

UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO

GERALDO MARQUES DE SOUSA JUNIOR

Desenvolvimento de startup de monitoramento de máquinas
industriais: da concepção à prototipagem

São Paulo
2024

GERALDO MARQUES DE SOUSA JUNIOR

Desenvolvimento de startup de monitoramento de máquinas
industriais: da concepção à prototipagem

Trabalho de Formatura em Engenharia de Produção

Orientador: Prof. Dr. Eduardo de Senzi Zancul

São Paulo
2024

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Catálogo-na-publicação

Marques de Sousa Junior, Geraldo

Desenvolvimento de startup de monitoramento de máquinas industriais:
da concepção à prototipagem / G. Marques de Sousa Junior -- São Paulo, 2024.
96 p.

Trabalho de Formatura - Escola Politécnica da Universidade de São
Paulo. Departamento de Engenharia de Produção.

1. Indústria 4.0 2. Métodos Ágeis 3. Aprendizado de Máquina
I. Universidade de São Paulo. Escola Politécnica. Departamento de
Engenharia de Produção II. t.

A minha mãe por me ensinar a sonhar e por viabilizar o caminho.

AGRADECIMENTOS

A minha mãe, por me ensinar a sonhar e por sempre ter me apoiado nessa jornada.

A minha avó por ensinar a importância dos estudos. Ao meus tios Eustáquio, Viviani e Tiago por sempre me incentivarem nessa jornada.

Ao Atha, por ter se tornado um irmão durante toda a jornada. Ao bilha (Tulio, Deco e Campa), ao amigos do intercâmbio (Eliseu, Seigi, Yuichi, Chen, Arthur, João, Lucca, Bf), e Amanda.

À família Magalhães, por todo acolhimento. Especialmente à Vitoria, pelo companheirismo durante o processo.

À Universidade de São Paulo (USP) por toda a estrutura e fonte rica de conhecimento. À Escola Politécnica por impulsionar o ensino de Engenharia no Brasil. À CentraleSupélec, pela oportunidade de expandir meus horizontes internacionalmente.

Aos Professores Zancul, Fleury e Artur, por todo apoio durante a graduação. Agradecimento especial ao Prof. Zancul, por ser grande mentor da startup e orientador deste Trabalho.

Aos Professores Christophe Rittano e Viviane Moureau, da CentraleSupélec por toda mentoria durante *minor* em Empreendedorismo. Ao Professor Charles Soussen por ter sido conselheiro na parte de Tratamento de Sinais.

*"The best thing a human being can do is help another human being know more."
Charlie Munger*

RESUMO

M. DE SOUSA JUNIOR, G. **Desenvolvimento de startup de monitoramento de máquinas industriais**: da concepção à prototipagem. 2024. Trabalho de Formatura – Escola Politécnica da Universidade de São Paulo, São Paulo, 2024.

O presente trabalho objetiva apresentar o desenvolvimento de uma startup de monitoramento de máquinas industriais no contexto da Indústria 4.0 para um grande player nacional do setor de bebidas. Ele cobre desde o processo de *customer discovery*, entendimento das principais dores e necessidades do cliente, até a fase de desenvolvimento de um modelo de classificação usando *deep learning*, finalizando com testes in loco na planta industrial. A temática de Indústria 4.0 vem ganhando cada vez mais notoriedade em um cenário onde empresas buscam maximizar eficiência, reduzindo perdas financeiras e *downtime* de máquinas. Contudo, o desenvolvimento de soluções de IoT enfrenta desafios significativos relacionados à falta de conectividade e acesso à internet em plantas industriais. Para contornar esse problema, o presente trabalho apresenta uma solução inovadora para o contexto: um modelo de *machine learning* embarcado capaz de monitorar o status de funcionamento de reservatórios de gás carbônico e utilizar a tecnologia LoRa para comunicação dos resultados da inferência. A elaboração e execução deste trabalho não envolveram somente a criação de uma solução de IoT para monitoramento de máquinas industriais, mas também a gestão de projetos e dos *stakeholders* do cliente. Após a implementação das frentes de trabalho, foi possível disponibilizar em tempo real o estado de operação dos reservatórios industriais da planta do cliente – um resultado considerado extremamente positivo pela liderança do cliente, dado a proposta inicial das ações planejadas. Esta iniciativa não só demonstrou a eficácia da solução desenvolvida, mas também seu grande potencial de impacto e expansão no setor industrial, contribuindo para a evolução da Indústria 4.0 no Brasil.

Palavras-chave: Indústria 4.0. Monitoramento de máquinas. Aprendizado Profundo de Máquina. Metodologias Ágeis.

ABSTRACT

M. DE SOUSA JUNIOR, G. **Desenvolvimento de startup de monitoramento de máquinas industriais**: da concepção à prototipagem. 2024. Trabalho de Formatura – Escola Politécnica da Universidade de São Paulo, São Paulo, 2024.

This work aims to present the development of a startup focused on monitoring industrial machines within the context of Industry 4.0 for a major national player in the beverage sector. It covers the entire process from customer discovery, understanding the client's main pains and needs, to the development phase of a classification model using deep learning, and concludes with in situ tests at the industrial plant. The theme of Industry 4.0 has been gaining increasing notoriety in a scenario where companies seek to maximize efficiency, reduce financial losses, and machine downtime. However, the development of IoT solutions faces significant challenges related to the lack of connectivity and internet access in industrial plants. To overcome this problem, this work presents an innovative solution: an embedded machine learning model capable of monitoring the operational status of carbon dioxide reservoirs and using LoRa technology for communicating inference results. The development and execution of this work involved not only creating an IoT solution for monitoring industrial machines but also project management and stakeholder engagement. After implementing the work fronts, it was possible to provide real-time operational status of the client's industrial reservoirs—a result considered extremely positive by the client's leadership, given the initial proposal of the planned actions. This initiative demonstrated not only the effectiveness of the developed solution but also its great potential for impact and expansion in the industrial sector, significantly contributing to the evolution of Industry 4.0 in Brazil.

Keywords: Industry 4.0. Machine Monitoring. Deep Learning. Agile Methodologies.

LISTA DE ILUSTRAÇÕES

Figura 1 – Tanque reservatório de gás carbônico da empresa BebidasCo	24
Figura 2 – Organograma da startup Máquina Feliz	26
Figura 3 – Estrutura do Trabalho de Formatura	29
Figura 4 – Cadeia de Valor de Dados	33
Figura 5 – Exemplo de Rede Neural Convolucional	37
Figura 6 – Matriz de confusão	39
Figura 7 – Exemplo de Espectrograma	41
Figura 8 – Exemplo de Espectrograma de Mel deste trabalho	42
Figura 9 – <i>Design Thinking</i> : um processo não linear	44
Figura 10 – Exemplo de diagrama de Ishikawa	47
Figura 11 – Matrix de Impacto x Esforço	48
Figura 12 – Diagrama da Estrutura Organizacional	51
Figura 13 – Diagrama da Estrutura Organizacional da Gerência de Produção	52
Figura 14 – Diagrama de Causa e Efeito do problema identificado	58
Figura 15 – Matriz de Impacto x Esforço para as soluções propostas	62
Figura 16 – Gráfico de Gantt com o planejamento do projeto	64
Figura 17 – Imagem de um ESP32 utilizado no projeto	66
Figura 18 – <i>Schema</i> da solução proposta para cumprir o primeiro objetivo	66
Figura 19 – Protótipo para o Objetivo 1	67
Figura 20 – Protótipo em ação	68
Figura 21 – Fluxograma do processo de tratamento de dados	69
Figura 22 – <i>Schema</i> da CNN adaptada utilizada para treinamento do modelo	73
Figura 23 – Ilustração do protótipo com antena LoRa	74
Figura 24 – Central desenvolvida em funcionamento na Gerência de Produção	75
Figura 25 – Fluxograma do Objetivo 4	75
Figura 26 – Onda sonora para áudios com e sem defeito	78
Figura 27 – Corrosão do protótipo 1 após operação	79
Figura 28 – Desenho esquemático da nova estrutura mecânica para o protótipo	80
Figura 29 – Espectrograma obtido para sinal sonoro com defeito	81
Figura 30 – Espectrograma de Mel do mesmo sinal com defeito	81
Figura 31 – Espectrograma de Mel de sinal sem defeito	82
Figura 32 – Evolução da função de perda	83
Figura 33 – Evolução da acurácia	84
Figura 34 – Matriz de confusão	85
Figura 35 – <i>Dashboard</i> de resultado na plataforma Grafana	86
Figura 36 – Fluxo de inferência	87
Figura 37 – Protótipo final instalado em reservatório de gás carbônico	88

LISTA DE TABELAS

Tabela 1 – Causas-raízes e Propostas de Solução	61
Tabela 2 – Resultados obtidos com piloto realizado	88

LISTA DE ABREVIATURAS E SIGLAS

CNN	<i>Convolutional Neural Network</i> - Rede Neural Convolucional
CIETEC	Centro de Inovação, Empreendedorismo e Tecnologia
CNPJ	Cadastro Nacional da Pessoa Jurídica
FFT	<i>Fast Fourier Transform</i> - Transformada Rápida de Fourier
GPIO	<i>General Purpose Input/Output</i>
I2C	<i>Inter-Integrated Circuit</i>
IA	Inteligência Artificial
IIoT	<i>Industrial Internet of Things</i>
IoT	<i>Internet of Things</i> - Internet das Coisas
LoRa	<i>Long Range</i>
LoRaWAN	<i>Long Range Wide Area Network</i>
MVP	<i>Minimum Viable Product</i> - Produto Mínimo Viável
NEU	Núcleo de Empreendedorismo da USP
STFT	Transformada de Fourier de Curto Tempo
USP	Universidade de São Paulo

SUMÁRIO

1	INTRODUÇÃO	23
1.1	A empresa e a Definição do Problema	23
1.2	Motivação e Importância do Trabalho	24
1.3	Papel do Autor no Desenvolvimento do Trabalho	26
1.4	Objetivo e Escopo	27
1.5	Organização do Trabalho	28
2	REVISÃO DA LITERATURA	31
2.1	Indústria 4.0 e Internet das Coisas	31
2.1.1	Inovações industriais e Internet das Coisas	31
2.1.2	Cadeia de Valor de Dados	32
2.1.3	<i>Hardware</i>	33
2.1.3.1	ESP32	34
2.1.3.2	Raspberry Pi	34
2.1.3.3	LoRaWAN	34
2.1.4	<i>Machine Learning</i>	35
2.1.4.1	Problemas de classificação	35
2.1.4.2	Redes Neurais Convolucionais	36
2.1.4.3	Função de perda: entropia cruzada	37
2.1.4.4	Métricas de avaliação	38
2.1.4.4.1	Acurácia	38
2.1.4.4.2	Matriz de confusão	38
2.1.5	Tratamento de Sinais	40
2.1.5.1	Transformada de Fourier	40
2.1.5.2	Espectrograma	40
2.1.5.3	Espectrograma de Mel	41
2.2	Desenvolvimento de Produto: uma Perspectiva de Negócios e <i>Startups</i>	43
2.2.1	<i>Design Thinking</i>	43
2.2.2	Gestão Ágil	44
2.2.3	<i>Lean Startup</i>	45
2.2.4	Minimum Viable Product (MVP)	46
2.2.5	Procedimento de Resolução de Problemas	46
2.2.5.1	Diagrama de causa x efeito	47
2.2.5.2	Matriz de impacto e esforço	47
3	DIAGNÓSTICO	49
3.1	Método	49

3.2	Análise da estrutura organizacional da fábrica	50
3.3	<i>Customer Discovery</i>	52
3.3.1	Guias de entrevista	53
3.3.1.1	Roteiro para Gerente e Coordenadores	53
3.3.1.2	Roteiro para Operadores de Manutenção	54
3.3.1.3	Roteiro para Diretor de IoT	54
3.3.2	Compilação de <i>insights</i> das entrevistas	55
3.3.2.1	<i>Insights</i> de entrevistas com Gerente e Coordenadores	55
3.3.2.2	<i>Insights</i> de entrevistas com Operadores de Manutenção	56
3.3.2.3	<i>Insights</i> de entrevistas com Diretor de IoT	57
3.4	Identificação de causas-raízes	58
3.5	Levantamento de soluções	59
3.6	Priorização de soluções	60
4	DESENVOLVIMENTO DO TRABALHO	63
4.1	Planejamento da implementação	63
4.2	Objetivo 1: Implementar sistema de coleta de dados de operação do tanque	65
4.2.1	Tecnologias a serem utilizadas	65
4.2.2	Detalhamento da solução	66
4.3	Objetivo 2: Construir base de dados com dados de operação do tanque	68
4.3.1	Tecnologias a serem utilizadas	68
4.3.2	Detalhamento da solução	69
4.3.2.1	Fracionamento dos áudios	69
4.3.2.2	Conversão do formato de onda em espectrograma de Mel	70
4.3.2.3	Redimensionamento e normalização	70
4.3.2.4	Embaralhamento dos dados	70
4.3.2.5	Conclusão do processamento de áudios	71
4.4	Objetivo 3: Desenvolver modelo de <i>machine learning</i> para classificação do status de funcionamento	71
4.4.1	Tecnologias a serem utilizadas	72
4.4.2	Detalhamento da solução	72
4.5	Objetivo 4: Disponibilizar informação de funcionamento da válvula em tempo real	73
4.5.1	Tecnologias a serem utilizadas	73
4.5.2	Detalhamento da solução	75
5	RESULTADOS E DISCUSSÃO	77
5.1	Resultado do Objetivo 1: coleta de dados de operação	77
5.1.1	Resultado da iteração sobre o protótipo	79

5.2	Resultado do Objetivo 2: processamento da base de dados coletada	80
5.3	Resultado do Objetivo 3: performance do modelo de <i>machine learning</i> de classificação	82
5.4	Resultado do Objetivo 4: disponibilização do status de operação no Grafana	86
5.5	Piloto realizado com cliente	86
5.6	Discussão com Diretor de IoT	88
6	CONCLUSÃO	91
	REFERÊNCIAS	93

1 INTRODUÇÃO

Neste capítulo, será apresentada a empresa em que foi realizado o Trabalho de Formatura, bem como as motivações para a realização do projeto e sua relevância. Ao fim, serão apresentados o objetivo do trabalho e a maneira como ele foi estruturado.

1.1 A empresa e a Definição do Problema

Nos últimos anos, a ascensão das tecnologias de Internet das Coisas (IoT) tem transformado diversos setores industriais, promovendo uma maior eficiência operacional e a capacidade de monitoramento em tempo real de dispositivos e sistemas (LEE; BAGHERI; KAO, 2015). Este trabalho pauta sobre o processo de desenvolvimento de uma startup de monitoramento de máquinas industriais: da concepção à prototipagem. O Autor deste trabalho é co-fundador desta empresa, e por motivos de confidencialidade será tratada como a startup Máquina Feliz.

A startup Máquina Feliz tem suas origens na disciplina *0303410 - Desenvolvimento Integrado do Produto*, quando parte do time fundador desenvolveu uma solução para uma empresa do ramo alimentício, que será denominada BebidasCo, por questões de confidencialidade. Após a conclusão desse primeiro projeto e ao fim da disciplina, o Autor se juntou ao time fundador para desenvolver uma solução de monitoramento de maquinário industrial. Nesse momento, as relações se profissionalizaram, a empresa Máquina Feliz abriu seu CNPJ, se regularizou e passou a ter relações comerciais com a empresa BebidasCo, que será tratada como cliente neste trabalho.

A empresa BebidasCo lançou um Edital com problemas latentes em suas plantas industriais, dentre eles a identificação de vazamentos em reservatórios de gás carbônico. Pelo contato com a Disciplina 0303410, os gerentes de uma das plantas procurou a startup Máquina Feliz para desenvolverem em conjunto uma solução capaz de monitorar vazamentos em uma de suas plantas industriais. A partir disso, a empresa Máquina Feliz lançou sua proposta de solução do problema e foi escolhida pelo Edital como uma solução inovadora para o monitoramento dos vazamentos.

Durante o processo de *Customer Discovery*, entendeu-se que o cliente gostaria de uma solução para monitoramento das válvulas desses tanques. Esses reservatórios se localizam a cerca de dois quilômetros de distância da parte central da planta industrial, em uma região de difícil acesso. Somado a isso, a válvula, parte de interesse do problema, localiza em seu topo, a cerca de cinco andares de altura, dificultando ainda mais o seu acesso.

Em conversas com o cliente, o Autor deste trabalho identificou que a BebidasCo possuía limitações no monitoramento de vazamentos em válvulas desses tanques: essa etapa dependia exclusivamente de um único funcionário que trabalha há mais de 30 anos na empresa e está prestes a se aposentar. Durante toda sua carreira, ele foi capaz de de-

Figura 1 – Tanque reservatório de gás carbônico da empresa BebidasCo



Fonte: Elaboração do Autor

envolver uma habilidade de diagnosticar vazamentos apenas pelo barulho da válvula do tanque. Contudo, os tanques se encontram em uma área de difícil acesso, e o colaborador visita a região apenas uma vez por mês. Como consequência, a BebidasCo estima perder cerca de R\$100.000,00 (cem mil reais) em decorrência do vazamento de gás carbônico mensalmente.

Dessa forma, este trabalho se propõe a criar uma solução automatizada para monitoramento de vazamentos de gás carbônico em válvulas de reservatórios.

1.2 Motivação e Importância do Trabalho

O fomento ao empreendedorismo nas universidades desempenha um papel crucial no cultivo de comunidades de startups vibrantes e inovadoras (FELD, 2012). Universidades não são apenas centros de educação e pesquisa, mas também de fomento de criatividade e inovação. Ao integrar o empreendedorismo em seu currículo, promover incubadoras de empresas, e facilitar a conexão entre estudantes e o ecossistema de startups local, as universidades podem desbloquear o potencial empreendedor de seus alunos. A startup Máquina Feliz é um caso de sucesso desse ecossistema de inovação que vem sendo criado na Universidade de São Paulo, com raízes em uma disciplina que fomenta o desenvolvimento de soluções para problemas reais de empresas, e incubada no CIETEC.

Durante os dois primeiros anos de graduação, o Autor foi membro ativo do Núcleo de Empreendedorismo da USP (NEU), cuja principal missão é fomentar o desenvolvimento de ecossistemas de empreendedorismo e inovação no ambiente acadêmico. Isso não apenas prepara os estudantes para carreiras futuras em um mundo cada vez mais dominado

por tecnologia e inovação, mas também contribui para o crescimento econômico local, a criação de empregos e o desenvolvimento de soluções inovadoras para desafios globais. Assim, parte da inspiração em co-fundar uma empresa vem deste contato logo cedo com o empreendedorismo na Universidade.

Além disso, a motivação por desenvolver algo do início vem do interesse por colocar em prática os aprendizados vistos durante o curso de Engenharia. (MORRIS; KURATKO; CORNWALL, 2013) reforça essa ideia e defende ainda que programas de empreendedorismo em universidades não apenas preparam os estudantes para iniciar seus próprios negócios, mas também desenvolvem habilidades críticas, como pensamento criativo, resolução de problemas e liderança, que são valiosas em qualquer carreira profissional.

Do ponto de vista do problema que este trabalho se propõe a resolver, a Indústria 4.0 representa uma revolução no modo como as fábricas operam, introduzindo automação avançada, análise de dados em tempo real, e sistemas cibernéticos. Central para este paradigma é a conectividade, permitindo que máquinas, sistemas e pessoas interajam com eficiência sem precedentes. No entanto, um dos grandes desafios enfrentados, especialmente em países como o Brasil, é a falta de infraestrutura de conectividade robusta nas fábricas. Muitas indústrias brasileiras ainda estão desconectadas, limitando sua capacidade de implementar soluções avançadas de Indústria 4.0.

Neste contexto, o trabalho desenvolvido pelo autor se destaca por buscar romper essa barreira de conectividade. O foco está na criação de um modelo *embedded* que é implementado diretamente em hardware para monitorar operações de máquinas industriais, mais especificamente as válvulas de reservatórios industriais. A inovação principal do modelo proposto reside na sua capacidade de funcionar independentemente de uma conexão à rede de Internet.


O modelo utiliza a transmissão de sinais por ondas de baixa frequência, uma abordagem que, embora menos comum, oferece vantagens significativas em cenários de baixa conectividade. Essas ondas podem penetrar obstáculos físicos e propagar-se por longas distâncias sem a necessidade de uma infraestrutura de rede extensa. Dessa forma, o modelo não apenas facilita o monitoramento contínuo e em tempo real das condições operacionais das máquinas, mas também se adapta perfeitamente às limitações de infraestrutura encontradas em muitas fábricas brasileiras.

Assim, o Autor não apenas contribui com uma solução prática para um problema técnico, mas também propõe uma maneira de avançar na implementação da Indústria 4.0 em ambientes menos favorecidos pela tecnologia digital. Este trabalho, portanto, não só é relevante para a indústria em geral, mas também para a pesquisa e desenvolvimento tecnológico, abrindo novos caminhos para a inovação em ambientes industriais desafiadores.

1.3 Papel do Autor no Desenvolvimento do Trabalho

Além de co-fundar a startup, o Autor foi responsável pelo desenvolvimento do algoritmo de sinalização de vazamento na válvula dos reservatórios. Em um time de três pessoas dedicadas ao desenvolvimento deste *software*, o Autor foi responsável por liderar os avanços da equipe no tratamento do sinal recebido pelo sensor, desenvolver uma rede neural convolucional para identificar o comportamento anormal da válvula e integrar resultados do modelo com o *hardware* desenvolvido pela *startup*.

Figura 2 – Organograma da startup Máquina Feliz



Fonte: Elaboração Própria

O organograma da Figura 2, podemos ver que a startup "Máquina Feliz" opera com uma equipe enxuta de seis colaboradores, e a organização é modelada para maximizar eficiência e inovação em meio a recursos limitados. Há ainda três áreas principais, sendo elas:

1. Relacionamento financeiro e comercial;
2. Desenvolvimento de *hardware*;
3. Desenvolvimento de modelo de *machine learning*.

Nesse sentido, um dos fundadores assume um papel crucial, gerenciando as relações comerciais com clientes e abrangendo áreas vitais como sucesso do cliente, finanças e vendas. Paralelamente, a equipe de *hardware*, composta por dois engenheiros, dedica-se à construção e refinamento do protótipo que desempenha a função essencial de coleta e transmissão de dados acústicos das máquinas para uma central situada a 2 km de distância. Crucialmente, o Autor, junto a outros dois membros, lidera a equipe de desenvolvimento de *machine learning*. Este grupo é encarregado de desenvolver os algoritmos que analisam os dados enviados pelo *hardware*. A responsabilidade da equipe é de transformar esses dados brutos em informações úteis, capazes de sinalizar a falha das máquinas.

No desenvolvimento de seu projeto na startup "Máquina Feliz", o autor empregou uma série de ferramentas para otimizar o fluxo de trabalho e assegurar a entrega de soluções tecnológicas eficientes. Para a gestão do projeto, foram utilizadas metodologias ágeis, fundamentais para a adaptação rápida às mudanças e para a priorização de tarefas em um ambiente dinâmico de startup. Ferramentas como Notion e Trello se mostraram essenciais, ajudando a equipe a organizar tarefas, prazos e responsabilidades de forma

visual e acessível, garantindo que todos os membros da equipe permanecessem alinhados e focados nos objetivos do projeto.

Além disso, o autor recorreu a ferramentas de apresentação como o PowerPoint para comunicar progressos, resultados e estratégias tanto internamente quanto para *stakeholders* externos. Essas apresentações eram cruciais para manter a transparência do projeto e para reportar de maneira eficaz os avanços e os desafios encontrados pelo caminho.

Contudo, o principal instrumento utilizado pelo Autor foi a programação em Python. Essa linguagem oferece uma extensa biblioteca de pacotes e *frameworks* que facilitam a manipulação de dados, a modelagem estatística e a implementação de algoritmos de aprendizado de máquina. Com Python, o Autor foi capaz de construir um *pipeline* de preparação dos dados coletados e treinar um modelo de classificação para determinação do estado de funcionamento da válvula do tanque.

1.4 Objetivo e Escopo

O trabalho de formatura proposto pelo autor tem como objetivo central o desenvolvimento de um protótipo no contexto da Indústria 4.0, abrangendo desde a fase inicial de concepção e descoberta das necessidades do cliente até a prototipação e coleta de resultados práticos junto ao mesmo. Este trabalho está estrategicamente dividido em duas etapas principais, cada uma com objetivos específicos e complementares, visando um entendimento profundo das necessidades do cliente e a aplicação prática de soluções tecnológicas.

A primeira etapa é focada em Customer Discovery. Nesta fase, o principal objetivo é entender a dor do cliente, identificando não apenas os problemas superficiais mas também as causas raízes dos mesmos. Isso envolve um processo de entrevistas detalhadas com o cliente, observações diretas das operações e coleta de feedback para entender melhor os desafios enfrentados no dia a dia da operação industrial. A partir dessas informações, hipóteses são levantadas sobre as causas dos problemas e, em colaboração com o cliente, prioriza-se quais desafios devem ser abordados. Este processo garante que o projeto mantenha um foco alinhado com as necessidades reais do cliente, aumentando a relevância e o impacto potencial da solução desenvolvida.

A segunda etapa é o Desenvolvimento do Protótipo. Com base nas informações e prioridades definidas na fase de Customer Discovery, esta fase concentra-se na construção de um protótipo que aborde o problema identificado. Este protótipo envolve a coleta de áudio das operações das válvulas industriais, o tratamento desses dados e a construção de um modelo de machine learning que possa classificar a operação da válvula com precisão. Este modelo visa detectar anomalias, prever falhas e melhorar a eficiência geral do processo, apoiando-se em tecnologias avançadas para oferecer uma solução robusta e inovadora.

Portanto, os objetivos deste trabalho de formatura são não só desenvolver um protótipo que melhore significativamente a operação das válvulas industriais através de análises

preditivas, mas também garantir que o processo de desenvolvimento seja iterativo e centrado no cliente, desde a fase de concepção até a implementação final. Essa abordagem assegura que o projeto final seja profundamente alinhado com as necessidades do usuário final, proporcionando uma solução verdadeiramente valiosa no ambiente da Indústria 4.0. Finalmente, no capítulo "5. Resultados e Discussão", será apresentado o impacto das ações implementadas para a resolução do problema, bem como os avanços obtidos pelo projeto tanto no algoritmo de *machine learning* quanto no uso de ondas de rádio de baixa frequência para transmissão de informações por longas distâncias.

1.5 Organização do Trabalho

Este Trabalho de Formatura está dividido em seis capítulos. O primeiro consiste na Introdução, e já foi apresentado.

O segundo capítulo aborda a Revisão Bibliográfica, apresentando o referencial teórico e o arcabouço acadêmico dos conceitos de Engenharia de Produção utilizados ao longo do trabalho. Este capítulo explora temas que foram fundamentais não apenas para a elaboração do diagnóstico dos desafios enfrentados pela BebidasCo, mas também para o desenvolvimento do protótipo do projeto. As ações implementadas na empresa foram fortemente embasadas nos conceitos estudados pelo autor durante o curso de Engenharia de Produção, e os conceitos de tratamento de sinais e *machine learning* foram amplamente estudados durante duplo-diploma do Autor na École CentraleSupélec.

O terceiro capítulo do Trabalho de Formatura é dedicado à seção de Diagnósticos da empresa. Neste capítulo, será descrita a metodologia empregada para diagnosticar os problemas enfrentados pela BebidasCo e para o levantamento de soluções potenciais. Serão destacados as principais dores da equipe de Gestão da Produção relacionadas à operação dos reservatórios de gás carbônico, bem como *insights* de entrevistas de *Customer Discovery* com os principais *stakeholders* do projeto. Ao final, haverá uma priorização dos problemas levantados e a especificação do problema a ser resolvido no capítulo seguinte.


O quarto capítulo foca no Desenvolvimento do Trabalho, detalhando os planos de ação que foram elaborados pelo autor do Trabalho de Formatura em colaboração com sua equipe, e como esses planos foram implementados na prática. Este capítulo aborda a execução dos planos criados para resolver os problemas identificados no capítulo de Diagnóstico, sobretudo para o *squad* do Autor relacionado ao desenvolvimento do modelo de *machine learning*.

No quinto capítulo, são apresentados os Resultados e a Discussão sobre os mesmos. Este capítulo aborda os resultados da etapa de coleta e processamento de áudio, bem como os resultados teóricos obtidos pelo modelo de *machine learning*. Além disso, há também uma sessão dedicada ao teste realizado *in loco* na fábrica da empresa BebidasCo, bem como uma discussão dos avanços do projeto com o Diretor de IoT.

Por fim, o trabalho conclui com um capítulo de Conclusão, onde o autor apresenta as considerações finais sobre o Trabalho e o aprendizado obtido ao longo do processo.

A estrutura lógica do Trabalho de Formatura é ilustrada no esquema 3 a seguir, organizando de forma clara a progressão e a integração entre os capítulos.

Figura 3 – Estrutura do Trabalho de Formatura



Fonte: Elaboração Própria

2 REVISÃO DA LITERATURA

Neste capítulo, será realizada uma análise detalhada da literatura, abordando conceitos e estratégias de resolução que se alinham à meta estabelecida no capítulo anterior. Esse processo visa fornecer uma fundamentação sólida para o método elaborado no contexto deste estudo.

Este capítulo divide a Revisão da Literatura em duas sessões principais: (i) revisão da temática de Indústria 4.0 e Internet das Coisas (IoT, do inglês *Internet of Things*) e (ii) revisão de temas de Negócios e *Startups*.

2.1 Indústria 4.0 e Internet das Coisas

Esta seção está dividida em cinco partes. Primeiro, há uma contextualização das inovações industriais, Indústria 4.0 e Internet das Coisas, seguido de uma sessão para explicar a Cadeia de Valor de Dados, como foco específico em Internet das Coisas. Em seguida, o Autor realiza uma revisão de conceitos de *Machine Learning*, Redes Neurais Convolucionais e, para finalizar, Tratamento de Sinais.

2.1.1 Inovações industriais e Internet das Coisas

A evolução da indústria tem sido marcada por ondas sucessivas de inovação, desde a mecanização e uso do vapor na Primeira Revolução Industrial até a digitalização e uso de tecnologias inteligentes que caracterizam a Quarta Revolução Industrial, ou Indústria 4.0. Esta última fase destaca-se pelo potencial transformador das tecnologias digitais, incluindo a Internet das Coisas, inteligência artificial (IA), robótica avançada, impressão 3D, e análise de big data. (SCHWAB, 2016) argumenta que esta nova era, diferenciada pelas inovações que desfazem os limites entre os mundos físico, digital e biológico, tem o potencial não apenas de alterar os modelos de negócios e indústrias, mas também de redefinir o que significa ser humano. Essas tecnologias estão convergindo para criar sistemas de produção mais flexíveis, eficientes e adaptáveis, promovendo uma mudança paradigmática na maneira como os produtos são fabricados, os serviços são oferecidos e as cadeias de valor são configuradas.

Um dos pilares da Indústria 4.0 é a Internet das Coisas, que permite a interconexão digital de máquinas, sistemas e ativos, facilitando a coleta, troca e análise de dados em tempo real. Em (BUYA; DASTJERDI, 2016b) a Internet das Coisas é apresentada não apenas como um avanço tecnológico, mas como uma revolução que reconfigura as fronteiras entre o digital e o físico, redefinindo fundamentalmente a maneira como vivemos, trabalhamos e interagimos. Esta obra profunda oferece uma visão abrangente que atravessa a mera conectividade de dispositivos inteligentes, mergulhando nas ramificações de como a IoT facilita uma integração sem precedentes de sistemas, potencializa a automação em escala e promove

uma interação mais natural e intuitiva entre humanos e máquinas. Isso não apenas otimiza a eficiência operacional, mas também habilita modelos de negócios inovadores, como a manufatura sob demanda e soluções personalizadas para o cliente final. A implementação da IoT, combinada com análises avançadas e IA, pode levar ao desenvolvimento de sistemas de manufatura autônomos, onde as decisões são tomadas com base em dados em tempo real, sem intervenção humana direta, melhorando significativamente a qualidade, a segurança e a sustentabilidade dos processos de produção.

A Internet das Coisas (IoT) em aplicações industriais, frequentemente referida como *Industrial Internet of Things* (IIoT), está revolucionando a maneira como as indústrias operam, oferecendo novos níveis de eficiência, automação e inteligência operacional. A IIoT utiliza sensores, máquinas, dispositivos inteligentes e sistemas de análise de dados para criar redes de dispositivos conectados capazes de coletar, trocar e analisar enormes volumes de dados em tempo real. Essa capacidade de integrar e interpretar dados de várias fontes está permitindo que as indústrias otimizem processos, melhorem a produtividade, reduzam custos e fomentem a inovação. Este trabalho foca na utilização de sensores e no uso de Inteligência Artificial para resolução de problema de vazamento em válvulas de tanques de gás carbônico da empresa BebidasCo.

Uma das principais aplicações da IIoT é na manutenção preditiva. Equipamentos industriais equipados com sensores podem monitorar constantemente seu próprio estado e desempenho, prevendo falhas antes que elas ocorram. Isso não apenas reduz o tempo de inatividade inesperado, mas também estende a vida útil do maquinário, resultando em economias significativas de custo e melhorias na eficiência operacional. Além disso, a análise de dados em tempo real possibilitada pela IIoT pode ajudar a otimizar a cadeia de suprimentos, ajustando a produção com base na demanda prevista e na disponibilidade de recursos, minimizando assim o desperdício e melhorando a entrega ao cliente.


2.1.2 Cadeia de Valor de Dados

O verdadeiro valor da Internet das Coisas (IoT) reside nos dados que ela fornece e nas percepções que resultam desses dados (Boston Consulting Group, 2018). Estudo liderado pela consultoria estadunidense Boston Consulting Group suporta a ideia de que há uma cadeia de valor na geração dos dados, e isso está diretamente associado à maturidade das soluções propostas. Especialmente em projetos de IoT, (Boston Consulting Group, 2018) sugere três principais etapas no processo do desenvolvimento de uma solução de IoT, como representado na figura 4: (i) Aquisição de dados; (ii) Desenvolvimento de produto ou serviço com esses dados; e (iii) Venda e suporte ao consumidor.

Este trabalho foca especialmente nas etapas (i) e (ii) do desenvolvimento de uma solução de IoT. Como a startup já possuía um cliente pagante durante etapa de desenvolvimento, o Autor foca especialmente nas etapas de Aquisição de Dados, com o uso de sensores, e

na elaboração de um Modelo de Análise e Processamento dos dados captados usando técnicas de *Machine Learning* e de tratamento de sinais.

Figura 4 – Cadeia de Valor de Dados



Fonte: (Boston Consulting Group, 2018)

2.1.3 Hardware

Esta seção apresentará uma introdução ao uso de *hardware* em soluções de IoT, cobrindo também o conceito de modelo embarcado, microcontroladores (citando especificamente dois exemplos: ESP32 e Raspberry Pi) e aspectos de comunicação, como LoRaWAN.

No contexto de IoT, os *hardwares* são componentes cruciais responsáveis por coletar, processar e transmitir dados, transformando objetos comuns em "inteligentes" (BUYA; DASTJERDI, 2016a). (BAHGA; MADISSETTI, 2014) reforça o papel central nas soluções de IoT, começando pela coleta de dados, onde sensores e dispositivos atuam como pontos de entrada essenciais para a obtenção de informações em tempo real. Em muitas aplicações de IoT, a necessidade de processamento e decisões em tempo real torna impraticável a dependência de uma constante comunicação com a nuvem, por isso, microcontroladores (como ESP32 e Raspberry Pi) são empregados para realizar o processamento localmente, o que contribui significativamente para a redução da latência, comumente conhecido por modelos embarcados.

(BAHGA; MADISSETTI, 2014) define um modelo embarcado em IoT pelo uso de algoritmos de *machine learning* implementados diretamente no *hardware* de um dispositivo IoT. Isso permite que o dispositivo execute tarefas de aprendizado de máquina localmente, sem depender de uma conexão constante com a nuvem.

Além disso, a comunicação é outro aspecto crítico, envolvendo não apenas protocolos tradicionais como Wi-Fi e Bluetooth, mas também tecnologias otimizadas para IoT, como LoRaWAN, que oferecem alta penetração e baixo consumo energético. A eficiência energética é especialmente valorizada em dispositivos de IoT, muitos dos quais operam com baterias em locais remotos e são projetados para maximizar a economia de energia.

2.1.3.1 ESP32

O ESP32 é um microcontrolador de baixo custo e altamente integrado, amplamente utilizado em projetos de Internet das Coisas (IoT) devido à sua combinação robusta de conectividade e capacidade de processamento (BAHGA; MADISETTI, 2014). O ESP32 é equipado com uma rica variedade de recursos de conectividade, incluindo Wi-Fi e Bluetooth, que são integrados diretamente no chip. Essa conectividade integrada facilita a construção de dispositivos IoT que precisam se comunicar com outras máquinas ou serviços baseados em nuvem, sem a necessidade de módulos adicionais, tornando o design geral mais compacto e eficiente em termos de energia.

Outro ponto forte do ESP32 é seu conjunto abrangente de interfaces periféricas. O chip oferece suporte a uma variedade de interfaces, como GPIO (*General Purpose Input/Output* para comunicação e controle de dispositivos externos) e I2C (*Inter-Integrated Circuit* possibilita conectar e orquestrar mais de um sensor). Isso o torna altamente versátil para conectar-se a vários sensores e atuadores, sendo capaz de lidar com as demandas de diversos projetos eletrônicos, desde simples microfones até automações complexas.

2.1.3.2 Raspberry Pi

O Raspberry Pi é equipado com um processador mais potente em comparação com muitos microcontroladores, incluindo o ESP32. Isso o torna adequado para tarefas que exigem mais capacidade de computação e memória, como processamento de imagens, análises mais complexas e a execução de múltiplas aplicações simultaneamente. Ele pode rodar sistemas operacionais completos como o Linux, fornecendo um ambiente de desenvolvimento robusto para software (Raspberry Pi Foundation, 2024). Para aplicações que exigem modelos de machine learning embarcados, a escolha entre Raspberry Pi e ESP32 pode depender do tamanho e da complexidade do modelo. O Raspberry Pi é mais adequado para modelos mais complexos e tarefas que requerem maior poder de processamento ou a necessidade de processar grandes volumes de dados rapidamente. Por outro lado, para aplicações que necessitam de operação eficiente e contínua com modelos de ML mais leves, o ESP32 pode ser a escolha ideal, devido à sua eficiência energética e capacidade de operar de forma autônoma em ambientes com energia limitada.

2.1.3.3 LoRaWAN

LoRaWAN (*Long Range Wide Area Network*) é uma tecnologia de comunicação para redes de área ampla projetada especificamente para IoT (LoRa Alliance, 2017). É um protocolo de que usa a tecnologia LoRa (Long Range) para comunicação sem fio de longo alcance com baixo consumo de energia. LoRaWAN é principalmente conhecida por sua capacidade de transmitir sinais a distâncias de até 15 km em ambientes rurais e mais de 5 km em ambientes urbanos densos. Essa capacidade é crucial para aplicações de IoT que

requerem cobertura ampla, minimizando a necessidade de múltiplos pontos de repetição ou infraestrutura de rede complexa.

2.1.4 *Machine Learning*

O aprendizado de máquina é descrito como um conjunto de técnicas e algoritmos que permitem que computadores melhorem seu desempenho em tarefas específicas com base em dados (MOHRI; ROSTAMIZADEH; TALWALKAR, 2012). Esta ciência combina elementos de estatística, inteligência artificial e ciência da computação para criar modelos que podem fazer previsões ou tomar decisões sem serem explicitamente programados para cada situação específica.

(WITTEN; FRANK, 2005) expuseram quatro principais conceitos subjacentes aos diversos algoritmos em aprendizado de máquina: o aprendizado supervisionado de classificação, que envolve a utilização de exemplos previamente classificados para construir modelos preditivos; o aprendizado de regras de associação, focado na descoberta de relações entre atributos que influenciam o valor de classe de uma instância; o aprendizado não supervisionado de agrupamento, que busca agrupar exemplos com base na similaridade conforme critérios definidos; e o aprendizado de regressão, que visa a criação de modelos matemáticos para prever valores contínuos de classes, estabelecendo correlações entre variáveis preditoras e a variável de interesse.

Falando especificamente sobre classificação, que será a técnica utilizada neste trabalho, (HASTIE; TIBSHIRANI; FRIEDMAN, 2009) a define como um problema central no aprendizado de máquina supervisionado, onde o objetivo é prever a categoria ou classe de uma observação com base em suas características. (LECUN et al., 1998) alavancou as redes neurais para representarem uma das abordagens mais versáteis e poderosas em aprendizado de máquina para a tarefa de classificação. Originárias da tentativa de modelar processos neurais biológicos, as redes neurais artificiais são sistemas compostos por camadas de nós ou "neurônios", interconectados de maneira a simular uma espécie de processamento cerebral. Esses sistemas são capazes de aprender padrões complexos a partir de grandes volumes de dados, tornando-os particularmente adequados para a classificação em diversos domínios, sobretudo no reconhecimento de imagens.

2.1.4.1 Problemas de classificação

Modelos de classificação são um pilar fundamental do machine learning, sendo projetados para prever a categoria ou classe de objetos, eventos ou condições com base em suas características de entrada (MITCHELL, 1997). Os modelos de classificação geralmente envolvem o aprendizado supervisionado, onde um modelo é treinado usando um conjunto de dados rotulado. O objetivo é que o modelo aprenda a relação entre as características de

entrada e a saída (rótulo) de modo que ele possa prever o rótulo de novas instâncias não vistas.

Dentre os métodos mais comuns, destaca-se as redes neurais convolucionais para modelos de classificação. As Redes Neurais Convolucionais (CNNs) são uma classe especializada de redes neurais que têm provado ser extremamente eficazes para tarefas que envolvem a análise de imagens (GOODFELLOW; BENGIO; COURVILLE, 2016). Elas utilizam uma arquitetura especialmente adequada para capturar padrões espaciais e temporais em dados, o que as torna ideais para tarefas como reconhecimento de imagem e vídeo.


2.1.4.2 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs) são uma classe de Redes Neurais profundas especializadas no processamento de dados que possuem uma topologia conhecida, como imagens. (KRIZHEVSKY; SUTSKEVER; HINTON, 2012) reforça que a arquitetura única das CNNs as torna excepcionalmente boas para capturar padrões hierárquicos nos dados - por exemplo, a partir de linhas e bordas em níveis mais baixos até formas complexas e objetos em níveis mais altos.

A capacidade de uma CNN de classificar imagens decorre de sua arquitetura, que imita de certa forma o mecanismo de visão do cérebro humano. (KRIZHEVSKY; SUTSKEVER; HINTON, 2012) descreve uma CNN típica em várias camadas, cada uma projetada para realizar uma tarefa específica de processamento de imagem:

1. Camadas Convolutivas: O coração da CNN. Aqui, filtros (ou *kernels*) são aplicados à imagem para produzir mapas de características através de operações de convolução. Esses filtros automaticamente aprendem a detectar características importantes durante o treinamento da rede.
2. Camadas de *Pooling* (Agrupamento): Seguem as camadas convolutivas e são usadas para reduzir as dimensões dos mapas de características, diminuindo assim o número de parâmetros a serem aprendidos e o esforço computacional. A operação mais comum de pooling é a max pooling, que seleciona os valores máximos de áreas específicas dos mapas de características.
3. Camadas Densas (*Fully Connected*): Após várias camadas convolutivas e de pooling, a rede tem camadas densas que têm a função de classificar a imagem com base nas características extraídas. Essas camadas são tradicionais camadas de redes neurais, onde todos os neurônios entre camadas consecutivas são conectados.
4. Camada de Saída: A última camada densa da rede, onde o número de neurônios corresponde ao número de classes de saída. A função de ativação usada nesta camada costuma ser a softmax para tarefas de classificação multiclasse, que distribui as probabilidades entre as várias classes.

Figura 5 – Exemplo de Rede Neural Convolucional



Fonte: LeNet 5 (Google)

2.1.4.3 Função de perda: entropia cruzada

A função de perda quantifica a diferença entre a previsão do modelo e os valores reais dos dados (GOODFELLOW; BENGIO; COURVILLE, 2016). É um componente essencial no treinamento de modelos, pois fornece um critério a ser minimizado durante o processo de aprendizagem. A função de perda orienta a otimização do modelo, ajustando os pesos de forma que o modelo faça previsões cada vez mais precisas.

A entropia cruzada é uma função de perda comumente usada em problemas de classificação. Originária da teoria da informação, a entropia cruzada mede a diferença entre duas distribuições de probabilidade: a distribuição real dos dados e a distribuição prevista pelo modelo (MITCHELL, 1997). Em contextos de classificação, isso se traduz em comparar a probabilidade prevista pelo modelo para a classe verdadeira de cada amostra com a distribuição ideal, onde a probabilidade da classe verdadeira é 1.

Para um problema de classificação com C classes, a entropia cruzada entre a distribuição verdadeira p e a distribuição estimada q para uma única amostra é dada por:

$$H(p, q) = - \sum_{i=1}^C p_i \log(q_i)$$

Onde:

- p_i é a probabilidade verdadeira da classe i , normalmente 0 ou 1 em problemas de classificação onde o verdadeiro rótulo da classe é conhecido.
- q_i é a probabilidade prevista de que a amostra pertença à classe i , como calculado pelo modelo.
- O logaritmo é naturalmente baseado em e , mas outras bases também podem ser usadas, como base 2 ou 10.

Aplicação em Machine Learning

Em problemas práticos de classificação, como na classificação de múltiplas classes, a entropia cruzada é comumente usada da seguinte forma:

- **Codificação *One-hot*:** O vetor de rótulos verdadeiros p é codificado em *one-hot*. Isso significa que se uma amostra pertence à classe j , então $p_j = 1$ e $p_i = 0$ para todos $i \neq j$.
- ***Softmax*:** Na camada de saída do modelo, a função *Softmax* geralmente é aplicada para obter as probabilidades previstas q que somam 1. A função *Softmax* é definida como:

$$q_i = \frac{e^{z_i}}{\sum_{k=1}^C e^{z_k}}$$

onde z_i são os *logits* (saídas antes da ativação *Softmax*) para a classe i .

- **Cálculo da Entropia Cruzada:** Para cada amostra, o termo $-\log(q_i)$ é considerado apenas para a classe verdadeira i (a que tem $p_i = 1$). A entropia cruzada é frequentemente calculada para um lote de amostras e a média é usada para estimação do gradiente durante o treinamento.

Dessa forma, a entropia cruzada é especialmente útil porque penaliza fortemente as previsões que estão confiantemente erradas. Quanto mais a previsão do modelo diverge da verdade, maior o valor da entropia cruzada, incentivando assim o modelo a ajustar suas previsões mais precisamente de acordo com a realidade observada. Esse método proporciona uma avaliação direta da qualidade das probabilidades previstas pelo modelo, tornando-o uma escolha popular para a função de perda em modelos de classificação.

2.1.4.4 Métricas de avaliação

Nesta subseção, duas principais métricas principais para avaliação de CNNs serão apresentadas: (i) acurácia e (ii) matriz de confusão (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.1.4.4.1 Acurácia

A acurácia é uma das métricas mais comuns para avaliação de modelos de classificação. Ela mede a proporção de previsões corretas (tanto verdadeiros positivos quanto verdadeiros negativos) em relação ao total de casos analisados. A formulação é dada por:

$$\text{Acurácia} = \frac{\text{Número de previsões corretas}}{\text{Total de previsões}}$$

2.1.4.4.2 Matriz de confusão

A matriz de confusão fornece uma matriz que não apenas conta os erros de classificação, mas os categoriza por tipo (por exemplo, confundindo uma classe com outra). A matriz é composta por quatro tipos de informação: verdadeiros positivos (TP), falsos positivos (FP),

verdadeiros negativos (TN) e falsos negativos (FN), permitindo análises mais detalhadas como precisão, recall e F1-score.

Figura 6 – Matriz de confusão

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Fonte: Elaboração Própria

Suponha que, após treinar e testar uma CNN em um conjunto de dados de imagens para classificação de duas classes (A, B), a matriz de confusão obtida foi:

	Predito A	Predito B
Real A	80	20
Real B	30	70

Avaliação das Métricas

Precisão para cada classe:

- Precisão A = $\frac{80}{80+30} = 0.727$

- Precisão B = $\frac{70}{70+20} = 0.778$

Recall para cada classe:

- Recall A = $\frac{80}{80+20} = 0.800$

- Recall B = $\frac{70}{70+30} = 0.700$

F1-Score para cada classe:

- F1-Score A = $2 \times \frac{0.727 \times 0.800}{0.727 + 0.800} = 0.762$

- F1-Score B = $2 \times \frac{0.778 \times 0.700}{0.778 + 0.700} = 0.736$

2.1.5 Tratamento de Sinais

O tratamento de sinais é um campo vasto e interdisciplinar que abrange a análise, processamento e interpretação de sinais para extrair informações úteis ou modificar esses sinais de alguma forma benéfica. Sinais podem ser qualquer coisa que transmita informação - desde sinais acústicos, como a fala e a música, até sinais elétricos, como os encontrados em equipamentos eletrônicos, e sinais biomédicos, como eletrocardiogramas (OPPENHEIM; SCHAFER, 1999).

No cerne do tratamento de sinais está a capacidade de transformar sinais de uma forma que torne certas características mais evidentes ou para reduzir ou eliminar informações desnecessárias ou indesejadas. Uma das técnicas utilizadas é a Transformada de Fourier.

2.1.5.1 Transformada de Fourier

A Transformada de Fourier é um princípio matemático fundamental na análise de funções ou sinais, permitindo decompor uma função em seus componentes de frequência. Ela é capaz de transitar entre o domínio do tempo e o domínio da frequência, oferecendo uma perspectiva detalhada sobre a estrutura interna dos sinais (KÖRNER, 2003). A formulação matemática da Transformada de Fourier de uma função contínua $f(t)$ no tempo é dada por:

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt$$

onde ω representa a frequência angular e j é a unidade imaginária. A Transformada de Fourier Inversa permite recuperar $f(t)$ a partir de $F(\omega)$:

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega)e^{j\omega t} d\omega \quad (2.1)$$


(KÖRNER, 2003) enumera que uma das principais aplicações da Transformada de Fourier é no processamento de sinais digitais, onde é usada para filtragem, compressão de dados, e análise espectral. A versão discreta da transformada, conhecida como Transformada Discreta de Fourier (DFT), e sua implementação computacional eficiente, a Transformada Rápida de Fourier (FFT), são fundamentais para o processamento digital de sinais, permitindo a análise e manipulação eficaz de sinais digitais em uma ampla gama de aplicações. Para o contexto deste trabalho, a Transformada Rápida de Fourier será utilizada para converter o áudio coletado no domínio da frequência para posterior análise com o espectrograma.

2.1.5.2 Espectrograma

Os espectrogramas são representações visuais que mostram como as intensidades das várias frequências de um sinal variam com o tempo (GOLD; MORGAN; ELLIS, 2011). Essa ferramenta é amplamente utilizada em análise de sinais para visualizar o espectro de

frequências de sinais de áudio, facilitando a identificação de padrões, a análise de características e a detecção de eventos. Os espectrogramas são obtidos através da Transformada de Fourier de Curto Termo (STFT), que divide o sinal em segmentos temporais e aplica a Transformada de Fourier a cada segmento, permitindo a análise da frequência ao longo do tempo.

Figura 7 – Exemplo de Espectrograma



Fonte: Elaboração do Autor

2.1.5.3 Espectrograma de Mel

A escala de Mel é uma escala perceptual de tons que é usada principalmente em processamento de áudio, especialmente em aplicações como o reconhecimento automático de voz e a compressão de áudio. Essa escala é baseada na percepção humana do som, de modo que ela reflete mais precisamente como os ouvintes humanos percebem as frequências do som do que a escala de frequência linear ou a escala logarítmica (STEVENS; VOLKMANN; NEWMAN, 1937). A ideia principal por trás da escala de Mel é que as diferenças entre tons consecutivos são percebidas igualmente ao longo da escala pelo ouvido humano.

A escala de Mel é definida por uma fórmula que mapeia a frequência em hertz para mels. Uma aproximação comum é a seguinte:


$$\text{Mel}(f) = 2595 \log_{10} \left(1 + \frac{f}{700} \right)$$

onde f é a frequência em hertz. Essa fórmula tenta simular a sensação auditiva de que, à medida que as frequências aumentam, são necessários incrementos maiores para que uma diferença seja percebida pelo ouvido.

Um avanço significativo na análise de espectrogramas é o Espectrograma de Mel, que é derivado da escala Mel. A escala Mel, como mencionado, é sobretudo uma escala

perceptual de pitches julgados pelos ouvintes para estar em intervalos equidistantes uns dos outros, o que significa que ela é baseada na percepção humana do som, ao contrário da frequência linear (CHOI; FAZEKAS; SANDLER, 2017). O Espectrograma de Mel, portanto, usa a escala Mel para o eixo de frequência, proporcionando uma representação mais intuitiva e perceptualmente relevante das características do som. Isso é especialmente útil na análise e reconhecimento de sons, pois melhora a representação de características que são importantes para a percepção humana (JURAFSKY; MARTIN, 2019) .

Figura 8 – Exemplo de Espectrograma de Mel deste trabalho



Fonte: Elaboração do Autor

(CHOI; FAZEKAS; SANDLER, 2017) retrata em um passo a passo sobre como obter um espectrograma de Mel. O primeiro passo na criação de um espectrograma de Mel é realizar uma Transformada de Fourier de curto prazo (STFT) no sinal de áudio. Isso converte o sinal de sua forma temporal para uma forma espectral, onde cada ponto no tempo é mapeado para um espectro de frequências que compõem esse sinal naquele instante. Após a STFT, as frequências são mapeadas para a escala de Mel. Esta escala agrupa as frequências em "bancos de filtros Mel", que são faixas de frequências que correspondem à percepção auditiva humana. As frequências mais baixas são divididas em faixas mais estreitas, enquanto as altas são agrupadas em faixas mais largas, refletindo como o ouvido humano percebe as mudanças de frequência. A energia (ou amplitude) das frequências dentro de cada banco de filtro é somada, e então o logaritmo dessa energia é calculado. Isso também se alinha melhor com a percepção humana, pois o ouvido humano percebe a intensidade do som de forma logarítmica. O resultado final, como apresentado na Figura 8, é representado como uma imagem onde o eixo horizontal representa o tempo, o eixo vertical representa os bancos de filtros de Mel, e a cor ou a intensidade de cada ponto na

imagem representa a magnitude (agora em escala logarítmica) da energia naquele banco de filtro e naquele momento no tempo.

2.2 Desenvolvimento de Produto: uma Perspectiva de Negócios e *Startups*

Esta segunda sessão da Revisão da Literatura foca no desenvolvimento de produto, mas sob uma perspectiva de negócios, não mais puramente técnica. Esta sessão inicia-se com uma revisão do tópico de *Design Thinking*, de Metodologias Ágeis e conceitos de *Lean Startup*. Em seguida, aborda uma revisão do procedimento de resolução de problemas dentro de organizações.

2.2.1 *Design Thinking*

A metodologia de *Design Thinking* é uma abordagem centrada no ser humano para inovação, que integra as necessidades das pessoas, as possibilidades da tecnologia e os requisitos para o sucesso do negócio. (EMIR, 2015) cita cinco etapas fundamentais para o desenvolvimento de produto:


1. **Empatia:** A primeira etapa é a Empatia, que envolve a compreensão profunda das necessidades, desejos e desafios dos usuários finais. Isso é alcançado por meio de observações, entrevistas e a imersão no ambiente e experiências dos usuários. O objetivo é colher insights ricos e humanos que servirão de base para as próximas etapas do processo.
2. **Definição:** Após a coleta de insights, a etapa de Definição busca identificar e delinear claramente o problema a ser resolvido. Isso envolve sintetizar as informações coletadas durante a fase de empatia em uma declaração de problema bem articulada, que captura as necessidades e desafios dos usuários de forma concisa.
3. **Ideação:** Na fase de Ideação, os participantes são incentivados a gerar uma ampla variedade de ideias e soluções possíveis para o problema definido. Técnicas de brainstorming, esboços e prototipagem rápida são comumente utilizadas para explorar diferentes abordagens e estimular a criatividade. O objetivo é fomentar o pensamento divergente e reunir uma seleção diversificada de soluções possíveis.
4. **Prototipagem:** A Prototipagem é a etapa em que as ideias selecionadas são transformadas em modelos tangíveis. Estes protótipos não precisam ser refinados ou funcionais; eles são criados rapidamente para testar conceitos e receber feedback. A prototipagem permite iterar rapidamente sobre ideias, refinando-as e aprimorando-as com base no feedback dos usuários e outras partes interessadas.
5. **Teste:** Finalmente, a etapa de Teste envolve avaliar os protótipos com usuários reais para coletar feedback sobre sua usabilidade, eficácia e apelo. Esta fase é crucial para

entender como as soluções propostas atendem às necessidades dos usuários e quais ajustes são necessários para melhorar o design. O processo de Design Thinking é iterativo, e o feedback coletado nesta fase pode levar a novas rodadas de empatia, definição, ideação e prototipagem.

(FOUNDATION, 2016) caracteriza a metodologia do *Design Thinking* como algo não linear. Por exemplo, as equipes podem saltar da etapa de teste para a etapa de definição se os testes revelarem insights que redefinam o problema. Ou, um protótipo pode despertar uma nova ideia, levando a equipe a retroceder para a etapa de ideação. Testes também podem criar novas ideias para projetos ou revelar insights sobre os usuários.

A figura 9 ilustra o caráter não linear dessa metodologia.

Figura 9 – *Design Thinking*: um processo não linear



Fonte: (FOUNDATION, 2016)

2.2.2 Gestão Ágil

O Manifesto Ágil (BEEDLE ARIE VAN BENNEKUM, 2001), desenvolvido por um grupo de desenvolvedores de software em 2001, revolucionou o campo da gestão de projetos e desenvolvimento de software. É um conjunto de princípios orientadores que priorizam flexibilidade, colaboração e capacidade de resposta na entrega de valor aos clientes.

O Manifesto Ágil enfatiza quatro valores-chave:

1. Indivíduos e interações mais que processos e ferramentas: Prioriza a importância da comunicação eficaz, colaboração e empoderamento dos indivíduos dentro de uma equipe;

2. Software funcional mais que documentação abrangente: Enfatiza a entrega de software tangível e funcional que atenda às necessidades dos clientes, em vez de focar somente em documentação extensiva;
3. Colaboração com o cliente mais que negociação de contratos: Promove o envolvimento ativo e a colaboração contínua com os clientes ao longo do processo de desenvolvimento, permitindo que os requisitos evoluam com base no feedback do cliente;
4. Responder a mudanças mais que seguir um plano: Reconhece a inevitabilidade da mudança e defende flexibilidade e adaptabilidade para responder a novos insights e dinâmicas de mercado.

2.2.3 *Lean Startup*

A metodologia *Lean Startup*, introduzida por (RIES, 2011), ganhou atenção significativa no âmbito do desenvolvimento de startups e inovação. Inspirada nos princípios da manufatura enxuta e nas metodologias de desenvolvimento ágil, a abordagem *Lean Startup* visa ajudar empreendedores a navegar pelas incertezas e riscos associados ao lançamento de novos empreendimentos. (RIES, 2011) baseia-se em suas experiências como empreendedor no setor de tecnologia e incorpora conceitos de desenvolvimento do cliente, design thinking e melhoria contínua para criar um framework para construir startups de sucesso.

As raízes do *Lean Startup* podem ser rastreadas até os princípios da manufatura enxuta popularizados pela Toyota nos anos 1950 (LIKER, 2004). O foco da Toyota na eliminação de desperdícios, otimização da criação de valor e melhoria contínua forneceu uma base sólida para a metodologia *Lean Startup*. Ries refinou ainda mais esses conceitos incorporando ideias do desenvolvimento de clientes, conforme defendido por Steve Blank, e métodos ágeis de desenvolvimento de software.

A metodologia *Lean Startup* enfatiza uma abordagem sistemática e iterativa para o desenvolvimento de produtos e validação de mercado. Encoraja os empreendedores a construir um Produto Mínimo Viável (MVP) - uma versão básica de seu produto ou serviço que possibilita testes e aprendizados rápidos. O feedback e as percepções obtidas de usuários iniciais e clientes são usados para refinar o produto, validar suposições e tomar decisões baseadas em dados.

Dessa forma, essa metodologia se torna particularmente relevante em situações onde há alta incerteza, volatilidade do mercado ou recursos limitados. É aplicável a diversas indústrias e setores, incluindo startups de tecnologia, empresas sociais e iniciativas de inovação corporativa. A metodologia pode ser especialmente benéfica para startups que buscam criar inovações disruptivas ou entrar em mercados inexplorados, pois permite que iterem e pivoteiem com base em feedback em tempo real e percepções de mercado.

2.2.4 Minimum Viable Product (MVP)

O conceito de Produto Mínimo Viável (MVP) é um princípio fundamental na metodologia Lean Startup. Cunhado por (RIES, 2011), o MVP representa a versão mais básica de um produto ou serviço que pode ser desenvolvida e lançada para coletar feedback de usuários pioneiros e clientes. O MVP é projetado para testar suposições, validar hipóteses e aprender com o uso no mundo real.

O desenvolvimento de um MVP envolve identificar as principais características ou funcionalidades que proporcionam valor aos clientes e estão alinhadas com a visão do produto. Essas características são priorizadas com base em sua importância e viabilidade para desenvolvimento inicial. O MVP é então construído, lançado e continuamente aprimorado com base no feedback do usuário e em insights orientados por dados. Este processo iterativo permite a rápida evolução e refinamento do produto.

A abordagem do MVP oferece vários benefícios, incluindo redução do tempo de entrada no mercado, menores custos de desenvolvimento e um foco nas necessidades e preferências do cliente. Ao lançar um MVP, os empreendedores podem validar suas suposições, ganhar tração inicial e tomar decisões informadas sobre o desenvolvimento futuro do produto. A abordagem do MVP é particularmente valiosa em mercados com alta incerteza e quando o conceito do produto ou a adequação ao mercado não estão bem estabelecidos.

2.2.5 Procedimento de Resolução de Problemas


O procedimento de resolução de problemas, conforme delineado por Hitoshi Kume (1993), enfatiza uma abordagem estruturada e sistemática para identificar, analisar e resolver problemas dentro de organizações. Essa metodologia se baseia na utilização de ferramentas estatísticas e na filosofia de melhoria contínua, fundamentos esses que são centrais para o controle de qualidade total. A essência do procedimento está em não apenas resolver problemas de maneira eficaz, mas também em prevenir sua recorrência, promovendo assim uma melhoria constante nos processos e produtos da organização (KUME, 1993).

(KUME, 1993) destaca a importância de uma abordagem passo a passo que começa com a definição clara do problema, seguida pela coleta e análise de dados relevantes. Este processo inclui a identificação das causas raiz do problema através de técnicas como o diagrama de Ishikawa e a análise de Pareto. Após a identificação das causas, são desenvolvidas estratégias de solução que são cuidadosamente implementadas e monitoradas para eficácia. A etapa final envolve a padronização das soluções bem-sucedidas e a reflexão sobre o processo de resolução de problemas, garantindo que os aprendizados sejam aplicados de forma a evitar problemas futuros. Esse ciclo de melhoria contínua é um aspecto fundamental da abordagem de (KUME, 1993) para a gestão da qualidade total.

2.2.5.1 Diagrama de causa x efeito

O diagrama de causa e efeito, também conhecido como diagrama de Ishikawa ou diagrama de espinha de peixe, é uma ferramenta visual utilizada para sistematicamente identificar, classificar e analisar as possíveis causas de um problema específico (ISHIKAWA, 1986). Desenvolvido por Kaoru Ishikawa na década de 1960, seu objetivo é facilitar a compreensão das raízes de um problema, promovendo uma análise aprofundada das circunstâncias que o cercam. Este diagrama é particularmente útil em processos de melhoria contínua e no controle de qualidade, servindo como um guia para equipes ao explorarem os fatores que contribuem para questões de desempenho ou qualidade.

Figura 10 – Exemplo de diagrama de Ishikawa



Fonte: (KUME, 1993)


O diagrama é estruturado de maneira que o problema seja colocado à direita, tipicamente na "cabeça" do peixe, com as principais categorias de causas potenciais estendendo-se à esquerda como "ossos" principais. Essas categorias variam dependendo do contexto, mas frequentemente incluem Pessoas, Métodos, Máquinas, Materiais, Medidas e Ambiente, seguindo a abordagem 6M, embora possam ser adaptadas conforme necessário. A partir destes "ossos" principais, ramificações menores são adicionadas para detalhar causas específicas. Este método promove uma visão abrangente e facilita a identificação de áreas-chave onde intervenções podem ser mais eficazes. Além disso, o uso do diagrama de causa e efeito estimula o trabalho em equipe e a colaboração, pois permite que diferentes perspectivas e experiências contribuam para a compreensão e solução do problema.

2.2.5.2 Matriz de impacto e esforço

A matriz de impacto e esforço, também conhecida como matriz de priorização ou matriz de Eisenhower (ANDERSEN; FAGERHAUG; BELTZ, 2010), é uma ferramenta de gestão de projetos e tomada de decisão que ajuda a classificar tarefas ou ideias com base em dois critérios principais: o impacto que terão se realizadas e o esforço necessário para implementá-las. Este método permite que gestores e equipes foquem recursos e atenção nas atividades que prometem o maior retorno sobre o investimento de tempo e esforço,

otimizando assim a eficiência e a eficácia na realização de projetos ou na resolução de problemas.

Figura 11 – Matrix de Impacto x Esforço



Fonte: (KUME, 1993)

A matriz é tipicamente dividida em quatro quadrantes, cada um representando uma combinação diferente de alto ou baixo esforço e alto ou baixo impacto. As tarefas no quadrante de alto impacto e baixo esforço são priorizadas acima de todas, pois são vistas como oportunidades de "vitórias rápidas" – atividades que proporcionam um valor significativo com relativamente pouca despesa de recursos. Em contrapartida, tarefas que requerem um alto esforço mas têm um baixo impacto são geralmente adiadas ou até mesmo descartadas. Usar esta matriz ajuda as equipes a evitar o desperdício de tempo em tarefas de baixo valor e a garantir que o foco esteja nas atividades mais críticas e recompensadoras.

Segundo (ANDERSEN; FAGERHAUG; BELTZ, 2010), aplicação da matriz de impacto e esforço pode variar desde o planejamento estratégico em nível organizacional até a gestão de tarefas diárias em projetos individuais. Sua simplicidade e flexibilidade a tornam uma ferramenta valiosa em uma ampla gama de contextos, incluindo desenvolvimento de produto, inovação, melhoria de processos e planejamento pessoal. Além de ajudar na priorização, a matriz pode ser um instrumento eficaz para fomentar discussões estratégicas em equipe, esclarecendo quais iniciativas devem receber recursos e atenção imediatos.

3 DIAGNÓSTICO

Este capítulo tem como objetivo apresentar um diagnóstico preliminar do desafio relatado pela empresa cliente BebidasCo. Este desafio motivou o Autor e sua equipe a implementar um dispositivo IoT para monitorar e sinalizar eventuais problemas de funcionamento nos reservatórios de gás carbônico do cliente, que será descrito com mais detalhe no capítulo seguinte.

Este capítulo está dividido em três etapas: (i) *Customer Discovery*, que consiste da primeira etapa do projeto de entendimento do problema; (ii) Desenvolvimento, em que o Autor expõe os principais artifícios técnicos usados para a prototipação do problema; e (iii) Testes, descrevendo a etapa de colocar em produção e instalar no cliente o protótipo construído.

3.1 Método

A escolha do tema deste Trabalho de Formatura consistiu em solucionar um problema relevante de planta industrial de bebida, mais especificamente do problema de vazamento em válvulas de tanques reservatórios de gás carbônico. Ao contrário de casos frequentes em que os problemas industriais encontram-se ocultos, e exigem um trabalho de mapeamento e descoberta desses empecilhos, na empresa BebidasCo o desafio encontrava-se relativamente claro.

A empresa BebidasCo realizava a aquisição de um volume determinado de gás carbônico, seguindo as orientações da equipe de produção e já considerando eventuais perdas no decorrer do processo. No entanto, ao final de cada mês, constatava-se a falta de insumo do tipo gás carbônico, essencial para concluir a produção. Esse déficit gerava um prejuízo significativo para a empresa, uma vez que comprometia tanto a capacidade de atender à demanda quanto a eficiência operacional, forçando a realização de compras emergenciais de CO_2 a preços de mercado frequentemente mais altos. Em conversa com o Gerente da Produção, essas perdas chegavam a casa de R\$100.000,00 por trimestre.

O processo de cálculo da necessidade de produção de CO_2 na BebidasCo era realizado de maneira automatizada, permitindo previsões e ajustes conforme a demanda prevista de produção. Entretanto, o monitoramento dos tanques de gás carbônico não seguia o mesmo padrão tecnológico. Os tanques são localizados em áreas afastadas da planta industrial, o que dificulta o acesso regular e a verificação da condição de operação. Além disso, não havia uma governança clara sobre frequência de visitas à área dos reservatórios ou um sistema digitalizado que permitisse um monitoramento contínuo e eficiente. A verificação de vazamentos de gás ficava restrita a uma manutenção semestral programada, que não era suficiente para identificar ou prevenir as perdas que ocorriam ao longo do ano.

Desta maneira, o método de resolução de problemas empregado neste trabalho parte do

pressuposto de que para resolver um problema devemos primeiro sinalizar o momento em que ele ocorre. Assim, o objetivo deste trabalho é criar uma solução que permita à empresa BebidasCo a sinalização do momento em que o tanque sai de um regime de operação estável para um turbulento, e foi empregado grande esforço de maneira a encontrar uma solução dado este contexto.

A maneira mais eficiente de alcançar os objetivos propostos é fundamentar a solução do problema em um sólido conhecimento do problema e levantamento de informações (KUME, 1993). Portanto, foi de suma importância adotar a dinâmica de *Customer Discovery*, iniciando com conversas com pessoas diretamente ligadas à operação da fábrica para entender o contexto das falhas observadas. O foco estava em compreender a lógica operacional da equipe de manutenção e identificar quais eram os obstáculos para realizar a manutenção ou a verificação frequente dos aparelhos. Essa fase inicial foi conduzida sem qualquer julgamento prévio ou proposta de modificação, visando uma imersão completa na realidade operacional e nos desafios enfrentados pela equipe no dia a dia.

Com uma visão mais aprofundada da área e da operação, foi possível levantar hipóteses sobre as causas raízes do problema por meio de um diagrama de causa e efeito. Seguiu-se um processo de *brainstorming* para enumerar possíveis soluções. Para avaliar essas soluções, utilizou-se uma matriz de impacto *versus* esforço, permitindo a seleção da opção que equilibrava melhor os benefícios esperados com os recursos disponíveis.

Esse processo foi notavelmente ágil, beneficiando-se do ambiente dinâmico da *startup* do Autor em formação e de um cliente altamente engajado. O objetivo era garantir que houvesse tempo suficiente para implementar uma primeira versão da solução, ainda que não totalmente madura, mas que permitisse alcançar progressivamente os *milestones* estabelecidos, ajustando e aprimorando a solução conforme necessário.

3.2 Análise da estrutura organizacional da fábrica

Antes de adentrarmos nos detalhes do processo de Customer Discovery, é fundamental apresentar a estrutura organizacional da Diretoria de Produção da fábrica específica com a qual estamos lidando. Esse panorama organizacional focará especialmente na Gerência de Produção, detalhando suas funções, responsabilidades e a interação com outras áreas gerenciais. Esse entendimento não só contextualiza a origem e a natureza dos desafios operacionais enfrentados, mas também destaca a importância desta gerência no sucesso das operações diárias e na implementação de melhorias. A clareza nesta estrutura é crucial para que possamos avançar com precisão no Customer Discovery, alinhando as necessidades identificadas com as possibilidades reais de intervenção e melhoria.

Na estrutura organizacional da fábrica, a gestão da produção é uma das áreas-chave, subordinada diretamente à Diretoria de Produção. Além da Gerência de Produção, a organização conta com outras gerências cruciais para o funcionamento da fábrica, como a

Gerência de Compras, a Gerência de Planejamento de Demanda, a Gerência de Qualidade, a Gerência de Recursos Humanos, a Gerência de Desenvolvimento de Produto, a Gerência de Segurança do Trabalho e a Gerência de Logística. Essas áreas são complementadas por setores especializados, como a Diretoria de Manutenção e Reparos, Gestão de Riscos, Legal e a Diretoria de IoT. O diagrama da Figura 12 ilustra a estrutura organizacional de parte da planta industrial da empresa BebidasCo.

Figura 12 – Diagrama da Estrutura Organizacional




Fonte: Elaboração Própria

Dando enfoque à Gestão de Produção, especificamente para esta planta, há um gerente de produção que coordena toda a área, apoiado por dois coordenadores. O primeiro coordenador é responsável por garantir a produção em si, focando na eficiência e na continuidade das operações diárias. O segundo coordenador tem a tarefa de garantir e monitorar os insumos necessários para a produção, assegurando que todos os materiais estejam disponíveis e sejam de qualidade adequada para evitar interrupções no processo produtivo. Importante destacar que a gestão da logística, embora interligada, não está subordinada à gerência de produção, possuindo sua própria estrutura de gestão dedicada. O mesmo é válido para Manutenção e Reparos.

Além desses coordenadores, a planta conta com um grupo significativo de operadores, aproximadamente 30, que desempenham funções mais manuais, como a operação das máquinas. Esses operadores são essenciais para a execução das tarefas diárias e para manter a linha de produção em funcionamento contínuo, desempenhando um papel fundamental na produtividade e eficácia da fábrica. O diagrama da figura 22 ilustra como está dividido e hierarquizado da Gerência de Produção.

A etapa de coleta de informações será realizada por meio de entrevistas detalhadas com cinco personagens dentro da estrutura organizacional da fábrica. As entrevistas incluirão o Gerente de Produção, que tem a visão geral sobre toda a produção e desafios operacionais; o Coordenador de Insumos, responsável por monitorar e garantir a disponibilidade de todos os insumos necessários para a produção; e o Coordenador de Produção, que foca na eficiência e continuidade das operações diárias. Além deles, serão entrevistados dois Operadores de Manutenção, que, embora não estejam diretamente ligados à Gerência de Produção, são parte crucial da Área de Manutenção e Reparos. Suas experiências práticas são essenciais para compreender as dificuldades e necessidades de manutenção

Figura 13 – Diagrama da Estrutura Organizacional da Gerência de Produção



Fonte: Elaboração Própria

na planta industrial. Essas entrevistas proporcionarão uma visão abrangente e detalhada dos processos, desafios e áreas de melhoria potencial dentro da operação da planta.

3.3 *Customer Discovery*

O objetivo final do *customer discovery* é duplo: primeiro, elencar e analisar os problemas identificados em um diagrama de causa e efeito, que permitirá visualizar as relações entre as causas e os efeitos observados na planta. Segundo, definir especificamente o problema central a ser atacado. Esse processo de mapeamento e definição é crucial para direcionar com precisão as etapas subsequentes do projeto, assegurando que os esforços de desenvolvimento se concentrem na solução das questões mais críticas e impactantes para a operação da fábrica. Através dessa metodologia sistemática, espera-se obter um entendimento profundo das raízes dos desafios enfrentados, estabelecendo uma base sólida para as soluções inovadoras que serão propostas.

Na primeira parte do *customer discovery*, o foco será em conduzir entrevistas com usuários envolvidos no problema. Foram conduzidas seis entrevistas com colaboradores da BebidasCo, dentre eles, Gerente Sênior de Planta Industrial, Coordenadora de Insumos, Coordenador de Produção, dois Operadores de Manutenção e Diretor de IoT. Para isso, foram elaborados dois planos de entrevista com objetivo três objetivos principais: (i) Entender o contexto operacional e impactos, (ii) Identificar a frequência e circunstâncias dos vazamentos e (iii) Explorar as práticas atuais de monitoramento e manutenção.

Dessa forma, dois guias de entrevista foram definidos, sendo que o primeiro foi circulado com o pessoal relacionado à operação da planta (portanto, Gerente, Coordenadores e Operadores) e o outro com o Diretor de IoT. O primeiro guia de entrevistas tem por principal objetivo mapear o contexto operacional e a frequência dos vazamentos. O segundo visa explorar as práticas atuais de monitoramento já implementadas, bem como mapear restrições tecnológicas

3.3.1 Guias de entrevista

Dado o contexto distinto dos três grupos selecionados para entendimento do problema, três guias de entrevista foram elaborados. O primeiro deles foi circulado com Gerente e Coordenadores, com o objetivo compreender a percepção geral do problema e explorar como se dá a comunicação e o relacionamento entre as equipes de produção e manutenção. O segundo guia foi circulado com os Operadores de Manutenção, para identificar desafios específicos relacionados ao acesso e manutenção dos tanques. Por fim, o terceiro roteiro foi direcionado ao Diretor de IoT, com a finalidade de também de pegar sua percepção acerca do problema e iniciativas anteriores.

A seguir serão ilustrados os guias de entrevistas:

3.3.1.1 Roteiro para Gerente e Coordenadores

O objetivo da entrevista com Gerente de Produção e Coordenadores de Insumos e de Produção são de compreender a percepção geral do problema e explorar como se dá o relacionamento com a equipe de manutenção. A seguir, o Autor ilustra o detalhamento do roteiro para as entrevistas:

Roteiro para entrevista com Gerente e Coordenadores:

- Parte 1: compreender percepção geral do problema
 - Quando o problema foi percebido pela primeira vez e como ele foi identificado?
 - Quais ações foram tomadas anteriormente para resolver ou mitigar o problema de vazamentos?
 - Há algum método já em prática para quantificar a perda financeira devido aos vazamentos?
- Parte 2: explorar relacionamento com equipe de manutenção
 - Com qual frequências as manutenções são realizadas?
 - Como é a comunicação com a equipe de manutenção em relação aos vazamentos? Há feedbacks regulares?
 - Me fale um pouco mais sobre a eficácia das manutenções programadas. Elas são suficientes para prevenir vazamentos?
 - Quais são os principais obstáculos encontrados pela equipe de manutenção ao verificar os tanques?

3.3.1.2 Roteiro para Operadores de Manutenção

Após uma primeira rodada de entrevistas com a gerência de Produção, elaborou-se um roteiro para entendimento do problema, sob a óptica dos Operadores de Manutenção. Para isso, o objetivo é de novo duplo: primeiro investigar se há sobrecarga na equipe de manutenção como um todo e segundo entender os desafios específicos enfrentados na manutenção dos tanques de gás carbônico.

Roteiro para entrevista com Operadores de Manutenção:

- Parte 1: investigar se há sobrecarga da equipe de manutenção no geral
 - O que você diria da carga de trabalho recente da equipe de manutenção? Você sente que sua carga de trabalho é gerenciável ou frequentemente se sente sobrecarregado?
 - Existem recursos suficientes (ferramentas, equipamentos, pessoal) disponíveis para a manutenção? E para a manutenção especificamente dos tanques?
- Parte 2: entender desafios específicos para manutenção de tanques
 - Como você sabe o que precisa de mais atenção na hora de dar manutenção nos tanques?
 - Como você identifica o tanque que está vazando?
 - Quão frequentemente os problemas de vazamento são detectados e quais são as causas mais comuns?

3.3.1.3 Roteiro para Diretor de IoT

Por fim, a última rodada de entrevista envolveu o Diretor de IoT, com o objetivo principal de entender o momento de incorporação de tecnologias da Indústria 4.0 e compreender soluções que já tentaram aplicar para resolver o problema.

Roteiro para entrevista com Diretor de IoT:

- Parte 1: entender incorporação de tecnologias da Indústria 4.0
 - Como você descreveria a jornada da empresa na adoção de tecnologias da Indústria 4.0 até agora?

- Pode dar exemplos de tecnologias específicas da Indústria 4.0 foram implementadas na empresa e por quê?
- Quais foram os maiores desafios encontrados durante a integração dessas tecnologias?
- Parte 2: entender desafios específicos para manutenção de tanques
 - Quais soluções tecnológicas foram tentadas para lidar com o problema de vazamentos?
 - Houve limitações tecnológicas ou outros obstáculos que impediram o sucesso dessas implementações?
 - Em que medida essas soluções foram bem-sucedidas ou não?

3.3.2 Compilação de *insights* das entrevistas

3.3.2.1 *Insights* de entrevistas com Gerente e Coordenadores

As entrevistas com o gerente e coordenadores da BebidasCo destacaram problemas crônicos com vazamentos nos tanques de CO₂, onde sinais de alerta como ruídos não são efetivamente monitorados. Desafios logísticos significativos devido à distância dos tanques comprometem a manutenção regular e impactam outras operações da fábrica. Há também uma falta de compreensão sobre o custo financeiro desses vazamentos, que ameaçam a continuidade da produção. As manutenções realizadas enfrentam questões de qualidade e consistência, com uma equipe de manutenção sobrecarregada. Os desafios logísticos e operacionais, especialmente a distância de 2 km dos tanques até a planta principal, criam um obstáculo significativo para manutenções regulares, afetando outras atividades essenciais da fábrica.

Insights de entrevistas com Gerente e Coordenadores:

1. Percepção Prolongada do Problema: O problema de vazamentos nos tanques de CO₂ é conhecido há algum tempo, indicando que a questão é recorrente e não foi resolvida efetivamente pelas abordagens adotadas até agora. A menção de um operador sobre o barulho incomum nos tanques sugere que os sinais de alerta são observáveis, mas talvez não estejam sendo adequadamente monitorados ou interpretados.
2. Desafios Logísticos e Operacionais: A distância dos tanques em relação à planta principal (2km) representa um obstáculo significativo para a manutenção regular. A

equipe de manutenção expressou que o tempo despendido no deslocamento e na execução das tarefas nos tanques compromete a realização de outras atividades essenciais na fábrica. Isso aponta para uma necessidade de repensar a logística de manutenção ou considerar a automação parcial desse processo.

3. **Impacto na Produção e Desconhecimento do Custo Financeiro:** O desconhecimento do impacto financeiro dos vazamentos é uma grande preocupação. A compra adicional de CO₂ baseada em estimativas empíricas, sem uma compreensão quantitativa das perdas, sugere uma lacuna crítica em termos de monitoramento e controle financeiro. Além disso, a possibilidade de paralisação da produção devido à falta de gás carbônico destaca a gravidade do problema.
4. **Efetividade da Manutenção Programada:** Embora as manutenções programadas sejam realizadas, parece haver uma incerteza quanto à qualidade e consistência dessas intervenções. Relatos de vazamentos recorrentes pouco após manutenções, como a troca de borrachas de válvulas, indicam falhas nos processos de manutenção ou na qualidade dos materiais utilizados.
5. **Limitações da Equipe de Manutenção:** A solicitação para aumentar a frequência das manutenções para trimestralmente foi negada devido à alta carga de trabalho da equipe de manutenção e ao envelhecimento da infraestrutura da fábrica. Isso sugere que as capacidades atuais da equipe de manutenção são insuficientes para atender às necessidades crescentes da planta, necessitando de uma revisão na alocação de recursos ou no aumento do efetivo.

3.3.2.2 *Insights* de entrevistas com Operadores de Manutenção

Os insights extraídos das entrevistas com os operadores de manutenção da BebidasCo revelam uma série de desafios operacionais e estruturais significativos que impactam diretamente a eficácia da manutenção e, consequentemente, a operação geral da planta. Estes desafios podem ser estruturados em quatro áreas principais:

Insights de entrevistas com Operadores de Manutenção:

1. **Sobrecarga de Trabalho e Problemas Recorrentes:** Os operadores de manutenção estão enfrentando uma alta demanda de trabalho, exacerbada por problemas contínuos e complexos, como a falha dos compressores que levou cerca de 6 meses para serem completamente reparados. Adicionalmente, uma pane elétrica recente prolongou o período de manutenções, estendendo-se por mais de um ano

em algumas áreas da planta. A constante necessidade de reparos emergenciais e manutenções prolongadas sobrecarrega a equipe, limitando sua capacidade de executar manutenções preventivas e rotineiras de forma eficaz.

2. **Desafios de Comunicação:** Existe uma falha de comunicação entre as equipes, onde os operadores frequentemente se deparam com discrepâncias entre as demandas reportadas e as reais necessidades de reparo. Essa ineficiência não apenas causa frustração, mas também resulta em perda de tempo e recursos, comprometendo a resposta a outras necessidades críticas.
3. **Manutenção dos tanques:** Os operadores indicaram que podem identificar facilmente os tanques com vazamentos pelo som anormal que produzem. Esta observação poderia ser utilizada para desenvolver um sistema de monitoramento mais eficiente. Devido à sobrecarga de trabalho e aos desafios logísticos, a manutenção dos tanques é muitas vezes restrita apenas àqueles que apresentam sinais óbvios de problemas. Isso sugere que muitos vazamentos podem não estar sendo adequadamente identificados ou reparados.
4. **Dificuldades logísticas de acesso:** o acesso aos tanques, que estão localizados a uma distância considerável da planta principal, é um processo demorado e fisicamente exigente. O transporte de equipamentos pesados e a necessidade de montagem de estruturas como escadas exacerbam a dificuldade e o tempo necessário para realizar qualquer intervenção.

3.3.2.3 *Insights* de entrevistas com Diretor de IoT

A entrevista com o diretor de IoT da BebidasCo revelou insights importantes sobre o processo de modernização da empresa e os desafios enfrentados na transição para a Indústria 4.0. A empresa está empenhada em adotar tecnologias avançadas para melhorar suas operações, mas enfrenta obstáculos significativos:

Insights de entrevistas com Diretor de IoT:

1. **Resistência de Parceiros Tecnológicos:** As startups de IoT mostraram relutância em desenvolver soluções para os tanques devido às suas condições desafiadoras. Isso inclui não apenas o problema de conectividade, mas também a preocupação com a longevidade e a manutenção dos dispositivos em ambientes expostos.


2. **Desafios de Infraestrutura:** Um dos principais problemas é a localização isolada dos tanques de CO₂, que complica a implementação de soluções baseadas em IoT. A exposição ao ar livre e a degradação dos componentes tecnológicos dificultam o uso de dispositivos inteligentes nessas áreas, aumentando a complexidade das intervenções necessárias.
3. **Conectividade Limitada:** Outro desafio crítico é a falta de conectividade adequada. Soluções anteriores testadas dependiam fortemente de uma conexão à internet, o que se mostrou inviável devido aos altos custos associados. A proposta de uma startup de incorporar um pacote de internet com chip 3G foi considerada muito cara, refletindo a dificuldade de encontrar soluções de custo efetivo que sejam viáveis para a localização e as necessidades específicas da fábrica.

3.4 Identificação de causas-raízes

Após uma apresentação geral da estrutura organizacional de parte da operação fabril e de resultados de entrevistas circuladas com *stakeholders* ficou claro o problema de vazamento nos tanques de gás carbônico. Especificamente para o contexto deste projeto, o problema será explorado em sua origem nesta sessão. Trata-se agora da fase de Definição dentro da metodologia do *Design Thinking*.

Para formular hipóteses sobre as causas raízes do problema identificado, foi empregado o Diagrama de Causa e Efeito. Após identificar as possíveis causas, cada uma foi descrita detalhadamente. Considerando que não foram relatados fatores relacionados à matéria-prima nas entrevistas, a categoria correspondente a este elemento foi excluída do diagrama principal, conforme descrito por (KUME, 1993).

Figura 14 – Diagrama de Causa e Efeito do problema identificado



Fonte: Elaboração Própria

Abaixo, as causas levantadas discutidas mais a fundo:

1. **Degradação de componentes devido a exposição ao ambiente:** Vedações e válvulas podem se deteriorar mais rapidamente devido a condições atmosféricas; corrosão de componentes metálicos não detectada a tempo.
2. **Tanques ficam mais afastados da fábrica, de difícil acesso:** Localização dos tanques complica logística de manutenção; condições de acesso dificultam transporte de equipamentos e ferramentas.
3. **Não há monitoramento dos vazamentos:** Falta de sistemas de detecção em tempo real; inexistência de protocolos para verificação regular fora do cronograma de manutenção. Reflexo também da falha em implementar rotinas de monitoramento que detectem reduções de pressão ou outros indicadores de vazamento de forma eficaz.
4. **Não há quantificação das perdas financeiras:** Falta de registros detalhados do consumo de CO₂ e comparação com o gás comprado; ausência de um sistema que integre dados de produção e consumo para análise de eficiência.
5. **Deficiência na coleta de dados:** Dados insuficientes ou imprecisos sendo coletados sobre o consumo e a perda de gás, o que impede uma análise adequada do problema.
6. **Processo de manutenção semestral possui falhas:** Manutenções são esparsas e podem não seguir um checklist detalhado; falha em atualizar os procedimentos de manutenção conforme novas tecnologias e materiais se tornam disponíveis.
7. **Intervalos de manutenção inadequados:** Intervalos muito longos entre as manutenções podem permitir que problemas pequenos se transformem em falhas maiores.
8. **Falha na padronização dos procedimentos:** A ausência de procedimentos padronizados para inspeção e manutenção dos tanques pode resultar em práticas inconsistentes e ineficazes.
9. **Equipe de manutenção sobrecarregada acaba não revisando todos os tanques:** Carga de trabalho excessiva impede a realização de manutenções preventivas adequadas; falta de pessoal qualificado para cobrir todas as áreas necessárias.

3.5 Levantamento de soluções

Com base nas causas raízes identificadas e analisadas nas etapas anteriores, o projeto avançou para a terceira etapa da metodologia de *Design Thinking*, focando na fase de Ideação. Essa etapa é crucial para gerar soluções criativas e eficazes, abordando diretamente os problemas identificados. Para isso, foi organizada uma sessão de *brainstorming* que

incluiu a participação ativa do cliente, especialmente o gerente e os coordenadores da planta.

Durante a sessão de brainstorming, todos os participantes foram encorajados a compartilhar suas ideias livremente, sem julgamentos, permitindo uma diversidade de soluções potenciais para emergir. O ambiente foi configurado para fomentar a criatividade e a inovação, com o objetivo de explorar todas as possíveis abordagens para resolver os problemas de vazamentos nos tanques de CO₂, os desafios logísticos e operacionais, e as falhas no sistema de monitoramento e manutenção.

Essa abordagem colaborativa permitiu que várias ideias fossem discutidas, desde a implementação de novas tecnologias de monitoramento até a revisão dos protocolos de manutenção e o treinamento aprimorado para a equipe de manutenção. A inclusão do gerente e dos coordenadores foi fundamental, pois eles trazem uma compreensão prática dos desafios diários e das limitações operacionais, garantindo que as soluções propostas fossem tanto inovadoras quanto aplicáveis no contexto real da fábrica.

Esta sessão do trabalho inclui um descritivo das soluções levantadas em conjunto com o cliente.

3.6 Priorização de soluções

Ao final da sessão de *brainstorming*, as ideias mais promissoras foram selecionadas para serem refinadas e testadas nas etapas subsequentes do processo de Design Thinking, movendo o projeto de melhorias um passo adiante em direção a soluções que realmente atacam uma dor da equipe e são sustentáveis no longo prazo.

A matriz resultante da sessão de refinamento com Gerente e Coordenadores é representada abaixo:

Com as propostas posicionadas na matriz, foi necessário escolher um critério para priorização da solução proposta. Tendo isso em vista, a equipe fundadora da *startup* optou por seguir com as soluções no quadrante de *Quick-wins*, ou seja, selecionar opções que trouxessem grande impacto em um curto prazo temporal para entregar valor ao cliente. Dessa forma, foi escolhida a solução às causas-raiz número 3 e 5.


Apesar da solução 4 estar acima da linha de corte para escolha das soluções, como ilustrado na Figura 15, ela se enquadra mais como uma consequência de desenvolver um sistema de monitoramento das válvulas dos tanques de gás carbônico, ou seja como uma fase futura do projeto.

Como próximo passo da equipe do Autor, foi elaborado um plano de trabalho alinhado com as expectativas e necessidades do cliente BebidasCo, como será explicitado no capítulo seguinte. Com isso, este Trabalho de Formatura descreverá a fase 4 de Prototipação da Metodologia do *Design Thinking*.

Tabela 1 – Causas-raízes e Propostas de Solução

Causa-raiz	Proposta de Solução
1- Degradação de componentes devido a exposição ao ambiente	Utilizar materiais mais resistentes e técnicas de proteção contra intempéries
2- Tanques ficam mais afastados da fábrica, de difícil acesso	Melhorar a infraestrutura de acesso aos tanques ou utilizar veículos automatizados para transporte de ferramentas
3- Não há monitoramento dos vazamentos	Implementar sistemas de monitoramento em tempo real com alertas automáticos
4- Não há quantificação das perdas financeiras	Desenvolver um sistema integrado de monitoramento de consumo e perdas de CO ₂
5- Deficiência na coleta de dados	Implementar sensores e sistemas de coleta de dados mais precisos e confiáveis
6- Processo de manutenção semestral possui falhas	Revisar e atualizar os checklists de manutenção, integrando novas tecnologias e materiais
7- Intervalos de manutenção inadequados	Reduzir os intervalos de manutenção, adotando uma abordagem baseada em condições
8- Falha na padronização dos procedimentos	Desenvolver e implementar um manual de procedimentos padrão para todas as operações de manutenção
9- Equipe de manutenção sobrecarregada acaba não revisando todos os tanques	Aumentar a equipe de manutenção e melhorar o treinamento técnico

Figura 15 – Matriz de Impacto x Esforço para as soluções propostas



Fonte: Elaboração Própria

4 DESENVOLVIMENTO DO TRABALHO

Neste capítulo, será descrito o desenvolvimento e implantação dos planos referentes aos problemas que foram diagnosticados na seção anterior. Trata-se da quarta etapa da Metodologia de *Design Thinking*, em que as duas ideias resultantes da etapa anterior de Ideação se transformaram em um protótipo tangível. O intuito deste capítulo é descrever como foi o processo de criação desses protótipos funcionais, que a cada momento buscava-se testar um conceito e receber *feedback* do cliente do projeto.

4.1 Planejamento da implementação

O desenvolvimento do projeto foi estruturado em várias etapas distintas, cada uma visando a construção incremental do sistema proposto. Esta abordagem modular permitiu não só uma organização clara das tarefas, mas também facilitou a gestão de possíveis ajustes no escopo do projeto durante seu progresso.

A implementação foi realizada seguindo princípios de desenvolvimento ágil, o que implicou em iterações constantes e frequentes com o cliente. Essa interação contínua foi essencial para assegurar que todas as funcionalidades desenvolvidas estivessem alinhadas com as expectativas e necessidades do cliente, permitindo ajustes rápidos e eficientes sempre que necessário. Durante cada *sprint*, foram realizadas reuniões de revisão e planejamento para avaliar o trabalho realizado e redefinir prioridades para o próximo ciclo.

A cada etapa, protótipos funcionais eram entregues ao cliente, proporcionando uma visão concreta do progresso do projeto e permitindo feedback imediato. Esse processo não só aumentou a satisfação do cliente, mas também incrementou a qualidade do produto final, pois permitiu a identificação e correção de problemas em estágios iniciais do desenvolvimento.


Em alinhamento com o cliente, as duas soluções propostas foram quebradas em quatro objetivos para o desenvolvimento do trabalho:

1. Objetivo 1: Implementar sistema de coleta de dados de operação do tanque
2. Objetivo 2: Construir base de dados com dados de operação do tanque
3. Objetivo 3: Desenvolver modelo de machine learning para classificação do status de funcionamento
4. Objetivo 4: Disponibilizar informação de funcionamento da válvula em tempo real

Nesse sentido, para garantir uma visão clara do cronograma e das fases de desenvolvimento, foi elaborado um Gráfico de Gantt pela equipe. Este gráfico serve como um macro-planejamento para o projeto, delineando todas as etapas, suas respectivas durações

e interdependências. O Gráfico de Gantt completo pode ser conferido na página seguinte, fornecendo um panorama detalhado do fluxo planejado para a execução do projeto.

Figura 16 – Gráfico de Gantt com o planejamento do projeto



Fonte: Elaboração Própria

Após a definição do Gráfico de Gantt, que estabeleceu as fases do desenvolvimento do projeto, o trabalho foi organizado em torno de quatro objetivos principais. Esses objetivos foram definidos após uma análise detalhada das causas-raízes, em particular as causas-raízes 1 e 8, com o intuito de enfrentar diretamente os problemas mais críticos identificados na etapa inicial de *Customer Discovery*. Vale destacar que a equipe fundadora optou por seguir uma abordagem mais ligada a desenvolvimento de um produto que a revisão de tópicos de governança e organização das equipes do cliente, em priorização definida com o próprio cliente.

O primeiro objetivo consiste na implementação de um sistema de coleta de dados do tanque. Este sistema é projetado para gravar automaticamente o áudio da operação da válvula do tanque, conforme relatado pelo Operador de manutenção na fase de *Discovery*. A coleta de dados, tanto em estado normal de operação quanto no defeituoso, é essencial para fornecer uma base sólida para o objetivo final de construir um modelo de machine learning que classifica o estado de operação do tanque e emite alertas automáticos para a Operação.

Seguindo para o segundo objetivo, busca-se construir uma base de dados robusta que possa armazenar e administrar os dados obtidos pelo sistema de coleta. Em um primeiro momento, a base de dados será estruturada com duas segmentações entre dados de operação normal e operação defeituosa. Esta infraestrutura facilitará o treinamento do modelo de *machine learning* na próxima etapa do projeto. Em um segundo momento, a base de dados deverá receber os áudios da operação do tanque a serem processados pelo modelo em tempo real.

O terceiro objetivo é desenvolver um modelo de *machine learning* que possa classificar o status de funcionamento do tanque com base nos dados coletados. Este modelo empregará técnicas de aprendizado de máquina para detectar padrões que indiquem diferentes

condições operacionais, desde operações normais até potenciais falhas. A implementação deste modelo é crucial para avançar a manutenção preditiva, elevando assim a eficiência operacional.

Por fim, é de extrema importância disponibilizar aos *stakeholders* do projeto uma plataforma de monitoramento e envio de alertas para casos de operação suspeita. Este portanto será o quarto *milestone* a ser alcançado pela startup do Autor.

4.2 Objetivo 1: Implementar sistema de coleta de dados de operação do tanque

A decisão de coletar dados de áudio da operação do tanque de gás carbônico na empresa BebidasCo foi fundamentada em uma descoberta chave durante a fase de *Customer Discovery*. As entrevistas realizadas com os operadores de manutenção revelaram que os sons emitidos pela válvula do tanque são indicativos do seu estado de funcionamento. Um colaborador experiente consegue discernir, apenas pelo som, se a válvula está operando corretamente ou se apresenta algum tipo de anomalia.

Este insight mostrou que a audição humana, uma ferramenta aparentemente simples, desempenha um papel crucial na manutenção preventiva e na detecção precoce de problemas. Portanto, a equipe decidiu replicar essa capacidade auditiva através de tecnologia, adicionando uma camada de análise objetiva e escalável. A utilização de algoritmos de machine learning para analisar os dados de áudio não apenas simula a percepção humana, mas também supera suas limitações, como a subjetividade, aumentando a confiabilidade e precisão na detecção de falhas.


4.2.1 Tecnologias a serem utilizadas

Para a coleta inicial de dados de áudio na operação do tanque, a equipe optou por uma abordagem pragmática e econômica, utilizando um microfone comum em conjunto com um ESP32 e um cartão de memória. Esta combinação foi escolhida para facilitar a rápida implementação e teste do conceito sem exigir investimentos significativos em hardware especializado.

O ESP32 é um microcontrolador com capacidades avançadas de Wi-Fi e Bluetooth, que se destaca pela sua versatilidade e baixo custo. O ESP32 possui um processador dual-core e inclui uma variedade de funcionalidades que são excepcionais para o seu tamanho e preço, como capacidades de comunicação, GPIOs (General Purpose Input/Output) e ADCs (Analog to Digital Converters) para entrada de áudio analógico.

Os GPIOs são pinos no ESP32 que podem ser programados para funcionar como entradas ou saídas para diversos tipos de dispositivos eletrônicos. No contexto do projeto, os GPIOs são utilizados para interagir com o microfone. Nesse sentido, os ADCs são fundamentais para converter o sinal analógico captado pelo microfone em dados digitais que podem ser processados pelo microcontrolador. No sistema proposto, os ADCs do ESP32

Figura 17 – Imagem de um ESP32 utilizado no projeto




Fonte: Elaboração Própria

desempenham um papel crucial ao permitir a utilização de microfones comuns, que são mais acessíveis e estão prontamente disponíveis. Eles capturam as variações de tensão geradas pelo microfone em resposta ao som ambiente e as convertem em valores digitais, que são então registrados em um cartão de memória que atuará como um banco de dados físico e temporário.

4.2.2 Detalhamento da solução

A solução proposta para monitorar o funcionamento do tanque de gás carbônico envolve a utilização de um microfone comum e um microcontrolador ESP32, configurados para captar e registrar os sons emitidos pela válvula do tanque em um cartão de memória. O microfone comum é responsável por capturar os sons do ambiente, transformando as ondas sonoras em sinais elétricos analógicos. Estes sinais são então enviados ao ESP32, que atua como o coração do sistema de coleta de dados.


Figura 18 – *Schema* da solução proposta para cumprir o primeiro objetivo

Fonte: Elaboração Própria

O ESP32, equipado com seus ADCs (Analog to Digital Converters), converte os sinais analógicos do microfone em dados digitais. Este processo permite que os sons capturados sejam transformados em uma forma que possa ser processada e analisada computacionalmente. O microcontrolador não apenas realiza essa conversão, mas também é responsável pelo gerenciamento inicial dos dados, como a filtragem de ruídos e a compressão preliminar dos dados de áudio.

Durante a fase inicial do projeto, a equipe optou por armazenar os dados diretamente em um cartão de memória conectado ao ESP32. Este método de armazenamento local foi escolhido devido à sua simplicidade e confiabilidade, permitindo uma coleta de dados ininterrupta e sem dependência de conexões de rede contínuas.

Figura 19 – Protótipo para o Objetivo 1



Fonte: Elaboração Própria

Após a coleta, os dados armazenados no cartão de memória foram transferidos para a nuvem. Esta transferência para um ambiente de computação em nuvem permitiu a realização de análises mais complexas e o treinamento de modelos de machine learning com maior capacidade de processamento e recursos que não estariam disponíveis localmente. Além disso, a utilização da nuvem facilita a escalabilidade do sistema e a integração com outras partes da infraestrutura tecnológica da empresa BebidasCo. Este arranjo da Figura 19 proporcionou uma base sólida para a próxima etapa do projeto, que envolve o desenvolvimento da base de dados com registros da operação do tanque. A Figura 20 ilustra o posicionamento no tanque, próximo às válvulas para a captura dos dados sonoros. Vale destacar que o *hardware* da Figura 19 está dentro de um pote azul de sorvete, com uma abertura para o microfone poder captar o áudio sem ecos. O intuito do pote foi poder fixar o protótipo para reduzir efeitos de vibrações do tanque.

Vale destacar também que a Figura 20 mostra o resultado prático do *schema* desenhado na Figura 18.

Figura 20 – Protótipo em ação



Fonte: Elaboração Própria

4.3 Objetivo 2: Construir base de dados com dados de operação do tanque


Com o protótipo da Figura 19 construído, foram coletadas um total de 8 horas de áudio, divididas igualmente entre condições de funcionamento normal e condições anormais da válvula. As primeiras 4 horas de gravação capturaram o funcionamento normal do tanque, realizadas pela equipe fundadora, que serviram como base para o modelo de *machine learning* reconhecer o estado operacional padrão. As subseqüentes 4 horas foram coletadas com a assistência da equipe de manutenção, durante períodos em que a válvula apresentava falhas, proporcionando dados cruciais para o treinamento do modelo em reconhecer situações de falhas operacionais.

4.3.1 Tecnologias a serem utilizadas

A segunda etapa crucial do desenvolvimento envolveu o processamento detalhado dos dados de áudio coletados para prepará-los para a análise de machine learning. Esta fase é essencial para garantir a qualidade e a usabilidade dos dados em modelos de classificação. Abaixo na figura 21 estão descritas as técnicas e processos utilizados para o processamento do áudio.

Após coleta de dados descrita na seção 4.2, o processamento dos dados inicia-se a

Figura 21 – Fluxograma do processo de tratamento de dados



Fonte: Elaboração Própria

partir do carregamento desses dados do banco de dados. A primeira etapa de transformação consiste em segmentar o áudio em trechos menores, e converter o áudio em um Espectrograma de Mel. Com o espectrograma gerado, é feito um embaralhamento dos dados para minimizar um efeito de viés temporal, para, em sequência prepará-los para *input* na CNN que será detalhada na seção 4.4. Para isso, é feito um redimensionamento das imagens dos espectrogramas, seguido de uma normalização dos dados. Por fim, as imagens são salvas em outro banco de dados que será consumido pelo modelo de *machine learning*.

4.3.2 Detalhamento da solução

Esta seção aborda de maneira detalhada o processo de tratamento dos dados coletados. Ela está dividida em três subseções. A primeira vai abordar o fracionamento dos áudios, seguido da etapa de remoção de ruídos e, por fim, da etapa de embaralhamento dos dados.

4.3.2.1 Fracionamento dos áudios

Os áudios coletados foram inicialmente fracionados em partes menores de cinco segundos cada. Esta técnica é comum em aplicações de processamento de áudio para *machine learning*, pois permite uma análise mais granular e facilita o manejo de grandes volumes de dados. Segmentar os áudios dessa forma ajuda a reduzir a complexidade computacional e permite que o modelo de machine learning identifique padrões e características relevantes em intervalos de tempo mais curtos, o que é particularmente útil para captar variações temporais sutis no som que podem indicar problemas operacionais.

4.3.2.2 Conversão do formato de onda em espectrograma de Mel

Para analisar essas ondas sonoras coletadas ao final da primeira etapa, é necessário transformá-las para o domínio frequência-tempo. Isso é feito utilizando a Transformada de Fourier de Tempo Curto (STFT). A STFT divide o sinal em várias janelas de tempo e executa uma transformada de Fourier em cada uma dessas janelas, mantendo assim informações essenciais sobre as frequências ao longo do tempo.

O resultado da STFT é um espectrograma, que é uma representação visual das variações de frequência do som ao longo do tempo e que pode ser tratado como uma imagem bidimensional. Os espectrogramas são representações visuais de um sinal sonoro. Enquanto as formas de onda iniciais representam a Amplitude versus Tempo, mostrando o sinal no domínio do tempo, o espectrograma muda essa perspectiva para Amplitude versus Frequência. Dessa forma, observamos o sinal no domínio da frequência, onde cada ponto no eixo x representa uma faixa de frequências em um momento específico.

Para afinar ainda mais a análise e aproximar a percepção do modelo à do ouvido humano, os espectrogramas são então convertidos para a escala de Mel. Esta conversão resulta em espectrogramas de Mel que destacam as frequências mais importantes para a percepção humana.

4.3.2.3 Redimensionamento e normalização

Como penúltima etapa do processamento de dados, vamos deixar as imagens geradas com dimensões ajustadas e com valores normalizados. Redimensionar garante que as imagens de entrada para a rede possuem tamanhos padronizados e não quebre a arquitetura da rede. Já a normalização ajusta os valores dos pixels da imagem para terem uma média próxima a zero e desvio padrão unitário, para acelerar o treinamento da rede.

Essas duas etapas constituem processamentos específicos para a arquitetura da CNN que será aplicada no próximo objetivo.

4.3.2.4 Embaralhamento dos dados

Após o fracionamento e a geração dos espectrogramas, as imagens foram embaralhadas aleatoriamente. Esta prática é fundamental para evitar que o modelo de *machine learning* desenvolva vieses baseados na sequência temporal dos dados. Em outras palavras, embaralhar os dados garante que o modelo não associe padrões que são simplesmente produtos da ordem de coleta dos dados, mas sim que aprenda a identificar características intrínsecas dos estados de funcionamento, independentemente de quando foram gravados. Isso contribui para a robustez do modelo, garantindo que ele generalize bem em novas e variadas situações, não apenas nas condições específicas sob as quais os dados foram coletados.

4.3.2.5 Conclusão do processamento de áudios

A conclusão da fase de pré-processamento dos dados de áudio, como parte do Objetivo 2 do projeto, foi um passo fundamental para a estruturação eficaz da base de dados necessária para o desenvolvimento subsequente de um modelo de *machine learning*. Este processo meticuloso envolveu várias etapas críticas: fracionamento dos áudios, conversão do formato de onda em espectrograma, geração do espectrograma de Mel e embaralhamento dos dados.

Inicialmente, os áudios coletados foram fracionados em segmentos de um minuto cada. Esta segmentação permitiu um manuseio mais eficiente dos dados, facilitando tanto a análise quanto o processamento subsequente, além de adequar o tamanho dos dados para análises de curto prazo, o que é essencial para a detecção de anomalias e o monitoramento contínuo da condição do tanque. Em seguida, procedeu-se à conversão do formato de onda em espectrograma e a consequente geração dos espectrogramas de Mel. Após esse processamento intermediário, os dados foram embaralhados aleatoriamente. Esse embaralhamento é essencial para garantir a imparcialidade do modelo de machine learning, evitando qualquer viés que possa surgir devido à ordem temporal em que os dados foram originalmente coletados. Isso assegura que o modelo treinado será capaz de generalizar bem em novas amostras de dados, independentemente de sua sequência temporal. Por fim, os dados foram registrados no banco de dados.

Com estas etapas, o Objetivo 2 de criação e estruturação da base de dados foi concluído com sucesso, resultando em um conjunto de dados de alta qualidade e bem preparado para a próxima fase do projeto. Agora, o trabalho está pronto para avançar para a Fase 3, que envolve a construção de um modelo de machine learning capaz de inferir o estado de funcionamento da máquina.

Este progresso marca um ponto de transição crucial no projeto, onde passamos do tratamento e preparação de dados para a implementação prática de soluções de inteligência artificial, trazendo o projeto um passo mais próximo da inovação tecnológica no ambiente industrial.

4.4 Objetivo 3: Desenvolver modelo de *machine learning* para classificação do status de funcionamento

No desenvolvimento do modelo de *machine learning*, a abordagem inovadora adotada foi transformar um problema de classificação de áudio em um problema de classificação de imagem. Essa transformação é realizada por meio da conversão dos sinais de áudio, já processados nas etapas anteriores, em espectrogramas.

Considerado uma representação compacta equivalente de um sinal de áudio, o espectrograma atua como uma espécie de 'impressão digital' do sinal. Esta representação captura de forma elegante as características essenciais dos dados de áudio em forma de

imagem. A ideia do modelo é replicar o que o colaborador de manutenção tem capacidade, ou seja de ouvir um som e classificar a operação da válvula. Para isso, o Autor fez uso do espectrograma de Mel.

Com esses dados de imagem em mãos, torna-se possível aplicar arquiteturas convencionais de Redes Neurais Convolucionais (CNNs) para processá-los.

4.4.1 Tecnologias a serem utilizadas


Na construção do modelo de classificação com redes neurais convolucionais (CNN), optamos por uma adaptação da arquitetura LeNet5, inicialmente desenvolvida para reconhecimento de dígitos manuscritos.

4.4.2 Detalhamento da solução

Essa arquitetura LeNet5 foi modificada e expandida para se adequar às especificidades dos nossos dados de espectrogramas. As camadas adicionadas e adaptadas são:

1. Redimensionamento (*Resizing*): Ajusta as dimensões da imagem de entrada para o tamanho necessário para processamento na rede, garantindo que todas as entradas sejam padronizadas em termos de tamanho. Esta etapa foi implementada junto ao processamento dos dados coletados.
2. Normalização: Esta camada normaliza os valores dos pixels da imagem para terem uma média próxima a zero e desvio padrão unitário. Isso ajuda a acelerar o treinamento da rede e reduzir a possibilidade de gradientes explosivos. Esta etapa foi implementada junto ao processamento dos dados coletados.
3. Convolução: Utiliza filtros (ou *kernels*) que são aplicados através da imagem para criar um mapa de características. Cada filtro detecta características específicas em locais diferentes da imagem.
4. *MaxPooling*: Reduz a dimensionalidade do mapa de características enquanto preserva as informações mais importantes. Faz isso escolhendo o valor máximo de cada região definida do mapa de características.
5. *Dropout*: Uma técnica de regularização usada para evitar o sobreajuste em modelos de aprendizado profundo. Ela "desliga" aleatoriamente um conjunto de neurônios durante o treinamento, o que ajuda a fazer com que o modelo seja robusto e menos dependente de qualquer neurônio específico.
6. Camada Densa (*Dense*): Uma camada densamente conectada que recebe todos os neurônios da camada anterior. Essa camada combina as características extraídas anteriormente para formar a saída, que é usada para classificar a entrada em categorias (neste caso, o status de funcionamento do tanque).

Figura 22 – *Schema* da CNN adaptada utilizada para treinamento do modelo



Fonte: Elaboração Própria

Essas modificações não apenas ajustam a arquitetura original para lidar com dados de áudio, mas também melhoram sua capacidade de capturar a complexidade e a variação dos sinais de som que indicam diferentes condições operacionais do tanque.

Para o treinamento do modelo de classificação, o Autor optou por um total de dez épocas. Foi utilizado um tamanho de batch de 32 para equilibrar entre eficiência computacional e estabilidade do treinamento. A função de perda escolhida foi a de entropia cruzada, comumente utilizada em problemas de classificação e alinhada com a literatura.

Os dados foram divididos em 70% para treinamento, 20% para teste e 10% para validação, com validação cruzada utilizada para assegurar uma avaliação robusta da capacidade do modelo de generalizar além dos dados de treino.

Com o modelo treinado, o capítulo 5 discute seus resultados teóricos, bem como o resultado prático de um piloto realizado com o cliente. A próxima seção discute como a inferência do modelo com relação ao estado de funcionamento da válvula foi disponibilizada ao cliente.

4.5 Objetivo 4: Disponibilizar informação de funcionamento da válvula em tempo real


Um dos principais desafios enfrentados pelo projeto do Autor foi a necessidade de transmitir informações em tempo real a partir de locais onde a conectividade à internet não estava disponível. Os tanques de gás carbônico, situados em áreas remotas dentro da empresa BebidasCo, representavam um cenário complexo para a implementação de soluções de IoT convencionais que dependem de uma conexão estável à internet.

4.5.1 Tecnologias a serem utilizadas

Para superar o desafio da conectividade, a equipe de *hardware* optou pelo uso de sinais de rádio de baixa frequência, especificamente através da tecnologia LoRa (Long Range). Esta tecnologia é ideal para comunicações a longa distância com consumo reduzido de energia, o que se adequava perfeitamente às limitações do ambiente.

LoRa opera em bandas de frequência que não exigem licença, o que reduz os custos de implementação e manutenção. Utiliza um método de modulação chamado "Chirp Spread Spectrum" que possui alta resistência a interferências e pode cobrir distâncias significativas, até quatro quilômetros em condições ideais. Essa capacidade foi essencial para transmitir dados do status da válvula dos tanques para uma central de controle conectada à internet.

Figura 23 – Ilustração do protótipo com antena LoRa



Fonte: Elaboração Própria

A Figura 23 ilustra o protótipo utilizado para coleta de dados combinado com a antena LoRaWAN. O intuito da antena não é o de transmitir o áudio coletado, mas sim o resultado da inferência do modelo de *machine learning* construído na seção 4.4. Além do protótipo da Figura 23, foi de fundamental importância construir também uma central, que ficava no escritório da gerência de produção, conectada à internet. A Figura 24 retrata essa central em ação.

Uma vez que os dados eram recebidos na central, era crucial que essas informações fossem apresentadas de forma acessível e segura para a equipe de produção e manutenção da BebidasCo. Para isso, a Máquina Feliz optou pelo uso do Grafana, uma plataforma de análise e monitoramento de código aberto que permite a criação de painéis de controle dinâmicos e informativos. Grafana foi escolhido por sua facilidade de integração através de APIs e sua compatibilidade com diversas fontes de dados. A plataforma se conecta diretamente com a central de dados, permitindo a visualização em tempo real do status operacional das válvulas. Além disso, Grafana atendeu às políticas de segurança de dados

Figura 24 – Central desenvolvida em funcionamento na Gerência de Produção




Fonte: Elaboração Própria

da BebidasCo, assegurando que todas as informações transmitidas estavam protegidas contra acessos não autorizados.

4.5.2 Detalhamento da solução

O fluxograma da Figura 25 retrata de maneira esquemática como essa inferência do modelo de *machine learning* foi transmitida usando LoRa e disponibilizada para a equipe de Produção e Manutenção da empresa BebidasCo. O primeiro passo nesse fluxograma consiste no recebimento pelo LoRa da classificação fornecida pelo modelo de *machine learning*. Como *output*, há uma classificação entre duas categorias possíveis: "sem defeito" ou "com defeito", que é transmitida pelo *hardware* para o LoRa. Inicia-se então o protocolo de comunicação com a central, localizada no escritório da Gerência de Produção. A central recebe o status de operação e, conectada à internet, faz a conexão com o Grafana e salva o resultado. O Grafana, como já está no sistema do cliente, possui o papel de exibir um *dashboard* com o status de operação inferido pelo modelo de *machine learning*.

Figura 25 – Fluxograma do Objetivo 4



Fonte: Elaboração Própria

5 RESULTADOS E DISCUSSÃO

Este capítulo é dedicado à apresentação e discussão dos resultados obtidos ao longo do desenvolvimento do projeto implementado pelo Autor e startup Máquina Feliz. A análise dos resultados é fundamental para validar a eficácia do algoritmo de *machine learning* desenvolvido e para demonstrar como a tecnologia pode ser aplicada de forma prática e benéfica no ambiente industrial.

A estrutura deste capítulo segue uma linha lógica subsequente do capítulo 4 Desenvolvimento do Trabalho. As quatro primeiras seções deste capítulo são referentes aos resultados obtidos com a conclusão de cada um dos objetivos definidos no capítulo anterior. Portanto, as duas primeiras seções deste capítulo discutem resultados da etapa de coleta e processamento dos dados. Em seguida, há a apresentação da performance do modelo de *machine learning*, explorando métricas de sucesso e áreas para futuras melhorias. O fluxo de inferência será detalhado para ilustrar como as previsões são geradas e utilizadas na prática, desde a etapa de coleta de áudio, até a disponibilização dos resultados em uma interface para o usuário.

Além disso, a seção 5.5 relata a experiência de um piloto realizado diretamente com o cliente, proporcionando uma visão real do funcionamento da solução no ambiente alvo. Por fim, a discussão com o diretor de IoT da BebidasCo oferece *insights* profundos sobre as expectativas do mercado e a recepção da tecnologia por parte de *stakeholders* chave.

5.1 Resultado do Objetivo 1: coleta de dados de operação

Neste contexto, focou-se na coleta de dados acústicos provenientes do funcionamento das válvulas dos tanques de gás carbônico. Com a assistência da equipe de manutenção da empresa BebidasCo, foi possível acessar tanques sob condições específicas de operação, tanto normais quanto anormais.


Durante o processo, coletaram-se oito horas de áudio, divididas igualmente entre condições normais e anormais de funcionamento. Esta divisão estratégica foi essencial para treinar o modelo para distinguir com precisão entre os dois estados operacionais. A seleção de tanques com defeito foi facilitada pela colaboração com os técnicos de manutenção, que identificaram as unidades que apresentavam sinais claros de mau funcionamento.

A partir desses dados, procedeu-se à fase de processamento, envolvendo a limpeza e a preparação dos dados acústicos para análise, assegurando a integridade e a utilidade do conjunto para as etapas de modelagem.

A Figura 26 ilustra um formato de onda coletado nessa parte. A imagem, confirma claramente que há uma diferença aparente entre os dois estados de operação.

Além disso, esse arranjo simplificado descrito na seção 4.2.2 trouxe um *feedback* rápido com relação à futura utilização do ESP32 como o "coração" do projeto. Nesse arranjo

Figura 26 – Onda sonora para áudios com e sem defeito



Fonte: Elaboração Própria

simplificado, o Autor percebeu que o ESP32 seria incapaz de receber um modelo de *embedded machine learning*. Além disso, esse arranjo mostrou à equipe responsável pelo *hardware* a necessidade de criação de uma caixa protetora do protótipo para reduzir efeitos de corrosão.

O ESP32, apesar de ser um microcontrolador bastante versátil e eficaz para uma série de aplicações IoT, apresenta algumas limitações significativas quando se trata de modelos de machine learning embutidos. Uma dessas limitações é sua capacidade de memória restrita: com RAM típica de apenas cerca de 520 KB e memória flash que pode variar de 4 MB a 16 MB, ele oferece pouco espaço para alocação de modelos de *machine learning* complexos, que geralmente exigem uma quantidade substancial de memória para pesos e operações de cálculo. Além disso, o processador do ESP32, embora capaz para tarefas de controle e conectividade, não possui o poder computacional necessário para processamento intensivo de dados, como aqueles requeridos por algoritmos de aprendizado profundo e de redes neurais convolucionais. Isso resulta em uma capacidade bastante limitada para executar inferências de forma eficiente e rápida, o que é muitas vezes crucial em aplicações de machine learning em tempo real. Portanto, enquanto o ESP32 é adequado para tarefas mais simples e menos demandantes, como registro de áudio, ele não é a escolha devida para implementações avançadas de machine learning sem suporte de hardware adicional.

Com relação ao estado físico do protótipo após oito horas de funcionamento, podemos notar claros sinais de corrosão na estrutura eletrônica, como apresentado na figura 27. Dessa forma, foi adicionado ao *backlog* de tarefas da equipe responsável pelo *hardware* o desenho e execução de uma estrutura mecânica que pudesse proteger o protótipo quando fosse operar em funcionamento real.

Por um lado, o grupo alcançou com sucesso o primeiro objetivo de montar uma prova de conceito que demonstrou a viabilidade de criar um dispositivo capaz de registrar a operação da máquina, confirmando a funcionalidade básica necessária para o projeto. Por outro lado, a experiência revelou a necessidade de iterações adicionais no protótipo para a fase de testes, sugerindo a substituição do hardware por um mais robusto, como o Raspberry Pi, além do investimento em uma estrutura mecânica que possa proteger melhor o protótipo.

Figura 27 – Corrosão do protótipo 1 após operação



Fonte: Elaboração Própria

Com relação ao controlador, o Raspberry Pi oferece vantagens significativas para o desenvolvimento do projeto, incluindo maior capacidade de processamento, possibilidade de rodar um sistema operacional completo como o Linux, e uma gama mais ampla de conectividade e opções de expansão. Esses atributos tornam o Raspberry Pi uma escolha excelente para projetos que exigem não apenas a coleta de dados, mas também processamento mais intensivo e interações mais complexas com outros sistemas e dispositivos. Essa mudança estratégica permitirá ao grupo explorar funcionalidades avançadas e garantir uma implementação mais eficiente e eficaz na próxima fase do projeto.


5.1.1 Resultado da iteração sobre o protótipo

A partir dessa iteração rápida de colocar um protótipo em ação e colher feedbacks, a startup Máquina Feliz tomou duas medidas rápidas:

1. Mudança na matéria-prima: no primeiro protótipo, foi usado poliestireno comum de filamentos de impressão 3D; no segundo protótipo, a startup passou a utilizar um poliestireno com tratamento impermeabilizante;
2. Adição de estrutura em acrílico: foi adicionado uma estrutura mecânica para armazenar o *hardware* e o LoRa, em acrílico impermeabilizado. Além disso, garras foram adicionadas para fixação do protótipo no tanque.

A Figura 28 retrata de maneira esquemática a solução obtida pela startup. Nela, vale destacar que agora o protótipo não ficará mais em um pote plástico comum, mas sim em uma estrutura de acrílico que estará agarrada ao tanque coletando áudio do funcionamento da operação.

Figura 28 – Desenho esquemático da nova estrutura mecânica para o protótipo




Fonte: Equipe de *hardware* da startup Máquina Feliz

5.2 Resultado do Objetivo 2: processamento da base de dados coletada

A primeira parte do processamento dos dados consistiu no funcionamento em trechos menores de cinco segundos. Em seguida, gerou-se um espectrograma do trecho, que pode ser observado na Figura 29. Infelizmente, quando plotamos esse espectrograma, não tem muita informação significativa que podemos extrair, por causa do fato da percepção humana auditiva estar contida num espectro restrito de frequência e amplitude. Isso está ilustrado em pequenos trechos num mapa de calor para valores de frequência próximos a 1000Hz.


Assim, como passo seguinte no processamento dos dados, o espectrograma foi convertido para a Escala de Mel, que faz a conexão entre as frequências percebidas pelo ouvido humano. A Figura 30 representa o mesmo espectrograma, mas agora na escala de Mel. Vale notar que a escala do domínio da frequência modifica, bem como a amplitude do sinal é alterada na Escala de Mel, tornando assim, próxima à percepção do ouvido humano

Figura 29 – Espectrograma obtido para sinal sonoro com defeito



Fonte: Elaboração Própria


Figura 30 – Espectrograma de Mel do mesmo sinal com defeito



Fonte: Elaboração Própria

Se compararmos a Figura 30, que retrata um áudio com vazamento da válvula, com a Figura 31 de outro espectrograma, mas agora sem defeito, percebemos claramente a diferença: no primeiro, sons de maiores intensidades são mais presentes (maior valor na escala de decibéis), independente da frequência. Na segunda imagem, por outro lado, intensidades elevadas são percebidas apenas em baixas frequências.

Figura 31 – Espectrograma de Mel de sinal sem defeito



Fonte: Elaboração Própria

Dessa forma, com essa clara diferenciação nos espectrogramas, o Autor procedeu por registrá-los no banco de dados após embaralhá-los, para serem usados como *input* para o modelo de *machine learning*.


5.3 Resultado do Objetivo 3: performance do modelo de *machine learning* de classificação

Para avaliar a performance do modelo de classificação, três principais métricas foram adotadas: (i) decaimento da função de perda, (ii) acurácia e (iii) matriz de correlação.

A primeira métrica considerada foi a evolução da função de perda de entropia cruzada ao longo das épocas de treinamento, como mostrado na Figura 32. Este gráfico apresenta duas curvas: a curva de perda de treinamento (azul) e a curva de perda de validação (laranja). Observa-se que ambas as curvas exibem um declínio significativo à medida que o número de épocas aumenta, indicando uma melhoria contínua na capacidade do modelo de generalizar a partir dos dados.

Inicialmente, a curva de perda de treinamento começa com um valor relativamente alto, próximo a 1,75. Este alto valor inicial indica que, no começo do treinamento, o modelo está longe de fazer previsões precisas. No entanto, a curva decai rapidamente já na primeira

Figura 32 – Evolução da função de perda



Fonte: Elaboração Própria

época, caindo para abaixo de 1, 25. Isso demonstra uma taxa de aprendizado inicial bastante eficaz, onde o modelo rapidamente absorve informações dos dados para melhorar suas previsões.


À medida que as épocas avançam, a taxa de decréscimo da perda diminui, e as curvas começam a se estabilizar e convergir. Por volta da quarta época, tanto a curva de treinamento quanto a de validação se estabilizam em torno de valores próximos a 0,6. A convergência dessas curvas em valores baixos e próximos sugere que o modelo não está apenas aprendendo os dados de treinamento, mas também generalizando bem para os dados de validação, o que é indicativo de que o modelo não está sofrendo de overfitting significativo.

Além da função de perda, a acurácia, como uma métrica de desempenho, indica a proporção de predições corretas (tanto verdadeiros positivos quanto verdadeiros negativos) em relação ao total de casos examinados. Na Figura 33, duas curvas representam a evolução da acurácia ao longo das épocas para os conjuntos de treinamento e validação. O gráfico mostra que a curva de acurácia de treinamento (em azul) inicia em cerca de 40%, o que é comum no início do treinamento quando o modelo ainda está aprendendo as características básicas dos dados. A curva de acurácia de validação (em laranja) começa em um patamar ligeiramente superior, próximo a 60%. Isso pode ocorrer devido a uma variedade de fatores, incluindo a natureza dos dados de validação, que podem ser inicialmente mais "fáceis" de prever com base na distribuição inicial de pesos do modelo.

Ambas as curvas mostram um aumento significativo e constante nas primeiras épocas. Este aumento indica que o modelo está aprendendo efetivamente e ajustando seus pesos para melhor categorizar as entradas. A curva de acurácia de treinamento, após o rápido

aumento inicial, continua a melhorar gradualmente, alcançando um platô próximo a 85%. A curva de validação, seguindo uma trajetória semelhante, também se estabiliza, sugerindo que o modelo mantém sua performance em dados novos, um sinal de boa generalização, reforçando o comportamento visto na função de perda.

Figura 33 – Evolução da acurácia



Fonte: Elaboração Própria


A Figura 34 apresenta a matriz de confusão obtida a partir do modelo de classificação. Esta matriz é uma ferramenta essencial para a avaliação do desempenho do modelo, permitindo uma visualização clara das previsões corretas e incorretas. A matriz de confusão apresentada tem a seguinte configuração:

Os valores na matriz de confusão são interpretados da seguinte maneira:

- Verdadeiro Positivo (VP): 599 instâncias foram corretamente classificadas como "Com defeito".
- Verdadeiro Negativo (VN): 625 instâncias foram corretamente classificadas como "Sem defeito".
- Falso Positivo (FP): 97 instâncias foram incorretamente classificadas como "Com defeito" quando na verdade eram "Sem defeito".
- Falso Negativo (FN): 60 instâncias foram incorretamente classificadas como "Sem defeito" quando na verdade eram "Com defeito".

Com base nesses valores, o Autor calculou métricas importantes para a avaliação do desempenho do modelo:

Figura 34 – Matriz de confusão



Fonte: Elaboração Própria

- **Acurácia:** A acurácia, como visto anteriormente, é a proporção de todas as previsões corretas (tanto verdadeiros positivos quanto verdadeiros negativos) entre o total de casos examinados. É calculada como:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} = \frac{1224}{1381} \approx 0,886$$

- **Precisão:** A precisão é a proporção de verdadeiros positivos em relação ao número total de positivos preditos (verdadeiros positivos mais falsos positivos). É calculada como:

$$\text{Precisão} = \frac{VP}{VP + FP} = \frac{599}{696} \approx 0,861$$

- **Recall (Sensibilidade):** O recall é a proporção de verdadeiros positivos em relação ao número total de positivos reais (verdadeiros positivos mais falsos negativos). É calculado como:

$$\text{Recall} = \frac{VP}{VP + FN} = \frac{599}{659} \approx 0,909$$

- **F1-Score:** O F1-Score é a média harmônica da precisão e do recall, fornecendo uma única métrica que balanceia ambos. É calculado como:

$$F1\text{-Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} = 2 \times \frac{0,861 \times 0,909}{0,861 + 0,909} \approx 0,884$$


A matriz de confusão e as métricas derivadas mostram que o modelo possui uma alta acurácia (88,6%) - e em linha com o analisado na fase de teste e validação, precisão (86,1%),

recall (90,9%) e F1-Score (88,4%), indicando um bom desempenho na classificação das instâncias "Com defeito" e "Sem defeito". No entanto, há uma quantidade de aproximadamente 12% entre falso positivo e falso negativo, sugerindo que não houve *overfitting*, ou seja, que o modelo é capaz de generalizar as informações do treinamento, e aplicar em uma base de dados não conhecida, porém mostra também um espaço para otimização desses valores em uma segunda versão do modelo de *machine learning*.

5.4 Resultado do Objetivo 4: disponibilização do status de operação no Grafana

Com o Objetivo 4 concluído, foi possível visualizar em tempo real, do escritório da Gerência de Produção, o status de operação da válvula do tanque de gás carbônico. A Figura 35 ilustra o *dashboard* obtido na interface Grafana do cliente BebidasCo. Vale destacar que a Figura 35 mostra três campos: o primeiro à esquerda, com um indicador que pode ser vermelho (indicando estado defeituoso) ou verde (representando o estado sem defeito); um campo ao centro para observar a variação no status de funcionamento em função do horário do dia; e o campo à direita para indicar que a central está continuamente se comunicando com o LoRa do protótipo.

Figura 35 – *Dashboard* de resultado na plataforma Grafana



Fonte: Elaboração Própria

Para o caso retratado na Figura 35, o modelo de *machine learning* a classificou como "com defeito", indicando possível vazamento. Isso está retratado no indicador em vermelho no campo à esquerda. Além disso, o campo ao centro ilustra que o vazamento perdura há pelo menos 23 horas, e a comunicação entre protótipo e LoRa funciona perfeitamente.


5.5 Piloto realizado com cliente

Para validar a eficácia do protótipo desenvolvido, realizamos um teste piloto em colaboração direta com o cliente. O teste envolveu a instalação do protótipo em um ambiente operacional real, mais especificamente acoplado a uma válvula de um tanque reservatório conhecido por apresentar problemas de vazamento. O objetivo principal desta fase experimental era verificar a capacidade do protótipo de detectar vazamentos em tempo real e notificar o usuário adequadamente.

O fluxograma da Figura 36 ilustra de maneira esquemática o funcionamento da inferência, ou seja, como o protótipo vai captar o áudio da operação da válvula, o modelo atribuirá uma

classificação a esse *input*, e um resultado será exibido para o usuário na plataforma do Grafana.

Figura 36 – Fluxo de inferência



Fonte: Elaboração Própria

Na Figura 36, o processo se inicia com o microfone do protótipo captando sinais de áudio da operação da válvula. O Raspberry Pi é responsável por converter trechos do áudio em um espectrograma de Mel, que será utilizado como *input* para inferência, através do modelo de *machine learning* já treinado. Vale ressaltar que aqui o modelo é uma matriz de coeficientes que fará cálculos e o seu *output* será uma classificação entre "com defeito" ou "sem defeito". Com essa classificação, o controlador enviará esse dado ao LoRa, que inicia o protocolo de comunicação com a central. A central, localizada no escritório da Gerência de Produção e conectada à internet, recebe o dado do protótipo e salva o dado recebido a partir da conexão com o Grafana. Por fim, o usuário final tem acesso, como ilustrado na Figura 35, ao estado de funcionamento da válvula do reservatório de gás carbônico.

Para validar o funcionamento desse fluxograma da Figura 36 na prática, foi realizado um teste *in-loco* na fábrica da BebidasCo. A Figura 37 mostra a instalação do protótipo em um dos tanques de gás carbônico da planta industrial. Nela, podemos ver na prática o resultado do desenho esquemático da Figura 28. Vale destacar aqui que o controlador e o microfone se encontram na parte interna da estrutura mecânica desenvolvida. Externamente, pode-se ver apenas a antena LoRa, responsável pela comunicação com a central.

A partir dessa instalação do protótipo, o áudio começou a ser gravado, e o modelo começou a gerar as inferências. A Tabela 2 a seguir ilustra os resultados da inferência do modelo de *machine learning* transmitidos pelo LoRa e recebidos na central.

Na Tabela 2, podemos perceber que o modelo de *machine learning* foi capaz de detectar que houve uma mudança no status de operação do tanque por volta das 10h29, saindo de um estado funcional para um estado com defeito. Essa mudança no status foi causada por um vazamento monitorado em parceria com a Equipe de Manutenção. O protótipo foi deixado em operação e o resultado da conexão com o Grafana está retratado na Figura 35.

Figura 37 – Protótipo final instalado em reservatório de gás carbônico



Fonte: Elaboração Própria

Data/Horário	Probabilidade Classe	Status
2022-05-21 10:27:53	0.958257	sem defeito
2022-05-21 10:27:58	0.995388	sem defeito
2022-05-21 10:28:03	0.889755	sem defeito
2022-05-21 10:28:08	0.956574	sem defeito
2022-05-21 10:28:13	0.939433	sem defeito
2022-05-21 10:28:18	0.653378	sem defeito
2022-05-21 10:28:23	0.650745	sem defeito
2022-05-21 10:28:28	0.535072	sem defeito
2022-05-21 10:28:33	0.637797	sem defeito
2022-05-21 10:28:38	0.438657	sem defeito
2022-05-21 10:28:43	0.096601	sem defeito
2022-05-21 10:28:48	0.140628	sem defeito
2022-05-21 10:28:53	0.343207	sem defeito
2022-05-21 10:28:58	0.229264	sem defeito
2022-05-21 10:29:03	0.241938	sem defeito
2022-05-21 10:29:08	0.019351	com defeito
2022-05-21 10:29:13	0.038802	com defeito
2022-05-21 10:29:18	0.024113	com defeito
2022-05-21 10:29:23	0.035903	com defeito
2022-05-21 10:29:28	0.045216	com defeito

Tabela 2 – Resultados obtidos com piloto realizado

5.6 Discussão com Diretor de IoT

O diretor de IoT da empresa BebidasCo, que acompanhou o teste final, destacou diversos pontos positivos da solução desenvolvida. Em primeiro lugar, ele ressaltou que

a startup conseguiu criar uma solução customizada para um problema muito específico, demonstrando um potencial significativo de escalabilidade. Esse aspecto é crucial no desenvolvimento de soluções para a Indústria 4.0, uma vez que muitas fábricas ainda não estão conectadas. O uso de um modelo embarcado, integrado a uma rede LoRa para transmissão dos dados de inferência, mostrou-se uma abordagem essencial e promissora, aplicável a diversos outros casos industriais.

Além disso, o diretor enfatizou o potencial de replicação da solução para outros contextos industriais. Embora o protótipo tenha sido desenvolvido especificamente para monitorar reservatórios de gás carbônico, o princípio subjacente – a detecção de falhas através da análise de ruídos – é aplicável a uma variedade de máquinas industriais. Esse potencial de adaptação e escalabilidade torna a solução da startup ainda mais valiosa no mercado.

De forma discreta, o diretor de IoT também manifestou interesse em uma possível aquisição da equipe fundadora da startup para continuar o desenvolvimento da solução internamente na empresa BebidasCo. Essa possibilidade sublinha o reconhecimento do valor e da inovação trazidos pela startup ao campo do monitoramento de máquinas industriais.

Esses resultados evidenciam não apenas a eficácia da solução desenvolvida, mas também o seu grande potencial de impacto e expansão no setor industrial. A startup demonstrou que é possível criar soluções tecnológicas avançadas e escaláveis, contribuindo significativamente para a evolução da Indústria 4.0.

6 CONCLUSÃO

A criação de projetos no contexto da Indústria 4.0 enfrenta diversos desafios, especialmente devido à baixa conectividade das fábricas no Brasil. Muitas unidades industriais ainda não possuem acesso à internet em suas operações, o que dificulta a implementação de tecnologias avançadas e conectadas. Esse cenário impõe barreiras significativas ao desenvolvimento e à adoção de soluções inovadoras que poderiam aumentar a eficiência e a segurança das operações industriais.

A solução desenvolvida pela startup do Autor vem para contornar esse problema de forma eficaz. Ao utilizar um modelo embarcado e empregando a tecnologia LoRa para comunicação entre o protótipo e uma central conectada à internet, a startup conseguiu contornar eficientemente esse desafio. Essa abordagem permite que dados críticos de monitoramento sejam coletados, inferidos e transmitidos de forma eficiente, superando as limitações de infraestrutura e conectividade em fábricas brasileiras. A tecnologia LoRa, com sua capacidade de transmissão de longa distância e baixo consumo de energia, mostrou-se ideal para essa aplicação, garantindo a comunicação necessária para a inferência dos modelos de *machine learning* embarcados.

Além disso, o algoritmo de *machine learning* proposto neste Trabalho possui um enorme potencial para a identificação de problemas em máquinas industriais a partir de ruídos, conforme ressaltado pelo diretor de IoT. Essa capacidade de detecção de falhas por meio da análise de ruídos é aplicável a uma variedade de máquinas industriais, ampliando o alcance e a utilidade da solução desenvolvida.

Inicialmente, este Trabalho de Formatura começou com a empresa Máquina Feliz ganhando uma licitação para resolver um problema de identificação de vazamentos. A partir disso, iniciou-se um processo de customer discovery, visando mapear as principais dores do cliente BebidasCo e especificar o problema a ser resolvido. Em sequência, quatro objetivos principais foram traçados para o trabalho: a coleta dos dados de operação, o processamento dos dados, o treinamento do modelo de *machine learning*, e, por fim, a disponibilização desses resultados em uma plataforma de IoT do cliente.

Do ponto de vista dos resultados para a startup Máquina Feliz, ao final deste piloto, a empresa não continuou suas operações em um novo projeto para aferir ganhos. Apesar de haver conversas para que os fundadores se juntassem à empresa BebidasCo, não houve interesse comum em dar continuidade ao projeto, uma vez que 80% da equipe tinha planos de se mudar de país. Assim, a Máquina Feliz foi recompensada financeiramente para realizar um processo de transferência das tecnologias e dos conhecimentos para a equipe de IoT da BebidasCo, que então deu continuidade ao projeto para aferir ganhos.

Para o Autor deste projeto, foi uma oportunidade não só de aplicar os conhecimentos obtidos durante a graduação em Engenharia de Produção e o duplo diploma na École CentraleSupélec, mas também uma oportunidade de empreender e oferecer uma solução

para um problema latente no cenário brasileiro. Esta rica experiência proporcionou aprendizados valiosos em diversas áreas, incluindo a aplicação prática de teoria acadêmica, desenvolvimento de soluções tecnológicas inovadoras, e a interação direta com clientes reais para resolver problemas concretos. Além disso, o projeto permitiu ao autor experimentar o processo de criação e crescimento de uma startup, enfrentando desafios reais e desenvolvendo habilidades essenciais para o empreendedorismo e a inovação.

Os resultados obtidos demonstram não apenas a eficácia da solução desenvolvida, mas também seu grande potencial de impacto e expansão no setor industrial. A startup do Autor provou ser possível criar soluções tecnológicas avançadas e escaláveis, contribuindo significativamente para a evolução da Indústria 4.0, mesmo em ambientes com infraestrutura limitada.

REFERÊNCIAS

- ANDERSEN, B.; FAGERHAUG, T.; BELTZ, L. *Guia para a Melhoria de Processos*. [S.l.: s.n.], 2010.
- BAHGA, A.; MADISETTI, V. *Internet of Things: A Hands-On Approach*. USA: VPT, 2014. ISBN 978-0996025507.
- BEEDLE ARIE VAN BENNEKUM, A. C. W. C. M. F. M. *Manifesto for Agile Software Development*. [S.l.: s.n.], 2001.
- Boston Consulting Group. *How Internet of Things (IoT) Data Ecosystems Transform B2B Competition*. 2018. Disponível em: <https://www.bcg.com/publications/2018/how-internet-of-things-iot-data-ecosystems-transform-b2b-competition>.
- BUYYA, R.; DASTJERDI, A. V. (Ed.). *Internet of Things (IoT): Principles and Paradigms*. Amsterdam: Elsevier, 2016. ISBN 9780128053959.
- BUYYA, R.; DASTJERDI, A. V. (Ed.). *Internet of Things: Principles and Paradigms*. [S.l.]: Morgan Kaufmann, 2016.
- CHOI, K.; FAZEKAS, G.; SANDLER, M. A tutorial on deep learning for music information retrieval. *arXiv preprint arXiv:1709.04396*, 2017.
- EMIR, E. Y. *Design Thinking Methodology Book*. [S.l.]: YAAY Design Ltd., 2015.
- FELD, B. *Startup Communities: Building an Entrepreneurial Ecosystem in Your City*. [S.l.]: Wiley, 2012.
- FOUNDATION, I. D. *Design Thinking (DT)*. 2016. Acesso em: 29 de março de 2024. Disponível em: <https://www.interaction-design.org/literature/topics/design-thinking>.
- GOLD, B.; MORGAN, N.; ELLIS, D. *Speech and Audio Signal Processing: Processing and Perception of Speech and Music*. [S.l.]: John Wiley & Sons, 2011.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. ed. New York, NY, USA: Springer, 2009.
- ISHIKAWA, K. *Guide to Quality Control*. [S.l.]: Asian Productivity Organization, 1986.
- JURAFSKY, D.; MARTIN, J. H. *Speech and Language Processing*. [S.l.]: Draft, 2019.
- KÖRNER, T. *Fourier Analysis*. [S.l.]: Cambridge University Press, 2003.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. p. 1097–1105.
- KUME, H. *Statistical Methods for Quality Improvement*. [S.l.]: AOTS, 1993.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, IEEE, v. 86, n. 11, p. 2278–2324, 1998.

LEE, J.; BAGHERI, B.; KAO, H.-A. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. *Manufacturing Letters*, v. 3, p. 18–23, 2015.

LIKER, J. K. *The Toyota Way: 14 Management Principles from the World's Greatest Manufacturer*. [S.l.]: McGraw-Hill, 2004.

LoRa Alliance. *LoRaWAN 1.1 Specification*. 2017. <https://loro-alliance.org/resource-hub/lorawanr-specification-v11>. Accessed: 2024-05-14.

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

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. *Foundations of Machine Learning*. Cambridge, MA, USA: The MIT Press, 2012.

MORRIS, M. H.; KURATKO, D. F.; CORNWALL, J. R. *Entrepreneurship Programs and the Modern University*. [S.l.]: Edward Elgar Publishing, 2013.

OPPENHEIM, A. V.; SCHAFER, R. W. *Discrete-Time Signal Processing*. 2. ed. Upper Saddle River, NJ, USA: Prentice Hall, 1999.

Raspberry Pi Foundation. *About the Raspberry Pi Foundation*. 2024. <https://www.raspberrypi.org/about/>. Accessed: 2024-05-14.

RIES, E. *The Lean Startup: How Today's Entrepreneurs Use Continuous Innovation to Create Radically Successful Businesses*. [S.l.]: Crown Business, 2011.

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

STEVENS, S. S.; VOLKMANN, J.; NEWMAN, E. B. A scale for the measurement of the psychological magnitude of pitch. *Journal of the Acoustical Society of America*, Acoustical Society of America, v. 8, n. 3, p. 185–190, 1937.

WITTEN, I. H.; FRANK, E. *Data Mining: Practical Machine Learning Tools and Techniques*. 2. ed. [S.l.]: Morgan Kaufmann Publishers, 2005.