

Sustentabilidade na Mesa: redução do desperdício alimentar em uma instituição de ensino com previsão de demanda por aprendizado de máquina (Relato Técnico)

Autores

Michel Silva de Souza ¹

Rafael Nobre Orsi²

Resumo

O desperdício de alimentos é um problema global significativo que compromete a segurança alimentar e a sustentabilidade do planeta. No Brasil, a situação é agravada pela desigualdade social e pela insegurança alimentar, tornando a questão ainda mais crítica. Este estudo se concentra no desperdício de alimentos em uma instituição de ensino, abordando a necessidade urgente de reduzir o desperdício e otimizar a gestão de recursos disponíveis. Para enfrentar esse desafio, foi proposto e implementado um sistema de previsão de demanda de refeições, utilizando técnicas de Machine Learning, com ênfase na regressão linear. O desenvolvimento do sistema incluiu a criação de um formulário online para que os alunos pudessem reservar suas refeições antecipadamente, permitindo uma coleta organizada de dados relevantes. Esses dados foram posteriormente tratados em planilhas do Google, assegurando sua integridade e prontidão para análise. Para facilitar a visualização e a interpretação das informações, foram criados *dashboards* interativos que permitiram uma análise mais intuitiva do consumo de refeições. O desenvolvimento dos modelos preditivos foi realizado utilizando Python e suas bibliotecas, como Pandas, Numpy, Matplotlib e Scikit-learn, proporcionando uma base sólida para a construção de previsões confiáveis. Os resultados obtidos mostraram que a regressão linear se destacou como uma ferramenta promissora para prever a demanda por refeições, demonstrando capacidade de identificar padrões relevantes. No entanto, a análise dos dados também revelou a necessidade de aprimorar a precisão das previsões. Para isso, é fundamental incluir variáveis adicionais, como o histórico de presenças dos alunos, previsões climáticas, períodos de provas e o calendário escolar, fatores que podem influenciar significativamente a demanda. As lições aprendidas com a implementação deste projeto não apenas ressaltam a importância da qualidade e da consistência dos dados, mas também enfatizam a necessidade de um monitoramento constante e de colaborações entre diferentes setores da instituição. Essa experiência impulsiona a busca por aprimoramentos contínuos e o investimento em tecnologias e ferramentas que promovam uma gestão de recursos mais responsável e sustentável nas instituições de ensino, contribuindo assim para a redução do desperdício de alimentos e para a promoção de um ambiente educacional mais eficiente e equitativo.

Palavras-chave: Desperdício de alimentos. Previsão de demanda. Machine learning. Regressão linear. Sustentabilidade.

Sustainability at the Table: reducing food waste in an educational institution with a predicted demand for machine learning (Technical Report)

Abstract

Food waste is a significant global issue that compromises food security and the sustainability of our planet. In Brazil, the situation is aggravated by social inequality and food insecurity, making the

¹ Mestrando no Programa de Mestrado Profissional em Gestão e Tecnologia em Sistemas Produtivos no Centro Estadual de Educação Tecnológica Paula Souza – CEETEPS. Orcid: 0009-0003-3951-202X

² Doutorado em Engenharia Elétrica pelo Centro Universitário FEI, docente e diretor da Escola Técnica – ETEC São Paulo no Centro Estadual de Educação Tecnológica Paula Souza – CEETEPS. Orcid: 0000-0003-4719-0131

problem even more critical. This study focuses on food waste in an educational institution, addressing the urgent need to reduce waste and optimize the management of available resources. To address this challenge, a meal demand forecasting system was proposed and implemented using Machine Learning techniques, with an emphasis on linear regression. The system's development included the creation of an online form for students to reserve their meals in advance, enabling the organized collection of relevant data. This data was then processed in Google Sheets, ensuring its integrity and readiness for analysis. To facilitate the visualization and interpretation of the information, interactive dashboards were created, allowing for a more intuitive analysis of meal consumption. The development of the predictive models was carried out using Python and its libraries, such as Pandas, Numpy, Matplotlib, and Scikit-learn, providing a solid foundation for constructing reliable predictions. The results obtained showed that linear regression stood out as a promising tool for predicting meal demand, demonstrating an ability to identify relevant patterns. However, the data analysis also revealed the need to improve the accuracy of predictions. To this end, it is essential to include additional variables, such as student attendance history, weather forecasts, exam periods, and the school calendar, factors that can significantly influence demand. The lessons learned from implementing this project not only highlight the importance of data quality and consistency but also emphasize the need for constant monitoring and collaborations between different sectors of the institution. This experience drives the pursuit of continuous improvements and investment in technologies and tools that promote more responsible and sustainable resource management in educational institutions, thereby contributing to the reduction of food waste and fostering a more efficient and equitable educational environment.

Keywords: Food waste. Demand forecasting. Machine learning. Linear regression. Sustainability.

INTRODUÇÃO

O desperdício de alimentos compromete a capacidade de alimentar a população mundial de forma sustentável, representando um desafio global com impactos diretos na segurança alimentar (FAO, 2021). Estima-se que cerca de um terço de toda a comida produzida para consumo humano seja desperdiçada, o que corresponde a aproximadamente a um terço de todos os alimentos produzidos (FAO, 2021). Estima-se que foram desperdiçados cerca de cerca de 1,05 bilhão de toneladas de alimentos em 2022 (FAO, 2024).

O impacto desse desperdício vai além do aspecto econômico. Em um país com histórico de desigualdade social, o problema da fome e da insegurança alimentar é uma realidade (BEZERRA, et. al., 2019). Por outro lado, a lei nº 11.346 garante o direito humano à alimentação adequada e reconhece a alimentação como um direito fundamental e um dever do Estado. Diante desse cenário, o desperdício de alimentos torna-se uma questão de justiça social, impactando diretamente o bem-estar da população e a garantia de acesso a uma dieta saudável e nutritiva (BRASIL, 2006).

O presente estudo aborda a problemática do desperdício de alimentos no contexto específico de uma instituição de ensino. O problema se intensifica quando é analisado o desperdício em refeitórios, cujos recursos são desperdiçados em grandes quantidades. Em especial, este estudo se concentra no Instituto Federal de São Paulo (IFSP) – Campus Itaquaquecetuba, onde o desperdício de refeições representa perdas significativas, de forma a

afetar diretamente o orçamento da instituição e o acesso dos alunos à alimentação. A busca por soluções eficientes e inovadoras para reduzir o desperdício em refeitórios é crucial para garantir a sustentabilidade orçamentária da instituição de ensino e o acesso à alimentação de qualidade para todos os alunos.

1.1 Objetivo

Este relato técnico tem como objetivo desenvolver e implementar um sistema de previsão de demanda de refeições no IFSP – Campus Itaquaquecetuba, utilizando técnicas de regressão linear, com base no histórico de reservas e consumo de refeições.

2 Análise do Problema e Solução Proposta

O desperdício de alimentos é um problema global com impactos socioeconômicos e ambientais significativos. No Brasil, a perda de alimentos ao longo da cadeia de produção, processamento, distribuição e consumo é um desafio crítico, agravado pela insegurança alimentar e a necessidade de garantir o direito à alimentação adequada para todos (SOUZA; PEREIRA, 2021).

A presente análise se concentra no problema do desperdício de alimentos no IFSP – Campus Itaquaquecetuba, especificamente no contexto do refeitório. Em 2023, o campus registrou um índice de desperdício de aproximadamente 30% das refeições preparadas, o que corresponde a um custo de R\$172.500,00 de um montante de R\$575.000,00 que é destinado a alimentação e é equivalente a 37% do orçamento total da instituição.

A legislação brasileira - bem como a EC 64, uma alteração na Constituição Federal que garante o direito humano à alimentação adequada, promulgada em 2010 e a PNSAN, instituída pela Lei Orgânica de Segurança Alimentar e Nutricional (LOSAN - Lei nº 10.633/2003), define diretrizes para a promoção da segurança alimentar e nutricional no Brasil - incentiva a redução do desperdício e o aproveitamento integral dos alimentos. No entanto, a proibição da doação de sobras de alimentos impede a utilização de alimentos ainda em condições de consumo, intensificando o problema.

Nesse contexto, é fundamental analisar as diferentes etapas da cadeia de produção onde ocorrem perdas e desperdícios no contexto brasileiro. No entanto, este estudo se concentra no desperdício na etapa de consumo, para o referido campus.

Para tentar solucionar esse problema, foi proposta a implementação de um sistema de previsão de demanda de refeições utilizando técnicas de Aprendizado de Máquina, especificamente a técnica de regressão linear. Essa abordagem permite identificar padrões em

dados históricos e gerar previsões mais precisas do que métodos tradicionais (MONTGOMERY; PECK; VINING, 2021).

Com essa abordagem, espera-se aumentar a eficiência dos gastos com alimentação, por meio da redução da taxa de desperdício de alimentos, para viabilizar uma melhor alocação dos recursos disponíveis no IFSP – Campus Itaquaquecetuba, contribuindo para a sustentabilidade da instituição e o bem-estar dos alunos.

2.1 Implementação e Resultados

A implementação da proposta para reduzir o desperdício de alimentos foi utilizada com um conjunto de ferramentas integradas. O uso de ferramentas como o Google Workspace e bibliotecas da linguagem Python viabilizou a implementação, permitindo um monitoramento contínuo e melhorias na gestão das refeições no campus.

Para implementar a solução que visa reduzir o desperdício de alimentos no IFSP, foram propostas as seguintes etapas, cada uma desempenhando um papel crucial no processo de coleta, análise, visualização e predição de dados.

2.2 Coleta de Dados

Foi implementado um sistema online, utilizando o formulário do Google, para que os alunos reservassem suas refeições com antecedência. A ferramenta era responsável por coletar dados como: nome do aluno; número da matrícula; turma; e data da reserva.

Os dados de reserva foram integrados a uma planilha do Google, garantindo um registro centralizado e organizado das informações.

2.3 Tratamento e Armazenamento dos Dados


Com a ajuda do Google Planilhas e do recurso de programação Apps Script, os dados coletados foram tratados e organizados, incluindo a remoção de entradas duplicadas e o preenchimento de valores ausentes, assegurando que as informações estivessem prontas para análises posteriores.

2.4 Visualização e Análise de Dados

Para entender melhor as tendências e padrões nos dados, foi utilizado o Looker Studio. Esta ferramenta permitiu a criação de *dashboards* interativos que facilitam a visualização das reservas e do consumo de refeições, possibilitando uma análise mais intuitiva e acessível. O *dashboard* exibe informações como:

- O número de reservas por dia, por turma e por semana.
- A taxa de consumo (porcentagem de alunos que reservaram e consumiram a refeição).
- A previsão de demanda para os próximos dias.
- Os dias com maior desperdício e as causas prováveis.

Figura 1: *Dashboard* dos Dados das Refeições



Fonte: Elaboração própria dos autores (2024).

3 Desenvolvimento de Modelos Preditivos

O desenvolvimento dos modelos preditivos para estimar a demanda de refeições no IFSP – Campus Itaquaquecetuba foi realizado utilizando o Google Colab como plataforma de desenvolvimento, permitindo a execução de códigos em Python com as bibliotecas Pandas, Numpy, Matplotlib e Scikit-learn. A biblioteca Pandas foi crucial para manipular e organizar os dados, incluindo a leitura dos arquivos CSV, o agrupamento dos dados por data, o tratamento de valores ausentes e a criação de novas variáveis explicativas. Já a biblioteca Numpy foi utilizada para operações matemáticas e transformações de dados, como o tratamento de valores ausentes e a conversão de dados para o formato adequado para os modelos de regressão. A biblioteca Matplotlib, por sua vez, foi empregada para a visualização de dados, gerando gráficos que ilustram a correlação entre as variáveis, como a demanda de refeições em relação ao dia da semana e eventos no campus. E, por fim, a biblioteca Scikit-learn foi utilizada para o desenvolvimento dos modelos de regressão linear, incluindo a implementação dos modelos de regressão linear, Ridge, Ridge com Validação Cruzada, Lasso e Lasso com Validação Cruzada.

Com os dados pré-processados e organizados com Pandas, foram implementados e avaliados os seguintes modelos de regressão: o modelo de regressão linear, treinado com os dados de treinamento e ajustado aos dados de teste, utilizando a função `LinearRegression()` da biblioteca Scikit-learn; a regressão Ridge, uma variante da regressão linear com um termo de regularização para evitar overfitting, implementada com a função `Ridge()` da biblioteca Scikit-learn; a regressão Ridge com Validação Cruzada, que otimiza o parâmetro de regularização do modelo de regressão Ridge por meio da função `RidgeCV()`; a regressão Lasso, outra variante da regressão linear com termo de regularização e capacidade de selecionar as variáveis mais relevantes, implementada com a função `Lasso()` da biblioteca Scikit-learn; e a regressão Lasso com Validação Cruzada, que otimiza o parâmetro de regularização do modelo Lasso por meio da função `LassoCV()`.

Para avaliar a performance dos modelos, foram utilizadas as seguintes métricas: o Mean Squared Error (MSE), que mede a média dos erros quadrados entre as predições e os valores reais; o Mean Absolute Error (MAE), que mede a média dos erros absolutos entre as predições e os valores reais; e o R2-score, que indica a proporção da variância do target que é explicada pelo modelo.

Em resumo, as bibliotecas Python e as técnicas de regressão linear implementadas no Google Colab se mostraram ferramentas importantes para a construção dos modelos preditivos, contribuindo para a análise da demanda de refeições no IFSP - Campus Itaquaquecetuba. Os

modelos, apesar de ainda apresentarem certa subestimação da demanda, representam um passo importante na direção da otimização da gestão de recursos e da redução do desperdício de alimentos.

3.1 Resultados dos Modelos Preditivos

O projeto utilizou a regressão linear como técnica principal para prever a taxa de consumo de refeições, considerando variáveis como o dia da semana, o número de reservas realizadas e o histórico de consumo anterior. A regressão linear, por meio da identificação e modelagem da relação linear entre essas variáveis preditoras (features) e o resultado que se desejava estimar (a taxa de consumo), permitiu desenvolver um modelo preditivo capaz de antecipar o comportamento dos alunos em relação ao consumo de refeições.

A partir desta abordagem foi gerado um conjunto de dados para otimizar a gestão alimentar e reduzir o desperdício, simplificando a visualização dos dados em uma equação linear, facilitando a interpretação e a tomada de decisões. Os resultados obtidos demonstram que a regressão linear se mostrou eficaz na previsão da demanda por refeições, contribuindo para a redução do desperdício de alimentos no campus.

Tabela 1: Predição para o dia 05/12/2023

<u>Reservas</u>	<u>Refeições Servidas</u>	<u>Desperdício</u>
136	121	15
<u>Modelo</u>	<u>Nome do Modelo</u>	<u>Predição</u>
1	Linear Regression	106
2	Ridge	106
3	Ridge CV	106
4	Lasso	107
5	Lasso CV	106

Fonte: Elaboração própria dos autores (2024).

A Tabela 1 apresenta os resultados de um modelo de predição de demanda de refeições para o dia 05/12/2023. Foram utilizadas 5 técnicas de Aprendizado de Máquina para a predição: Regressão Linear, Ridge, Ridge com Validação Cruzada (CV), Lasso e Lasso com Validação Cruzada (CV). As predições foram comparadas com o número real de refeições servidas, considerando também o número de reservas feitas para o dia.

Observando os dados da Tabela 1, pode-se notar que o número de reservas foi de 136, enquanto o número de refeições servidas foi de 121. Isso indica um desperdício de 15 refeições.

Ao analisar os resultados dos modelos de predição, percebemos que, em sua maioria, as predições ficaram abaixo do número de refeições servidas. A regressão linear previu 106

refeições, o Ridge previu 106, o Ridge com CV previu 106, o Lasso previu 107 e o Lasso com CV previu 106.

Em resumo, os modelos de Machine Learning testados apresentaram uma tendência a subestimar a demanda de refeições, com o número de predições variando entre 106 e 107, enquanto o número de refeições servidas foi de 121. Essa subestimação indica que, para o dia em questão, os modelos poderiam ter sido otimizados para prever uma demanda maior, o que resultaria em um menor desperdício de alimentos.

Tabela 2: Predição para o dia 06/12/2023

<u>Reservas</u>	<u>Refeições Servidas</u>	<u>Desperdício</u>
113	93	20
<u>Modelo</u>	<u>Nome do Modelo</u>	<u>Predição</u>
1	Linear Regression	93
2	Ridge	93
3	Ridge CV	93
4	Lasso	89
5	Lasso CV	92

Fonte: Elaboração própria dos autores (2024).

No dia 06/12, conforme Tabela 2, foram feitas 113 reservas, mas apenas 93 refeições foram servidas, gerando um desperdício de 20 refeições. Nos modelos de Machine learning os resultados foram distintos/diversos:

- A Regressão Linear, Ridge e Ridge com Validação Cruzada (CV) tiveram previsões precisas, prevendo 93 refeições cada, o mesmo número de refeições servidas.
- O modelo Lasso previu 89 refeições, subestimando a demanda em 4 refeições.
- O modelo Lasso com Validação Cruzada (CV) previu 92 refeições, subestimando a demanda em 1 refeição.

Comparando com os resultados do dia 05/12, os modelos de Machine Learning tiveram um desempenho melhor no dia 06/12, especialmente a Regressão Linear, Ridge e Ridge com Validação Cruzada (CV), que conseguiram prever a demanda com precisão.

Tabela 3: Predição para o dia 07/12/2023

<u>Reservas</u>	<u>Refeições Servidas</u>	<u>Desperdício</u>
113	107	6
<u>Modelo</u>	<u>Nome do Modelo</u>	<u>Predição</u>
1	Linear Regression	103
2	Ridge	103
3	Ridge CV	103
4	Lasso	103
5	Lasso CV	104

Fonte: Elaboração própria dos autores (2024).

No dia 07/12/2023, de acordo com a Tabela 3, foram realizadas 113 reservas e servidas 107 refeições, resultando em um desperdício de 6 refeições.

Os modelos de predição apresentaram resultados variados:

- Regressão Linear, Ridge, Ridge com CV e Lasso previram 103 refeições, subestimando a demanda em 4 refeições.
- Lasso com CV previu 104 refeições, subestimando a demanda em 3 refeições.

Comparando com os dias anteriores, os modelos de Machine Learning tiveram um desempenho similar, com a maioria subestimando a demanda. Apesar de algumas previsões estarem próximas ao número de refeições servidas, os modelos ainda precisam de ajustes para se tornarem mais precisos e reduzir o desperdício de alimentos.

Tabela 4: Predição para o dia 08/12/2023

<u>Reservas</u>	<u>Refeições Servidas</u>	<u>Desperdício</u>
89	62	27
<u>Modelo</u>	<u>Nome do Modelo</u>	<u>Predição</u>
1	Linear Regression	69
2	Ridge	69
3	Ridge CV	71
4	Lasso	72
5	Lasso CV	72

Fonte: Elaboração própria dos autores (2024).

No dia 08/12/2023, conforme a Tabela 4, foram feitas 89 reservas e servidas 62 refeições, resultando em um desperdício de 27 refeições.

Os modelos de predição apresentaram resultados foram distintos/diversos:

- Regressão Linear previu 69 refeições, subestimando a demanda em 7 refeições.
- Ridge previu 69 refeições, subestimando a demanda em 7 refeições.
- Ridge com CV previu 71 refeições, subestimando a demanda em 9 refeições.
- Lasso e Lasso com CV previram 72 refeições, subestimando a demanda em 10 refeições.

Comparando com os dias anteriores, os modelos de Machine Learning tiveram um desempenho pior no dia 08/12, subestimando a demanda em maior proporção. Essa diferença pode estar relacionada a fatores como a época do ano, eventos no campus ou outros fatores que influenciaram a demanda de refeições.

É importante analisar os dados e ajustar os modelos de predição para melhorar a precisão das previsões e reduzir o desperdício de alimentos.

Figura 2: Comparativo entre os Modelos de Predição

REGISTROS REAIS	MODELO 1	MODELO 2	MODELO 3	MODELO 4	MODELO 5
Refeições Reservadas	Linear Regression	Ridge	Ridge CV	Lasso	Lasso CV
451	371	371	373	377	374
SERVIDAS	DIFERENÇA				
383	12	12	10	6	9
DESPERDÍCIO					
68					

Fonte: Elaboração própria dos autores (2024).

A Figura 2 apresenta os resultados da predição de demanda de refeições para 4 dias, utilizando 5 modelos de Machine Learning: Regressão Linear, Ridge, Ridge com Validação Cruzada (CV), Lasso e Lasso com Validação Cruzada (CV). Ao analisar os dados, podemos notar que:

- **O desperdício é alto:** Em todos os dias analisados, a quantidade de refeições servidas foi menor que o número de reservas. O desperdício variou de 6 a 27 refeições por dia, evidenciando a necessidade de melhorar a precisão das previsões.
- **Predições variam:** As previsões dos modelos de Machine Learning tiveram resultados divergentes, com algumas subestimando a demanda e outras se aproximando mais do número de refeições servidas.
- **Regressão linear e Ridge com CV se destacam:** Para os 4 dias analisados, o modelo de Regressão Linear e o Ridge com Validação Cruzada (CV) apresentaram as menores diferenças entre a predição e o número real de refeições servidas.
- **Lasso e Lasso com CV tiveram desempenho similar:** Os modelos Lasso e Lasso com Validação Cruzada (CV) tiveram um desempenho similar, com uma subestimação consistente da demanda.

Uma visão completa da concepção do projeto e aplicação dos métodos de aprendizagem de máquina está disponível no link a seguir: [\[link\]](#). O código-fonte do projeto está disponível no Google Colab, permitindo a replicação do estudo e a exploração das técnicas de Machine Learning aplicadas para a previsão da demanda de refeições. A disponibilização do código facilita a compreensão da metodologia utilizada e sua aplicação em outros contextos.

Em resumo, os modelos de Machine Learning testados mostraram resultados promissores, mas ainda apresentam margem para melhorias na precisão. A análise dos dados indica que a Regressão Linear e o Ridge com Validação Cruzada (CV) se mostraram como os modelos mais precisos para esse conjunto de dados. É importante continuar a análise e o ajuste

dos modelos para aprimorar as previsões e reduzir o desperdício de alimentos no IFSP - Campus Itaquaquecetuba.


4 Lições Aprendidas

A implementação de um sistema de previsão de demanda de refeições no IFSP - Campus Itaquaquecetuba, utilizando técnicas de Machine Learning, destacou a importância da consistência e integridade dos dados para a precisão dos modelos, além da escolha adequada do modelo e do monitoramento contínuo. A colaboração entre as diferentes áreas da instituição foi essencial para o sucesso dessa iniciativa.

Embora os resultados tenham sido promissores, a análise dos dados indicou a necessidade de aprimoramentos no sistema. A inclusão de variáveis adicionais, como o histórico de presença dos alunos, previsões meteorológicas, períodos de provas e o calendário escolar, poderia aumentar a precisão das previsões e reduzir o desperdício de alimentos. Esse passo não apenas melhoraria o modelo, mas também permitiria uma análise mais abrangente e personalizada da demanda.

A análise de correlação entre as variáveis "dia da semana", "reservas", "reservas do dia anterior" e "consumo do dia anterior" revelou relações significativas conforme a Figura 3. A correlação mais forte foi entre "reservas" e "taxa de consumo", sugerindo que um maior número de reservas tende a resultar em um aumento na taxa de consumo.


Figura 3: Correlação entre as variáveis



Fonte: Elaboração própria dos autores (2024).

As métricas de desempenho dos modelos de predição, avaliadas por MSE, MAE e R^2 , conforme o gráfico 1, oferecem insights sobre a qualidade do ajuste do modelo aos dados. O MSE (Mean Squared Error) apresentou um valor em torno de 0,03, indicando um bom alinhamento entre previsões e valores reais. O MAE (Mean Absolute Error) ficou em aproximadamente 0,11, o que sugere uma baixa diferença média entre as previsões e os resultados efetivos, evidenciando a precisão do modelo. Já o R^2 (R-squared) foi de 0,19, o que indica que o modelo explica apenas uma parte limitada da variabilidade dos dados. Isso sugere que, embora o desempenho em termos de MSE e MAE seja bom, o modelo ainda pode ser aprimorado com a inclusão de novas variáveis ou a exploração de diferentes abordagens modelares.

Gráfico 1: Gráfico de Resíduos



Fonte: Elaboração própria dos autores (2024).

A análise da correlação entre as variáveis, juntamente com as métricas de desempenho, é crucial para entender melhor como o modelo se ajusta aos dados e identificar oportunidades de otimização.

A busca por soluções inovadoras para garantir uma gestão de recursos mais eficiente e sustentável no IFSP - Campus Itaquaquecetuba permanece uma prioridade.

CONSIDERAÇÕES FINAIS

A presente análise explorou a problemática da questão do desperdício de alimentos no refeitório do IFSP - Campus Itaquaquecetuba, com o objetivo de identificar soluções inovadoras que otimizem a gestão de recursos e promovam a sustentabilidade da instituição. A implementação de um sistema de previsão de demanda de refeições, utilizando técnicas de

Machine Learning, especialmente a regressão linear, mostrou-se uma estratégia promissora para reduzir o desperdício e aumentar a eficiência do serviço de alimentação.

A experiência proporcionou valiosos aprendizados sobre coleta, tratamento e análise de dados, além da seleção e aplicação de modelos de Machine Learning para prever a demanda. Com a criação de um sistema online de reservas, o uso de ferramentas como Google Planilhas e Apps Script para tratamento de dados, e o desenvolvimento de *dashboards* interativos no Looker Studio, conseguimos visualizar e analisar informações de maneira mais eficaz, o que facilitou a tomada de decisões estratégicas.

No entanto, a busca por soluções para a redução do desperdício de alimentos continua. A análise dos dados coletados e a avaliação do desempenho dos modelos de Machine Learning destacaram a necessidade de aprimorar a precisão das previsões. É fundamental explorar técnicas mais adequadas ao nosso contexto e realizar análises mais profundas, levando em conta fatores adicionais que influenciam a demanda de refeições.

Acredita-se que desenvolver soluções inovadoras para a gestão de recursos e a redução do desperdício de alimentos é crucial para garantir a sustentabilidade do IFSP - Campus Itaquaquecetuba. As lições aprendidas ao longo deste projeto nos incentivam a buscar melhorias contínuas e a investir em tecnologias e ferramentas que promovam uma gestão de recursos mais responsável e eficiente.

REFERÊNCIAS

BEZERRA, Mariana Silva; JACOB, Michelle Cristine Medeiros; FERREIRA, Maria Angela Fernandes; VALE, Diôgo; MIRABAL, Isabelle Ribeiro Barbosa; LYRA, Clélia de Oliveira. **Insegurança alimentar e nutricional no Brasil e sua correlação com indicadores de vulnerabilidade**. Revista Ciência & Saúde Coletiva. Disponível em: <<https://www.scielo.br/j/csc/a/vpGZNFNcKySWVrVy4KR3Gtc/>>. Acesso em: 1 out. 2024.

BRASIL. **Lei nº 11.346, de 15 de dezembro de 2006**. Disponível em:

<https://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/lei/111346.htm>. Acesso em: 4 out. 2024.

FAO. (2021). **Food waste Index Report**. Roma: FAO. Disponível em:

<<https://www.unep.org/resources/report/unep-food-waste-index-report-2021>>. Acesso em: 5 Out. 2024.

FAO. (2024). **Food waste Index Report**. Roma: FAO. Disponível em: <https://www.unep.org/resources/publication/food-waste-index-report-2024>. Acesso em: 5 Out. 2024

MONTGOMERY, Douglas C.; PECK, Elizabeth A.; VINING, Geoffrey. **Introduction to Linear Regression Analysis**. New York: Wiley, 2021.