão em uma linha SMT**

**MANAUS
2025**

JOÃO VICTOR PESSOA DA SILVA

INTELIGÊNCIA ARTIFICIAL PARA A PREVISÃO DE CAPACIDADE PRODUTIVA:

Desenvolvimento de um Modelo Preditivo de Machine Learning para Suporte à
Decisão em uma linha SMT

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Produção da Escola Superior de Tecnologia da Universidade do Estado do Amazonas, como parte dos requisitos para a obtenção do grau de Bacharel em Engenharia de Produção.

Orientador(a): Prof(a). Dr, Alessandro de Souza Bezerra.

MANAUS
2025

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).
Sistema Integrado de Bibliotecas da Universidade do Estado do Amazonas.

S586i

Silva, João Victor Pessoa da

INTELIGÊNCIA ARTIFICIAL PARA A PREVISÃO DE
CAPACIDADE PRODUTIVA: : Desenvolvimento de um Modelo
Preditivo de Machine Learning para Suporte à Decisão em uma linha
SMT / João Victor Pessoa da Silva. Manaus : [s.n], 2025.

65 f.: color.; 21.0 cm.

TCC - Graduação em Engenharia de Produção- Universidade do
Estado do Amazonas, Manaus, 2025.

Inclui Apêndice.

Inclui Anexo.

Orientador: Alessandro de Souza Bezerra.

1. capacidade produtiva. 2. machine learning. 3. XGBoost. 4.
previsão de produção. 5. Power BI. I. Alessandro de Souza Bezerra
(Orient.) II. Universidade do Estado do Amazonas. III. Título

CDU(1997)658.5

JOÃO VICTOR PESSOA DA SILVA

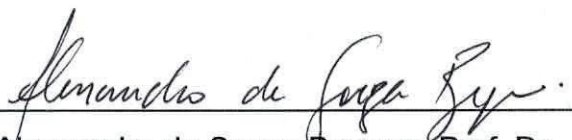
INTELIGÊNCIA ARTIFICIAL PARA A PREVISÃO DE CAPACIDADE PRODUTIVA:


Desenvolvimento de um Modelo Preditivo de Machine Learning para Suporte à
Decisão em uma linha SMT

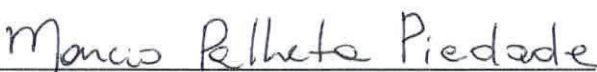
Trabalho apresentado ao curso de Engenharia de Produção da Universidade do Estado do Amazonas, como requisito parcial para a obtenção do grau de Bacharel em Engenharia de Produção.

Data de aprovação: Manaus (AM), 13 de novembro de 2025.

Banca examinadora:


Alessandro de Souza Bezerra, Prof. Dr.
Universidade do Estado do Amazonas


Renata da Encarnação Onety, Prof. Dra.
Universidade do Estado do Amazonas


Márcio Palheta Piedade, Prof. Dr.
Universidade do Estado do Amazonas

DEDICATÓRIA

Dedico este trabalho especialmente aos meus pais, Ana e Celsimar, que me possibilitaram chegar até este momento, sempre apoiando meus sonhos e me ensinando lições fundamentais para que eu me tornasse quem sou hoje, além de me darem todo o amor possível. Dedico também ao meu irmão, Caio, por estar comigo em toda a minha trajetória, e à minha namorada, Gabrielle, por tornar minha caminhada profissional e universitária mais leve e por fazer tudo ganhar sentido. Por fim, dedico ao meu tio Milton, que, sem dúvida, está orgulhoso de mim lá de cima.

AGRADECIMENTOS

Agradeço primeiramente a Deus por me possibilitar concluir minha vida acadêmica com muita saúde e por me guiar no caminho certo. Afinal, a trajetória é árdua e o caminho é longo.

Sou eternamente grato à minha mãe, Ana, e ao meu pai, Celsimar, por sempre me aconselharem a tomar as melhores decisões e, principalmente, por oferecerem absolutamente tudo que puderam para o meu crescimento.

Agradeço a todos os professores que participaram da minha formação, em especial aos professores Adan Medeiros, Raimundo Correa e Ricardo Barboza, que tornaram minha caminhada acadêmica mais proveitosa e rica, auxiliando-me com sábias palavras e direcionamentos.

Ao professor Alessandro Bezerra, por acreditar no meu trabalho e me orientar de maneira extremamente eficiente, e à professora Nadja, por toda a paciência e pelas valiosas orientações.

Agradeço aos meus colegas de faculdade, fundamentais na minha formação, por prestarem apoio em todas as dificuldades encontradas e deixarem o clima sempre mais leve e divertido, especialmente aos amigos Anderson Maffu, Daniel Prado, Gustavo Barpa, Fylype Wase, Igor Pitiri Pedro Luka e Rodrigo Messias.

Aos colegas de trabalho que encontrei ao longo desses anos de estudo, especialmente Ana Lídia, Hermeson Moraes e Willem, que foram as pessoas que mais compartilharam conhecimento comigo, sem medir esforços, e que criaram um forte vínculo de amizade a partir da prática da nossa profissão.

Agradeço também a todos que me deram palavras negativas e menosprezaram minhas conquistas, pois isso me deu ainda mais combustível durante a caminhada. O sucesso não é um acidente.

*“Insanidade é continuar fazendo sempre a
mesma coisa e esperar resultados diferentes”*
Autor Desconhecido

RESUMO

Este estudo aplica técnicas de Inteligência Artificial, com foco em *Machine Learning*, para previsão da capacidade produtiva em uma linha SMT de uma empresa do Polo Industrial de Manaus (PIM). O método tradicional utilizado pela organização baseia-se em cronoanálises pontuais e estimativas manuais, o que limita a precisão e a agilidade na identificação de gargalos e no planejamento da produção. O objetivo deste trabalho consiste em desenvolver um modelo preditivo baseado no algoritmo XGBoost e integrá-lo a um *dashboard* no Power BI, fornecendo uma ferramenta mais robusta, automatizada e confiável para suporte à tomada de decisão. A pesquisa caracteriza-se como estudo de caso com abordagem quantitativa, utilizando dados reais de produção e paradas de linha entre maio de 2024 e setembro de 2025. Após o pré-processamento dos dados, modelagem e avaliação por métricas como MAE, RMSE e R^2 , o modelo apresentou desempenho superior ao método tradicional, oferecendo previsões mais precisas e alinhadas ao comportamento real da linha. A integração dos resultados ao *dashboard* permitiu visualizações interativas por turno, mês e histórico de produção, ampliando a capacidade de análise e o monitoramento da operação.

Palavras chaves: capacidade produtiva; *machine learning*; XGBoost; previsão de produção; *Power BI*.

ABSTRACT

This study applies Artificial Intelligence techniques, specifically Machine Learning, to forecast production capacity in an SMT manufacturing line of a company located in the Industrial Pole of Manaus (PIM). The organization's traditional method relies on manual time measurements and static calculations, which limit precision and slow down the identification of bottlenecks and production planning. The aim of this research is to develop a predictive model based on the XGBoost algorithm and integrate it into a Power BI dashboard, providing a more reliable and data-driven tool to support decision-making. The study is conducted as a quantitative case study using real production and downtime records from May 2024 to September 2025. After data preprocessing, modeling, and evaluation using metrics such as MAE, RMSE, and R^2 , the proposed model demonstrated higher accuracy compared to the traditional approach, better reflecting the operational behavior of the production line. The integration with the dashboard enabled interactive analyses by shift, month, and historical performance, enhancing visibility over capacity indicators.

Keywords: *production capacity; machine learning; XGBoost; forecasting; Power BI.*

LISTA DE FIGURAS

Figura 1 – Linha SMT automatizada	15
Figura 2 - Etapas básicas do processo SMT	21
Figura 3 - Medições de tempo de ciclo das máquinas	38
Figura 4 - Método de capacidade produtiva atual	39
Figura 5 - Informações dos dados de parada de linha	40
Figura 6 - Informações dos dados quantidade de placas produzidas	40
Figura 7 - Estrutura final da base de dados após pré-processamento	42
Figura 8 - Dashboard de previsão de capacidade produtiva (Power BI)	46
Figura 9 - Importância média das variáveis segundo valores SHAP.....	52
Figura 10 – Painel interativo no Power BI com filtros por turno	53
Figura 11 - Painel interativo no Power BI com filtros por mês	54

SUMÁRIO

1	INTRODUÇÃO	13
1.1	CONTEXTUALIZAÇÃO, PROBLEMA E JUSTIFICATIVA DA PESQUISA	13
1.2	HIPÓTESE(S)	14
1.3	OBJETIVOS	14
1.3.1	Objetivo geral	14
1.3.2	Objetivos específicos	15
1.4	USO DE INTELIGÊNCIA ARTIFICIAL (IA) E CONSIDERAÇÕES ÉTICAS	15
1.5	ESTRUTURAÇÃO DO TRABALHO	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	EVOLUÇÃO DOS SISTEMAS PRODUTIVOS	17
2.2	<i>SURFACE-MOUNT TECHNOLOGY (SMT)</i>	19
2.2.1	Etapas do processo SMT	20
2.2.2	Vantagens e desafios	22
2.3	CRONOANÁLISE	23
2.4	CAPACIDADE PRODUTIVA	24
2.5	PREVISÃO DE PRODUÇÃO	26
2.6	REGRESSÃO LINEAR	27
2.7	INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING	28
2.7.1	Métricas de Avaliação de Modelos Preditivos	29
2.8	<i>XG BOOST – EXTREME GRADIENT BOOSTING</i>	31
2.9	APLICAÇÃO DO XGBOOST NA PREVISÃO DE PRODUÇÃO	33
2.10	<i>POWER BI</i> E VISUALIZAÇÃO DE DADOS	35
2.11	RECURSOS COMPUTACIONAIS DE APOIO	36
3	MATERIAIS E MÉTODOS	37
3.1	METODOLOGIA	37
3.1.1	Método atual de cálculo da capacidade produtiva	38
3.2	COLETA DE DADOS	39

3.2.1	Pré-processamento dos Dados	40
3.3	MODELAGEM PREDITIVA	42
3.3.1	Engenharia de Atributos	43
3.3.2	Métricas de avaliação do modelo	43
3.3.3	Análise da importância das variáveis	44
3.3.4	Geração das previsões e exportação	44
3.3.5	Desenvolvimento do Dashboard	45
4	RESULTADOS E DISCUSSÃO	49
4.1	COMPARAÇÃO ENTRE OS MODELOS DE PREVISÃO	49
4.2	AVALIAÇÃO DAS MÉTRICAS DE DESEMPENHO DO MODELO	50
4.3	ANÁLISE DE IMPORTÂNCIA DAS VARIÁVEIS (<i>SHAP Values</i>)	51
4.4	ANÁLISE QUANTITATIVA DOS RESULTADOS COM DASHBOARD ..	52
4.4.1	Validação da Hipótese 2	53
5	CONSIDERAÇÕES FINAIS	56
6	RECOMENDAÇÕES	58
	REFERÊNCIAS	59
	ANEXO A – CÓDIGO EM PYHTON PARA CRIAÇÃO DE MODELO	61

1 INTRODUÇÃO

Em um cenário industrial competitivo, a otimização de processos produtivos e a gestão eficiente da capacidade são cruciais. Nas linhas de montagem de superfície (SMT), a previsão precisa da produção é desafiada pela complexidade dos processos e paradas inesperadas, gerando incertezas nas projeções de produção e na identificação de gargalos, o que compromete a tomada de decisão ágil e a aderência ao plano de produção (Corrêa, 2010). Diante disso, a Inteligência Artificial (IA) e o *Machine Learning* (ML) surgem como ferramentas transformadoras, capazes de analisar grandes volumes de dados históricos para identificar padrões complexos e gerar previsões de capacidade produtiva mais acuradas e robustas. Essa abordagem baseada em dados é fundamental para otimizar o planejamento e controle da produção, permitindo decisões mais assertivas e proativas, mitigando perdas e garantindo a competitividade no ambiente fabril moderno.

1.1 CONTEXTUALIZAÇÃO, PROBLEMA E JUSTIFICATIVA DA PESQUISA

Em ambientes industriais altamente competitivos, como o Polo Industrial de Manaus (PIM), onde a empresa em estudo está inserida, a gestão da capacidade produtiva é um elemento crucial para a sobrevivência e crescimento. O PIM, um polo fabril diversificado e de grande importância econômica, exige constante otimização e uso eficiente de recursos para atender às demandas do mercado. Assim, a aplicação de modelos preditivos baseados em Inteligência Artificial para prever com precisão a capacidade produtiva em linhas de produção complexas, como as de montagem de superfície (SMT), torna-se indispensável. Essa abordagem não só garante a competitividade, mas também aprimora a tomada de decisão estratégica neste ambiente dinâmico e de alta produção.

Na empresa em estudo, a análise da capacidade produtiva enfrenta desafios significativos. Historicamente, a coleta de dados e a integração entre as informações do chão de fábrica e os sistemas de análise têm sido obstáculos. Esse cenário tradicionalmente resulta em processos que demandam tempo excessivo, estão sujeitos a erros humanos e dificultam a obtenção de resultados confiáveis e ágeis para a tomada de decisões estratégicas. Mesmo com o uso de ferramentas básicas de análise de dados, a capacidade de prever a capacidade futura com alta precisão e de

forma proativa, considerando a complexidade das variáveis operacionais, ainda é limitada.

Diante desse cenário e da crescente maturidade das tecnologias de Inteligência Artificial e Machine Learning, surgem os seguintes problemas de pesquisa:

- a) Como melhorar e otimizar o processo de análise de dados para estudo de capacidade produtiva?
- b) De que forma um modelo preditivo de Machine Learning, alimentado por dados de produtividade e paradas de linhas, pode agilizar a tomada de decisões e otimização do planejamento da produção?
- c) É viável desenvolver um dashboard que forneça previsões de capacidade produtiva, e permita simulações de cenários para a tomada de decisão estratégica?

Frente aos desafios da gestão eficiente da capacidade produtiva em linhas automatizadas, a adoção de soluções tecnológicas avançadas que integrem análise preditiva de dados é indispensável. Neste contexto, a aplicação de Inteligência Artificial surge como uma abordagem promissora, permitindo a análise de grandes volumes de dados para otimizar a gestão proativa do fluxo produtivo.

Este estudo visa, portanto, propor uma solução prática baseada em Machine Learning para a previsão da capacidade produtiva em diferentes cenários. Com isso, busca-se modernizar processos, impulsionar a excelência operacional e contribuir para o avanço da gestão da produção, alinhando-se aos conceitos da Indústria 4.0 e da manufatura inteligente.

1.2 HIPÓTESES

Hipótese 1: O uso de modelos de aprendizado de máquina (*XGBoost*) permitirá a precisão das previsões de capacidade produtiva de forma mais eficiente que os métodos manuais atualmente utilizados.

Hipótese 2: A integração entre o modelo preditivo os *Dashboard* interativos em Power BI, facilita o monitoramento do desempenho produtivo e apoia a tomada de decisão no chão de fábrica.

1.3 OBJETIVOS

1.3.1 Objetivo geral

Desenvolver uma solução computacional inteligente que utilize inteligência artificial através de Machine Learning para a análise preditiva da capacidade produtiva, com um Dashboard de visualização e apoio à tomada de decisão.

1.3.2 Objetivos específicos

- a) Realizar, de forma eficiente, com o apoio de IA e utilizando modelo de Machine Learning, a previsão da capacidade produtiva em diferentes cenários;
- b) Criar um Dashboard interativo no Power BI para facilitar a visualização e interpretação da capacidade produtiva do processo, promovendo a tomada de decisões mais assertivas e ágeis;
- c) Avaliar a aplicabilidade do modelo desenvolvido como ferramenta para análise e previsão da capacidade produtiva, em substituição ao método tradicional de cálculo.

1.4 USO DE INTELIGÊNCIA ARTIFICIAL (IA) E CONSIDERAÇÕES ÉTICAS

Neste trabalho, ferramentas de Inteligência Artificial foram utilizadas exclusivamente como apoio no desenvolvimento da pesquisa, mantendo-se sempre a autoria e responsabilidade intelectual do conteúdo sob responsabilidade do autor. O modelo ChatGPT (OpenAI) foi empregado para auxiliar na organização de ideias, na estruturação de seções do texto e na revisão gramatical, sempre com conferência, ajustes e validação humana.

Além do suporte textual, a IA também foi utilizada como ferramenta de apoio técnico durante o desenvolvimento do código em Python, especialmente para esclarecimento de dúvidas relacionadas ao algoritmo *XGBoost* e à interpretação dos gráficos SHAP gerados no Google Colab. Ressalta-se que todos os cálculos, códigos, pré-processamentos e análises foram executados, conferidos e ajustados manualmente pelo autor, sem delegar à IA qualquer função decisória ou autoria de resultados. As ferramentas de IA serviram estritamente como recurso complementar, conforme previsto pelas diretrizes éticas da instituição.

1.5 ESTRUTURAÇÃO DO TRABALHO

Este trabalho de conclusão de curso está estruturado em seis seções principais, visando uma abordagem compreensiva e sistemática do tema.

A seção 1 apresenta a pesquisa, contextualizando o problema identificado, sua relevância para o ambiente industrial, além de expor os objetivos geral e específicos, a justificativa do estudo e a organização do conteúdo.

A seção 2 aborda a fundamentação teórica, discutindo os principais conceitos relacionados à evolução dos sistemas produtivos, aos princípios da cronoanálise, ao cálculo da capacidade produtiva, às características das linhas SMT/PCBA, aos sistemas de coleta de dados e aos métodos de previsão. Esta seção também apresenta o algoritmo *XGBoost* e seu uso em aplicações preditivas.

Na seção 3 são descritos a metodologia empregada, o conjunto de dados analisado, os critérios de seleção e tratamento das variáveis, bem como o processo de treinamento do modelo preditivo. Também são detalhadas as etapas de interpretação das variáveis por meio dos valores *SHAP* e a construção do dashboard no Power BI.

A seção 4 apresenta os resultados obtidos, incluindo a comparação entre o método tradicional de cálculo da capacidade produtiva e o modelo proposto, a análise das métricas de desempenho, a importância relativa das variáveis e a visualização dos dados por meio do *dashboard*.

Por fim, a seção 5 reúne as conclusões do estudo, discutindo o alcance dos objetivos, as contribuições práticas e teóricas e as limitações encontradas, enquanto a seção 6 apresenta sugestões de trabalhos futuros que possam aprofundar ou expandir o uso de modelos preditivos e ferramentas de inteligência artificial na gestão da capacidade produtiva.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta revisão de literatura, são abordados os principais conceitos e fundamentos que sustentam este estudo, incluindo a evolução dos sistemas produtivos, desde os modelos clássico até a adoção de tecnologias avançadas aplicadas à manufatura. Também são apresentados os princípios da tecnologia de montagem em superfície (SMT), essencial para a automação e eficiência das linhas eletrônicas, e a utilização da cronoanálise como ferramenta para medir tempos, identificar gargalos e otimizar processos. Além disso, são explorados conceitos de capacidade produtiva e previsão de produção, com destaque para o uso de modelos de aprendizado de máquina, como o *XGBoost*, e o apoio de dashboards e ferramentas de visualização de dados para monitoramento e análise em tempo real, fortalecendo a tomada de decisão baseada em informações confiáveis.

2.1 EVOLUÇÃO DOS SISTEMAS PRODUTIVOS

A evolução dos sistemas produtivos ao longo do tempo reflete as mudanças sociais, econômicas e tecnológicas enfrentadas pelas indústrias. Desde o início da Revolução Industrial, com a mecanização dos processos, até os dias atuais, com a aplicação de tecnologias avançadas, diferentes modelos foram desenvolvidos para aumentar a eficiência e atender às demandas de um mercado em constante transformação. Nesse processo de evolução, surgiram abordagens que buscaram sistematizar e aprimorar a forma de produzir, como o Taylorismo, que marcou uma nova etapa na organização do trabalho.

Desenvolvido por Frederick Winslow Taylor, o Taylorismo marcou o início da aplicação sistemática de princípios científicos à gestão da produção. Taylor propôs que a eficiência poderia ser alcançada pela análise detalhada de cada tarefa, promovendo a padronização dos processos e a especialização do trabalho. Esse modelo introduziu os estudos de tempos e movimentos, que permitiram identificar os métodos mais eficientes para a execução de atividades produtivas. Ao propor a separação entre o planejamento e a execução das tarefas, Taylor lançou as bases para a administração científica, um marco importante para a Engenharia de Produção (Chiavenato, 2014).

Embora o Taylorismo tenha desempenhado um papel fundamental na racionalização do trabalho e no aumento da produtividade, ele também suscitou

questões sobre o bem-estar dos trabalhadores, muitas vezes tratados de forma mecanicista. Em contraste, abordagens contemporâneas da gestão da produção e da engenharia organizacional enfatizam a necessidade de integrar fatores humanos e motivacionais aos sistemas produtivos, buscando uma visão mais holística e sustentável que transcende a mera eficiência técnica.

Baseando-se nos princípios do Taylorismo, Henry Ford desenvolveu o Fordismo, um modelo de produção em massa que transformou a indústria no início do século XX. O sistema Fordista introduziu a linha de montagem, permitindo a fabricação de produtos em larga escala e com custos reduzidos. Essa abordagem foi essencial para a popularização de bens de consumo, como os automóveis, e consolidou a padronização como uma prática indispensável na manufatura.

Autores como Slack et al. (2010) destacam que o Fordismo foi uma resposta às demandas de um mercado em expansão, onde a uniformidade e a eficiência eram prioridades. No entanto, a rigidez do modelo limitava a capacidade de adaptação às mudanças do mercado e a personalização dos produtos, gerando um cenário desafiador para a competitividade. Essa falta de flexibilidade contribuiu para o declínio do Fordismo em favor de modelos mais adaptáveis e voltados para a inovação. Nesse contexto, o Toyotismo surgiu como uma alternativa capaz de superar as limitações do modelo fordista, propondo uma nova forma de organização da produção mais flexível e eficiente.

Idealizado por Taiichi Ohno, o Toyotismo trouxe uma ruptura significativa em relação aos modelos anteriores ao focar na produção enxuta, ou Lean Manufacturing. Baseado nos princípios de redução de desperdícios e melhoria contínua, o Sistema Toyota de Produção (TPS) incorporou ferramentas como o Just-in-Time e o Kanban, que promovem a sincronização da produção com a demanda real, e o Kaizen, que estimula a inovação e o engajamento dos trabalhadores.

Assim, a evolução dos sistemas produtivos, desde os princípios da administração científica até a produção enxuta, reflete a busca contínua por maior eficiência, flexibilidade e qualidade. Essa trajetória histórica consolidou os fundamentos que sustentam as práticas modernas de manufatura e abriu caminho para a integração de tecnologias avançadas nos processos produtivos. Nesse cenário de transformação, surgiram sistemas automatizados e altamente precisos, como a Surface-Mount Technology (SMT), que representa a aplicação

contemporânea desses conceitos na produção de componentes eletrônicos em larga escala.

2.2 SURFACE-MOUNT TECHNOLOGY (SMT)

A *Surface-Mount Technology (SMT)*, ou tecnologia de montagem em superfície, é uma das principais inovações resultantes da evolução dos sistemas produtivos e do avanço da automação industrial. Desenvolvida para atender à crescente demanda por miniaturização, precisão e velocidade nos processos de montagem de placas eletrônicas, a SMT se consolidou como o padrão dominante na indústria eletrônica moderna.

O SMT surgiu como resposta à crescente demanda por dispositivos mais compactos e com melhor desempenho, impulsionada pela expansão da indústria eletrônica nas décadas de 1960 e 1970. Com o avanço dos materiais e a popularização da automação industrial, o processo foi sendo aprimorado até tornar-se o padrão de fabricação predominante nas décadas seguintes (SYLVAN, 2017).

A tecnologia de montagem superficial representa um marco tecnológico ao unir precisão, eficiência e confiabilidade. A automação das etapas de aplicação de pasta de solda, posicionamento de componentes e soldagem por refusão garantiu alta padronização e repetibilidade, reduzindo a intervenção manual e os custos de produção. Além disso, o uso de sistemas automatizados de inspeção, como *SPI (Solder Paste Inspection)* e *AOI (Automated Optical Inspection)*, assegura a qualidade das juntas de solda e a rastreabilidade do processo, aspectos fundamentais em linhas de produção que exigem elevado controle de qualidade.


Nas linhas de montagem de módulos de multimídia automotivo, o *SMT* desempenha papel essencial por permitir a integração de múltiplas funções eletrônicas em um espaço reduzido, garantindo confiabilidade e desempenho adequado às condições do ambiente veicular. Essa tecnologia oferece diversas vantagens competitivas para a indústria eletrônica moderna, entre as quais destacam-se:

- Maior densidade de componentes na placa, reduzindo volumes e peso do conjunto final.
- Automatização da montagem: o uso de equipamentos de impressão de pasta de solda, de máquinas de posicionamento (“pick & place”) e fornos de refusão favorece a padronização, a escala e a repetibilidade do processo.

- Redução de etapas de manufatura (menos furos na placa, menos inserções manuais) e, conseqüentemente, menores custos e tempo de ciclo.
- Adequação a requisitos de miniaturização e desempenho (por exemplo, em componentes de alta frequência, aplicações automotivas ou portáteis).

A consolidação da tecnologia SMT não apenas representou um avanço na forma de produzir circuitos eletrônicos, mas também estabeleceu novos padrões de qualidade e eficiência industrial. A compreensão detalhada das etapas que compõem esse processo, conforme ilustrado na Figura 1, é fundamental para garantir o controle produtivo e a confiabilidade das montagens eletrônicas.

Figura 1 – Linha SMT automatizada



Fonte: PCBAsic, 2025.

2.2.1 Etapas do processo SMT


O processo Surface-Mount Technology (SMT) é composto por uma sequência de etapas interdependentes que exigem alto grau de precisão, controle de qualidade e padronização. Cada fase desempenha um papel essencial na obtenção de uma montagem eletrônica confiável, e pequenas variações em qualquer uma delas podem comprometer a integridade do produto final.

Segundo Cao et al. (2020), a integração entre equipamentos automatizados, controle ambiental e inspeção contínua é o que garante a eficiência e a estabilidade do processo SMT. Em linhas modernas, o fluxo de produção é amplamente automatizado e monitorado por sistemas inteligentes capazes de detectar falhas em

tempo real e ajustar parâmetros automaticamente, o que reduz o retrabalho e aumenta a produtividade.

A montagem SMT é estruturada de forma linear, em que cada etapa prepara a placa para a próxima, buscando a máxima eficiência e repetibilidade. A padronização dos procedimentos e o controle dos parâmetros críticos, como viscosidade da pasta de solda, velocidade de deposição, temperatura de refusão e precisão de posicionamento são fundamentais para evitar defeitos como pontes de solda, desalinhamentos, bolhas e curtos-circuitos, conforme ilustrado na Figura 2.

Figura 2 – Etapas básicas do processo SMT



Fonte: Adaptado de Mdpi, 2022.

Assim, o domínio das etapas do processo é indispensável não apenas para o controle da qualidade, mas também para a otimização da capacidade produtiva e redução do tempo de ciclo.

O processo SMT padrão envolve várias etapas críticas que necessitam de controle rigoroso:

1. Aplicação de pasta de solda: utilização de estêncil para depositar pasta na placa, conforme o padrão dos pads.
2. Posicionamento dos componentes: máquinas de posicionamento colocam componentes SMD sobre a pasta depositada nos locais correspondentes.
3. Refusão da solda: a placa com os componentes passa por um forno de refusão que derrete a pasta de solda, assegurando a fixação mecânica e elétrica dos componentes.

4. Inspeção e controle de qualidade: verificações como Solder Paste Inspection (SPI), Automated Optical Inspection (AOI), e testes de confiabilidade são essenciais para garantir a qualidade das montagens.
5. Reparos e controle de defeitos: eventuais reposicionamentos, retrabalho e análise de falhas fazem parte do ciclo, sobretudo quando se trabalha com componentes finos ou pacotes avançados.

O controle eficaz dessas etapas é determinante para assegurar a qualidade e confiabilidade dos produtos eletrônicos, especialmente em setores que demandam alto desempenho, como o automotivo. A constante evolução dos equipamentos, associada à integração com sistemas de monitoramento baseados em inteligência artificial, tem permitido alcançar níveis cada vez maiores de precisão, rastreabilidade e eficiência na manufatura SMT.

2.2.2 Vantagens e desafios

A adoção do SMT trouxe uma série de benefícios que transformaram o modo como as empresas produzem e projetam seus sistemas eletrônicos. A possibilidade de montagem direta dos componentes sobre a superfície da placa permitiu reduzir significativamente o espaço ocupado, aumentar a densidade de circuitos e melhorar o desempenho elétrico, especialmente em aplicações que exigem alta frequência e baixo consumo de energia. Além disso, a automação proporcionada por máquinas de inserção e fornos de refusão contribuiu para o aumento da produtividade e da padronização, reduzindo a variabilidade típica dos processos manuais.

Entretanto, essa tecnologia também introduziu novos desafios. A miniaturização dos componentes e a alta precisão exigida nas etapas de impressão de pasta de solda e posicionamento demandam controle rigoroso de processo e equipamentos de alto desempenho. Pequenas variações de alinhamento ou de temperatura no forno de refusão podem resultar em defeitos de solda que comprometem a confiabilidade do produto acabado. Outro ponto crítico é o gerenciamento térmico, uma vez que componentes de montagem superficial são mais sensíveis a variações de temperatura durante a operação e ao estresse mecânico proveniente da diferença de dilatação entre materiais.

Em linhas de montagem automotiva, como as utilizadas para produção de módulos de multimídia, o SMT representa uma etapa estratégica por garantir qualidade e repetibilidade em grande escala. O uso de sistemas automatizados de

inspeção, como SPI (Solder Paste Inspection) e AOI (Automated Optical Inspection), tornou-se essencial para detectar desvios ainda nas fases iniciais do processo, evitando retrabalhos e perdas posteriores. Assim, o SMT não apenas aumenta a eficiência produtiva, mas também contribui para a confiabilidade e longevidade dos produtos eletrônicos, aspectos fundamentais no setor automotivo.

2.3 CRONOANÁLISE

A análise dos processos SMT evidencia a importância de compreender e controlar os tempos de ciclo para garantir a eficiência e a estabilidade produtiva. Nesse contexto, a cronoanálise destaca-se como uma das principais ferramentas da Engenharia de Produção voltadas à medição e otimização do desempenho operacional. Segundo Corrêa e Corrêa (2017), o estudo sistemático dos tempos de execução das atividades é essencial para identificar gargalos, padronizar processos e aumentar a produtividade industrial.

De acordo com Tubino (2017), a cronoanálise é um método estruturado que busca determinar o tempo padrão necessário para a execução de uma tarefa, considerando fatores como fadiga, ritmo de trabalho e variações operacionais. Essa medição possibilita o balanceamento das linhas de montagem, o cálculo do takt time e a determinação da capacidade real de produção, elementos fundamentais para o gerenciamento eficiente dos sistemas produtivos.

Um conceito fundamental associado à análise de tempos é o de gargalo de produção, definido como o ponto do processo que limita o ritmo global da linha. Segundo Tubino (2017), o gargalo corresponde à operação com o maior tempo de ciclo, restringindo a vazão total do sistema e determinando o ritmo máximo de produção. A correta identificação desse posto é essencial para o balanceamento da linha, pois orienta esforços de melhoria contínua e permite concentrar ações em atividades que efetivamente impactam o desempenho geral. De acordo com Slack et al. (2022), a eliminação ou mitigação de gargalos pode resultar em aumentos significativos de produtividade, redução de estoques intermediários e maior estabilidade do fluxo produtivo.

Em linhas de produção SMT, a aplicação da cronoanálise permite observar o comportamento dos equipamentos e operadores, medindo o tempo de ciclo de cada etapa do processo. A partir desses dados, é possível identificar o posto de gargalo, compreender o ritmo produtivo e propor melhorias no fluxo operacional. Contudo, o

método manual de medição apresenta limitações quanto à sua frequência de aplicação e à dependência de observação humana, além de ser suscetível a erros e subjetividades.

Com o avanço da digitalização industrial e a consolidação da Indústria 4.0, a cronoanálise vem sendo gradualmente integrada a sistemas automatizados de coleta e processamento de dados. Segundo Pereira et al. (2021), tecnologias como sensores, sistemas supervisórios e algoritmos de aprendizado de máquina permitem capturar informações de produção em tempo real, transformando a análise de tempos em um processo contínuo, automatizado e preditivo. Essa evolução amplia o potencial da cronoanálise, que deixa de ser uma ferramenta pontual e passa a atuar como base conceitual para modelos inteligentes de gestão da produção.

Dessa forma, a cronoanálise mantém sua relevância como instrumento de estudo e padronização de tempos, mas assume, no contexto da manufatura moderna, um papel complementar aos sistemas de análise de dados e de previsão de desempenho. Essa integração entre técnicas clássicas e tecnologias emergentes reforça a importância da cronoanálise como suporte ao planejamento e controle da produção.

2.4 CAPACIDADE PRODUTIVA

A capacidade produtiva é um dos conceitos fundamentais em sistemas produtivos, pois está diretamente relacionada à quantidade de produtos ou serviços que uma organização consegue gerar em um determinado período, utilizando os recursos disponíveis de maneira eficiente. De acordo com Slack et al. (2009), a capacidade produtiva representa o limite máximo de produção que pode ser alcançado em um sistema, levando em consideração restrições de mão de obra, máquinas, materiais e infraestrutura. O estudo da capacidade produtiva é indispensável para a gestão eficiente dos recursos, permitindo que a organização planeje suas operações de forma a atender à demanda do mercado com o menor custo possível. Segundo Corrêa e Corrêa (2012), a análise da capacidade produtiva deve considerar não apenas o desempenho das máquinas e equipamentos, mas também fatores humanos, como a eficiência dos operadores e os tempos de parada para descanso, manutenção ou ajustes.

A capacidade produtiva pode ser analisada sob diferentes perspectivas, que ajudam a fornecer uma visão mais completa do potencial e do desempenho real da

organização. A capacidade projetada é definida como o potencial teórico de produção em condições ideais, sem interrupções. A capacidade efetiva, por sua vez, considera as perdas inerentes e inevitáveis do processo, como manutenções planejadas e paradas programadas, representando o máximo que a empresa espera alcançar sob condições operacionais normais. Já a capacidade real reflete o desempenho efetivamente observado no dia a dia, incluindo os impactos de imprevistos, como quebras de máquinas ou ausências de operadores (Chase et al., 2006). Essa distinção é importante porque o cálculo e a análise desses três níveis proporcionam uma visão prática e mais próxima da realidade da operação, auxiliando gestores a tomar decisões informadas sobre a alocação de recursos e a necessidade de melhorias no processo produtivo.

A capacidade produtiva é influenciada por uma gama de fatores interconectados. O layout da fábrica ou do ambiente de serviço, por exemplo, impacta diretamente a fluidez do processo e a movimentação. O nível de automação e a tecnologia empregada são determinantes para a velocidade e precisão da produção. A mão de obra, sua qualificação, treinamento e motivação, afeta diretamente o desempenho e a eficiência. A manutenção adequada dos equipamentos é vital para garantir sua disponibilidade e evitar paradas não programadas, que reduzem significativamente a capacidade. Adicionalmente, a integração de sistemas de informação, como planilhas avançadas e interfaces de coleta de dados, desempenha um papel significativo na análise da capacidade, facilitando a obtenção de dados precisos para tomada de decisão (Corrêa, 2010). Essas ferramentas possibilitam calcular e monitorar a capacidade produtiva, identificar gargalos e ajustar a produção em tempo real, aumentando a eficiência operacional.

Compreender e otimizar a capacidade produtiva é essencial para o sucesso competitivo de uma empresa, assumindo um papel estratégico fundamental. Como destacam Heizer et al. (2004), uma capacidade subutilizada representa desperdício de recursos, enquanto uma capacidade insuficiente pode levar a atrasos na entrega e insatisfação dos clientes. Uma capacidade bem dimensionada permite à empresa aproveitar oportunidades de crescimento, manter a flexibilidade para inovar e reagir aos concorrentes, consolidando sua posição no mercado. Analisar a capacidade não é apenas um indicador de eficiência, mas um fator estratégico para a definição de políticas de crescimento e investimento, impulsionando a organização a identificar

áreas de melhoria, priorizar investimentos em tecnologia e adaptar-se rapidamente às mudanças na demanda do mercado

. A tomada de decisão sobre o nível de capacidade, portanto, é complexa e exige uma visão holística do negócio, com planejamento de longo prazo para garantir que os recursos disponíveis possam acompanhar a evolução das necessidades do mercado e sustentar o crescimento desejado, o que nos leva a considerar a importância da aplicação de técnicas para mensurar e otimizar esses recursos. Nesse sentido, a previsão de produção torna-se uma ferramenta essencial para apoiar a definição de estratégias produtivas e antecipar cenários futuros

2.5 PREVISÃO DE PRODUÇÃO

A previsão de produção é um componente vital na gestão industrial, atuando como um pilar fundamental para a tomada de decisões estratégicas e operacionais. Seu conceito central reside na estimativa de eventos futuros, geralmente a demanda por produtos ou serviços, com o objetivo de planejar as atividades produtivas de forma eficiente. Em um ambiente de negócios cada vez mais volátil e incerto, a capacidade de prever com precisão o que o mercado exigirá é crucial para a sustentabilidade e a importância da previsão se manifesta na redução de incertezas, otimização de recursos e garantia de que a empresa esteja preparada para atender às necessidades dos clientes (Slack et al., 2009). Uma previsão inadequada pode resultar em excesso de estoque e desperdício de recursos, ou em falta de produtos e perda de vendas, afetando a reputação e a competitividade da organização.

As aplicações da previsão de produção são vastas e perpassam diversas áreas da gestão de operações. Ela é indispensável no planejamento de capacidade, onde as estimativas futuras de demanda guiam as decisões sobre investimentos em equipamentos, expansão de instalações e contratação de mão de obra. Na gestão de estoques, uma previsão acurada permite determinar os níveis ótimos de matéria-prima, produtos em processo e produtos acabados, minimizando custos de armazenagem e riscos de obsolescência ou ruptura. A programação de máquinas e o sequenciamento de tarefas se beneficiam da previsão ao otimizar a utilização dos ativos, reduzir tempos de setup e evitar gargalos. Por fim, a análise de demanda se aprofunda nos padrões históricos de consumo e nas tendências de mercado, enriquecendo as previsões e permitindo uma compreensão mais profunda do comportamento do consumidor (Stevenson, 2015).

Historicamente, a previsão de produção baseou-se em métodos estatísticos e matemáticos, amplamente utilizados por sua simplicidade e boa aplicabilidade em cenários com comportamento estável de demanda. Entre eles, destaca-se a regressão linear, que busca estabelecer relações entre a demanda e variáveis explicativas, oferecendo resultados satisfatórios em contextos com poucas variáveis e padrões bem definidos. Contudo, tais métodos apresentam limitações ao lidar com a complexidade e a não linearidade dos dados industriais modernos.

Em contrapartida, os métodos baseados em aprendizado de máquina (*machine learning*) têm ganhado destaque, oferecendo abordagens mais robustas e adaptáveis. Técnicas como Redes Neurais Artificiais, Random Forests e *XGBoost* demonstram elevada capacidade de identificar padrões complexos e interações não lineares em grandes volumes de dados, superando frequentemente os modelos tradicionais em termos de precisão e generalização (Makridakis, Spiliotis & Assimakopoulos, 2018).

A escolha do método mais adequado depende da natureza dos dados, da disponibilidade de recursos computacionais e da expertise da equipe, mas a tendência é que a combinação ou a evolução para abordagens mais avançadas se torne cada vez mais necessária para aprimorar a assertividade das estimativas. Com isso, torna-se essencial explorar as bases metodológicas que sustentam a validação e a implementação prática dessas técnicas.

2.6 REGRESSÃO LINEAR

A regressão linear é uma das técnicas estatísticas mais utilizadas na análise de dados e na construção de modelos de previsão. Seu princípio consiste em identificar e quantificar a relação entre uma variável dependente e uma ou mais variáveis independentes, permitindo estimar o comportamento futuro de um processo com base em dados históricos. Segundo Montgomery, Peck e Vining (2012), a regressão busca ajustar uma equação matemática que descreve, de forma aproximada, como a variável de interesse é influenciada por fatores explicativos.

Na regressão linear simples, o modelo relaciona uma variável dependente Y a apenas uma variável independente X , sendo expresso pela equação:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

Em que β_0 representa o intercepto (ou ponto onde a reta cruza o eixo Y), β_1 o coeficiente angular (taxa de variação de Y em relação a X) e ε o termo de erro aleatório.

Conforme Hair et al. (2009), esse tipo de modelo é adequado quando o objetivo é compreender o impacto direto de uma única variável sobre o resultado analisado.

Já a regressão linear múltipla considera duas ou mais variáveis independentes, possibilitando representar fenômenos mais complexos e multifatoriais. Nessa abordagem, o modelo é definido por:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon$$

De acordo com Gujarati e Porter (2011), a regressão múltipla permite estimar o efeito individual de cada variável explicativa, controlando a influência das demais. Essa flexibilidade a torna especialmente útil em contextos industriais, onde diferentes fatores — como tempo de parada, tipo de máquina e turno de trabalho — podem afetar simultaneamente o desempenho produtivo.

A regressão linear é considerada um método de previsão supervisionado, pois requer dados históricos nos quais as variáveis de entrada e a variável de saída sejam conhecidas. Apesar de sua simplicidade e facilidade de interpretação, o modelo linear possui limitações quando as relações entre as variáveis não seguem um comportamento estritamente linear ou quando há interações complexas entre os fatores analisados.

Nessas situações, técnicas mais avançadas de aprendizado de máquina, como o *XGBoost*, surgem como uma evolução da regressão linear, incorporando algoritmos capazes de lidar com padrões não lineares, interações entre variáveis e dados ruidosos, proporcionando maior precisão nas previsões.

2.7 INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING

A Inteligência Artificial (IA) é um dos principais pilares da transformação digital e da Indústria 4.0, sendo aplicada em diversos contextos produtivos com o objetivo de automatizar, prever e otimizar processos. De acordo com Russell e Norvig (2021), a IA pode ser compreendida como o campo da ciência da computação que busca desenvolver sistemas capazes de aprender, raciocinar e tomar decisões de maneira semelhante ao ser humano. Sua utilização no ambiente industrial tem se expandido rapidamente, impulsionada pela necessidade de lidar com grandes volumes de dados e pela busca por eficiência e confiabilidade nos processos produtivos.

No contexto da manufatura, a IA atua como uma ferramenta estratégica para a análise de dados operacionais, permitindo que empresas antecipem falhas, melhorem o planejamento da produção e otimizem a utilização de recursos. Segundo Davenport

e Kalakota (2019), a aplicação de algoritmos inteligentes possibilita interpretar informações em tempo real e transformar dados históricos em previsões precisas, tornando o processo decisório mais ágil e fundamentado. Essa capacidade analítica é essencial em sistemas produtivos modernos, que operam com alto grau de automação e exigem respostas rápidas a variações de demanda e desempenho.

Entre os diversos ramos da Inteligência Artificial, destaca-se o Aprendizado de Máquina (Machine Learning – ML), que constitui o núcleo das aplicações preditivas industriais. O ML consiste em métodos e algoritmos que permitem que sistemas aprendam padrões e comportamentos a partir de dados, sem depender de programação explícita. Conforme Goodfellow, Bengio e Courville (2016), o aprendizado de máquina utiliza técnicas como regressão, classificação e agrupamento para identificar tendências e realizar previsões com base em informações históricas. Essa abordagem torna-se particularmente valiosa em linhas de produção, onde a previsão de capacidade, a análise de gargalos e o controle de paradas dependem de dados coletados continuamente.

A aplicação de IA e ML em processos produtivos, especialmente em linhas SMT (Surface-Mount Technology), permite construir modelos preditivos capazes de antecipar o comportamento da produção e auxiliar na tomada de decisão operacional. Esses modelos utilizam dados operacionais e históricos do processo produtivo para identificar tendências e padrões de desempenho e estimar o comportamento futuro da linha, contribuindo para uma gestão mais precisa e preditiva da capacidade produtiva. Além de reduzir a necessidade de medições manuais e minimizar erros humanos, o uso dessas técnicas promove uma análise mais precisa e integrada do sistema produtivo. Dessa forma, a Inteligência Artificial e o Machine Learning assumem papel central na previsão e otimização da capacidade produtiva, transformando dados operacionais em conhecimento estratégico.

2.7.1 Métricas de Avaliação de Modelos Preditivos

A avaliação de modelos preditivos é uma etapa essencial no desenvolvimento de soluções baseadas em aprendizado de máquina, pois permite mensurar o grau de precisão e confiabilidade das previsões em relação aos valores reais observados. Segundo Han, Kamber e Pei (2012), o uso de métricas adequadas possibilita comparar diferentes algoritmos e validar se o modelo proposto apresenta desempenho satisfatório para o problema estudado.

Entre as métricas mais utilizadas em modelos de regressão estão o Erro Absoluto Médio (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Determinação (R^2).

O MAE (Mean Absolute Error) mede a média das diferenças absolutas entre os valores previstos e os valores reais. Representa, em unidades do próprio dado analisado, o quanto as previsões se desviam dos resultados observados. Quanto menor o MAE, mais precisas são as previsões do modelo.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

O RMSE (Root Mean Squared Error), por sua vez, é uma métrica mais sensível a erros grandes, pois eleva ao quadrado as diferenças antes de calcular a média. Isso faz com que desvios maiores sejam penalizados de forma mais intensa. O RMSE também é expresso nas mesmas unidades da variável-alvo e, assim como o MAE, quanto menor seu valor, maior a precisão do modelo (Chai & Draxler, 2014).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Já o R^2 (Coeficiente de Determinação) indica o quanto da variabilidade dos dados reais é explicada pelo modelo. Ele varia de 0 a 1, sendo que valores próximos de 1 indicam um ajuste mais forte entre as previsões e os valores observados. Segundo Montgomery et al. (2012), essa métrica é amplamente utilizada por expressar a capacidade explicativa do modelo em termos percentuais.

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

A combinação dessas métricas permite uma análise mais abrangente do desempenho preditivo, equilibrando a sensibilidade a erros individuais com a capacidade de explicação geral do modelo. Dessa forma, é possível selecionar a abordagem mais adequada às características e ao comportamento dos dados analisados.

2.8 XG BOOST – EXTREME GRADIENT BOOSTING

A crescente complexidade dos desafios em Engenharia de Produção, especialmente na previsão e otimização de sistemas, tem impulsionado a adoção de métodos avançados de aprendizado de máquina. Entre eles, o *XGBoost* (*eXtreme Gradient Boosting*) se destaca como uma ferramenta preditiva de alta performance, consolidando-se como um dos algoritmos mais eficazes em contextos de dados tabulares. Sua definição reside na implementação otimizada de algoritmos de *gradient boosting* para árvores de decisão, representando uma evolução significativa sobre os métodos tradicionais de boosting ao incorporar inovações que o tornam excepcionalmente rápido, flexível e robusto (Chen & Guestrin, 2016). Originalmente desenvolvido por Tianqi Chen, o *XGBoost* ganhou proeminência por sua capacidade de entregar resultados de ponta em diversas competições de ciência de dados, tornando-se uma referência para análises preditivas em cenários industriais e de negócios.

As características principais do *XGBoost* são cruciais para compreender sua superioridade. Primeiramente, ele integra mecanismos de regularização L1 (Lasso) e L2 (Ridge) diretamente na função de custo. Essa regularização penaliza modelos excessivamente complexos, mitigando o risco de *overfitting* e promovendo a construção de modelos mais generalizáveis que performam bem em dados não vistos (Friedman, 2001). Adicionalmente, o *XGBoost* é reconhecido por sua alta eficiência e capacidade de lidar com grandes volumes de dados. Isso é alcançado por meio de otimizações de hardware, como o uso de computação paralela e distribuída, otimização de cache e manuseio eficiente de blocos de dados esparsos, o que permite o processamento de grandes conjuntos de dados de forma escalável (Chen & Guestrin, 2016). A flexibilidade do algoritmo também se manifesta no seu suporte a variáveis numéricas e categóricas, podendo ser aplicado em uma vasta gama de problemas sem a necessidade de pré-processamentos complexos para tipagem de dados.

O funcionamento do *XGBoost* baseia-se na construção de um modelo composto por árvores de decisão sequenciais. Em vez de treinar uma única árvore ou várias árvores independentes (como em Random Forest), o *gradient boosting* constrói as árvores uma após a outra, onde cada nova árvore tenta corrigir os erros (resíduos) da combinação das árvores anteriores. Esse processo iterativo é guiado pela minimização de uma função de perda usando gradiente, onde o algoritmo direciona o aprendizado das novas árvores para as áreas onde o modelo atual está mais incorreto.

A cada iteração, uma nova árvore é adicionada ao ensemble, e sua contribuição é ponderada por um fator de aprendizado (*learning rate*), permitindo que o modelo aprenda gradualmente e de forma mais estável (Hastie, Tibshirani & Friedman, 2009).

Para que o XGBoost atinja seu potencial máximo, a calibração de seus hiperparâmetros é de suma importância. O *learning rate* (taxa de aprendizado) controla o tamanho do passo que o algoritmo dá em cada iteração, influenciando diretamente a velocidade de convergência e o risco de *overfitting*. O *max_depth* define a profundidade máxima de cada árvore, limitando sua complexidade individual. O *n_estimators* (número de estimadores) determina a quantidade de árvores a serem construídas no modelo ensemble. Parâmetros como *subsample* e *colsample_bytree* controlam a amostragem de linhas e colunas (características), respectivamente, em cada iteração de construção de árvore. Essas técnicas de *subsampling* (também conhecidas como *feature sampling* e *data sampling*) são importantes para reduzir a variância e prevenir o *overfitting*, contribuindo para a robustez e a capacidade preditiva do modelo (Chen & Guestrin, 2016). A otimização cuidadosa desses hiperparâmetros, frequentemente realizada por meio de técnicas de busca em grade (*grid search*) ou otimização bayesiana, é um passo crítico para extrair o máximo desempenho do XGBoost em uma aplicação específica, garantindo que o modelo seja capaz de aprender padrões complexos nos dados para realizar previsões precisas.

Além de sua eficiência computacional, o XGBoost é classificado como um modelo ensemble, pois combina o resultado de múltiplas árvores de decisão para gerar uma predição final mais precisa e robusta. Nesse tipo de abordagem, diversas “árvores fracas” são treinadas de forma sequencial, e cada uma busca corrigir os erros das anteriores — um processo conhecido como *boosting*. Ao final, a soma ponderada dessas árvores forma um modelo capaz de capturar relações complexas entre as variáveis de entrada, reduzindo o viés e a variância do aprendizado (Chen & Guestrin, 2016).

Apesar de seu alto desempenho, o XGBoost é considerado um modelo opaco, ou seja, sua estrutura interna não é facilmente interpretável por humanos. Isso ocorre porque o resultado final é fruto da interação entre centenas de árvores de decisão, o que dificulta a visualização direta da contribuição individual de cada variável. O algoritmo inicia o processo com árvores simples e, a cada iteração, verifica os resíduos das previsões anteriores para construir novas árvores corretivas, aprimorando continuamente o desempenho do modelo. Essa característica de melhoria sequencial

garante alta acurácia, mas reduz a transparência interpretativa em comparação a métodos lineares tradicionais.

2.9 APLICAÇÃO DO XGBOOST NA PREVISÃO DE PRODUÇÃO

A transição de um algoritmo de *machine learning* do conceito teórico para uma aplicação prática em um ambiente industrial, como a previsão de produção, exige uma série de etapas metodológicas bem definidas. A eficácia do *XGBoost*, conforme discutido na seção anterior, é maximizada quando os dados são cuidadosamente preparados e o modelo é validado de forma rigorosa, permitindo a extração de insights operacionais valiosos.

A primeira etapa crucial é o pré-processamento de dados. Dados brutos raramente são adequados para o treinamento de modelos preditivos e, portanto, exigem tratamento. O tratamento de valores ausentes é fundamental, pois muitos algoritmos são sensíveis a gaps nos dados; estratégias como a imputação por média, mediana ou por métodos mais sofisticados (como k-nearest neighbors ou modelos preditivos específicos) devem ser consideradas, embora o *XGBoost* tenha certa robustez inerente a esses valores (Chen & Guestrin, 2016). A codificação de variáveis categóricas é outra exigência, transformando atributos textuais (e.g., tipo de parada, turno de trabalho) em formatos numéricos que o algoritmo possa processar, utilizando técnicas como One-Hot Encoding, Label Encoding ou Target Encoding, dependendo da natureza da variável e do seu impacto na performance do modelo. Além disso, a normalização ou transformação de features temporais, como hora do dia ou dia da semana, em representações cíclicas (e.g., seno/cosseno) pode melhorar a capacidade do modelo de capturar padrões sazonais (Hyndman & Athanasopoulos, 2018).

Um aspecto que impacta significativamente a performance de modelos de previsão é a criação de variáveis derivadas (feature engineering). Esta etapa consiste em construir novas features a partir dos dados existentes, adicionando informações contextuais importantes. Para a previsão de produção, a extração de sazonalidade é essencial, gerando variáveis como dia da semana, mês, trimestre ou indicadores de feriados, que podem influenciar diretamente o volume produtivo ou a ocorrência de paradas. A inclusão de médias móveis ou lags de variáveis cruciais (e.g., produção dos últimos X dias, média de paradas da semana anterior) pode capturar tendências e dependências temporais, fornecendo ao modelo informações sobre o estado

passado do sistema. A criação de indicadores de gargalos históricos, como a frequência ou duração média de paradas específicas em determinados períodos, transforma eventos passados em preditores valiosos para o desempenho futuro da linha (Aghajari & Rezaei, 2021).

Após o pré-processamento e a engenharia de features, a validação do modelo é indispensável para garantir sua capacidade de generalização para dados não vistos e evitar o *overfitting*. Para dados de séries temporais, a validação cruzada tradicional pode ser inadequada. Em vez disso, técnicas como cross-validation baseada em séries temporais ou, mais comumente, a estratégia de Time Series Split (ou Walk-Forward Validation) são preferíveis. Este método treina o modelo em dados históricos e testa em um período subsequente, simulando a aplicação real do modelo em produção e garantindo que o conjunto de teste seja sempre futuro em relação ao conjunto de treinamento (Bergmeir & Benítez, 2012).

A performance do modelo é quantificada por métricas estatísticas amplamente utilizadas em problemas de regressão, como o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Determinação (R^2). Essas medidas permitem avaliar a precisão do modelo e a sua capacidade de generalização em relação aos dados reais, garantindo uma análise quantitativa consistente da qualidade preditiva do *XGBoost*.

A interpretação dos resultados vai além da mera avaliação numérica da performance. O *XGBoost*, através de sua estrutura de árvores, permite a análise da feature importance, que ranqueia as variáveis de entrada de acordo com sua contribuição para as previsões do modelo. Além disso, entre as técnicas mais utilizadas para interpretar modelos de aprendizado de máquina baseados em árvores de decisão, destaca-se o método SHAP (SHapley Additive exPlanations), desenvolvido por Lundberg e Lee (2017). Essa abordagem, fundamentada na teoria dos jogos de Shapley, permite quantificar a contribuição de cada variável de entrada para o resultado previsto pelo modelo. Os valores SHAP são amplamente empregados em algoritmos como o *XGBoost*, por fornecerem uma explicação clara e consistente sobre a influência individual das variáveis no processo preditivo, contribuindo para maior transparência e interpretabilidade dos resultados. Essa capacidade é fundamental para identificar quais fatores são os mais influentes na previsão de produção, oferecendo insights acionáveis para a gestão operacional e a tomada de decisões focadas na causa raiz dos problemas.

Para que o modelo preditivo seja plenamente utilizado, sua integração com dashboards é um passo estratégico. A utilização do modelo para gerar previsões diárias ou semanais de produção e a subsequente exibição desses resultados em plataformas como Power BI, Tableau ou outras ferramentas de Business Intelligence, transforma as saídas complexas do modelo em informações acessíveis e visualmente intuitivas para gestores e operadores. Essa integração facilita o monitoramento contínuo, a identificação proativa de desvios e o planejamento adaptativo, maximizando o valor do *machine learning* na otimização dos processos produtivos.

2.10 POWER BI E VISUALIZAÇÃO DE DADOS

O *Power BI* é uma ferramenta de *Business Intelligence (BI)* desenvolvida pela *Microsoft*, amplamente utilizada para transformar dados brutos em informações visuais e interativas. Seu principal objetivo é facilitar a interpretação e o monitoramento de indicadores de desempenho, possibilitando que gestores e operadores tomem decisões com base em informações atualizadas e de fácil compreensão (Microsoft, 2023). A plataforma permite integrar múltiplas fontes de dados e criar dashboards dinâmicos, relatórios personalizados e análises comparativas, sendo ideal para o ambiente industrial, onde a agilidade e a clareza das informações são essenciais para o controle da produção.

No contexto da manufatura e da Indústria 4.0, o *Power BI* atua como uma interface de visualização capaz de transformar grandes volumes de dados em informações estratégicas para a gestão da produção. A ferramenta possibilita a análise visual de indicadores de desempenho, contribuindo para a identificação de tendências, gargalos e oportunidades de melhoria. Ao apresentar as informações de forma interativa e intuitiva, o *Power BI* auxilia gestores e engenheiros na tomada de decisões baseadas em evidências, promovendo uma cultura de gestão orientada por dados e aprimorando o controle operacional nas organizações industriais.

Mais do que uma ferramenta analítica, o *Power BI* funciona como um painel de controle operacional, permitindo que líderes de produção, engenheiros e supervisores monitorem os indicadores em tempo real diretamente no ambiente fabril. Essa visualização facilita a identificação rápida de desvios, a priorização de ações corretivas e o alinhamento entre as equipes de manutenção e produção. O uso do *Power BI*, aliado a modelos preditivos, transforma dados históricos e previsões em

informações acionáveis, promovendo uma gestão mais eficiente e baseada em evidências.

Dessa forma, o Power BI consolida-se como o elo final entre a inteligência artificial e a tomada de decisão operacional, proporcionando uma ferramenta visual que apoia a melhoria contínua e o aumento da eficiência produtiva nas linhas SMT. Ao centralizar as informações de previsão, paradas e desempenho em um único ambiente interativo, a ferramenta contribui para uma cultura de gestão orientada por dados e voltada à otimização da capacidade produtiva.

2.11 RECURSOS COMPUTACIONAIS DE APOIO

a) *Python*: Linguagem de programação amplamente utilizada em aplicações de ciência de dados e inteligência artificial, devido à sua simplicidade, flexibilidade e ampla disponibilidade de bibliotecas. Destacam-se ferramentas como *Pandas*, *NumPy*, *Scikit-learn* e *XGBoost*, empregadas para manipulação de dados, criação de modelos preditivos e cálculo de métricas de desempenho. A linguagem também se integra facilmente a plataformas de visualização, favorecendo a análise exploratória e a comunicação dos resultados.

b) *Google Colab*: Plataforma gratuita baseada em nuvem que fornece um ambiente de execução interativo para códigos em *Python*. O Colab permite a execução de scripts sem necessidade de configuração local, com suporte a bibliotecas de aprendizado de máquina e armazenamento em nuvem. Essa ferramenta possibilita maior agilidade e acessibilidade durante o desenvolvimento de soluções analíticas e modelos preditivos (Google, 2024).

3 MATERIAIS E MÉTODOS

3.1 METODOLOGIA

Este estudo caracteriza-se como um estudo de caso aplicado com objetivos explicativos e abordagem quantitativa.

De acordo com Yin (2015), o estudo de caso permite a investigação aprofundada de um fenômeno dentro de seu contexto real, sendo especialmente útil em pesquisas organizacionais. Assim, este trabalho é conduzido em uma empresa do Polo Industrial de Manaus (PIM), tendo como foco o setor PCBA, onde são analisados dados reais de produção para compreender o desempenho do processo e propor melhorias sustentadas por evidências.

Segundo Gil (2002), a pesquisa aplicada busca gerar conhecimentos voltados à solução de problemas concretos, característica que se alinha ao objetivo deste estudo: otimizar a capacidade produtiva e reduzir gargalos em um ambiente fabril real. Dessa forma, os resultados aqui obtidos não se limitam ao campo teórico, mas oferecem aplicações práticas para o aperfeiçoamento dos processos na linha de montagem.

A pesquisa também possui caráter explicativo, pois procura compreender as causas que influenciam o desempenho produtivo. De acordo com Severino (2016), esse tipo de estudo é essencial para identificar relações entre variáveis e compreender os fatores que impactam os resultados. No presente trabalho, essa abordagem é utilizada para correlacionar os dados operacionais coletados com o desempenho da linha, evidenciando o efeito das melhorias implementadas no processo.

Por fim, a abordagem quantitativa foi escolhida por possibilitar a mensuração objetiva do desempenho do sistema produtivo. Conforme Creswell e Creswell (2018), essa abordagem garante rigor e confiabilidade por meio do uso de métodos estatísticos. No contexto deste estudo, a análise de indicadores como tempos de ciclo, capacidade produtiva e ocorrência de gargalos permite uma avaliação precisa do processo e embasa a tomada de decisão para otimização da linha de produção.

A empresa em estudo atua no setor de eletroeletrônicos automotivos, fabricando módulos multimídia destinados à integração de funções de áudio, vídeo, navegação e conectividade em veículos. Localizada no Polo Industrial de Manaus

(PIM), a organização possui linha de produção automatizada, com foco em qualidade e rastreabilidade.

A linha analisada é responsável pela montagem das placas eletrônicas (PCBA), composta pelas etapas de inserção manual de componentes, máquina de solda, ICT (In-Circuit Test), FCT (Functional Circuit Test), aplicação de cola/adesivo e estação de verificação. Esse fluxo garante a integridade elétrica, funcional e mecânica do produto, assegurando a conformidade com os padrões de qualidade exigidos pelo setor automotivo.

3.1.1 Método atual de cálculo da capacidade produtiva

Na linha de produção analisada, a previsão da capacidade produtiva é realizada por meio de medições diretas no ambiente fabril. O processo consiste na cronometragem manual do tempo de ciclo de cada posto de trabalho, utilizando práticas tradicionais de cronoanálise, conforme evidenciando na Figura 3.

Figura 3 – Medições de tempo de ciclo das máquinas

Operation	No	Operation	Station Qty	Manpower	Time										Average	T/T(8%)
					1	2	3	4	5	6	7	8	9	10		
	1	Manual Insertion (Automatic + Manual)	1	1	31,22	31,67	31,77	30,99	33,1	32,83	31,67	29,33	29,33	29,89	31,18	33,6744
	3	Selective Soldering (Automatic)	1	0	42,35	41,64	42,72	41,48	41,87	42,15	42,17	41,84	42,21	42,02	42,045	45,4086
	4	Cooling Machine (Automatic)	1	0	17,41	16,12	16,89	17,82	18,43	18,01	16,46	18,01	18,55	18,34	17,604	19,01232
	5	Inspeção Visual	1	1	10,59	10,43	10,43	10,37	10,75	10,75	10,46	10,25	10,46	10,73	10,522	11,36376
	6	Teste ICT (Automatic)	1		23,25	25,37	23,52	26,25	23,3	26,02	23,71	23,14	23,91	23,87	24,234	26,17272
	7	NG Buffer(Automatic)	1		12,81	12,11	12,71	12,57	12,93	12,62	12,21	12,73	12,22	12,21	12,512	13,51296
	8	Teste FCT(Automatic + Manual)	6	1	91,36	90,16	91,34	90,75	91,5	90,54	91,67	90,6	91,82	90,23	90,997	98,27676
	9	Adhesive Scan (Manual)	1	1	8,41	8,91	8,41	8,42	8,48	8,43	7,91	7,72	7,46	7,92	8,207	8,86356

Fonte: Elaborado pelo próprio autor, 2025.

Com base nessas medições, identifica-se o posto gargalo, ou seja, aquele que apresenta o maior tempo de ciclo, o qual determina o ritmo máximo de produção da linha.

A partir desse tempo de ciclo é calculado o takt time teórico, que representa o tempo necessário para produzir uma unidade dentro do tempo disponível de produção. Com base nesse valor, estima-se a capacidade produtiva teórica da linha, obtida pela razão entre o tempo total disponível e o takt time calculado. Esse método fornece uma estimativa do potencial produtivo da linha em condições ideais, sem considerar paradas planejadas, retrabalhos ou perdas operacionais.

Figura 4 – Método de capacidade produtiva atual

No	Process	Tact time	Actual UPH
1	Manual Insertion P01 + P02	33,67	107
2	Selective Soldering (Automatic)	45,41	79
3	Cooling Machine (Automatic)	19,01	189
4	Inspeção Visual + (Conexão do Cabo WIFI Manual)	11,36	317
5	Teste ICT (Automatic)	26,17	138
6	NG Buffer(Automatic)	13,51	266
7	Teste FCT(Automatic)	16,38	220
8	Adhesive Scan (Manual)	8,86	406
TOTAL		174,4	
TOTAL (Manual Process)		70,3	

Turno	Target	UPH p/turno
1° Turno	6,00	951
2° Turno	6,00	951

Fonte: Elaborado pelo próprio autor, 2025.

Apesar de amplamente utilizado, esse método depende de acompanhamento presencial, análises pontuais e está sujeito a variações subjetivas associadas à observação humana. Além disso, a abordagem não incorpora oscilações operacionais do dia a dia, como paradas não planejadas, falhas de equipamentos, e retrabalho, fatores que impactam diretamente o desempenho real da linha e podem gerar divergências significativas entre a capacidade estimada e a produção efetivamente realizada.

Diversos autores reforçam essas limitações. Segundo Slack et al. (2022), métodos de medição baseados em cronoanálise e observação humana tendem a oferecer apenas uma estimativa estática da capacidade, não refletindo a variabilidade inerente ao processo produtivo. Da mesma forma, Tubino (2017) destaca que a falta de atualização contínua dos parâmetros operacionais pode resultar em análises defasadas em relação ao comportamento real da linha de produção. Esse cenário evidencia que, apesar da cronoanálise permanecer relevante para o entendimento do processo, sua aplicação isolada não é suficiente para monitorar e analisar o desempenho produtivo de forma contínua e responsiva às mudanças do ambiente fabril.

3.2 COLETA DE DADOS

O processo produtivo ocorre de forma contínua e interligada, com monitoramento realizado por sistemas digitais de registro de produção e paradas.

Neste estudo, foram utilizados dados históricos provenientes desses sistemas, contendo informações sobre máquina parada, data e hora do acionamento, data e hora de liberação da linha, tempo total de parada e classificação do tipo de parada, conforme ilustra a Figura 3, além da quantidade de placas produzidas por dia, apresentada na Figura 4. Essas informações serviram de base para o desenvolvimento do modelo de Inteligência Artificial voltado à previsão da capacidade produtiva da linha de montagem.

Figura 5 – Informações dos dados de parada de linha

No	Equipment	CallDate	CallTime	CancelDate	CancelTime	Response Time	Reason
----	-----------	----------	----------	------------	------------	---------------	--------

Fonte: Elaborado pelo próprio autor, 2025.

Figura 6 – Informações de quantidade de placas produzidas

Classification	Total	2025-01						
		01	02	03	04	05	06	07
2. Production Quantity	45662	1831	1217	1541	587	0	0	0

Fonte: Elaborado pelo próprio autor, 2025.

Os dados foram obtidos a partir de dois sistemas distintos utilizados pela empresa. As informações de quantidade produzida foram extraídas do sistema GMES (*Global Manufacturing Execution System*), responsável pelo registro automático das unidades fabricadas por meio de sensores na saída da linha. Já os dados de paradas foram coletados do sistema Andon, que realiza o monitoramento em tempo real dos eventos de interrupção, e posteriormente armazenados no sistema RAS, utilizado para consultas operacionais.

A base analisada abrange o período de maio de 2024 a setembro de 2025, totalizando 708 registros de paradas não planejadas. Em complemento, foram utilizados os dados da produção diária no mesmo intervalo temporal, o que possibilitou correlacionar os eventos de parada com o desempenho produtivo da linha. A integração dessas duas bases foi essencial para compreender o impacto das paradas na capacidade produtiva e compor as variáveis de entrada do modelo preditivo.

3.2.1 Pré-processamento dos Dados

Para garantir a confiabilidade e a consistência da análise, os dados passaram por um processo estruturado de pré-processamento, com as seguintes etapas aplicadas:

a) Limpeza dos dados: remoção de registros com campos vazios, acionamentos de teste e acionamentos incorretos que não representavam paradas reais de produção.

b) Padronização das informações de parada: A coluna Reason apresentava a estrutura Causa Raiz – Ação – Responsável. Para este estudo, foi extraída apenas a Causa Raiz, resultando na variável Tipo de parada.

Já na coluna Equipment, a descrição continha: tipo de acionamento, máquina e linha (ex.: “Line Stop – Selective Soldering – PCB1”). Foram extraídos somente os dados referentes à máquina e à linha, compondo a variável Máquina parada.

c) Tratamento de formatos de data: as datas foram padronizadas para um único formato reconhecido pelo modelo preditivo, possibilitando cálculos consistentes sobre o intervalo temporal.

d) Conversão de unidade de medida: a coluna Response Time, originalmente no formato hh:mm:ss, foi convertido para segundos, passando a compor a variável Tempo de parada, permitindo o uso como variável quantitativa contínua.

e) Criação de variável categórica: foi criada a variável Turno para indicar a escala produtiva de cada dia, sendo atribuídos os valores 1.0 para dias com produção em dois turnos e 0.5 para dias com produção em apenas um turno.

Após o pré-processamento, a base inicial de 782 registros resultou em 572 acionamentos válidos, com a remoção de registros referentes a testes, inconsistências ou preenchimento incorreto. Essa etapa foi fundamental para garantir a integridade dos dados utilizados no treinamento do modelo, assegurando maior precisão e representatividade nas análises subsequentes.

Após o pré-processamento, os dados foram reorganizados em uma estrutura consolidada contendo apenas as variáveis essenciais ao modelo, conforme ilustrado na Figura 5. A base final contempla informações diárias de produção e paradas de linha, apresentadas nas seguintes colunas:

- Data: dia do registro de produção e/ou parada;
- Quant. Produzida: quantidade de placas fabricadas no dia;
- Tipo de parada: classificação da causa raiz do evento;
- Máquina parada: equipamento responsável pela interrupção;

- Tempo de parada: duração do evento de parada (segundos);
- Turno: escala produtiva do dia (1.0 = dois turnos; 0.5 = um turno);

Essa estrutura final foi utilizada como entrada para o treinamento do modelo *XGBoost*, permitindo a análise integrada entre volume produtivo e fatores operacionais que impactam a capacidade da linha.

Figura 7 – Estrutura final da base de dados após pré-processamento

Data	Quant. Produzida	Tipo de parada	Máquina parada	Tempo de parada	turno
------	------------------	----------------	----------------	-----------------	-------

Fonte: Elaborado pelo próprio autor, 2025.

3.3 MODELAGEM PREDITIVA

A modelagem preditiva foi conduzida utilizando técnicas de *Machine Learning* com o objetivo de estimar a quantidade de placas que a linha seria capaz de produzir, considerando as variáveis operacionais tratadas no pré-processamento dos dados. O algoritmo selecionado para o desenvolvimento do modelo foi o *XGBoost*, devido ao seu bom desempenho em problemas de regressão com dados tabulares e sua capacidade de lidar com relações não lineares entre as variáveis.

O conjunto de variáveis de entrada utilizado inclui atributos relacionados ao contexto operacional da linha e indicadores temporais que refletem possíveis padrões de sazonalidade da produção. Esse conjunto de features permite ao modelo aprender como fatores como paradas e datas específicas influenciam a capacidade produtiva da linha.

O conjunto de dados foi dividido em treino e teste, utilizando 70% dos registros para o treinamento e 30% para avaliação do desempenho do modelo. Essa estratégia permite inferir a capacidade de generalização do modelo para dados ainda não vistos, garantindo maior confiabilidade às previsões realizadas.

Após o treinamento, foram aplicadas métricas estatísticas como *MAE* (*Mean Absolute Error*), *RMSE* (*Root Mean Squared Error*) e R^2 (Coeficiente de Determinação) para avaliar a precisão do modelo.

A implementação foi realizada em linguagem *Python*, utilizando bibliotecas como *Pandas*, *NumPy*, *Scikit-Learn*, *XGBoost* e *Matplotlib* em ambiente Google Colab. O código completo utilizado para o tratamento, treinamento, validação e geração das previsões está incluído no Anexo A, garantindo transparência metodológica.

3.3.1 Engenharia de Atributos

Além das variáveis originais presentes na base de dados, foram geradas variáveis derivadas que possibilitaram o aprendizado mais eficiente do modelo. As principais transformações aplicadas foram:

a) Extração de características temporais: a partir da coluna de data, foram geradas as variáveis: dia da semana, mês, dia do ano, dia do mês, semana do ano e ano — permitindo identificar padrões cíclicos e variações sazonais da produção.

b) Codificação numérica de variáveis categóricas: as variáveis Tipo de parada e Máquina parada foram convertidas para valores numéricos, preservando-se separadamente dicionários de mapeamento para consulta e interpretação no Power BI.

c) Aplicação de regras de coerência operacional: garantiu-se a consistência lógica dos dados por meio das regras:

Se Tempo de parada = 0, então Tipo de parada = 0 e Máquina parada = 0

Em domingos (dayofweek = 6) → previsão de produção igual a 0 e demais variáveis também zeradas

d) Preparação dos cenários futuros: para a previsão de 365 dias, foram consideradas as mesmas variáveis operacionais utilizadas no treinamento do modelo, garantindo coerência entre os dados históricos e as projeções futuras.

Esses aprimoramentos permitiram que o modelo capturasse com maior fidelidade o comportamento produtivo e a influência das paradas na capacidade da linha.

3.3.2 Métricas de avaliação do modelo

Para avaliar o desempenho do modelo preditivo desenvolvido, foram utilizadas métricas estatísticas amplamente adotadas em problemas de regressão, permitindo mensurar a precisão das previsões em relação aos dados reais:

a) Erro Médio Absoluto (MAE - Mean Absolute Error): Representa a média das diferenças absolutas entre valores reais e previstos, indicando o erro médio de forma clara e direta. Quanto menor esse valor, maior a precisão do modelo na estimativa da produção.

b) Raiz do Erro Quadrático Médio (RMSE - Root Mean Squared Error): Penaliza de maneira mais intensa erros maiores, sendo útil para identificar discrepâncias

significativas entre previsão e valores observados. Também deve ser o mais baixo possível.

c) Coeficiente de Determinação (R^2): Indica o quanto o modelo é capaz de explicar a variabilidade dos dados reais. Valores próximos de 1 representam alto poder explicativo do modelo em relação ao comportamento produtivo da linha.

A utilização simultânea dessas três métricas fornece uma visão mais completa da performance do modelo, garantindo uma análise confiável de sua capacidade preditiva antes da aplicação dos resultados em ambiente industrial.

3.3.3 Análise da importância das variáveis

Para avaliar a interpretabilidade do modelo e compreender a influência de cada variável nas previsões realizadas, aplicou-se a técnica SHAP (SHapley Additive exPlanations), amplamente utilizada para modelos baseados em árvores de decisão, como o *XGBoost*. Essa técnica atribui a cada variável um valor que representa sua contribuição média para o resultado final, indicando se seu efeito tende a aumentar ou reduzir a previsão da produção.

A aplicação do SHAP possibilitou identificar as variáveis com maior impacto sobre a capacidade produtiva prevista pelo modelo. Os resultados demonstraram que a variável “turno” foi a mais influente, seguida por variáveis temporais como ano, dia do ano e dia do mês, evidenciando a importância da escala produtiva e da sazonalidade no comportamento da linha. Em seguida, o tempo de parada e o dia da semana também apresentaram relevância, indicando a influência das interrupções operacionais e do calendário de trabalho sobre a produção. Já as variáveis tipo de parada e máquina parada tiveram impacto reduzido, o que indica que o modelo reconheceu que o tempo total de parada é mais determinante do que a origem específica da falha.

Com isso, o uso do *SHAP* contribuiu para validar a coerência lógica do modelo *XGBoost*, demonstrando que ele aprendeu relações compatíveis com a realidade fabril e permitindo uma análise mais transparente dos fatores que influenciam a capacidade produtiva.

3.3.4 Geração das previsões e exportação

Concluída a etapa de treinamento, o modelo *XGBoost* foi utilizado para gerar previsões de produção considerando um horizonte futuro de 365 dias, abrangendo um

ciclo completo de operação fabril. Para cada data prevista, o modelo utiliza a mesma estrutura de atributos empregada no treinamento, garantindo coerência estatística entre o aprendizado e as inferências realizadas.

As previsões contemplam os diferentes cenários operacionais da linha, incluindo dias com funcionamento em dois turnos (1.0) e dias com operação reduzida em apenas um turno (0.5), refletindo a dinâmica real da fábrica. O resultado dessa etapa é exportado em formato de planilha Excel, contendo todas as variáveis de entrada e a estimativa de produção diária calculada pelo algoritmo, possibilitando integração direta com ferramentas de Business Intelligence.

Além da planilha de previsões, o modelo também gera arquivos complementares contendo dicionários de mapeamento das variáveis categóricas utilizadas no treinamento. Esses dicionários são exportados em formato de planilha, apresentando, por exemplo, uma coluna com o código numérico atribuído e outra com o nome correspondente da categoria (como 1 = Máquina de Solda, 2 = ICT, 3 = FCT). Essa estrutura é fundamental porque, durante o processo de modelagem, as variáveis textuais são convertidas em números para permitir o processamento pelo algoritmo. Assim, ao integrar os resultados no Power BI, esses dicionários permitem reverter a codificação numérica, substituindo automaticamente os códigos pelos nomes originais e garantindo a correta interpretação das variáveis no dashboard.

3.3.5 Desenvolvimento do Dashboard

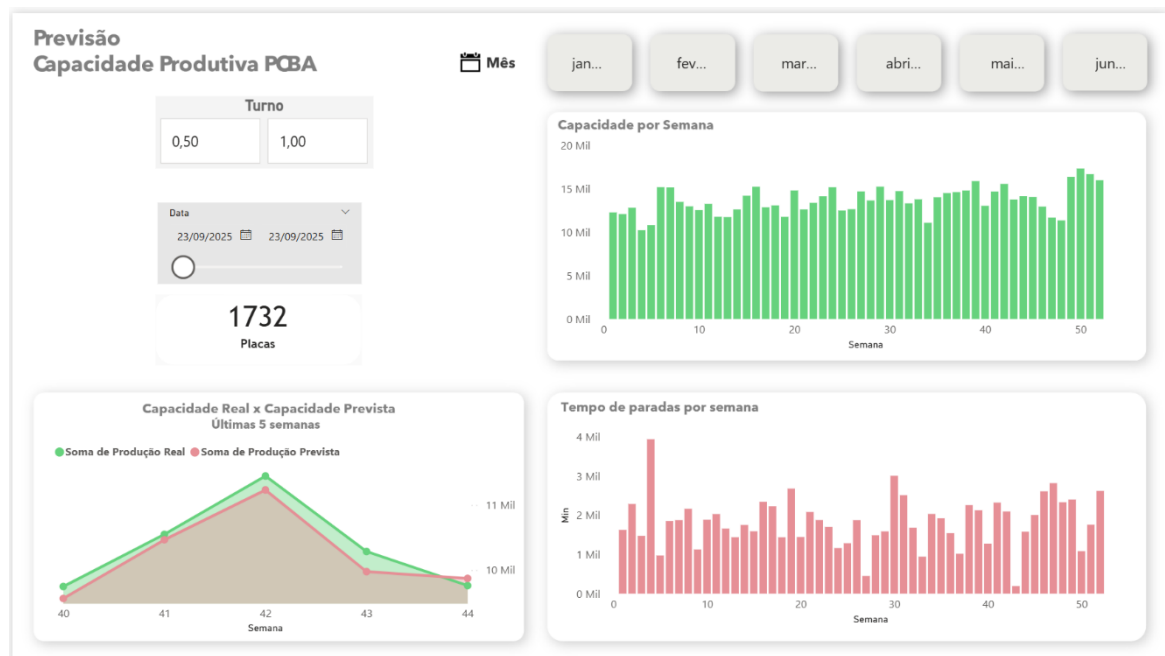
O *Dashboard* foi desenvolvido na plataforma Power BI com o objetivo de consolidar e transformar os resultados do modelo preditivo em indicadores visuais de fácil interpretação, permitindo o acompanhamento contínuo da capacidade produtiva da linha de montagem PCBA. A ferramenta possibilita a análise comparativa entre a produção real e a produção prevista pelo modelo de Inteligência Artificial (IA), de forma dinâmica e orientada por dados.

A construção do painel foi estruturada para fornecer uma visão integrada do desempenho produtivo, com foco em indicadores-chave que representam o comportamento operacional da linha ao longo do tempo. Os dados provenientes do modelo *XGBoost* foram exportados em formato de planilha e posteriormente importados para o Power BI, garantindo a coerência entre as previsões geradas em Python e as visualizações apresentadas. Esse processo de integração manual permite a atualização controlada das informações, assegurando que os resultados exibidos

no *Dashboard* correspondam às previsões mais recentes produzidas pelo modelo e aos dados reais de produção coletados na linha.

Para garantir uma análise representativa do comportamento produtivo, foram utilizados os dados referentes às últimas cinco semanas de produção, correspondentes ao período mais recente disponível no banco de dados. Esse recorte temporal assegura que o modelo seja treinado e validado com informações atualizadas, refletindo as condições reais de operação da linha. Além disso, o horizonte de previsão foi definido para os seis meses subsequentes, de modo a permitir a análise estratégica da capacidade produtiva futura em escala semanal, conforme mostra a Figura 8. Essa abordagem foi adotada por se alinhar à prática de planejamento da empresa, que realiza o acompanhamento da produção com base em planos semanais, tornando o formato da previsão mais útil para a gestão operacional e as reuniões de acompanhamento.

Figura 8 – Dashboard de previsão de capacidade produtiva (Power BI)



Fonte: Elaborado pelo próprio autor, 2025.

O Dashboard apresenta filtros interativos por turno de operação (0,5 – um turno ou 1,0 – 2 turnos), período (mensal e semanal) e intervalo de datas, possibilitando análises segmentadas e personalizadas. Entre os principais indicadores apresentados, destacam-se:

a) Capacidade por Semana: gráfico de colunas que representa a quantidade total de placas produzidas a cada semana, permitindo identificar variações de produtividade, picos de desempenho e principalmente a capacidade produtiva disponível para atingir o plano semanal de produção do processo;

b) Capacidade Real x Capacidade Prevista: gráfico de áreas sobrepostas que compara os resultados reais de produção com as previsões do modelo de IA, evidenciando a precisão do algoritmo e o alinhamento entre estimativas e resultados observados;

c) Tempo de Paradas por Semana: gráfico de barras com visualização que mostra o total de minutos de parada acumulados em cada semana, auxiliando na identificação dos períodos de maior impacto produtivo;

d) Indicador de Produção Diária: cartão numérico centralizado que exibe, de forma imediata, o volume produzido (em placas) para o dia selecionado;

e) Segmentação por Turno e Mês: botões e segmentadores que permitem filtrar rapidamente os dados por período ou regime de operação, otimizando a navegação e facilitando a comparação entre cenários.

Embora o Dashboard tenha sido desenvolvido para consolidar os resultados do modelo preditivo e facilitar a visualização dos indicadores de desempenho produtivo, optou-se por não incluir as variáveis “Máquina Parada” e “Tipo de Parada” entre os elementos apresentados no dashboard. Essas informações foram consideradas durante o treinamento do modelo, porém não estão entre as que mais contribuem diretamente para a previsão da capacidade produtiva, foco central deste estudo.

Além disso, observou-se que as previsões relacionadas a essas variáveis apresentavam comportamento pouco consistente, uma vez que o modelo *XGBoost* busca padrões estatísticos gerais de produção e não é voltado à previsão de eventos específicos de falha ou parada. Dessa forma, elas foram utilizadas apenas até a etapa de geração da planilha de previsão, enquanto o dashboard concentra-se em métricas quantitativas consolidadas, como tempo total de parada, turno, capacidade prevista e capacidade real que representam de forma mais objetiva o desempenho produtivo da linha.

O painel foi projetado com ênfase na clareza visual e na padronização estética, utilizando uma paleta neutra com tons de verde para a produção real e vermelha para a produção prevista, de forma a destacar a correlação entre os resultados. O layout prioriza a disposição lógica das informações: indicadores gerais no topo, análises

semanais no centro e comparativos de desempenho na base, garantindo fluidez na interpretação dos dados.

Além de representar o desempenho produtivo, o Dashboard também funciona como uma ferramenta de validação visual dos resultados do modelo preditivo, permitindo comparar as previsões geradas com os valores reais registrados de forma clara e quantitativa. Ainda que a atualização dos dados ocorra de maneira manual, o painel proporciona uma análise integrada entre os resultados previstos e os observados, reforçando o caráter aplicado do estudo. Essa relação entre o modelo de IA e a visualização de dados contribui para a tomada de decisão baseada em evidências e para uma compreensão mais acessível do comportamento produtivo da linha.

4 RESULTADOS E DISCUSSÃO

4.1 COMPARAÇÃO ENTRE OS MODELOS DE PREVISÃO

Nesta etapa, é apresentado o comparativo entre o método tradicional de cálculo da capacidade produtiva — atualmente utilizado pela empresa — e o modelo preditivo desenvolvido com o algoritmo *XGBoost* (*Extreme Gradient Boosting*). O objetivo é identificar qual abordagem demonstra maior proximidade com a produção real e avaliar se a aplicação de aprendizado de máquina melhora a precisão das estimativas de capacidade produtiva.

A Tabela 1 apresenta os valores correspondentes à produção real e às previsões obtidas por ambos os modelos durante um período de dez dias consecutivos de operação.

Tabela 1 – Comparativo entre produção real e previsões dos modelos

Data	Produção Real	Previsão Modelo Antigo	Previsão <i>XGBoost</i>
01/10/2025	1501	1902	1383
02/10/2025	1587	1902	1542
03/10/2025	1591	1902	1586
04/10/2025	1585	1902	1543
06/10/2025	1610	1902	1597
07/10/2025	1750	1902	1716
08/10/2025	1741	1902	1715
09/10/2025	1809	1902	1792
10/10/2025	1822	1902	1813
11/10/2025	1836	1902	1833

Fonte: Elaborado pelo próprio autor, 2025.

A análise dos resultados demonstra que o modelo *XGBoost* apresentou valores mais próximos à produção real em praticamente todos os dias analisados, acompanhando de forma coerente as variações naturais da linha de produção. Em contrapartida, o modelo tradicional manteve um valor fixo de 1902 unidades por dia, o que resultou em superestimativas significativas, especialmente nos dias de menor produção, com desvios médios superiores a 300 unidades.

Enquanto o modelo tradicional manteve um erro médio absoluto de aproximadamente 311 unidades, o modelo *XGBoost* apresentou um erro médio de apenas 27 unidades, representando uma redução de cerca de 91% no erro médio.

Essa melhoria evidencia o ganho de precisão obtido com o uso de técnicas de aprendizado de máquina, permitindo previsões muito mais ajustadas à realidade operacional.

De modo geral, o modelo *XGBoost* conseguiu refletir a dinâmica real do processo produtivo, ajustando suas previsões de acordo com as oscilações da produção diária e oferecendo uma representação mais fiel da capacidade produtiva. Esse comportamento comprova que a metodologia proposta é capaz de capturar o padrão de comportamento das variáveis que influenciam a produção, traduzindo-se em previsões mais confiáveis e úteis para a tomada de decisão.

Com base nesses resultados, confirma-se a Hipótese 1 deste estudo: o uso de modelos de aprendizado de máquina, como o *XGBoost*, permite prever a capacidade produtiva de forma mais eficiente e precisa do que o método manual tradicional utilizado pela empresa.

4.2 AVALIAÇÃO DAS MÉTRICAS DE DESEMPENHO DO MODELO

Após a etapa de treinamento e teste do modelo *XGBoost*, foi realizada a avaliação de desempenho utilizando as seguintes métricas estatísticas: Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Coeficiente de Determinação (R^2). Os resultados obtidos foram: MAE = 109,89; RMSE = 168,49; $R^2 = 0,902$.

Os resultados evidenciam um alto desempenho do modelo preditivo, com um R^2 de 0,902, indicando que aproximadamente 90,2% da variabilidade da produção real foi explicada pelo modelo. Esse valor demonstra uma forte correlação entre as previsões e os valores observados, evidenciando a capacidade do *XGBoost* de capturar a dinâmica do processo produtivo.

O MAE de 109,89 unidades indica que, em média, as previsões apresentaram um desvio de cerca de 110 unidades em relação à produção real, o que representa um erro reduzido considerando o volume produtivo médio diário da linha. Já o RMSE de 168,49 unidades confirma a consistência do modelo, revelando que não há grandes discrepâncias entre as amostras previstas e os valores reais.

De forma geral, as métricas obtidas demonstram que o modelo apresenta elevada acurácia e estabilidade preditiva, sendo capaz de generalizar bem os padrões observados nos dados de treinamento para novas observações.

4.3 ANÁLISE DE IMPORTÂNCIA DAS VARIÁVEIS (SHAP Values)

Para compreender quais fatores exerceram maior influência sobre as previsões do modelo preditivo, foi realizada uma análise de importância das variáveis utilizando os valores SHAP (SHapley Additive exPlanations). Essa técnica permite mensurar o impacto médio de cada variável sobre o resultado previsto, considerando a contribuição individual de cada atributo na formação das previsões. Diferentemente das métricas internas de importância do modelo, os valores *SHAP* possibilitam uma interpretação mais transparente e causal, indicando não apenas o quanto uma variável é utilizada, mas o quanto ela efetivamente altera o valor previsto (Lundberg & Lee, 2017).


A Figura X apresenta o gráfico de importância média das variáveis obtido a partir dos valores *SHAP*. Observa-se que a variável “turno” apresentou o maior impacto médio nas previsões, demonstrando sua relevância direta sobre a capacidade produtiva estimada. Esse resultado é coerente com o comportamento real do processo produtivo, uma vez que os turnos possuem tempos disponíveis e condições operacionais distintas, afetando significativamente o volume final de produção.

Em seguida, as variáveis “year”, “dayofyear” e “dayofmonth” também mostraram influência relevante, indicando que aspectos temporais e sazonais têm papel importante na previsão. Já a variável “Tempo de parada” apresentou impacto intermediário no gráfico SHAP, evidenciando que, embora exerça influência sobre a capacidade produtiva — visto que maiores tempos de parada tendem a reduzir o volume de produção —, essa relação não se mostrou tão intensa quanto o esperado. Isso pode ser explicado pelo fato de o modelo *XGBoost* captar apenas parcialmente esse efeito, uma vez que parte de sua variabilidade está correlacionada a outros fatores, como o turno e as variáveis temporais. Além disso, o modelo tende a suavizar os efeitos de eventos pontuais para otimizar o desempenho global, o que reduz o peso relativo de variáveis com ocorrência irregular.

Por fim, variáveis como “Tipo de parada” e “Máquina parada” apresentaram impacto médio reduzido, reforçando que, apesar de representarem informações operacionais relevantes, seus efeitos são mais pontuais e menos consistentes em relação à capacidade produtiva total. Dessa forma, a análise SHAP evidencia que o modelo *XGBoost* conseguiu identificar corretamente os fatores de maior peso sobre a produção diária, destacando-se a influência do turno e das variáveis temporais. Esse tipo de interpretação é essencial para consolidar a confiabilidade do modelo, pois

demonstra que suas previsões estão alinhadas à lógica operacional da linha de montagem, permitindo que os resultados sejam utilizados de forma prática no apoio à tomada de decisão.

Figura 9 – Importância média das variáveis segundo valores *SHAP*



Fonte: Elaborado pelo próprio autor (2025), a partir de execução em Python (Google Colab).

4.4 ANÁLISE DOS RESULTADOS COM DASHBOARD

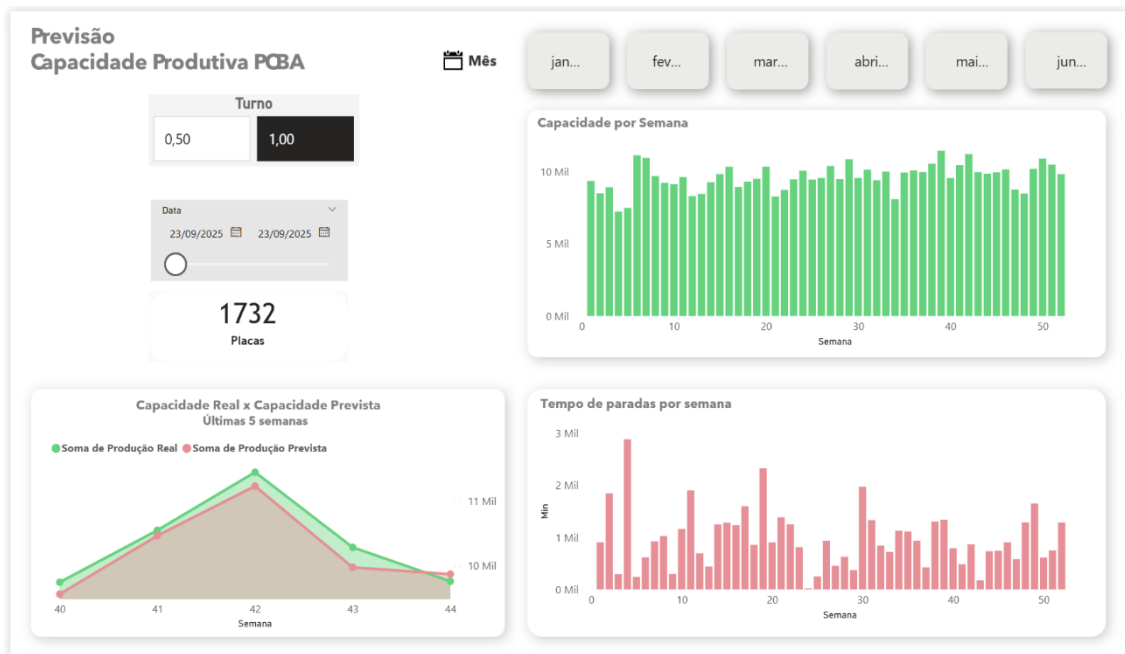
A integração dos dados de previsão com o Dashboard desenvolvido no Power BI permitiu uma análise quantitativa e visual do desempenho produtivo ao longo do período estudado. A ferramenta possibilitou explorar indicadores estratégicos por meio de filtros interativos, permitindo a segmentação dos resultados por turno de trabalho e mês de produção, conforme Figura 10 e 11, respectivamente, o que facilita a comparação de padrões operacionais e o acompanhamento das variações de desempenho.

As visualizações foram organizadas em painéis que exibem tanto a previsão diária e semanal de produção quanto o histórico real registrado, possibilitando observar a coerência entre as estimativas do modelo *XGBoost* e o comportamento real da linha de montagem. Essa análise integrada permite identificar tendências, variações sazonais e possíveis gargalos, tornando a interpretação dos dados mais dinâmica e acessível.

Na análise segmentada por turno, observou-se que as previsões apresentaram comportamento consistente com os dados históricos, refletindo corretamente o aumento ou a redução da capacidade conforme a disponibilidade de tempo produtivo e as características operacionais de cada turno. Já o filtro por mês permitiu destacar períodos de maior estabilidade e momentos de variação, evidenciando o impacto de fatores externos, como ajustes de demanda e mudanças no ritmo de produção.

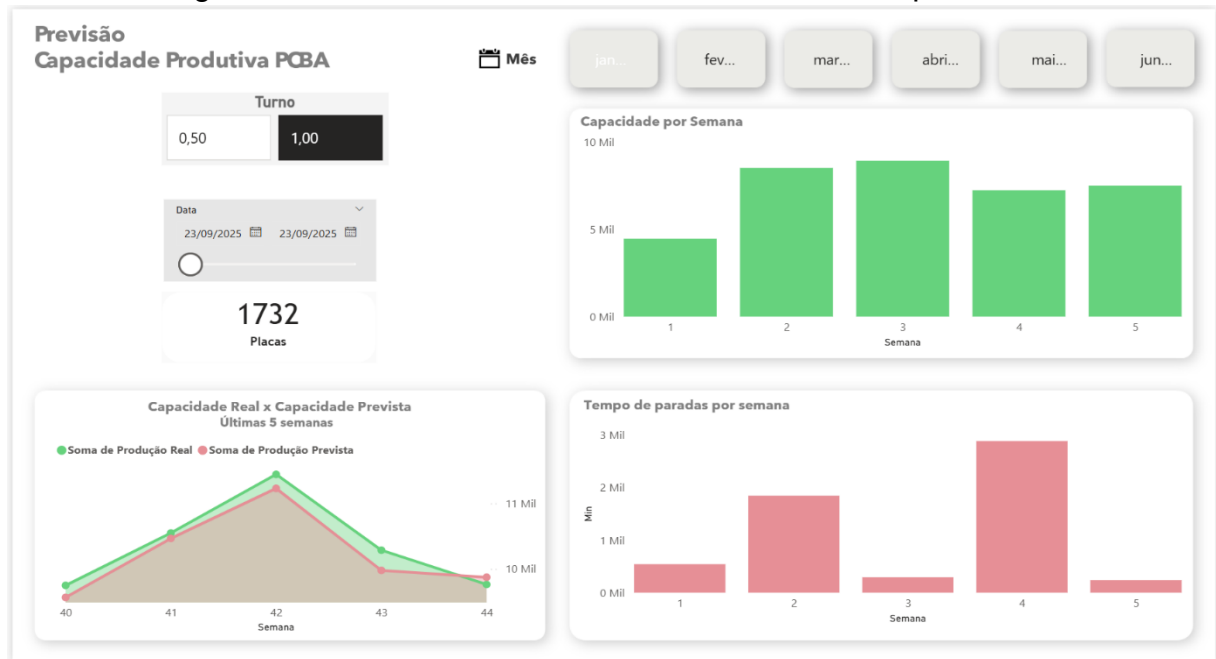
Além disso, o Dashboard possibilitou a comparação direta entre a produção prevista e a produção real, evidenciando visualmente a precisão do modelo e a proximidade entre os valores observados e estimados. Essa representação gráfica favorece o monitoramento contínuo da eficiência da linha e fornece uma base sólida para a tomada de decisões estratégicas relacionadas à capacidade produtiva.

Figura 10 – Painel interativo no Power BI com filtros por turno



Fonte: Elaborado pelo próprio autor, 2025.

Figura 11 – Painel interativo no Power BI com filtros por mês



Fonte: Elaborado pelo próprio autor, 2025.

4.4.1 Validação da Hipótese 2

A segunda hipótese deste estudo propôs que a integração entre o modelo preditivo desenvolvido em Python e o Dashboard interativo no Power BI facilitaria o monitoramento do desempenho produtivo e apoiaria a tomada de decisão no chão de fábrica.

Com base na análise dos resultados, essa hipótese foi confirmada. A combinação entre as previsões geradas pelo modelo *XGBoost* e as visualizações dinâmicas do Power BI permitiu compreender o comportamento da capacidade produtiva de forma clara, quantitativa e atualizada. O painel consolidou em um único ambiente as informações de produção real, previsão semanal e indicadores por turno, possibilitando uma leitura rápida e intuitiva dos resultados.

Essa integração proporcionou ganhos significativos na interpretação dos dados, especialmente por traduzir resultados complexos do modelo em informações visuais acessíveis a engenheiros, supervisores e gestores. Além disso, o uso do Dashboard permitiu observar de maneira prática a aderência das previsões em relação à produção real, reforçando a confiabilidade do modelo e seu potencial de aplicação na rotina fabril.

A ferramenta mostrou-se útil não apenas para acompanhamento da eficiência produtiva, mas também como suporte às reuniões de alinhamento e planejamento,

permitindo que as decisões sejam baseadas em evidências concretas extraídas dos dados operacionais. Com isso, o sistema cumpre sua função como instrumento de apoio à gestão, consolidando a proposta de um ambiente de monitoramento integrado entre Inteligência Artificial e Business Intelligence, conforme estabelecido na hipótese inicial.

5 CONSIDERAÇÕES FINAIS

Este trabalho teve como propósito propor uma abordagem inovadora para a previsão da capacidade produtiva em uma linha de montagem de multimídia automotivo, fundamentada na aplicação de técnicas de aprendizado de máquina e na integração de ferramentas de inteligência de dados. A proposta surgiu a partir da constatação de limitações nos métodos convencionais de previsão utilizados pela empresa, baseados em planilhas e medições manuais de tempo de ciclo, que demandavam alto esforço operacional, apresentavam baixa precisão e dificultavam a tomada de decisão em tempo hábil.

Por meio da modelagem de dados históricos e da implementação do algoritmo *XGBoost (Extreme Gradient Boosting)*, foi possível desenvolver um modelo preditivo capaz de estimar, com alto grau de acurácia, a capacidade produtiva real da linha. O modelo apresentou desempenho consistente, com métricas satisfatórias, confirmando a eficiência da abordagem baseada em aprendizado de máquina em relação ao método tradicional.

Simultaneamente, a integração dos resultados ao Dashboard interativo no Power BI possibilitou a visualização dinâmica dos indicadores de produção, ampliando a compreensão do comportamento operacional da linha e facilitando a análise por turno, mês e semana. Essa ferramenta transformou dados complexos em informações estratégicas, permitindo o monitoramento contínuo e a comparação direta entre a produção real e a prevista, de forma visual, acessível e alinhada à realidade do chão de fábrica.

A pesquisa atingiu plenamente o objetivo geral de desenvolver uma solução computacional inteligente para prever a capacidade produtiva da linha, bem como os objetivos específicos de modelar os dados de produção, aplicar o algoritmo *XGBoost* na previsão da capacidade produtiva e integrar os resultados em um ambiente interativo de *Business Intelligence*.

A aplicabilidade do modelo foi avaliada de forma conceitual e experimental, demonstrando sua viabilidade como ferramenta automatizada para análise e previsão da capacidade produtiva em substituição ao método tradicional de cálculo. Embora ainda não tenha sido implantado no ambiente real da empresa em estudo, os resultados obtidos comprovam o potencial de aplicação prática e a robustez da

metodologia proposta para apoiar a gestão produtiva e o planejamento da capacidade de forma mais precisa e orientada por dados.

Os resultados obtidos demonstraram que a utilização conjunta de Machine Learning e Power BI contribui diretamente para a confiabilidade dos processos produtivos, fornecendo subsídios concretos para o Planejamento e Controle da Produção. O modelo permite avaliar, com base em dados reais do ano anterior, se a demanda solicitada por clientes pode ser atendida dentro da capacidade da linha, garantindo maior segurança nas previsões e maior credibilidade nas decisões.

Além disso, a ferramenta mostrou-se útil como apoio às reuniões de alinhamento e revisões de desempenho, sendo capaz de apresentar, de forma clara e quantitativa, o comportamento produtivo da linha e suas variações operacionais. A integração entre o modelo preditivo e o dashboard reforça o papel da Inteligência Artificial como instrumento de apoio gerencial, consolidando uma visão mais analítica e baseada em evidências para a gestão da produção.

No âmbito científico e acadêmico, este estudo reforça a relevância da interdisciplinaridade entre engenharia de produção, ciência de dados e inteligência artificial, demonstrando a viabilidade de aplicação dessas tecnologias no contexto fabril do Polo Industrial de Manaus. A metodologia proposta é aplicável a outros contextos industriais e pode ser expandida para prever indicadores complementares, como eficiência, disponibilidade de máquinas ou consumo energético, alinhando-se aos princípios da Indústria 4.0 e à digitalização dos processos produtivos.

Por fim, conclui-se que a integração entre aprendizado de máquina e inteligência de dados representa uma estratégia eficaz para o avanço da gestão produtiva, promovendo ganhos em precisão, transparência e eficiência operacional, além de fortalecer a cultura de decisão baseada em dados e o compromisso contínuo com a melhoria dos processos.

6 RECOMENDAÇÕES

Os resultados demonstraram o potencial do modelo preditivo no apoio ao planejamento da capacidade produtiva; contudo, algumas limitações foram identificadas. Entre elas, destacam-se a falta de integração direta entre o modelo desenvolvido e os sistemas corporativos, bem como a necessidade de atualização manual do dashboard, o que restringe sua aplicação contínua no ambiente industrial. Além disso, o modelo ainda não foi testado em operação real, limitando sua validação prática.

Como continuidade deste estudo, recomenda-se o desenvolvimento de um fluxo automatizado de coleta e atualização dos dados, permitindo que as previsões sejam alimentadas em tempo quase real. Sugere-se também testar outros algoritmos de *Machine Learning*, como *LightGBM*, *Random Forest* e redes neurais, a fim de ampliar a robustez preditiva e comparar o desempenho com o *XGBoost*.

Outra recomendação é integrar o dashboard ao PCP e demais áreas operacionais, para que as informações preditivas possam ser utilizadas diretamente na elaboração dos planos de produção e no acompanhamento das metas. Isso aumentaria a confiabilidade das decisões e melhoraria o alinhamento entre demanda e capacidade.

Por fim, propõe-se aplicar a metodologia em outras linhas em diferentes ambientes produtivos, a fim de avaliar sua aderência em cenários distintos e fortalecer o uso de inteligência artificial como ferramenta estratégica de suporte à tomada de decisão.

REFERÊNCIAS

- BALDWIN, Richard; EVENETT, Simon.** *Industrial Automation and the Future of Manufacturing*. Geneva: CEPR, 2020.
- BARNES, Ralph.** *Estudo de Movimentos e Tempos*. São Paulo: Edgard Blücher, 1977.
- CAO, H.; ZHANG, Q.; LI, X.** *Surface Mount Technology in Electronic Manufacturing: Process Control and Quality Improvement*. *Journal of Manufacturing Systems*, v. 55, p. 345–358, 2020.
- CAO, Qiang; WU, Yifan; ZHANG, Hao; LI, Jun.** *Statistical Analysis for Component Shift in Pick and Place Process of Surface Mount Technology*. arXiv preprint, 2020. Disponível em: <https://arxiv.org/abs/2002.07807>. Acesso em: 21 out. 2025.
- CHEN, Tianqi; GUESTRIN, Carlos.** *XGBoost: A Scalable Tree Boosting System*. *Proceedings of the 22nd ACM SIGKDD*, 2016.
- CHIAVENATO, Idalberto.** *Introdução à Teoria Geral da Administração*. 8. ed. Rio de Janeiro: Elsevier, 2014.
- CHOPRA, Sunil; CHASE, Richard B.; AQUILANO, Nicholas J.** *Administração da Produção e Operações*. 10. ed. São Paulo: McGraw-Hill, 2006.
- CHRISTOPHER, Martin.** *Logística e Gerenciamento da Cadeia de Suprimentos*. São Paulo: Cengage Learning, 2011.
- CORRÊA, Henrique L.; CORRÊA, Carlos A.** *Administração de produção e operações: manufatura e serviços – uma abordagem estratégica*. 5. ed. São Paulo: Atlas, 2017.
- DAVENPORT, Thomas H.; KALAKOTA, Ravi.** **The potential for artificial intelligence in healthcare.** *Future Healthcare Journal*, v. 6, n. 2, p. 94–98, 2019.
- GAITHER, Norman; FRAZIER, Greg.** *Administração da Produção e Operações*. São Paulo: Thomson, 2002.
- GIL, Antonio Carlos.** *Métodos e Técnicas de Pesquisa Social*. 6. ed. São Paulo: Atlas, 2002.
- HEIZER, Jay; RENDER, Barry.** *Administração da Produção: bens e serviços*. 8. ed. São Paulo: Prentice Hall, 2004.
- JAMES, Gareth et al.** *An Introduction to Statistical Learning*. Springer, 2013.
- LEE, Jay; KAO, H.; YANG, S.** *Service Innovation and Smart Analytics for Industry 4.0*. *Procedia CIRP*, 2014.

LUNDBERG, Scott; LEE, Su-In. *A Unified Approach to Interpreting Model Predictions*. Advances in Neural Information Processing Systems, 2017.

MAKRIDAKIS, Spyros; SPILIOTIS, Evangelos; ASSIMAKOPOULOS, Vassilios. *Statistical and Machine Learning Forecasting Methods: Concerns and Ways Forward*. PLoS ONE, v. 13, n. 3, 2018.

MONTGOMERY, Douglas C.; PECK, Elizabeth A.; VINING, Geoffrey G. **Introduction to Linear Regression Analysis**. 5. ed. Hoboken: Wiley, 2012.

MARTINS, Petrônio Garcia; LAUGENI, Fernando Person. *Administração da Produção*. São Paulo: Saraiva, 2015.

MDPI. *Surface-Mount Technology Assembly Process Overview*. MDPI Electronics, 2022.

MEHRA, A.; MISHRA, S. *Machine Learning for Manufacturing Systems*. IEEE Access, 2020.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to Linear Regression Analysis**. 5. ed. Hoboken: Wiley, 2012.

OHNO, Taiichi. *O Sistema Toyota de Produção: além da produção em larga escala*. Porto Alegre: Bookman, 1997.

PEREIRA, A. C.; SIMÕES, M.; MACHADO, J. C. *Indústria 4.0: fundamentos, perspectivas e aplicações no Brasil*. 2. ed. Rio de Janeiro: LTC, 2021.

SEVERINO, Antônio Joaquim. *Metodologia do Trabalho Científico*. São Paulo: Cortez, 2017.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. *Administração da Produção*. 4. ed. São Paulo: Atlas, 2009.

STEVENSON, William J. *Operations Management*. 12. ed. New York: McGraw-Hill, 2015.

SYLVAN, Andreas. *Internet of Things in Surface Mount Technology Electronics Assembly*. 2017. Dissertação (Mestrado) – KTH Royal Institute of Technology, Estocolmo, 2017.

TAYLOR, Frederick W. *Princípios da Administração Científica*. São Paulo: Atlas, 1995.

TUBINO, Dalvio F. *Planejamento e controle da produção: teoria e prática*. 4. ed. São Paulo: Atlas, 2017.

WOMACK, James; JONES, Daniel. *A Mentalidade Enxuta nas Empresas*. Rio de Janeiro: Elsevier, 2004.

ANEXOS

ANEXO A – CÓDIGO EM PYTHON PARA CRIAÇÃO DE MODELO

```

# =====
# BLOCO 1 – IMPORTAÇÕES E LEITURA DOS DADOS
# =====
import pandas as pd
import numpy as np
import xgboost as xgb
from sklearn.model_selection import train_test_split, cross_val_score
from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score
import joblib
from google.colab import files
import matplotlib.pyplot as plt

# leitura da base
df = pd.read_excel('Base de dados 17182825.xlsx') # ajuste o nome conforme necessário

# Visualização inicial
print(df.shape)
print(df.columns)
display(df.head())
print(df.dtypes)

# =====
# BLOCO 2 – TRATAMENTO DE DATAS E FEATURE ENGINEERING
# =====

# Converter coluna de data
df['Data'] = pd.to_datetime(df['Data'], dayfirst=True, errors='coerce')

# Criar variáveis de tempo
df['dayofweek'] = df['Data'].dt.dayofweek # 0 = segunda, 6 = domingo
df['month'] = df['Data'].dt.month
df['dayofyear'] = df['Data'].dt.dayofyear
df['dayofmonth'] = df['Data'].dt.day
df['weekofyear'] = df['Data'].dt.isocalendar().week.astype(int)
df['year'] = df['Data'].dt.year

# =====
# BLOCO 3 – TRATAMENTO DE CATEGORIAS E TIPOS (FORÇANDO 'Sem parada' = 0)
# =====

# 1) Preencher ausentes com 'Sem parada'
df['Máquina parada'] = df['Máquina parada'].fillna('Sem parada')
df['Tipo de parada'] = df['Tipo de parada'].fillna('Sem parada')

# 2) Garantir tempo de parada numérico
df['Tempo de parada'] = pd.to_numeric(df['Tempo de parada'], errors='coerce').fillna(0.0)

def encode_with_sem_parada_first(series):
    # pega todas as categorias que existem
    cats = series.astype(str).unique().tolist()
    # garante que 'Sem parada' é a primeira
    if 'Sem parada' in cats:
        cats.remove('Sem parada')
    ordered = ['Sem parada'] + sorted(cats)
    cat_series = pd.Categorical(series, categories=ordered)
    codes = cat_series.codes
    mapping = {cat: i for i, cat in enumerate(ordered)}
    inv_map = {i: cat for i, cat in enumerate(ordered)}
    return codes.astype('int32'), mapping, inv_map

# 3) codificar forçando 0 = Sem parada
df['Tipo de parada'], tipo_map, tipo_inv_map = encode_with_sem_parada_first(df['Tipo de parada'])
df['Máquina parada'], maquina_map, maquina_inv_map = encode_with_sem_parada_first(df['Máquina parada'])

# 4) coerência final: se tempo de parada == 0 -> tudo 0
mask_sem_parada = df['Tempo de parada'] == 0
df.loc[mask_sem_parada, 'Tipo de parada'] = 0
df.loc[mask_sem_parada, 'Máquina parada'] = 0

# 5) turno numérico
df['turno'] = df['turno'].astype(float)

print("Mapeamento Tipo de parada:", tipo_map)
print("Mapeamento Máquina parada:", maquina_map)

# =====
# BLOCO 4 – SELEÇÃO DE FEATURES, TREINO E AVALIAÇÃO
# =====

# Features e variável alvo
features = ['dayofweek', 'month', 'dayofyear', 'dayofmonth', 'weekofyear', 'year',
            'Tempo de parada', 'Tipo de parada', 'Máquina parada', 'turno']
X = df[features].astype(np.float32)
y = df['Quant. Produzida'].astype(np.float32)

# Divisão treino/teste
train_X, test_X, train_y, test_y = train_test_split(X, y, test_size=0.3, random_state=123)

# Modelo
model = xgb.XGBRegressor(
    objective='reg:squarederror',
    n_estimators=500,
    max_depth=4,
    learning_rate=0.1,
    random_state=123
)
model.fit(train_X, train_y)

# Avaliação
pred_test = model.predict(test_X)
mae = mean_absolute_error(test_y, pred_test)
rmse = np.sqrt(mean_squared_error(test_y, pred_test))
r2 = r2_score(test_y, pred_test)

print("===== METRICAS DO MODELO =====")
print(f"MAE : {mae:.2f}")
print(f"RMSE : {rmse:.2f}")
print(f"R² : {r2:.3f}")

# Gráfico Real vs Previsto
plt.scatter(test_y, pred_test, alpha=0.6)
plt.xlabel("Produção Real")
plt.ylabel("Produção Prevista")
plt.title("Comparativo Real vs Previsto - XGBoost")
plt.show()

# =====
# BLOCO 5 – SHAPE VALUE (IMPORTÂNCIA DAS VARIÁVEIS)
# =====

```

```

import shap

# Inicializa o Interpretador SHAP
# Tenta passar a função de previsão diretamente
try:
    explainer = shap.Explainer(model.predict, test_X)
except TypeError:
    # Se o método acima falhar, tenta o TreeExplainer com o modelo
    print(f"shap.Explainer com model.predict falhou. Tentando shap.TreeExplainer...")
    try:
        explainer = shap.TreeExplainer(model)
    except Exception as e:
        print(f"Erro ao inicializar TreeExplainer: {e}")
        print("Pode haver um problema de compatibilidade de versão ou na instalação do SHAP.")
        explainer = None # Garante que explainer é None se ambos falharem

if explainer is not None:
    # Calcula os valores SHAP para o conjunto de teste
    # Para shap.Explainer, o método é explainer(data)
    try:
        shap_values = explainer(test_X)

        # Exibe a importância média de cada variável
        shap.summary_plot(shap_values, test_X, plot_type="bar")

        # Exibe o gráfico de dispersão com o efeito de cada variável
        shap.summary_plot(shap_values, test_X)

        # (Opcional) Visualizar o impacto de uma variável específica
        # Note: The feature name needs to match exactly the column name in test_X
        # Assuming 'Tempo de parada' is the correct column name
        if 'Tempo de parada' in test_X.columns:
            shap.dependence_plot("Tempo de parada", shap_values, test_X)
        else:
            print("A coluna 'Tempo de parada' não foi encontrada em test_X para o dependence plot.")

    except Exception as e:
        print(f"Erro ao calcular ou plotar valores SHAP: {e}")
        print("Verifique se os dados de entrada para SHAP estão corretos.")

else:
    print("Não foi possível inicializar um explainer SHAP.")
# =====
# BLOCO 6 - FUNÇÃO DE PREVISÃO INDIVIDUAL
# =====

def prever_producao(data_str, turno, tipo_parada=None, maquina_parada=None, tempo_parada=None,
                    usar_defaults=True):
    d = pd.to_datetime(data_str, dayfirst=True, format='%d/%m/%Y', errors='coerce')
    if pd.isna(d):
        raise ValueError("Formato inválido. Use 'dd/mm/yyyy'.")

    default_tipo = df['Tipo de parada'].mode().iloc[0]
    default_maquina = df['Máquina parada'].mode().iloc[0]
    default_tempo = df['Tempo de parada'].median()

    tipo_code = tipo_map.get(tipo_parada, default_tipo) if isinstance(tipo_parada, str) else default_tipo
    maquina_code = maquina_map.get(maquina_parada, default_maquina) if isinstance(maquina_parada, str) else default_maquina
    tempo_parada_val = tempo_parada if tempo_parada is not None else default_tempo

    novo = pd.DataFrame({
        'dayofweek': [d.dayofweek],
        'month': [d.month],
        'dayofyear': [d.dayofyear],
        'dayofmonth': [d.day],
        'weekofyear': [int(d.isocalendar().week)],
        'year': [d.year],
        'Tempo de parada': [tempo_parada_val],
        'Tipo de parada': [tipo_code],
        'Máquina parada': [maquina_code],
        'turno': [turno]
    })

    pred = model.predict(novo)[0]
    if d.dayofweek == 6: # domingo
        pred = 0.8

    return {'data': d.strftime('%d/%m/%Y'), 'turno': turno, 'previsao': float(pred)}
# =====
# BLOCO 7 - PREVISÃO DOS PRÓXIMOS 365 DIAS (0,5 e 1,0)
# =====

from datetime import timedelta
import numpy as np
import pandas as pd

np.random.seed(123)

# =====
# função pra montar 1 cenário
# =====

def gerar_cenario(turno_val, df_base, model):
    # datas futuras
    data_inicial = df_base['Data'].max() + pd.Timedelta(days=1)
    datas_futuras = pd.date_range(start=data_inicial, periods=365, freq='D')

    # combinações reais de tipo x máquina (sem zeros)
    combos_reais = (
        df_base.groupby(['Tipo de parada', 'Máquina parada'])
        .size()
        .reset_index(name='freq')
    )
    combos_reais = combos_reais[
        (combos_reais['Tipo de parada'] != 0) & (combos_reais['Máquina parada'] != 0)
    ]

    # probabilidade proporcional à frequência
    if not combos_reais.empty:
        combos_reais['prob'] = combos_reais['freq'] / combos_reais['freq'].sum()

    # estatística do tempo de parada
    tp = pd.to_numeric(df_base['Tempo de parada'], errors='coerce')
    tempo_min = float(tp.min(skipna=True)) if np.isfinite(tp.min(skipna=True)) else 0.8
    tempo_max = float(tp.max(skipna=True)) if np.isfinite(tp.max(skipna=True)) else 0.8

```

```

# estatística do tempo de parada
tp = pd.to_numeric(df_base['Tempo de parada'], errors='coerce')
tempo_min = float(tp.min(skipna=True)) if np.isfinite(tp.min(skipna=True)) else 0.0
tempo_max = float(tp.max(skipna=True)) if np.isfinite(tp.max(skipna=True)) else 0.0
tempo_medio = float(tp.mean(skipna=True)) if np.isfinite(tp.mean(skipna=True)) else 0.0
if tempo_max < tempo_min:
    tempo_max = tempo_min

# dataframe futuro
df_fut = pd.DataFrame({
    'data': datas_futuras,
    'dayofweek': datas_futuras.dayofweek,
    'month': datas_futuras.month,
    'dayofyear': datas_futuras.dayofyear,
    'dayofmonth': datas_futuras.day,
    'weekofyear': datas_futuras.isocalendar().week.astype(int),
    'year': datas_futuras.year,
    'turno': float(turno_val)
})

# gerar tempo de parada
if tempo_max == tempo_min:
    df_fut['Tempo de parada'] = 0.0
else:
    sigma = max((tempo_max - tempo_min) / 4.0, 1e-6)
    mu = tempo_medio
    arr = np.random.normal(mu, sigma, len(df_fut))
    df_fut['Tempo de parada'] = np.clip(arr, tempo_min, tempo_max)

# Domingos = 0
mask_dom = df_fut['dayofweek'] == 6
df_fut.loc[mask_dom, 'Tempo de parada'] = 0.0

# inicializa categorias
df_fut['Tipo de parada'] = 0
df_fut['Máquina parada'] = 0

# linhas que realmente tiveram parada
mask_parada = (df_fut['Tempo de parada'] > 0) & (~mask_dom)

if mask_parada.any() and not combos_reais.empty:
    idx = df_fut.index[mask_parada]
    # sorteia combinações reais, com peso
    sorteados = combos_reais.sample(
        n=len(idx),
        replace=True,
        weights='prob',
        random_state=123
    ).reset_index(drop=True)

    df_fut.loc[idx, 'Tipo de parada'] = sorteados['Tipo de parada'].values
    df_fut.loc[idx, 'Máquina parada'] = sorteados['Máquina parada'].values
else:
    # se não tiver combo real, zera tudo
    df_fut.loc[mask_parada, ['Tipo de parada', 'Máquina parada']] = 0

# segurança final: domingo é tudo 0
df_fut.loc[mask_dom, ['Tempo de parada', 'Tipo de parada', 'Máquina parada']] = 0

# agora PREENCHE NaN (era isso que estava te deixando célula vazia no Excel)
df_fut['Tipo de parada'] = df_fut['Tipo de parada'].fillna(0).astype(int)
df_fut['Máquina parada'] = df_fut['Máquina parada'].fillna(0).astype(int)
df_fut['Tempo de parada'] = df_fut['Tempo de parada'].fillna(0).astype(float)

# Faz a previsão
features_pred = [
    'dayofweek', 'month', 'dayofyear', 'dayofmonth', 'weekofyear', 'year',
    'Tempo de parada', 'Tipo de parada', 'Máquina parada', 'turno'
]
preds = model.predict(df_fut[features_pred])
preds = np.maximum(preds, 0.0)
df_fut['Previsão Quant. Produzida'] = preds

# domingos = 0 mesmo
df_fut.loc[mask_dom, 'Previsão Quant. Produzida'] = 0.0

# checagem (só pra você ver no colab)
erros = df_fut[
    ((df_fut['Tempo de parada'] == 0) & ((df_fut['Tipo de parada'] != 0) | (df_fut['Máquina parada'] != 0))) |
    ((df_fut['Tempo de parada'] > 0) & ((df_fut['Tipo de parada'] == 0) | (df_fut['Máquina parada'] == 0)))
]
print(f"Turno {turno_val} + inconsistências (esperado 0): {len(erros)}")

return df_fut

# gera os dois cenários
df_futuro_05 = gerar_cenario(0.5, df, model)
df_futuro_10 = gerar_cenario(1.0, df, model)

# exporta em um único arquivo com duas abas
with pd.ExcelWriter("Previsao_365_Futuros.xlsx") as writer:
    df_futuro_05.to_excel(writer, sheet_name="Turno 0.5", index=False)
    df_futuro_10.to_excel(writer, sheet_name="Turno 1.0", index=False)

print("📁 Arquivo 'Previsao_365_Futuros.xlsx' gerado com sucesso!")

from google.colab import files
files.download("Previsao_365_Futuros.xlsx")
# -----
# BLOCO 8 - PREVISÃO DOS PRÓXIMOS 365 DIAS (TURNO 1.0)
# -----

from datetime import timedelta
import numpy as np
import pandas as pd

np.random.seed(123)

# 1) Datas Futuras
data_inicial = df['data'].max() + pd.Timedelta(days=1)
datas_futuras = pd.date_range(start=data_inicial, periods=365, freq='D')

```

```

# 2) Conjuntos válidos numéricos para tipo/máquina
tipos_validos = [int(v) for v in pd.Series(df['Tipo de parada']).dropna().unique().tolist() if int(v) != 0]
maquinas_validas = [int(v) for v in pd.Series(df['Máquina parada']).dropna().unique().tolist() if int(v) != 0]

has_tipos = len(tipos_validos) > 0
has_maquinas = len(maquinas_validas) > 0

# 3) Estatísticas do tempo de parada (seguras)
tp = pd.to_numeric(df['Tempo de parada'], errors='coerce')
tempo_min = float(tp.min(skipna=True)) if np.isfinite(tp.min(skipna=True)) else 0.0
tempo_max = float(tp.max(skipna=True)) if np.isfinite(tp.max(skipna=True)) else 0.0
tempo_medio = float(tp.mean(skipna=True)) if np.isfinite(tp.mean(skipna=True)) else 0.0

if not np.isfinite(tempo_min): tempo_min = 0.0
if not np.isfinite(tempo_max): tempo_max = 0.0
if tempo_max < tempo_min: tempo_max = tempo_min

# 4) Criar DataFrame futuro
df_futuro_10 = pd.DataFrame({
    'Data': datas_futuras,
    'dayofweek': datas_futuras.dayofweek,
    'month': datas_futuras.month,
    'dayofyear': datas_futuras.dayofyear,
    'dayofmonth': datas_futuras.day,
    'weekofyear': datas_futuras.isocalendar().week.astype(int),
    'year': datas_futuras.year,
    'turno': 1.0 # aqui é o turno completo
})

# 5) Gerar Tempo de parada
if tempo_max == tempo_min:
    df_futuro_10['Tempo de parada'] = 0.0
else:
    sigma = max((tempo_max - tempo_min) / 4.0, 1e-6)
    mu = tempo_medio
    arr = np.random.normal(mu, sigma, len(df_futuro_10))
    df_futuro_10['Tempo de parada'] = np.clip(arr, tempo_min, tempo_max)

# 6) Domingos = tudo 0
mask_domingo = df_futuro_10['dayofweek'] == 6
df_futuro_10.loc[mask_domingo, 'Tempo de parada'] = 0.0

# 7) Inicializa tipo/máquina como 0
df_futuro_10['Tipo de parada'] = 0
df_futuro_10['Máquina parada'] = 0

# 8) Paradas reais
mask_parada = (df_futuro_10['Tempo de parada'] > 0) & (~mask_domingo)

if mask_parada.any() and has_tipos and has_maquinas:
    idx = df_futuro_10.index[mask_parada]
    df_futuro_10.loc[idx, 'Tipo de parada'] = np.random.choice(tipos_validos, size=len(idx))
    df_futuro_10.loc[idx, 'Máquina parada'] = np.random.choice(maquinas_validas, size=len(idx))
else:
    df_futuro_10.loc[mask_parada, ['Tempo de parada', 'Tipo de parada', 'Máquina parada']] = 0

# 9) Coerência final
mask_zero = df_futuro_10['Tempo de parada'] == 0
df_futuro_10.loc[mask_zero, ['Tipo de parada', 'Máquina parada']] = 0

mask_incoerente = (df_futuro_10['Tempo de parada'] > 0) & (
    (df_futuro_10['Tipo de parada'] == 0) | (df_futuro_10['Máquina parada'] == 0)
)
df_futuro_10.loc[mask_incoerente, ['Tempo de parada', 'Tipo de parada', 'Máquina parada']] = 0

df_futuro_10.loc[mask_domingo, ['Tempo de parada', 'Tipo de parada', 'Máquina parada']] = 0

# 10) Fazer previsão
features_pred = ['dayofweek', 'month', 'dayofyear', 'dayofmonth', 'weekofyear', 'year',
                 'Tempo de parada', 'Tipo de parada', 'Máquina parada', 'turno']

pred = np.asarray(model.predict(df_futuro_10[features_pred]), dtype=float)
pred = np.maximum(pred, 0.0)
df_futuro_10['Previsão Quant. Produzida'] = pred
df_futuro_10.loc[mask_domingo, 'Previsão Quant. Produzida'] = 0.0

# 11) Verificação (esperado 0 inconsistências)
erros = df_futuro_10[
    ((df_futuro_10['Tempo de parada'] == 0) & ((df_futuro_10['Tipo de parada'] != 0) | (df_futuro_10['Máquina parada'] != 0))) |
    ((df_futuro_10['Tempo de parada'] > 0) & ((df_futuro_10['Tipo de parada'] == 0) | (df_futuro_10['Máquina parada'] == 0)))
]
print(f"Inconsistências (esperado 0): {len(erros)}")

# 12) Exportar pro Power BI
display(df_futuro_10.head(10))
df_futuro_10.to_excel("Previsao_365_Turno_10.xlsx", index=False)
print("Arquivo 'Previsao_365_Turno_10.xlsx' gerado com sucesso!")

from google.colab import files
files.download("Previsao_365_Turno_10.xlsx")

```