

APLICAÇÃO DE AUTOMAÇÃO E INTELIGÊNCIA ARTIFICIAL NA INDÚSTRIA 4.0: UM ESTUDO DE CASO EM UMA INDÚSTRIA ALIMENTÍCIA

Duarte dos Santos¹, Priscila Mayara; Franco², Lucas Tex Barbosa; Oliveira², Gustavo Melo de

1 – Professora na Universidade do Vale do Sapucaí.

2 – Graduando em Engenharia de Controle e Automação na Universidade do Vale do Sapucaí.

prisciladuarte@univas.edu.br; lucastex55@hotmail.com; gustavodeoliveira502@gmail.com

RESUMO

Este artigo explora a aplicação dos princípios da Indústria 4.0 e técnicas de *Machine Learning* na otimização do processo de produção de maionese em uma empresa. Os dados utilizados são referentes ao processo de produção desse tipo de produto. Um modelo preditivo foi construído utilizando um algoritmo de árvore de decisão. Este modelo tem a função de prever o ponto de corte ideal no processo, com o intuito de minimizar o desperdício de ingredientes. O modelo foi integrado ao sistema de controle da fábrica, permitindo ajustes automáticos nos parâmetros do processo para atingir o ponto de corte desejado. A implementação deste sistema resultou em alguns benefícios econômicos, melhorando a eficiência operacional e reduzindo os custos associados ao desperdício. Além disso, a otimização do processo contribuiu para a sustentabilidade ambiental, reduzindo o consumo de matérias-primas e a geração de resíduos. A combinação da Indústria 4.0 com técnicas de *Machine Learning* se mostrou uma ferramenta eficaz para a otimização da produção, permitindo a criação de um sistema inteligente que se ajusta automaticamente para alcançar o ponto de corte desejado, evitando a produção de produtos fora das especificações.

Palavras-chave: *Machine Learning*, Otimização da Produção, Redução do Desperdício, Eficiência Operacional, Sustentabilidade.

1. INTRODUÇÃO

No Brasil, o tema “Indústria 4.0” ainda é relativamente novo, e está em fase inicial de implantação. Atualmente, devido à necessidade constante de se obter processos mais competitivos e sustentáveis, existe uma grande motivação para otimizar processos. A indústria situa-se no centro da economia mundial e, para dar continuidade a sua rotina de operação, precisa se reformular nas áreas de logística, tecnologia e processos. As transformações vinculadas ao conceito da Indústria 4.0 têm o potencial de elevar a flexibilidade, a rapidez, a eficiência produtiva e a qualidade dos processos de produção (Boston Consulting Group, 2015).

Oliveira e Simões (2017), consideram que as discussões e debates relacionados ao tema sustentabilidade são fundamentais para a alavancagem desses novos aspectos na prática da indústria brasileira. Sustentabilidade é um conceito de longo prazo, e está relacionada ao

longo anseio social por encontrar uma forma de desenvolvimento que respeite às necessidades do presente sem atrapalhar as próximas gerações. A Sustentabilidade Empresarial representa a empresa e sua conexão, principalmente, com o meio ambiente. Segundo Tertuliano et al. (2019), nas empresas, o conceito de sustentabilidade está ligado diretamente com responsabilidade social.

Este estudo tem como objetivo a aplicação dos pilares da indústria 4.0, visando a sustentabilidade, mas com foco na automação industrial, propondo possíveis tecnologias que podem ser implementadas na indústria sem grandes exigências de conhecimento técnico ou recursos econômicos. Os projetos sustentáveis no contexto industrial trazem boas perspectivas para a empresa, principalmente em termos de redução de custos, mas também podem levar ao aumento dos lucros e à possibilidade de estratégias de "marketing verde".

O trabalho é baseado em um estudo de caso em uma empresa de produtos alimentícios, Empresa X. A empresa X é uma indústria multinacional, com um complexo de cerca de 12 mil m² de área construída distribuídos em uma área de 40 mil m², e possui um portfólio de dezenas de produtos para os mais diversos públicos como, por exemplo, maionese, ketchup, sopas e temperos.

O estudo de caso é baseado em aplicações voltadas para a redução de desperdício de matéria prima e ajuste de qualidade na padronização dos produtos, principalmente o que diz respeito ao peso. Constantemente, indústrias são impactadas com elevação de gastos voltados a margens errôneas de medidas dos produtos, e devido a essa preocupação, esse estudo visa apresentar uma discussão para a elaboração de uma automação inteligente, utilizando ferramentais de ciências de dados como, por exemplo, a linguagem de programação PYTHON[®] e armazenamento de dados em nuvem. Assim, o objetivo da pesquisa é aplicar conhecimentos relacionados a inteligência artificial no contexto de automação de uma indústria visando, principalmente, o desenvolvimento de um sistema inteligente que consiga reduzir e padronizar o volume de ingredientes em uma receita de maionese, buscando aumentar o padrão de qualidade do produto final e reduzir desperdício.

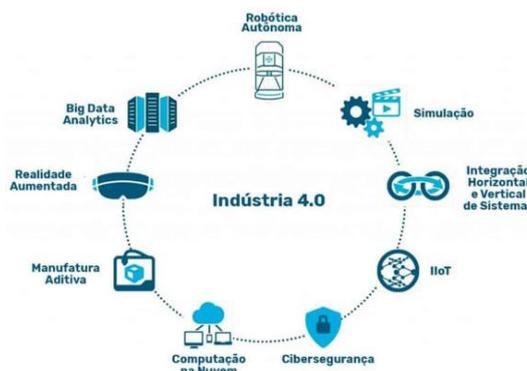
2. INDÚSTRIA 4.0

A Indústria 4.0 é um termo amplamente adotado para descrever o avanço no gerenciamento e produção em cadeia. Também conhecida como a quarta Revolução Industrial, a Indústria 4.0 é um conceito que teve origem em 2011, na Alemanha, como resultado de um projeto governamental. Esse projeto reconheceu a tecnologia como um

sólido alicerce para a transformação e evolução necessárias na indústria em escala global, estabelecendo sistemas inteligentes de produção que conectam máquinas, sistemas e recursos (Gomes; Santos; Campos, 2018).

Os procedimentos e tecnologias necessários para que uma empresa possa migrar para a Indústria 4.0, ou começar uma empresa com o objetivo de se tornar uma Indústria 4.0, são conhecidos como os pilares da Indústria 4.0 (Falcão, 2019). A partir dos estudos de diversos autores, os seis pilares amplamente considerados na Indústria 4.0 são: modularidade, interoperabilidade, capacidade em tempo real, virtualização, modularização e orientação à serviços (Falcão, 2019). O grupo Boston Consulting Group (BCG) apresenta uma proposta composta por 9 pilares, o que torna o conceito da indústria 4.0 mais completo. Os pilares que formam essa formulação são: Sistema de Integração Horizontal e Vertical; Manufatura Aditiva; Robôs autônomos; Big Data; IoT (Internet of Things); Simulação; Segurança cibernética; Computação em Nuvem e Gestão de Qualidade. Na Figura 1 é possível verificar a integração desses pilares dentro desse conceito.

Figura 1 - Indústria 4.0.



Fonte: ISA Distrito 4 (2016)

Um aspecto adicional a ser considerado no contexto da quarta revolução industrial é a implementação da manufatura inteligente, que utiliza inteligência artificial para aumentar a conectividade entre máquinas e a tomada de decisões automatizada. Essa tecnologia proporciona os benefícios esperados pela indústria 4.0, tais como, aprimoramento da qualidade, redução de tempo e custos, aproveitamento de dados para criar oportunidades e impulsionar a melhoria contínua nos processos de produção (Duran, 2020).

2.1 Robôs autônomos

A definição de robô é “máquina controlada por computador” e são programadas para mover, manipular objetos e realizar diversos trabalhos (Pscheidt, 2007). Segundo o autor, atualmente os robôs estão divididos em diversos grupos como, por exemplo:

- AGV (Automated Guided Vehicle), que usam sensores que detectam linhas;
- Robôs utilizando Inteligência Artificial;
- Robôs para navegação;
- Robôs Interplanetários que são utilizados para explorações de outros planetas.

Com o grande desenvolvimento da tecnologia, computadores podem ser usados para desenvolver novas técnicas de controle robótico. Estas técnicas estão permitindo que esses robôs executem tarefas complexas, como: aprender com a experiência, navegar por ambientes desconhecidos, desviar de obstáculos imprevistos e reagir de forma inteligente a estímulos do ambiente (Pscheidt, 2007, p. 15). Assim, robôs autônomos são máquinas inteligentes capazes de executar tarefas no mundo por si só, sem controle humano explícito.

2.2 Microsoft Azure®

A arquitetura de computação em nuvem transforma a maneira de operar, passando de um modelo baseado na compra de equipamentos para um modelo baseado na obtenção de serviços, o que proporciona flexibilidade e utilização eficiente dos recursos. Atualmente, a Tecnologia da Informação (TI) volta a ser centralizada em grandes centros de armazenamento e processamento (Veras, 2015). A computação em nuvem foi desenvolvida para oferecer facilmente recursos virtuais, tanto em termos de hardware e software, plataformas de desenvolvimento e serviços. Esses recursos são adquiridos de acordo com as necessidades, permitindo otimizar o uso. Geralmente, é explorado por meio de um modelo de pagamento conforme o uso, com garantias fornecidas pelo provedor de serviços (Vaquero et al. 2009).

O Azure é um sistema de armazenamento em nuvem, e estabelece conjuntos de disponibilidade, associando regiões que estão no mesmo continente e são fisicamente separadas por pelo menos 480 km umas das outras. Essa abordagem incentiva os usuários a projetar seus sistemas e aplicativos em torno dessas regiões, visando criar uma configuração de recuperação ativa/ativa que prioriza a disponibilidade e o isolamento. Além disso, certos serviços do Azure, como o Blob Storage, oferecem opções de replicação automática dos dados entre essas regiões (Microsoft, 2020).

Os principais serviços do Azure, que englobam computação, armazenamento, rede e banco de dados, incluem:

- Computação: máquinas virtuais do Azure, Azure App Service, Azure Kubernetes Service;
- Armazenamento: Azure Blob Storage e Azure Managed Disks;

- Rede: Azure Virtual Network (VNet);
- Banco de dados: Azure SQL Database, Azure SQL Data Warehouse, Azure Table Storage e CosmosDB.

2.3 Machine Learning

Os sistemas de aprendizado de máquina, também conhecidos como sistemas de machine learning, são capazes de adquirir conhecimento por meio da análise de dados e têm como objetivo tomar decisões com pouca intervenção humana, seja com o propósito de concluir uma tarefa, realizar previsões precisas ou simplesmente agir de maneira inteligente (Mitchell; 1997; Müller, 2017). Essa abordagem tem se tornado cada vez mais popular na área da ciência da computação e em diversos outros campos nos últimos dez anos. O aprendizado de máquina encontra aplicação em uma ampla gama de áreas, como pesquisa na internet, filtragem de spam em emails, recomendação de produtos, publicidade, detecção de fraudes, classificação de imagens e muitas outras aplicações.

A grande vantagem de empregar técnicas de Aprendizado de Máquina em comparação com a programação explícita é que os resultados obtidos são mais precisos (Schapire, 2008). A utilização do aprendizado de máquina dispensa a necessidade de criar sistemas com múltiplas validações condicionais, métodos recursivos e outras abordagens de programação. Em vez disso, os algoritmos têm a capacidade de aprender e extrair conhecimento a partir de dados previamente adquiridos, permitindo a identificação de padrões em um programa ou a análise de novas entradas de dados.

O processo de geração de conhecimento e aprendizado de padrões e dados pelo aprendizado de máquina, requer uma compreensão da hierarquia do sistema. Essa hierarquia envolve o processo de indução, que consiste na inferência lógica utilizada para obter conclusões gerais a partir de um conjunto específico de exemplos. A indução é um mecanismo amplamente empregado pelo cérebro humano para adquirir novo conhecimento (Monard; Baranauskas, 2003). Durante o processo de indução, várias hipóteses de conhecimento são geradas com base nos exemplos analisados, sendo que essas hipóteses podem ser verdadeiras ou não (Carvalho et al., 2011). É importante ressaltar que a eficácia do processo de indução depende tanto da quantidade de dados disponíveis quanto da seleção adequada das amostras e variáveis/atributos dos dados. Quando o número de dados é baixo ou as amostras não são bem escolhidas, as hipóteses resultantes podem ter pouco valor. Portanto, o aprendizado de máquina requer conjuntos de dados volumosos para ser capaz de

aprender e extrair informações relevantes para a resolução do problema em questão. Além disso, é fundamental que as variáveis presentes nesses conjuntos de dados sejam informativas e gerem o maior número possível de hipóteses para o algoritmo aprender (Carvalho et al., 2011). Essas hipóteses podem ser avaliadas através de um modelo hierárquico para a busca de uma solução final.

2.4 Algoritmo árvore de decisão

De acordo com Russell e Norvig (2013), uma árvore de decisão é uma representação funcional que recebe um vetor de atributos como entrada e retorna uma única "decisão" como resultado. É um algoritmo de construção simples que segue a estratégia gulosa de dividir e conquistar, priorizando o teste do atributo mais relevante primeiro, aquele que tem maior impacto na classificação. Nesse contexto, a aplicação de machine learning em um processo de automatização dos ingredientes em uma receita, pode fazer uso de árvores de decisão para determinar quais ingredientes e suas quantidades são mais adequados para atingir o resultado desejado.

O algoritmo de árvore de decisão resolve problemas complexos dividindo-os em subproblemas mais simples de forma recursiva. A árvore de decisão é um grafo acíclico composto por nós de divisão e nós folha. Os nós de divisão, que têm dois ou mais sucessores, realizam testes condicionais nos atributos para determinar o próximo nó. Por exemplo, um nó de teste condicional pode verificar a idade e direcionar para um nó subsequente se a idade for maior que 18, ou para outro nó subsequente se for menor. Os nós folha são rotulados com os valores das classes do conjunto de dados e estão localizados nas extremidades das árvores (Carvalho et al., 2011).

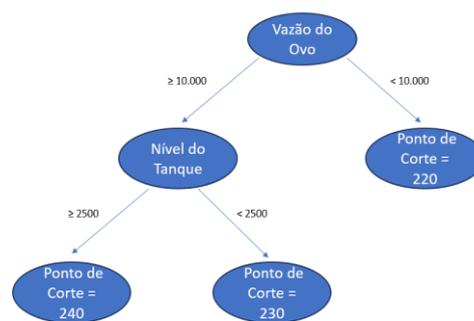
A indução de decisão em uma árvore de decisão, visa torná-la consistente com os exemplos e mantê-la o mais compacta e superficial possível (Norvig; Russell, 2013). Os algoritmos utilizam heurísticas locais que avaliam um passo à frente, uma vez que uma decisão é tomada, não há retrocesso (sem backtracking), o que pode levar a resultados subótimos globalmente. Exemplos de algoritmos de árvore de decisão incluem CART (Classificação e Regressão de Árvore) e C4.5 (Árvore de Decisão de Classe).

A entropia é uma medida de aleatoriedade de uma variável aleatória e indica a dificuldade de prever o atributo alvo. Em cada nó de decisão, verifica-se qual atributo reduz mais a aleatoriedade da classe durante a divisão. O ganho de informação é calculado como a diferença entre a entropia do conjunto de exemplos, e a soma ponderada das entropias das partições. A construção da árvore tem como objetivo reduzir a entropia, ou seja, diminuir a

incerteza na previsão do atributo alvo (Carvalho et al., 2011). O ganho de informação é definido em termos de entropia, sendo desejável escolher atributos que reduzam a entropia de forma mais significativa, levando à classificação correta dos exemplos. Quanto mais próxima de zero a entropia, maior a certeza na variável para determinar o atributo alvo.

Em alguns problemas, o uso do aprendizado com árvores de decisão pode resultar em árvores muito grandes quando não são identificados padrões. Isso pode levar a super ajustes (overfitting), com nós redundantes e sem valor (Norvig; Russell, 2013). Uma técnica chamada poda pode ser utilizada para combater isso, eliminando ruídos e o overfitting. A poda envolve a generalização de hipóteses no conjunto de treinamento para melhorar o desempenho da árvore, reduzindo folhas redundantes e a profundidade da árvore gerada. Existem duas abordagens: pré-poda e pós-poda. Na pré-poda, alguns exemplos de treinamento são ignorados durante a geração das hipóteses, enquanto na pós-poda, as hipóteses são primeiro criadas a partir do treinamento e depois generalizadas, e partes irrelevantes são removidas, como cortar ramos em uma árvore de decisão (Monard; Baranauskas, 2003). A Figura 2 apresenta um exemplo para uma árvore de decisão para previsão de valores do ponto de corte, como forma de esclarecer a maneira como esse tipo de metodologia funciona.

Figura 2 – Modelo fictício do funcionamento da árvore de decisão



Fonte: Elaborado pelo Autor (2023)

2.5 Controle feedback

O objetivo do controle de processos é garantir a estabilidade de um determinado processo, mantendo-o dentro de condições operacionais predefinidas. Para atingir esse objetivo, um controlador age para conduzir a variável controlada ao valor desejado (setpoint), buscando minimizar o desvio ou erro em direção a zero. Isso é realizado através da manipulação de outras variáveis que exercem influência sobre o processo em questão (Stephanopoulos, 1984).

Existem diversos tipos de sistemas com abordagens influenciadas pela escolha das variáveis que serão medidas, manipuladas ou controladas. Por exemplo, sistemas Single Input Single Output (SISO) e Multiple Input Multiple Output (MIMO), que são determinados pelo número de variáveis que são manipuladas e controladas. Além disso, a sequência de medição em relação à perturbação no sistema também desempenha um papel significativo.

O controle feedforward e o controle feedback são duas abordagens de controle de processos. O controle feedforward mede as perturbações antes de afetarem o sistema e toma ações corretivas antecipadas. No entanto, essa abordagem requer uma estimativa de como as perturbações medidas afetarão o processo, o que pode ser desafiador devido à complexidade do sistema ou à presença de múltiplas perturbações (LeBlanc; Coughanowr, 2009). Por outro lado, o controle feedback ajusta a variável manipulada em resposta a um desvio na variável controlada. Nesse caso, a medição ocorre após a perturbação ter afetado o sistema. Devido à complexidade dos sistemas e à dificuldade de estimar o impacto das perturbações, o controle feedback é mais comumente utilizado (LeBlanc; Coughanowr, 2009).

O controle feedback pode ser classificado em duas categorias: o problema de servo, que envolve ajustes no setpoint, e o problema regulatório, que busca controlar as perturbações que afetam o processo. Essa análise é relevante para o estudo em andamento, que emprega técnicas de machine learning na automatização dos ingredientes de receitas. Nesse contexto, é crucial destacar a importância do controle feedback como parte essencial do trabalho, permitindo ajustes precisos no setpoint e o controle eficiente de perturbações, garantindo um processo automatizado de alta qualidade.

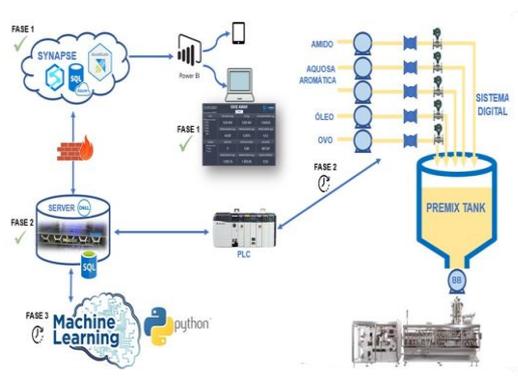
Quando o sistema possui múltiplas entradas e múltiplas saídas (MIMO, Multiple Input Multiple Output), em contraste com sistemas de única entrada e única saída (SISO, Single Input Single Output), a abordagem se torna mais complexa (Ogata, 2010; Stephanopoulos, 1984). Com base nos desvios medidos, também conhecidos como erros, são tomadas ações para minimizá-los por meio da manipulação de variáveis do processo através de um controlador.

3. METODOLOGIA

3.1 Desenvolvimento do projeto

O projeto foi desenvolvido para viabilizar padronização na produção de maionese nessa empresa. O progresso do projeto foi gerenciado ao longo de três fases distintas (Figura 3). Onde na fase 3, foi feito os testes no modelo com um banco de dados resumido, na fase 2 foi feita a conexão do modelo com o banco de dados reais e na fase 1, foi onde os dados armazenados na nuvem puderam ser disponibilizados para consultas.

Figura 3 - Fases do desenvolvimento do projeto.



Fonte: Elaborado pelo Autor (2023)

3.2 Coleta de dados

Foram coletados dados diretamente do processo de produção da Empresa X por meio de sensores que registram as informações no servidor. Os dados obtidos foram divididos em 9 variáveis (colunas), sendo elas e suas descrições:

- VAZAO_SP - Vazão do ponto de ajuste
- NIVEL - Nivel do tanque
- TEMPERATURA - Temperatura do Ambiente
- OVO_NIVEL_1 - Nivel do tanque 1 de Ovo
- OVO_NIVEL_2 - Nivel do tanque 2 de Ovo
- OVO_TEMP_1 – Temperatura do tanque 1 de Ovo
- OVO_TEMP_2 – Temperatura do tanque 2 de Ovo
- DOSAGEM_OVO – Quantidade de ovos Necessários na receita
- SP_CORTE_OVO – Ponto de ajuste do corte

3.3 Preparação dos Dados para Machine Learning

Antes da aplicação de técnicas de Machine Learning, os dados passaram por um processo de limpeza e preparação. Os valores ausentes foram tratados por meio de métodos adequados, como interpolação ou exclusão se necessário. A detecção de outliers foi realizada usando boxplot para garantir que esses valores discrepantes não distorcessem os resultados finais. Além disso, foi feita uma análise de correlação para verificar como as variáveis se comportam entre si, podendo notar que a DOSAGEM_OVO é a variável com maior relação com o SP_CORTE_OVO. Uma matriz de correlação entre essas variáveis é observada na Figura 4.

Figura 4 – Matriz de correlação das variáveis.

| | VAZAP_SP | NIVEL | TEMPERATURA | OVO_NIVEL_1 | OVO_NIVEL_2 | OVO_TEMP_1 | OVO_TEMP_2 | DOSAGEM_OVO | SP_CORTE_OVO |
|--------------|----------|---------|-------------|-------------|-------------|------------|------------|-------------|--------------|
| VAZAP_SP | 1 | -0,015 | -0,3 | 0,0046 | 0,012 | -0,028 | -0,016 | 0,24 | 0,4 |
| NIVEL | -0,015 | 1 | 0,054 | -0,0031 | -0,046 | -0,016 | 0,0045 | -0,044 | -0,043 |
| TEMPERATURA | -0,3 | 0,054 | 1 | -0,051 | -0,023 | -0,017 | 0,0024 | -0,11 | -0,18 |
| OVO_NIVEL_1 | 0,0046 | -0,0031 | -0,051 | 1 | -0,21 | -0,55 | 0,23 | 0,052 | 0,042 |
| OVO_NIVEL_2 | 0,012 | -0,046 | -0,023 | -0,21 | 1 | 0,18 | -0,55 | 0,078 | 0,027 |
| OVO_TEMP_1 | -0,028 | -0,016 | -0,017 | -0,55 | 0,18 | 1 | -0,16 | -0,039 | 0,0094 |
| OVO_TEMP_2 | -0,016 | 0,0045 | 0,0024 | 0,23 | -0,55 | -0,16 | 1 | -0,046 | 0,02 |
| DOSAGEM_OVO | 0,24 | -0,0044 | -0,11 | 0,052 | 0,078 | -0,039 | -0,046 | 1 | 0,54 |
| SP_CORTE_OVO | 0,4 | -0,043 | -0,18 | 0,042 | 0,027 | 0,0094 | 0,02 | 0,54 | 1 |

VAZAP_SP NIVEL TEMPERATURA OVO_NIVEL_1 OVO_NIVEL_2 OVO_TEMP_1 OVO_TEMP_2 DOSAGEM_OVO SP_CORTE_OVO

Fonte: Elaborado pelo Autor (2023)

3.4 Comunicação com o PLC e Disponibilização dos Dados

Na fase dois do projeto, ocorreu a integração entre os resultados do modelo de Machine Learning e o sistema de controle da fábrica. O Programmable Logic Controller (PLC) foi configurado para receber as previsões do modelo e ajustar automaticamente os parâmetros do processo para atingir o ponto de corte desejado. Além disso, na fase um do projeto os dados foram disponibilizados em um servidor na nuvem, permitindo uma análise contínua do desempenho do processo e do modelo de previsão.

3.5 Avaliação e Interpretação dos Resultados

A avaliação do modelo foi realizada com base em métricas de desempenho, como erro quadrático médio (MSE). O MSE, abreviação de Mean Squared Error, é uma métrica

que calcula o erro quadrático médio das previsões. Basicamente, é a média dos erros ao quadrado associados a cada valor previsto, conforme expresso na Equação 1 a seguir.

Equação 1 – Erro quadrático médio

$$MSE_{(y,\hat{y})} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad [1]$$

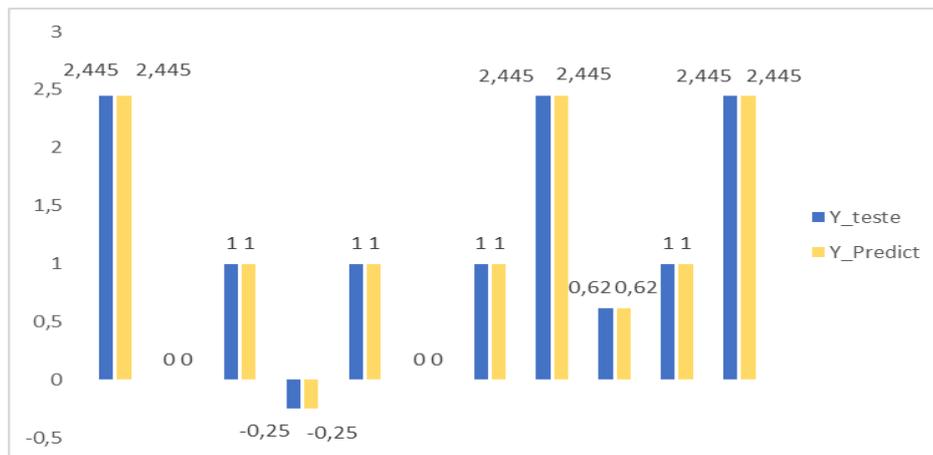
O MSE quantifica o quão bem o modelo é capaz de prever o ponto de corte desejado. Esses resultados foram interpretados para determinar a eficácia do modelo na redução do desperdício de ingredientes, e otimização do processo de produção de maionese.

4. Resultados da Aplicação de Machine Learning

A fase 3 do projeto concentrou-se na aplicação de técnicas de Machine Learning para prever o ponto de corte desejado no processo de produção de maionese. O modelo foi construído utilizando as variáveis VAZAO_SP, NIVEL, TEMPERATURA, VO_NIVEL_1, VO_NIVEL_2, OVO_TEMP_1, OVO_TEMP_2 e DOSAGEM_OVO como entradas (X) e a variável SP_CORTE_OVO como saída (Y).

Utilizando o algoritmo de árvore de decisão, o modelo foi treinado e testado com os dados coletados do processo de produção. Após o treinamento do modelo, foram realizados testes utilizando dados não vistos durante o treinamento (conjunto de teste). A figuras 6 e a tabela 1, ilustram o resultado do teste, comparando os valores previstos (Y_pred) com os valores reais (Y_test).

Figura 6 - Resultado do Teste do Modelo de Machine Learning



Fonte: Elaborado pelo Autor (2023)

Tabela 1 - Resultado do Teste do Modelo de Machine Learning tabulados no python

| Índice | Y_teste | Y_Predict |
|--------|---------|-----------|
| 0 | 2,445 | 2,445 |
| 1 | 0 | 0 |
| 2 | 1 | 1 |
| 3 | -0,25 | -0,25 |
| 4 | 1 | 1 |
| ... | 0 | 0 |
| 1061 | 1 | 1 |
| 1062 | 2,445 | 2,445 |
| 1063 | 0,62 | 0,62 |
| 1064 | 1 | 1 |
| 1065 | 2,445 | 2,445 |

Fonte: Elaborado pelo Autor (2023)

Como observado nas Figuras 6 e 7, os valores previstos (Y_pred) pelo modelo estão muito próximos dos valores reais (Y_test), indicando que o modelo é capaz de fazer previsões precisas para o ponto de corte desejado no processo de produção de maionese. O modelo apresenta um índice de acerto de 99%, um valor que é considerado satisfatório. Isso indica a eficácia do modelo na redução do desperdício de ingredientes e otimização do processo.

O aspecto de sustentabilidade do processo produtivo da indústria 4.0 em conjunto com técnicas de Machine Learning, tornou-se uma ferramenta para a otimização na produção de maionese pela empresa. Já a combinação entre os pilares da Indústria 4.0 e a automação inteligente na análise de dados em tempo real, contribuiu com a minimização de desperdício

de ingredientes e um significativo custo evitado. A utilização do Machine Learning permitiu a criação de um modelo capaz de prever, com alta precisão, o ponto de corte desejado, para os ingredientes e para o insumo final durante o envase, no processo com base nas variáveis do sistema.

5. CONSIDERAÇÕES FINAIS

Esse estudo de caso demonstrou que a aplicação dos princípios da Indústria 4.0, principalmente o que diz respeito a inteligência computacional, como o uso de técnicas de Machine Learning, por exemplo, pode ter um impacto significativo na sustentabilidade ambiental das operações industriais. O desenvolvimento e implementação de um modelo de previsão do ponto de corte no processo de produção de maionese, resultou em uma redução substancial do desperdício de ingredientes, contribuindo para a eficiência operacional e a redução do impacto ambiental.

O uso de tecnologias como automação, Machine learning e análise de dados em tempo real permitiu a criação de um sistema inteligente que se ajusta automaticamente para alcançar o ponto de corte desejado, evitando a produção de produtos fora das especificações. Isso não só reduziu o desperdício, mas também aumentou a eficiência do processo, reduzindo os custos operacionais e aumentando a competitividade da Empresa.

Além dos benefícios econômicos, a implementação deste sistema resultou em vantagens ambientais significativas. A redução do desperdício de ingredientes contribui para a sustentabilidade ao diminuir o consumo de matérias-primas e reduzir a geração de resíduos. Além disso, a automação e a análise de dados permitiram otimizar o consumo de energia e recursos, contribuindo para a redução da utilização de carbono no processo de produção.

REFERÊNCIAS

BOSTON CONSULTING GROUP. **Industry 4.0: The future of productivity and growth in manufacturing industries**. BCG Perspectives, 2015a. Disponível em: < https://www.bcgperspectives.com/content/articles/engineered_products_project_business_industry_40_future_productivity_growth_manufacturing_industries/ > Acesso em 07 jul. 2023.

CARVALHO, André et al. **Inteligência Artificial: Uma abordagem de Aprendizado de Máquina**. Rio de Janeiro: Ltc, 2011.

DURAN, Michel. **O papel da Inteligência Artificial na indústria 4.0**, 25 nov. 2020. Disponível em: <https://www.unisoma.com.br/inteligencia-artificial-industria-4-0/>. Acesso em: 07 jul. 2023.

FALCÃO, A.C.R.A. de. **Sistematização dos Pilares da Indústria 4.0: Uma Análise Utilizando Revisão Bibliográfica Sistemática**. Dissertação (Mestrado em Engenharia de Produção) - Universidade de São Paulo, 2019.

COUGHANOWR, D. R.; LEBLANC, S. E. **Process Systems Analysis and Control**. 3rd ed. New York: McGraw-Hill, 2009.

GOMES, G. P; SANTOS, W. P; CAMPOS, P. S. Indústria 4.0: um novo conceito de gerenciamento nas indústrias. **Revista Científica Semana Acadêmica**. v. 10, n. 1, p. 01-11, 2018.

ISA DISTRITO 4. “**Industria 4.0 & IIoT**”. 2015. Disponível em: <<http://www.isadistrito4.org.br/grupos/industria40/>>. Acesso em: 07 jul. 2023.

MITCHELL, T. M. **Machine Learning**. [S.l.]: McGraw-Hill Science/Engineering/Math, 1997. 432 p.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. **Conceitos sobre aprendizado de máquina, Sistemas Inteligentes, Fundamentos e Aplicações**, v. 1, n. 1, 2003.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. **Sistemas Inteligentes Fundamentos e Aplicações**. Barueri, Sp: Manole Ltda, 2003. p. 39-56. Disponível em: <<http://dcm.ffclrp.usp.br/~augusto/publications/2003-sistemas-inteligentes-cap4.pdf>>. Acesso em: 07 jul. 2023.

MÜLLER, S. G. A. C. **Introduction to Machine Learning with Python A Guide for Data Scientists**. 1. ed. [S.l.]: O’Reilly Media, 2017. 400 p

NORVIG, Peter; RUSSELL, Stuart. **Inteligência artificial: Tradução da 3a Edição**. 3. ed. Rio de Janeiro: Elsevier Editora, 2013.

OGATA, K. **Engenharia de controle moderno**. 5. ed. São Paulo: Pearson Prentice Hall, 2010.

OLIVEIRA, F. T. DE; SIMÕES, W. L. A Indústria 4.0 e a produção no contexto dos estudantes da engenharia. **Simpósio de Engenharia de Produção**, v. 1, p. 6, 2017.

PSCHIDEIT, É.R. **robô autônomo – modelo chão de fábrica**. Monografia (Engenharia da Computação) - Centro Universitário Positivo, 2007.

SCHAPIRE, R. **COS 511: Theoretical Machine Learning**. 2008. 6 p. Disponível em: <https://www.cs.princeton.edu/courses/archive/spr08/cos511/scribe_notes/0204.pdf>. Acesso em: 07 jul. 2023.

STEPHANOPOULOS, G. **Chemical process control: an introduction to theory and practice.** Upper Saddle River, NJ: Prentice-Hall, 1984.

TERTULIANO, et al. **Indústria 4.0: a inovação aliada a sustentabilidade.** Programa de Pós-Graduação em Administração e Programa de Pós-Graduação em Economia FEA/PUC-SP, 2019.

VAQUERO, Luiz M; RODERO-MERINO, Luiz; CACERES, Juan; LINDENER, Maik. A break in the Clouds: towards a cloud definition. **ACM Sigcomm Computer Communication Review**, vol. 39, n. 1, Jan 2009.

VERAS, Manoel. **Computação em Nuvem: Nova Arquitetura de TI.** Rio de Janeiro: Brasport, 2015. 174 p.