

GESTÃO DE SUPRIMENTOS EM SISTEMAS PRODUTIVOS: UMA ABORDAGEM PREDITIVA COM CIÊNCIA DE DADOS E INTELIGÊNCIA ARTIFICIAL

SUPPLY MANAGEMENT IN PRODUCTIVE SYSTEMS: A PREDICTIVE APPROACH WITH DATA SCIENCE AND ARTIFICIAL INTELLIGENCE

MICHEL SILVA DE SOUZA

CENTRO PAULA SOUZA

CARLOS HIDEO ARIMA

RAFAEL NOBRE ORSI

UNIDADE DE POS GRADUAÇÃO, EXTENSÃO E PESQUISA - CENTRO PAULA SOUZA

Comunicação:

O XIII SINGEP foi realizado em conjunto com a 13th Conferência Internacional do CIK (CYRUS Institute of Knowledge), em formato híbrido, com sede presencial na UNINOVE - Universidade Nove de Julho, no Brasil.

GESTÃO DE SUPRIMENTOS EM SISTEMAS PRODUTIVOS: UMA ABORDAGEM PREDITIVA COM CIÊNCIA DE DADOS E INTELIGÊNCIA ARTIFICIAL

Objetivo do estudo

Apresentar o desenvolvimento e a validação de um produto técnico-tecnológico baseado em Inteligência Artificial, projetado para transformar o planejamento reativo de suprimentos em um modelo proativo, otimizando a gestão de um refeitório institucional e reduzindo o desperdício de alimentos.

Relevância/originalidade

A originalidade reside na aplicação de um comitê de modelos preditivos e uma arquitetura híbrida customizada para solucionar um problema de gestão crônico em sistemas produtivos. O trabalho oferece um modelo replicável para promover a eficiência e a sustentabilidade.

Metodologia/abordagem

Foi realizada uma pesquisa aplicada, envolvendo agregação de dados, engenharia de features e seleção automática de variáveis. Um comitê de modelos foi treinado e validado através de backtesting e um teste hold-out, simulando a operação real para validar a eficácia da intervenção.

Principais resultados

O modelo campeão alcançou um R^2 de 64,37% no teste final. A simulação de backtesting demonstrou que a estratégia de produção guiada pela IA reduziu o desperdício em mais de 50% e o custo operacional total em 23,18% (economia de R\$ 6.700,96).

Contribuições teóricas/metodológicas

A principal contribuição é a arquitetura de um sistema que integra a precisão estatística de um modelo híbrido a uma lógica de negócio (margem de segurança adaptativa e limite por reservas), transformando a previsão em uma recomendação de gestão acionável e segura.

Contribuições sociais/para a gestão

A solução oferece uma ferramenta prática para gestores otimizarem a cadeia de suprimentos, reduzindo custos e o impacto ambiental. Demonstra um caminho viável para a modernização da gestão e a promoção da sustentabilidade (ODS) em instituições de ensino e serviços de alimentação.

Palavras-chave: Gestão de Sistemas Produtivos, Ciência de Dados, Inteligência Artificial, Previsão de Demanda, Redução de Desperdício

SUPPLY MANAGEMENT IN PRODUCTIVE SYSTEMS: A PREDICTIVE APPROACH WITH DATA SCIENCE AND ARTIFICIAL INTELLIGENCE

Study purpose

To present the development and validation of an AI-based technical-technological product designed to transform reactive supply planning into a proactive model, optimizing the management of an institutional cafeteria and reducing food waste.

Relevance / originality

The originality lies in applying a predictive model committee and a custom hybrid architecture to solve a chronic management problem in productive systems. The work offers a replicable model to promote efficiency and sustainability.

Methodology / approach

Applied research was conducted, involving data aggregation, feature engineering, and automatic variable selection. A model committee was trained and validated through backtesting and a hold-out test, simulating real-world operations to validate the intervention's effectiveness.

Main results

The champion model achieved an R^2 of 64.37% in the final test. Backtesting simulation showed that the AI-guided production strategy reduced waste by over 50% and the total operational cost by 23.18%, saving R\$ 6,700.96.

Theoretical / methodological contributions

The main contribution is a system architecture that integrates the statistical precision of a hybrid model with business logic (adaptive safety margin and reservation limits), transforming a forecast into an actionable and safe management recommendation.

Social / management contributions

The solution provides a practical tool for managers to optimize the supply chain, reducing costs and environmental impact. It demonstrates a viable path for modernizing management and promoting sustainability (SDGs) in educational institutions and food services.

Keywords: Production Systems Management, Data Science, Artificial Intelligence, Demand Forecasting, Waste Reduction

TÍTULO: GESTÃO DE SUPRIMENTOS EM SISTEMAS PRODUTIVOS: UMA ABORDAGEM PREDITIVA COM CIÊNCIA DE DADOS E INTELIGÊNCIA ARTIFICIAL

1 Introdução

A eficiência dos sistemas produtivos é um fator crítico para a sustentabilidade de qualquer organização, seja ela pública ou privada. No contexto da educação profissional, a gestão de serviços de apoio, como os refeitórios institucionais, representa um complexo sistema produtivo caracterizado pela sequência de entrada (insumos), conversão (preparo) e saída (refeições servidas). A otimização deste sistema é fundamental não apenas para a estabilidade financeira da instituição, mas também para o cumprimento de metas de sustentabilidade, um pilar da Indústria 5.0 (LENG et al., 2024).

Atualmente, um dos processos mais significativos na gestão de refeitórios de grandes IE é a previsão de demanda, o que gera impactos diretos na cadeia de suprimentos. A situação-problema analisada neste estudo emerge da dinâmica operacional entre uma instituição de ensino superior tecnológico e a empresa terceirizada responsável pelo preparo das refeições. O processo atual de planejamento de suprimentos é reativo e ineficiente: o quantitativo de refeições necessárias para a semana subsequente é comunicado à empresa apenas às sextas-feiras, com aproximadamente três dias de antecedência. Este prazo extremamente curto, que coincide com o final de semana, impõe um severo desafio logístico à empresa, que enfrenta dificuldades na aquisição de insumos, especialmente perecíveis. Para mitigar o risco de desabastecimento, a prática corrente leva a uma superprodução cautelar ou a compras emergenciais com custos elevados, culminando em desperdício de recursos e configurando uma falha crítica no sistema produtivo. Na literatura, algumas abordagens apontam o uso de IA e o *Machine Learning* (ML) como soluções promissoras para mitigar o desperdício e otimizar cadeias de suprimentos (ONYEAKA et al., 2025; RAJENDRAN et al., 2025; OLAWALE et al., 2025). Adicionalmente, a aplicação de IA em hotéis e restaurantes para ajuste de porções e gestão de estoque (CLARK et al., 2023) valida a relevância prática desta abordagem.

O objetivo deste estudo é, portanto, apresentar o desenvolvimento e a validação de um produto técnico-tecnológico utilizando técnicas de Ciência de Dados (CD) e Inteligência Artificial (IA). Este trabalho visa transformar o processo reativo de planejamento em um modelo proativo com um sistema que fornece previsões acuradas com maior antecedência, baseando-se em dados históricos de demanda, calendário e fatores externos, conforme a literatura indica (CHAUDHARI et al., 2025). Esta intervenção busca reduzir o desperdício de alimentos, otimizar a gestão da cadeia de suprimentos, aumentar a eficiência operacional e promover a sustentabilidade e inovação em sistemas produtivos (LENG et al., 2024; OLAWALE et al., 2025).

Este relato detalha a metodologia de construção do sistema, desde a fundamentação teórica até a implementação prática e a análise dos resultados, demonstrando o potencial das tecnologias digitais como ferramenta de apoio à decisão para resolver problemas complexos em ambientes organizacionais (XU et al., 2021; TRIPATHI et al., 2021).

2 Referencial Teórico

A aplicação de tecnologias digitais para otimizar sistemas produtivos tem sido amplamente documentada na literatura, com a IA e o ML emergindo como ferramentas poderosas para a previsão de demanda e a gestão de cadeias de suprimentos. Este referencial teórico contextualiza a solução proposta com base em estudos que validam sua abordagem, alinhando-se ao tema das Tecnologias Digitais e Sustentabilidade em Sociedades Resilientes.

Recentemente, têm surgido trabalhos que mostram que a IA é uma tecnologia transformadora na gestão de serviços de alimentação. Estudos como os de Onyeaka et al. (2025) destacam o papel da IA na minimização do desperdício de alimentos (*food waste*) através de análises preditivas que permitem um planejamento mais acurado. A capacidade de prever a demanda com precisão pode reduzir o desperdício em até 30% (Kanwal et al., 2025), um dado que reforça o potencial de impacto econômico e ambiental da solução aqui desenvolvida. Publicações de mercado, como a análise da Shiji Insights (2025) e o trabalho de Clark et al. (2023), confirmam que hotéis e restaurantes já utilizam sistemas baseados em IA para ajustar porções e gerenciar estoques de forma dinâmica, validando a relevância prática desta abordagem.

Para que um modelo preditivo seja eficaz é importante saber selecionar as variáveis que causam maior impacto no processo. Trabalhos como o de Chaudhari et al. (2025) e uma análise sistemática da área apontam que variáveis como o histórico de demanda, dados de calendário (dias da semana, feriados), características do cardápio e dados climáticos são preditores-chave. A complexidade aumenta quando centenas de variáveis são criadas, como neste estudo, tornando essencial o uso de técnicas de seleção de *features* para construir um modelo parcimonioso e robusto o suficiente para evitar o ruído de variáveis irrelevantes (XU et al., 2021).

No que tange aos algoritmos, a escolha por um “comitê de modelos” está alinhada com as melhores práticas. Chaudhari et al. (2025) e Rajendran et al. (2025) mencionam algoritmos como *Gradient Boosting* e *XGBoost* como estado da arte para problemas de previsão em dados tabulares, devido à sua alta performance. Além desses, a arquitetura metodológica adotada neste trabalho emprega um modelo híbrido residual, que combina a robustez de modelos lineares, como *Ridge*, para capturar tendências gerais com a capacidade de modelos de árvores, como *ExtraTrees*, para aprender os resíduos. Essa abordagem de *ensemble learning*, que também inclui técnicas como *Voting* e *Stacking*, permite explorar a diversidade de algoritmos para otimizar a precisão, conforme discutido por Kuhl et al. (2021) e Mohaiminul et al. (2024), garantindo a confiabilidade do sistema (TRIPATHI et al., 2021).

A solução proposta, ao integrar CD com a aplicabilidade da IA, alinha-se a abordagens promissoras na literatura que apontam para uma otimização dos sistemas produtivos para a sustentabilidade (OLAWALE et al., 2025). Desta forma, neste estudo é apresentado uma aplicação de modelagem, com intervenção gerencial fundamentada que visa aprimorar a governança e a eficiência do sistema produtivo em análise.

3 Metodologia

Este relato técnico descreve o processo de desenvolvimento e implementação de um produto tecnológico, concebido como uma intervenção gerencial para solucionar a ineficiência na cadeia de suprimentos de refeições de uma instituição de ensino superior tecnológico. Todo o processo metodológico, desde a análise exploratória até a validação do modelo final, foi documentado em um notebook computacional, cujo código-fonte está disponível para fins de reprodutibilidade e será fornecido mediante solicitação para garantir o anonimato durante o processo de revisão. O conjunto de dados original, por conter informações sensíveis da instituição de ensino, não foi disponibilizado.

3.1 Caracterização do Problema e Coleta de Dados

O ponto de partida foi a análise do sistema produtivo de refeições, identificando o principal gargalo: a ausência de um mecanismo de previsão de demanda que permitisse um planejamento de suprimentos com antecedência. A única informação disponível para a gestão

era a contagem de reservas, que, como será demonstrado, é um indicador insuficiente para um planejamento preciso.

Um dos desafios centrais na gestão de serviços de alimentação é a discrepância entre o número de itens reservados e o consumo efetivo. Conforme ilustrado na Figura 1, que compara o total de reservas diárias com a demanda real de refeições servidas ao longo do período analisado, mostrando que existe uma variabilidade significativa entre as duas séries. Em certos dias, a demanda supera as reservas, enquanto em outros ocorre o inverso. Esta volatilidade torna o planejamento baseado apenas em reservas, que é uma prática arriscada, justificando a necessidade de um modelo preditivo mais robusto que possa aprender com esses padrões e incorporar outras variáveis de contexto.




Figura 1 - Análise da Variabilidade entre Reservas e Demanda Real

Para desenvolver a solução, foi realizada a coleta de dados primários e secundários. Os dados primários consistem nos próprios registros diários de refeições servidas e reservadas na instituição de ensino, abrangendo um período histórico de 78 dias letivos. Foram coletados também dados secundários que, conforme a literatura, influenciam o comportamento do consumidor e são relevantes para o contexto, como: o calendário acadêmico, para identificar dias letivos, feriados e eventos; e dados meteorológicos, de temperatura e precipitação (Chaudhari et al., 2025). O resultado foi um *dataset* inicial com 15.279 registros individuais, que serviu de base para a construção do modelo.

3.2 Estruturação dos Dados e Seleção de Features

Os dados brutos, em nível de registro individual, foram transformados por um processo de agregação para que cada linha representasse um único dia e suas características consolidadas. Em seguida, foi aplicada a engenharia de *features*, para enriquecer o *dataset* com informações contextuais e temporais. Foram criadas 243 variáveis preditivas, incluindo:

- **Lags e Médias Móveis:** Variáveis que representam a demanda de dias anteriores (ex: lag_1d, lag_7d) e a média de consumo recente (ma_7d), permitindo ao modelo capturar tendências e sazonalidades de curto prazo.
- **Features de Calendário:** Variáveis que codificam o dia da semana, mês e dia do ano, incluindo representações cíclicas (seno/cosseno) para melhor interpretação pelos algoritmos.

- **Features de Contexto:** Variáveis que integram dados de reservas, meteorologia e eventos acadêmicos, fornecendo ao modelo uma visão holística dos fatores que podem influenciar a demanda.

Com um conjunto tão vasto de variáveis, a primeira etapa da análise foi explorar quais possuíam a maior relação linear com a demanda. As Figuras 2 e 3 apresentam as 10 *features* com maior correlação positiva e negativa, respectivamente.




Figura 2 - Top 10 Features com Maior Correlação Positiva com a Demanda

A análise exploratória inicial identificou as variáveis com maior correlação linear positiva com a demanda diária. A Figura 2 apresenta as dez features mais impactantes, destacando reservas_total e alunos_unicos_dia como os principais impulsionadores do consumo. Variáveis de contexto, como a ocorrência de quartas-feiras (ocorrencia_quarta) e o histórico de consumo (delta_serv_res_lag_3d), também se mostraram preditores relevantes nesta fase inicial de análise.




Figura 3 - Top 10 Features com Maior Correlação Negativa com a Demanda

A Figura 3 complementa a análise ao apresentar as dez features com a maior correlação linear negativa com a demanda. Destaca-se a variável *dia_semana*, indicando que a demanda tende a diminuir com o avançar da semana. Fatores como a ocorrência de sextas-feiras (*ocorrencia_sexta*) e características do cardápio, como a presença de proteína bovina, também surgem como importantes detratores do consumo.

Diante da alta dimensionalidade, tornou-se fundamental determinar o número ideal de *features* para evitar a inclusão de ruído e a complexidade desnecessária. Para isso, foi realizada uma análise de desempenho em função do número de *features*. O resultado, ilustrado na Figura 4, demonstrou que a performance ótima (menor Erro Médio Absoluto) foi atingida com um conjunto enxuto de apenas 5 features, validando a escolha por um modelo mais parcimonioso e robusto.




Figura 4 - Desempenho (MAE) vs. Número de Features Seleccionadas

A relação interna entre as 5 features finais selecionadas e a variável alvo (*servidas_total*) é detalhada no mapa de correlação da Figura 5.




Figura 5 - Mapa de Correlação das Features Seleccionadas

A análise da primeira linha do mapa de correlação (Figura 5) revela *insights* importantes para a modelagem:

- **Correlação Positiva Forte:** As variáveis `alunos_unicos_dia` (0.60) e `reservas_total` (0.56) apresentam a maior correlação positiva com a demanda, confirmando que o número de pessoas presentes e o número de reservas são preditores fundamentais. A variável `delta_serv_res_lag_3d` (0.49), que representa a diferença entre refeições servidas e reservadas há três dias, também mostra uma forte correlação positiva, indicando que o “comportamento de *no-show*” recente é um forte preditor da demanda atual.
- **Correlação Negativa:** A variável `dia_semana` (-0.52) mostra uma correlação negativa, indicando que a demanda tende a diminuir ao longo dos dias da semana (onde segunda-feira = 0 e sexta-feira = 4).
- **Multicolinearidade:** O mapa também expõe relações entre as próprias *features*, como a forte correlação negativa entre `dia_semana` e `dia_semana_cos` (-0.97). Essa compreensão é vital para a escolha de algoritmos, pois modelos baseados em árvores, como os utilizados neste estudo, são inerentemente robustos a problemas de multicolinearidade.

Essa análise visual mostrou a relevância das *features* selecionadas e, também, forneceu um entendimento mais profundo da dinâmica dos dados, orientando a construção de um modelo preditivo mais preciso e interpretável.

3.3 Desenvolvimento e Treinamento do Sistema Preditivo

Para garantir a escolha da solução preditiva mais robusta e precisa, a metodologia empregou uma abordagem de modelagem competitiva, cujo fluxo de trabalho está ilustrado na Figura 6. O processo foi desenhado para simular o desafio operacional real, desde a preparação dos dados até a validação final do modelo.

O ponto de partida foram os **Dados Históricos Processados**, um conjunto de 69 dias de operação já agregados e enriquecidos com *features*. Este conjunto foi submetido a uma **Divisão Estratégica**, separando os 14 dias mais recentes como **Conjunto de Teste Final (Hold-Out)**, dados que o modelo nunca veria durante o treinamento, e os 55 dias restantes como **Conjunto de Treino/Validação**.

Este último conjunto alimentou a **Fase de Modelagem Competitiva**, que consistiu em três etapas sequenciais: um **Benchmark de Modelos** base, a **Otimização de Hiperparâmetros** dos melhores candidatos com a biblioteca *Optuna*, e a **Avaliação de Ensembles** avançados. O resultado desta fase foi a **Seleção do Modelo Campeão**, a arquitetura “Campeão Híbrido”.

Finalmente, na etapa de **Validação Final**, o modelo campeão foi treinado com todos os 55 dias do conjunto de treino e avaliado uma única vez no **Conjunto de Teste Final**, provando sua eficácia em prever a demanda em um cenário futuro desconhecido.




Figura 6 - Fluxograma da Metodologia de Desenvolvimento e Validação do Modelo

Os modelos base foram selecionados para abranger diferentes abordagens de aprendizado de máquina, garantindo diversidade nas estratégias de previsão:

- **Modelos baseados em Árvores de Decisão (*Gradient Boosting, XGBoost, LightGBM, CatBoost, RandomForest, ExtraTrees*):** Escolhidos por sua alta performance em dados tabulares e capacidade de capturar interações complexas e não-lineares, sendo amplamente citados na literatura como estado da arte para problemas de previsão (Chaudhari et al., 2025).
- **Modelos Lineares (*ElasticNet, Ridge*):** Incluídos para fornecer uma perspectiva linear e servir como um baseline robusto.
- **Modelos baseados em Distância (KNN):** Utilizados por sua lógica de decisão distinta, que analisa a proximidade dos dados em vez de regras hierárquicas.

Além dos modelos individuais, três técnicas avançadas de *ensemble learning* foram implementadas para potencializar a acurácia final, uma estratégia validada para otimizar a precisão em problemas complexos (Kuhl et al., 2021; Mohaiminul et al., 2024):

- **Modelo Híbrido Residual:** Uma arquitetura customizada, desenvolvida neste estudo, que combina um modelo linear (*Ridge*) para capturar a tendência principal dos dados, e um modelo de árvore (*ExtraTrees*) que é treinado especificamente para aprender e corrigir os erros (resíduos) do modelo linear.
- **Voting Ensemble (Comitê Ponderado):** Esta técnica agrega as previsões de múltiplos modelos especialistas (KNN, *ExtraTrees*, *Ridge*, *CatBoost*) através de uma votação ponderada, buscando um “conselho de especialistas” que equilibra performance e diversidade.
- **Custom Stacking Ensemble (Empilhamento de Modelos):** Uma abordagem em que um meta-modelo (*Ridge Regression*) é treinado para aprender a melhor forma de combinar as previsões *out-of-fold* dos modelos base. Esta técnica permite ao *Stacking* aprender os padrões de erro de cada modelo e ponderar suas “opiniões” de forma inteligente.

O processo de validação foi desenhado para simular o desafio operacional real: prever a demanda para um dia futuro desconhecido. Para isso, os 69 dias de dados históricos foram divididos da seguinte forma, uma prática comum para evitar otimismo nos resultados e garantir a robustez do modelo (Tripathi et al., 2021):

- **Conjunto de Teste Final (Hold-Out):** Os 14 dias mais recentes com demanda representativa foram completamente separados para uma única avaliação final, simulando a operação em um período futuro.

Conjunto de Treino e Validação: Os 55 dias restantes foram utilizados para treinar os modelos e realizar a validação cruzada temporal (*TimeSeriesSplit*), uma técnica essencial para avaliar modelos em dados sequenciais, pois garante que o treinamento seja sempre feito com dados passados para prever o futuro, evitando vazamento de informações.

4 Análise e Discussão dos Resultados

A avaliação do sistema preditivo foi conduzida com o objetivo de validar sua eficácia como ferramenta de apoio à decisão. Os resultados quantitativos, obtidos a partir da etapa de validação, e a aplicação prática do modelo no cenário de teste final (*hold-out*) são apresentados e discutidos a seguir.

4.1 Desempenho dos Modelos Preditivos

Para identificar o algoritmo mais eficaz, foi realizada uma avaliação comparativa do comitê de 10 modelos base e 3 arquiteturas de *ensemble*. O desempenho foi mensurado utilizando métricas padrão para regressão, conforme validado na literatura (Chaudhari et al., 2025). O *benchmark* inicial (Figuras 7, 8 e 9) destacam o Modelo Híbrido como a arquitetura mais promissora.




Figura 7 - Benchmark dos Modelos por Coeficiente de Determinação (R^2)

O benchmark inicial do comitê de modelos foi realizado para identificar as arquiteturas mais promissoras. A Figura 7, que compara o Coeficiente de Determinação (R^2) de cada modelo, destaca claramente a superioridade do Modelo Híbrido. Com um R^2 de 42,40%, ele demonstrou um poder explicativo consideravelmente maior que os demais modelos base, consolidando-se como o principal candidato para a fase de otimização.



Figura 8 - Benchmark de Modelos por Erro Médio Absoluto (MAE)

A Figura 8 complementa a análise ao comparar o Erro Médio Absoluto (MAE) das três arquiteturas finalistas. A imagem ilustra que o Campeão Híbrido obteve o menor erro médio (13.05 refeições), reforçando sua capacidade de manter um erro baixo de forma consistente e superando as abordagens de ensemble mais tradicionais.




Figura 9 - Benchmark de Modelos por Coeficiente de Determinação (R^2)

O Coeficiente de Determinação (R^2), ilustrado na Figura 9, mede a proporção da variância na demanda que cada modelo consegue explicar. O Campeão Híbrido novamente alcançou o melhor resultado, com um R^2 de 49.73%, significando que o modelo explica quase 50% da variabilidade dos dados — um indicador de forte poder preditivo para um problema com alta volatilidade.

Após uma fase de otimização de hiperparâmetros com *Optuna*, as três arquiteturas de *ensemble* foram comparadas. A Tabela 1 consolida os resultados da validação cruzada, confirmando a superioridade do modelo Campeão Híbrido.

Tabela 1 - Comparativo de Desempenho dos Ensembles Finais (Validação Cruzada)

	MAE	RMSE	R2
Campeao_Hibrido	13.047825	15.617246	0.497282
<i>CustomStacking</i>	14.083890	17.336900	0.397241
<i>VotingRegressor</i>	14.260796	16.975271	0.423900

A análise das figuras 8 e 9 e da tabela 1, que representam o erro médio esperado em número de refeições, revela que o Modelo Híbrido (Campeão Otimizado) obteve o melhor desempenho, com um MAE de 13.05 refeições. Este resultado demonstra a capacidade do modelo de manter um erro médio baixo de forma consistente, superando significativamente os demais algoritmos testados. Similarmente, para o RMSE (Raiz do Erro Quadrático Médio), o Modelo Híbrido também se destacou com o menor valor de 15.62, indicando a maior precisão geral entre os competidores. Quanto ao Coeficiente de Determinação (R^2), o Modelo Híbrido novamente alcançou o melhor resultado, com um R^2 de 0.497, significando que o modelo explica aproximadamente 50% da variabilidade dos dados, um indicador de forte poder preditivo.

4.2 Análise da Predição no Cenário de Teste Final (Hold-Out)

A validação mais crítica do sistema consistiu em testar o modelo campeão em um conjunto de hold-out de 14 dias, um período que ele nunca havia visto durante o treinamento. Neste cenário, que simula a operação real, a solução alcançou um Erro Médio Absoluto (MAE) de 10.68 refeições e um Coeficiente de Determinação (R^2) de 64.37%. Este resultado é uma forte evidência da acurácia e da confiabilidade do sistema para o planejamento operacional. A Figura 10 ilustra a alta aderência das previsões do modelo à demanda real durante este período de teste.




Figura 10 - Desempenho do Modelo Campeão no Teste Final (Hold-Out)

Para o período em questão, o modelo demonstrou um Erro Médio Absoluto (MAE) de 10.68 refeições, um RMSE de 14.61 e um Coeficiente de Determinação (R^2) de 64.37%. Este resultado, com um erro baixo e uma capacidade de explicar quase dois terços da variação da demanda, é uma forte evidência da acurácia e da confiabilidade do sistema para o planejamento operacional.

A Figura 10 ilustra essa alta aderência, comparando a demanda real (linha contínua azul) com as previsões do modelo (linha tracejada vermelha). É notável a capacidade do sistema em capturar tanto os picos quanto os vales da demanda ao longo do período de teste, demonstrando que a tecnologia pode, de fato, fornecer estimativas muito próximas da realidade, mesmo em um cenário de alta volatilidade.

4.3 Análise de Impacto Prático e Financeiro (Backtesting)

A principal contribuição deste sistema reside em sua capacidade de superar a incerteza inerente ao planejamento baseado apenas em reservas. Como demonstrado na Figura 1, a variabilidade entre as reservas e a demanda real é substancial. Utilizar o número de reservas como único preditor resultaria em erros diários significativos, em alguns dias, uma falta de mais de 50 refeições; em outros, um excedente de mais de 40. Essa discrepância reflete um desafio universal em serviços de alimentação, onde a intenção do consumidor nem sempre se traduz em consumo efetivo. Trata-se de um problema análogo enfrentado em indústrias como a hoteleira, que lida com a imprevisibilidade no número de hóspedes (Shiji Insights, 2025), e a aérea, que gerencia a complexidade logística da preparação antecipada de refeições (Kanwal et al., 2025).

A eficácia do sistema de IA desenvolvido é comprovada ao comparar diretamente a precisão do modelo com a variabilidade das reservas. Enquanto o planejamento baseado em reservas apresenta desvios que frequentemente ultrapassam 30/40 refeições, o modelo Campeão (Modelo Híbrido) alcançou um erro médio (MAE) de 10.68 refeições e um erro quadrático médio (RMSE) de 14.61 refeições no conjunto de testes. A Figura 10 ilustra essa superioridade: a linha de previsão (vermelha) se ajusta de forma muito mais consistente à demanda real (azul) do que a linha de reservas (apresentada na Figura 1), suavizando os picos e vales extremos da intenção do consumidor.

Neste produto tecnológico é feita uma otimização ao traduzir a previsão em uma recomendação acionável. A Figura 11 ilustra a “Sugestão de Preparo”, que incorpora a precisão do modelo a regras de negócio inteligentes, com margem de segurança e limite de reservas, oferecendo à gestão uma ferramenta de apoio para o planejamento.




Figura 11 - Visualização da Saída do Sistema: Previsões e Sugestão de Preparo

A análise da Figura 11 revela a inteligência do sistema e sua contribuição direta para a gestão. O gráfico compara o número de Reservas Efetuadas (linha azul) com a Previsão Otimizada (linha vermelha) para os dias futuros, evidenciando a aplicação das regras de negócio:

- **Evitando a Superprodução:** Para os dias 16 e 17/06, a previsão otimizada é consistentemente menor que o número de reservas. O sistema identifica que, apesar do alto número de reservas, a demanda real esperada é menor, recomendando uma produção mais enxuta para evitar o desperdício.
- **Mitigando o Risco:** No dia 20/06, o sistema prevê uma demanda muito baixa (48 refeições), mesmo com 86 reservas. Esta previsão conservadora, provavelmente baseada em padrões históricos (ex: proximidade de feriados), evita um desperdício massivo que ocorreria ao seguir o método reativo, provando ser uma ferramenta de mitigação de risco.

Essa funcionalidade transforma a gestão de reativa para proativa. Com essas informações disponíveis com semanas de antecedência, a empresa parceira pode otimizar a compra de insumos e reduzir drasticamente as perdas, resolvendo o gargalo logístico que motivou este estudo.

Para complementar esta análise e demonstrar o impacto financeiro direto da solução, apresentamos o resumo do desempenho simulado da estratégia “IA (Máxima)” em comparação com a linha de base “Reservas (Base)” no período de 55 dias de *backtesting*:

Tabela 2 - Resumo do Desempenho das Estratégias no Backtesting

Estratégia	Total de Sobras	Total de Faltas	Custo Total Estimado
IA (Máxima)	421	429	R\$ 22.203,44
Reservas (Base)	847	409	R\$ 28.904,40

A estratégia “IA (Máxima)” demonstrou uma redução significativa no custo total estimado (R\$ 22.203,44 vs. R\$ 28.904,40) mesmo que isso tenha implicado em um ligeiro aumento nas faltas em comparação com a linha de base. No entanto, a redução de sobras foi substancialmente maior (421 pratos vs. 847 pratos), o que, no contexto de um refeitório, é frequentemente mais desejável para evitar desperdício de alimentos perecíveis.

Para uma visão mais granular do desempenho diário das estratégias, o placar de vitórias diárias é apresentado na Figura 12:




Figura 12 - Placar de Vitórias Diárias

O placar de vitórias diárias reforça a superioridade da estratégia de IA, com 21 dias onde a IA venceu por ter menos sobras, e 30 dias de empate (onde ambas as estratégias tiveram o mesmo custo total). A linha de base venceu em apenas 4 dias por ter menos faltas. Isso indica que a IA, ao otimizar o balanço entre sobras e faltas, conseguiu um desempenho mais consistente e vantajoso na maioria dos dias.

4.4 Produto Final: Plano de Ação para a Gestão

Um modelo preditivo, por si só, não resolve o problema de gestão. A etapa final da metodologia foi traduzir a previsão estatística em uma recomendação prática e acionável. Para isso, foram implementadas duas regras de negócio no sistema:

- **Margem de Segurança Inteligente:** Com base na análise dos erros históricos do modelo campeão, foi calculada uma margem de segurança de aproximadamente 11 refeições (MAE de 10.68) para ser adicionada à previsão. Esta margem, que pode ser adaptativa por dia da semana, visa mitigar o risco de subestimação, que é mais crítico para a operação do que a superestimação.
- **Limite por Reservas:** A recomendação final de preparo (Sugestão de Preparo) foi definida como o menor valor entre a previsão + margem e o total de reservas do dia. Esta regra garante que o sistema nunca sugira preparar mais refeições do que o número de pessoas que já se comprometeram a consumir, evitando o desperdício evidente. Esta metodologia resultou em um produto tecnológico que não apenas prevê um número, mas prescreve uma ação de gestão informada e segura.




Figura 13 - Visualização da Saída do Sistema: Previsões e Sugestão de Preparo

A Figura 13 ilustra a saída final do sistema: um plano de ação diário que fornece à gestão uma visão completa para a tomada de decisão. O gráfico apresenta:

- **Reservas Efetuadas (linha azul):** O número de refeições já confirmadas, servindo como uma linha de base.
- **Previsão Central (IA) (linha pontilhada):** A estimativa mais provável de demanda, calculada pelo modelo campeão.

- **Faixa de Incerteza (área sombreada):** O intervalo entre a Sugestão Mínima (IA) e a Sugestão Máxima (IA). Esta faixa representa a variabilidade esperada da previsão, calculada com base na margem de segurança adaptativa.

Esta visualização transforma a gestão de reativa para proativa. Em vez de um único número, o sistema fornece um cenário completo de risco. Para o dia 20/06, por exemplo, o modelo prevê uma demanda central baixa, mas a faixa de incerteza indica um risco considerável. Essa ferramenta permite à gestão tomar decisões informadas, como alinhar a produção à previsão central para economizar, ou produzir mais perto da sugestão máxima para garantir o nível de serviço, mesmo diante de eventos atípicos.

5 Considerações Finais e Contribuições

Este estudo detalhou o desenvolvimento de um produto tecnológico destinado a melhorar a gestão do sistema produtivo de refeições de uma instituição de ensino superior. A intervenção proposta, materializada em um sistema de previsão de demanda baseado em IA, demonstrou ser uma ferramenta eficaz para otimizar o planejamento de suprimentos, mitigar o desperdício de alimentos e, conseqüentemente, aprimorar a eficiência operacional e a sustentabilidade da instituição.

O objetivo inicial de criar um mecanismo que fornecesse previsões acuradas com maior antecedência foi alcançado. Os resultados da validação do modelo, que culminaram em um erro médio absoluto (MAE) de aproximadamente 10.68 refeições e um coeficiente de determinação (R^2) de 64.37% no teste final, validam a robustez da metodologia empregada. Mais importante que a precisão estatística, o sistema incorpora uma lógica de negócio com margem de segurança inteligente e limite por reservas que transforma a previsão em uma recomendação de preparo diretamente aplicável pela gestão, configurando-se como um autêntico sistema de apoio à decisão.

Contribuições para a Gestão e o Setor Produtivo:

A principal contribuição deste trabalho é a apresentação de uma solução tecnológica replicável para um desafio comum em diversas organizações: a gestão de recursos em cenários de demanda flutuante. Para a instituição analisada e sua empresa parceira, a implementação deste sistema representa:

1. **Otimização da Cadeia de Suprimentos:** A capacidade de prever a demanda com semanas de antecedência resolve o gargalo logístico, permitindo à empresa fornecedora um planejamento de compras mais eficiente, com potencial redução de custos e melhoria na qualidade dos insumos.
2. **Redução de Custos e Desperdício:** Ao minimizar a superprodução, o sistema contribui diretamente para a redução de despesas com alimentos não consumidos e custos de descarte, aliviando o orçamento da instituição.
3. **Promoção da Sustentabilidade:** Alinhado aos Objetivos de Desenvolvimento Sustentável (ODS), o projeto demonstra um caminho prático para que instituições de ensino incorporem a sustentabilidade em suas operações diárias, servindo de exemplo para a comunidade acadêmica.

Limitações e Propostas para Trabalhos Futuros:

A principal limitação deste estudo reside no volume de dados históricos disponíveis, que abrangeu um período de aproximadamente quatro meses. Embora os resultados sejam

promissores, um histórico mais longo permitiria capturar sazonalidades anuais e aumentar ainda mais a confiabilidade do modelo.

Como propostas para a evolução deste trabalho técnico-profissional, destacam-se:

1. **Implantação em Produção e Monitoramento Contínuo:** O próximo passo natural é a implementação do sistema na rotina da gestão do refeitório, com o re-treinamento periódico do modelo à medida que novos dados são coletados.
2. **Desenvolvimento de uma Interface de Usuário (Dashboard):** A criação de um painel de controle interativo para que os gestores possam visualizar as previsões e ajustar parâmetros, tornando a ferramenta ainda mais acessível.
3. **Integração via API:** Conforme apontado pela literatura (Shiji Insights, 2025), a integração do sistema de previsão com outros sistemas da instituição (como sistemas de compra ou controle de estoque) via API (*Application Programming Interface*) representaria um avanço significativo na automação dos processos de gestão.
4. **Escalabilidade:** O modelo e a metodologia aqui descritos são escaláveis e poderiam ser adaptados para outros campi ou outras instituições de ensino que enfrentam desafios similares.

Em suma, este trabalho evidencia como a aplicação de tecnologias digitais, fundamentada em uma metodologia científica, pode gerar soluções para problemas da gestão em sistemas produtivos, fortalecendo a sinergia entre academia e setor produtivo e contribuindo para a formação de profissionais capazes de liderar a inovação em suas organizações.

6 Referências

- Chaudhari, M. A., Phapale, A., Gagare, P., Kardile, T., & Phatangare, A. (2025). Forecasting and Modelling of Food Demand Supply Chain using Machine Learning. *International Journal of Innovative Research in Multidisciplinary Physical Sciences (IJIRMPs)*, 13(2), 1-16. <https://www.ijirmps.org/papers/2025/2/232389.pdf>
- Clark, M., Basavaraja, D., Kanavikar, J., & Donnelly, P. (2025). Exploring the potential of AI-driven food waste management strategies used in the hospitality industry for application in household settings. *Frontiers in Artificial Intelligence*, 6, 1429477. <https://doi.org/10.3389/frai.2024.1429477>
- Kanwal, N., Zhang, M., Zeb, M., Hussain, M., & Wang, D. (2025). Revolutionizing food safety in the airline industry: AI-powered smart solutions. *Trends in Food Science & Technology*, 159, 104970. <https://doi.org/10.1016/j.tifs.2025.104970>
- Kuhl, N., Hirt, R., Baier, L., Schmitz, B., & Satzger, G. (2021). How to Conduct Rigorous Supervised Machine Learning in Information Systems Research: The Supervised Machine Learning Report Card. *Communications of the Association for Information Systems*, 48.
- Leng, J., Wang, D., Shen, B., Li, Z., Liu, Q., Chen, X., & Liu, C. (2024). Unlocking the power of industrial artificial intelligence towards Industry 5.0: Insights, pathways, and challenges. *Journal of Manufacturing Systems*, 72, 103-116. <https://doi.org/10.1016/j.jmsy.2024.01.001>
- Mohaiminul, M., Khan, M. A. R., & Rahman, M. M. (2024). A Review on Large Language Models: Architectures, Applications, Taxonomies, Open Issues and Challenges. *IEEE Access*.

Olawale, R. A., Olawumi, M. A., & Oladapo, B. I. (2025). Sustainable farming with machine learning solutions for minimizing food waste. *Journal of Stored Products Research*, 112, 102611. <https://doi.org/10.1016/j.jspr.2025.102611>

Onyeaka, H., Akinsemolu, A., Miri, T., Nnaji, N. D., Duan, K., Pang, G., Tamasiga, P., Khalid, S., Al-Sharify, Z. T., & Ugwa, C. (2025). Artificial Intelligence in Food System: Innovative Approach to Minimizing Food Spoilage and Food Waste. *Journal of Agriculture and Food Research*, 21, 101895. <https://doi.org/10.1016/j.jafr.2025.101895>

Rajendran, B., Babu, M., & Anandhabalaji, V. (2025). A predictive modelling approach to decoding consumer intention for adopting energy-efficient technologies in food supply chains. *Decision Analytics Journal*, 15, 100561. <https://doi.org/10.1016/j.dajour.2025.100561>

Shiji Insights. (2025). Technology's role in reducing hotel food waste. Shiji Group. <https://insights.shijigroup.com/technologys-role-in-reducing-hotel-food-waste/>

Tripathi, S., et al. (2021). Ensuring the Robustness and Reliability of Data-Driven Knowledge Discovery Models in Production and Manufacturing. *Frontiers in Artificial Intelligence*, 4, 73. <https://doi.org/10.3389/frai.2021.721471>

Xu, Z., et al. (2021). Data science: connotation, methods, technologies, and development. *Data Science and Management*, 4(2), 79-88. <https://doi.org/10.1016/j.dsm.2021.08.001>