

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

**RODRIGO MESSIAS MORAES**

**INTELIGÊNCIA ARTIFICIAL EM *LEAN MANUFACTURING*:  
aplicação de processamento de linguagem natural no controle de *Andon***

**MANAUS  
2025**

**RODRIGO MESSIAS MORAES**

**INTELIGÊNCIA ARTIFICIAL EM *LEAN MANUFACTURING*:**

**aplicação de processamento de linguagem natural no controle de *Andon***

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

Orientador: Prof. Dr, Alessandro de Souza Bezerra

MANAUS  
2025

## Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

**Sistema Integrado de Bibliotecas da Universidade do Estado do Amazonas.**

M828i      Moraes, Rodrigo Messias

Inteligência artificial em Lean Manufacturing : aplicação de processamento de linguagem natural no controle de Andon / Rodrigo Messias Moraes . Manaus : [s.n], 2025.

72 f.: color.; 21,0 cm.

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

Inclui Bibliografia. Inclui Apêndice.

Inclui Anexo.

Orientador: Alessandro de Souza Bezerra.

CDU(1997)658.5

**RODRIGO MESSIAS MORAES**

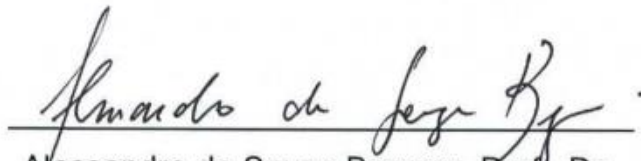
**INTELIGÊNCIA ARTIFICIAL EM *LEAN MANUFACTURING*:**

aplicação de processamento de linguagem natural no controle de *Andon*

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

Data de aprovação: Manaus (AM), 11 de junho de 2025.

Banca examinadora:



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



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



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

## DEDICATÓRIA

*Dedico este trabalho aos meus pais, Norma e Gilberto, por todos os ensinamentos, valores e princípios que me formaram e me conduzem até aqui, tornando-me quem eu sou hoje, que sempre estiveram ao meu lado, me deram amor incondicional e jamais deixaram que me faltasse algo. Às minhas irmãs, Cris, Carol e Sabrina, à minha avó Edneia, que, com amor, dedicação e cuidado, foram fundamentais em minha trajetória. Agradeço também à Aline, pela parceria. Ao meu tio Márcio pela convivência e em especial minha Tia Cris e meu Tio Erasmo, que também são responsáveis por eu estar conseguindo realizar esta etapa em minha vida, agradeço de todo coração, esta conquista não é só minha.*

## **AGRADECIMENTOS**

Agradeço, primeiramente, a Deus, pelo dom da vida, pela saúde e por me fortalecer em cada etapa dessa jornada.

Aos meus pais e a toda a minha família por todo o amor, recurso, apoio e incentivo, fundamentais para que eu chegasse até aqui.

Agradeço a todos os professores que fizeram parte da minha formação, que, com dedicação, paciência e amor pelo ensino, compartilharam não apenas conhecimento, mas também valores que levarei por toda a vida. Em especial, agradeço a professora Rejane por todo suporte, lições e paciência.

Agradeço ao orientador Alessandro, que, apesar dos desafios no início da construção deste trabalho, acreditou na ideia e, com sua orientação, apontou o caminho, mostrando as possibilidades e os ajustes necessários para a concretização deste projeto. Registro aqui minha profunda admiração e gratidão.

Aos meus colegas de faculdade, que tornaram essa caminhada mais leve, deixando memórias que ficarão para sempre, e que compartilharam conhecimentos, companheirismo e apoio.

Aos meus colegas de trabalho, que não mediram esforços para me ajudar, esclarecer minhas dúvidas e me auxiliar sempre que precisei. A todos vocês, meu sincero agradecimento, por fazerem parte dessa trajetória.

E a mim, por não ter desistido desta jornada. Esse trabalho é, também, a prova da minha resiliência, da minha determinação e da minha capacidade de transformar desafios em conquistas.

*“O sucesso é a soma de pequenos esforços repetidos  
diariamente.”*

***Robert Collier***

*“Mas lembre-se: aconteça o que acontecer,  
Nada como um dia após o outro dia.”*

***Racionais MC's***

## RESUMO

Este estudo aplica técnicas de Inteligência Artificial, por meio do Processamento de Linguagem Natural (PLN), ao controle do sistema *Andon*, alinhando-se aos princípios do *Lean Manufacturing*. A pesquisa foi realizada em uma empresa do Polo Industrial de Manaus (PIM), onde o controle dos acionamentos do *Andon* é feito manualmente, por meio de planilhas *Excel*, o que limita a análise e a interpretação dos dados, especialmente daqueles registros que não resultam em paradas críticas. O objetivo consiste em transformar os registros históricos do *Andon* em informações organizadas e acessíveis, por meio da aplicação de modelos de PLN, aliados a um *Dashboard* desenvolvido no *Power BI* como suporte à tomada de decisão. A metodologia caracteriza-se como estudo de caso, com abordagem quantitativa, utilizando 955 registros coletados, dos quais 645 foram considerados válidos após o tratamento dos dados. O modelo de PLN, baseado na arquitetura GPT-4, foi configurado com os registros históricos utilizando a técnica de Recuperação Aumentada de Geração (RAG), permitindo interpretar automaticamente informações como sintoma, causa e ação dos eventos, superando limitações relacionadas à ambiguidade e à falta de padronização textual. Paralelamente, desenvolveu-se um *Dashboard* no *Power BI* para análise quantitativa, possibilitando a identificação de padrões de falhas, postos críticos e tempo acumulado de paradas. Também foi criado um protótipo de assistente virtual em *Streamlit*, conectado à API da *OpenAI*, capaz de responder a consultas em linguagem natural com base nos dados processados. Os resultados demonstram que a integração entre análise de dados e PLN contribui de forma significativa para aprimorar o controle do processo produtivo, melhorar a organização das informações, reduzir falhas operacionais e apoiar a tomada de decisão na gestão industrial.

**Palavras-chave:** *Lean Manufacturing*; processamento de linguagem natural; inteligência artificial; *Andon*; *Power BI*.

## **ABSTRACT**

*This study applies Artificial Intelligence techniques, through Natural Language Processing (NLP), to the control of the Andon system, in alignment with Lean Manufacturing principles. The research was conducted in a company located in the Industrial Hub of Manaus (PIM), where the control of Andon activations is performed manually using Excel spreadsheets, which limits the analysis and interpretation of data, especially records that do not result in critical stoppages. The objective is to transform historical Andon records into organized and accessible information through the application of NLP models, combined with a Dashboard developed in Power BI to support decision-making. The methodology is characterized as a case study with a quantitative approach, using 955 records, of which 645 were considered valid after data preprocessing. The NLP model, based on the GPT-4 architecture, was configured with historical records using the Retrieval-Augmented Generation (RAG) technique, allowing for the automatic interpretation of textual information such as symptoms, causes, and actions, overcoming limitations related to textual ambiguity and lack of standardization. In parallel, a Power BI Dashboard was developed for quantitative analysis, enabling the identification of failure patterns, critical workstations, and accumulated downtime. A prototype of a virtual assistant was also created in Streamlit, connected to the OpenAI API, capable of responding to natural language queries based on the processed data. The results demonstrate that the integration of data analysis and NLP significantly contributes to improving process control, enhancing information organization, reducing operational failures, and supporting decision-making in industrial management.*

**Keywords:** *Lean Manufacturing; natural language processing; artificial intelligence; Andon; Power BI.*

## LISTA DE FIGURAS

Figura 1	– Sistema <i>Andon</i> .....	20
Figura 2	– Sistema <i>Andon</i> em operação.....	21
Figura 3	– Informações Gerais dos Dados 1.....	34
Figura 4	– Informações Gerais dos Dados 2.....	34
Figura 5	– Código no <i>Google Colab</i> .....	37
Figura 6	– <i>Dashboard</i> Completo.....	41
Figura 7	– Resultados para a hipótese 1.....	43
Figura 8	– Resultados para a hipótese 2.....	44
Figura 9	– <i>Dashboard</i> Filtrado em Stop (Parada de Linha) .....	47
Figura 10	– <i>Dashboard</i> Filtrado em <i>Warning</i> (Atenção) .....	48
Figura 11	– Interface do Assistente no <i>Streamlit</i> - Pergunta 1.....	51
Figura 12	– Interface do Assistente no <i>Streamlit</i> - Pergunta 2.....	52
Figura 13	– Melhoria na estrutura no trilho .....	55
Figura 14	– Melhoria na reposição de dispensador .....	55
Figura 15	– Instalação de mangueira de sopro de ar nos conectores.....	56

## LISTA DE SIGLAS

<b>API</b>	<i>Application Programming Interface</i>
<b>GPT</b>	<i>Generative Pre-trained Transformer</i>
<b>IA</b>	Inteligência Artificial
<b>NLP</b>	<i>Natural Language Processing</i>
<b>PDF</b>	<i>Portable Document Format</i>
<b>PIM</b>	Polo Industrial de Manaus
<b>PLN</b>	Processamento de Linguagem Natural
<b>RAG</b>	Recuperação Aumentada de Geração
<b>TPS</b>	<i>Toyota Production System</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>13</b>
1.1	CONTEXTUALIZAÇÃO.....	13
1.2	PROBLEMA.....	14
1.3	JUSTIFICATIVA DA PESQUISA.....	14
1.4	HIPÓTESES.....	15
1.5	OBJETIVOS.....	15
1.5.1	<b>Objetivo geral</b> .....	<b>15</b>
1.5.2	<b>Objetivos específicos</b> .....	<b>15</b>
1.6	LIMITAÇÃO DO ESTUDO.....	16
1.7	ESTRUTURAÇÃO DO TRABALHO.....	16
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>17</b>
2.1	<i>LEAN MANUFACTURING</i> .....	17
2.2	<i>ANDON</i> .....	20
2.3	INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA.....	22
2.4	PROCESSAMENTO DE LINGUAGEM NATURAL (PLN).....	24
2.5	RECUPERAÇÃO AUMENTADA DE GERAÇÃO (RAG).....	27
2.6	MODELO DE LINGUAGEM.....	28
2.7	<i>POWER BI</i> E VISUALIZAÇÃO DE DADOS.....	29
2.8	TRABALHOS CORRELATOS.....	30
2.9	RECURSOS COMPUTACIONAIS DE APOIO.....	31
<b>3</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>33</b>
3.1	METODOLOGIA.....	33
3.2	COLETA E ANÁLISE DE DADOS.....	33
3.2.1	<b>Coleta de dados</b> .....	<b>34</b>
3.2.2	<b>Pré-processamento de Dados</b> .....	<b>35</b>
3.3	APLICAÇÃO DE RAG NO ASSISTENTE GPT.....	36
3.3.1	<b>Avaliação técnica do modelo de linguagem</b> .....	<b>38</b>
3.4	DESENVOLVIMENTO DO <i>DASHBOARD</i> .....	40
3.4.1	<b>Avaliação técnica do <i>Dashboard</i> para hipótese 2</b> .....	<b>42</b>
<b>4</b>	<b>ANÁLISE DOS RESULTADOS</b> .....	<b>43</b>
4.1	VALIDAÇÃO DAS HIPÓTESES.....	43

4.2	RESULTADOS DO MODELO DE LINGUAGEM REALIZADO.....	45
4.3	ANÁLISE QUANTITATIVA DO <i>DASHBOARD</i> .....	47
4.4	ANÁLISE DOS RESULTADOS DO MODELO COM O <i>DASHBOARD</i> .....	49
4.5	PROPOSTA INTERATIVA COM <i>STREAMLIT</i> .....	50
4.6	ANÁLISES DE MELHORIA DO PROCESSO DE PRODUÇÃO.....	54
<b>5</b>	<b>CONCLUSÃO</b> .....	<b>57</b>
<b>6</b>	<b>RECOMENDAÇÕES</b> .....	<b>59</b>
	<b>REFERÊNCIAS</b> .....	<b>60</b>
	<b>ANEXOS</b> .....	<b>64</b>
	<b>APÊNDICE</b> .....	<b>68</b>

## 1 INTRODUÇÃO

A eficiência operacional é fundamental nos ambientes industriais contemporâneos, pois permite sustentar a produtividade e a qualidade dos produtos, conforme Womack, Jones e Roos (2004). Nesse contexto, o sistema *Andon*, um dos pilares da filosofia *Lean Manufacturing*, desempenha um papel crucial na detecção imediata de problemas e na implementação de soluções corretivas rápidas, conforme destacado por Ohno (1988), que enfatiza a importância da visualização de problemas para melhorar a eficiência.

Ao sinalizar visual ou auditivamente anomalias no processo de produção, este sistema possibilita que operadores e gestores intervenham prontamente, minimizando consequências adversas e visando o aumento da importância da busca da qualidade e com foco na melhoria contínua do processo (Silva, 2024). Essa capacidade de intervenção rápida é essencial para reduzir o tempo de inatividade e melhorar a eficiência operacional, conforme destacado por diversos estudos sobre o sistema *Andon*, que mostram sua eficácia em aumentar a produtividade e a qualidade dos produtos ao minimizar desperdícios e garantir a entrega de produtos de alta qualidade (Castro, 2016; Santos, 2025).

### 1.1 CONTEXTUALIZAÇÃO

A implementação eficaz do sistema *Andon* é particularmente relevante em regiões industriais dinâmicas, como o Polo Industrial de Manaus (PIM), onde a competitividade e a eficiência são cruciais para o sucesso das empresas. O PIM, um dos mais modernos centros industriais da América Latina, abriga mais de 500 indústrias de ponta em segmentos como eletroeletrônico, duas rodas, naval, mecânico, metalúrgico e termoplástico (Suframa, 2023). A região é responsável por um faturamento anual superior a R\$120 bilhões e gera cerca de meio milhão de empregos diretos e indiretos, contribuindo significativamente para o desenvolvimento econômico da Amazônia. A produção do PIM é majoritariamente destinada ao mercado brasileiro, com uma pequena parcela exportada para mercados internacionais (Suframa, 2024).

## 1.2 PROBLEMA

Na empresa em estudo, localizada no Polo Industrial de Manaus (PIM), o procedimento atual de análise e controle do sistema *Andon* é realizado com suporte do *software Microsoft Excel 2013*. Esse método limita-se à análise descritiva dos acionamentos que resultam em defeitos no produto ou paradas de linha superiores ou inferiores a três minutos. Tal abordagem pode ocasionar perdas de informações relevantes, já que os demais acionamentos não são considerados. Além disso, fatores como ambiguidade textual, variações linguísticas, erros ortográficos e as limitações tecnológicas do *Excel* dificultam a análise precisa dos dados, comprometendo a acuracidade das decisões e das estratégias para melhoria contínua.

Diante desse cenário, surgem as seguintes perguntas de pesquisa:

- a) Por que somente os acionamentos que geram defeitos ou paradas de linha são analisados, enquanto os demais são ignorados, mesmo que representem problemas no processo?
- b) Se todos os acionamentos fossem monitorados, seria possível identificar padrões, antecipar falhas e propor melhorias mais eficazes no processo produtivo?
- c) Diante de uma base descritiva no *Excel*, onde cada linha representa um acionamento, é possível utilizar técnicas de inteligência artificial para interpretar automaticamente esses dados e apoiar na tomada de decisão?

## 1.3 JUSTIFICATIVA DA PESQUISA

Frente a esses desafios, a aplicação de tecnologias avançadas, como o *Natural Language Processing* (NLP), emerge como uma solução promissora para otimizar e aprimorar o processo de análise dos problemas do controle de *Andon*. O PLN oferece a capacidade de compreender, interpretar e processar a linguagem humana de forma inteligente, proporcionando um mapeamento mais preciso, contextualizado e eficiente dos problemas.

Além disso, o PLN facilita a identificação de padrões, tendências e *insights* valiosos que podem ser utilizados para impulsionar a melhoria contínua e a *Excelência* operacional. Portanto, este estudo visa não apenas abordar as limitações do método atual da análise de *Andon*, mas também contribuir significativamente para o avanço teórico no campo do *Lean Manufacturing* e para o estímulo à inovação tecnológica no ambiente industrial.

Ao focar na aplicação de PLN no controle de *Andon* para ambientes de manufatura, busca-se fornecer uma solução inovadora e adaptável que responda aos desafios específicos enfrentados pela empresa e esteja alinhada com as demandas da indústria moderna.

#### 1.4 HIPÓTESES

Hipótese 1: O uso do modelo de linguagem com aplicação da técnica RAG, a partir dos registros históricos do sistema *Andon*, permitirá interpretar os textos e fornecer *insights* úteis para a tomada de decisão.

Hipótese 2: O uso de *Dashboards* interativos em *Power BI* contribui para uma análise mais estratégica dos dados do sistema *Andon*, ao permitir a visualização clara dos postos críticos, tempos acumulados de parada e padrões de acionamento.

#### 1.5 OBJETIVOS

##### 1.5.1 Objetivo geral

Desenvolver uma solução de apoio à análise dos registros do sistema *Andon*, por meio da integração entre modelos de linguagem, recuperação aumentada de geração (RAG) e um *Dashboard* com *Power BI*.

##### 1.5.2 Objetivos específicos

- a) Analisar os registros históricos do sistema *Andon* da empresa;
- b) Estruturar e transformar esses registros em formato PDF para viabilizar o uso como base textual para customizar o modelo de linguagem;
- c) Customizar um assistente de linguagem baseado em GPT, utilizando Recuperação Aumentada de Geração (RAG), para interpretar os dados textuais dos acionamentos e gerar respostas com *insights* relevantes;
- d) Criar um *Dashboard* interativo no *Power BI* que possibilite uma visualização clara e ágil dos dados de acionamento;
- e) Avaliar a aplicabilidade do modelo de linguagem e o *Dashboard* como ferramenta de suporte à análise tradicional de dados para melhoria contínua no processo produtivo.

## 1.6 LIMITAÇÃO DO ESTUDO

O estudo abrange um período de coleta de 1 (um) ano, compreendido entre os meses de fevereiro de 2024 a fevereiro de 2025, totalizando 955 registros de acionamentos do sistema *Andon*.

Após o tratamento da base de dados, 645 registros foram considerados viáveis e utilizados como amostra da pesquisa. Os demais registros não foram aproveitados por apresentarem inconsistências ou características que os tornavam inadequados para os objetivos do estudo, como acionamentos de teste do *Andon*, linhas em branco ou registros incorretos. Ainda assim, os dados utilizados representam aproximadamente 67,5 % do total, sendo suficientes para refletir de maneira adequada as ocorrências reais e sustentar os testes e análises propostos.

## 1.7 ESTRUTURAÇÃO DO TRABALHO

Este trabalho está estruturado em cinco seções principais.

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

A seção 2 aborda a fundamentação teórica, discutindo os principais conceitos relacionados ao sistema *Andon*, à análise de dados no contexto industrial, ao uso de *Dashboards* interativos por meio do *Power BI*, bem como aos modelos de linguagem baseados em inteligência artificial, especialmente os fundamentados na arquitetura GPT.

A seção 3, são descritos a metodologia empregada, o tipo de pesquisa, os critérios de seleção e tratamento dos dados, bem como o ambiente de estudo. Este capítulo também detalha o processo de construção do *Dashboard* e aplicação da técnica RAG com o modelo GPT com base nos registros históricos extraídos do sistema *Andon*.

A seção 4 apresenta os resultados obtidos, incluindo a interface desenvolvida no *Power BI*, as respostas geradas pelo modelo de linguagem e a análise de sua aplicabilidade como ferramenta de apoio à tomada de decisão.

Por fim, a seção 5 traz as considerações finais, discutindo as contribuições do estudo e suas limitações. A seção 6, aborda as possíveis recomendações para trabalhos futuros que explorem o uso de tecnologias baseadas em inteligência artificial na melhoria contínua de processos produtivos.

## 2 REFERENCIAL TEÓRICO

Na revisão de literatura, será abordado o conceito de *Lean Manufacturing*, explorando suas principais ferramentas e sua importância na eliminação de desperdícios e na melhoria da eficiência produtiva. Além disso, será discutido o sistema *Andon*, um dos mecanismos utilizados dentro do *Lean* para o monitoramento e resposta rápida a problemas na produção, garantindo maior controle e agilidade na resolução de falhas.

A revisão incluirá ainda a aplicação de tecnologias voltadas para Processamento de Linguagem Natural (PLN), bem como os modelos de linguagem baseados em GPT (*Generative Pre-trained Transformer*) e sua relevância no desenvolvimento de assistentes inteligentes. Serão apresentados os principais recursos da linguagem de programação *Python* aplicados na área de PLN e Inteligência Artificial (IA), além do uso de ferramentas como o *Power BI*, que permite a visualização e análise de dados de forma dinâmica e interativa. Por fim, serão abordados trabalhos correlatos que fundamentam e as ferramentas utilizadas que dão suporte às práticas analisadas neste estudo.

### 2.1 LEAN MANUFACTURING

O termo *Lean Manufacturing* tornou-se mundialmente conhecido com a publicação do livro *The Machine That Changed the World*, escrito por James Womack, Daniel Jones e Daniel Roos (2004). Este livro apresenta os resultados de uma extensa pesquisa sobre o Sistema *Toyota* de Produção (TPS), realizada no âmbito do programa *Internacional Motor Vehicle Program* (IMVP) com o patrocínio do Instituto de Tecnologia de *Massachusetts* (MIT). O termo "*Lean*" foi proposto pelos autores para disseminar as práticas eficientes do TPS em diversos setores industriais, não se restringindo apenas à indústria automobilística.

O Sistema de Produção Enxuta (*Lean Manufacturing*) remonta ao final da Segunda Guerra Mundial, quando a *Toyota* enfrentou severas limitações financeiras e de recursos no Japão. Em contraste com a Produção em Massa americana, que exigia altos investimentos em estoques e produzia altos níveis de defeitos, a *Toyota* buscava um modelo de gestão mais eficiente. Taiichi Ohno, executivo da *Toyota*, realizou diversas viagens aos Estados Unidos para estudar o sistema de produção em

massa e identificar maneiras de aprimorar a eficiência da fábrica da *Toyota* (Liker, 2021).

O conceito de Manufatura Enxuta se disseminou pelo mundo e várias são as definições desta filosofia:

a) *Lean Manufacturing* é um sistema de produção que visa maximizar a eficiência e minimizar os desperdícios em processos produtivos e administrativos, aumentando a produtividade e a qualidade dos produtos (Womack; Jones; Roos, 2004);

b) O objetivo do *Lean Manufacturing* é criar mais valor para o cliente com menos recursos, eliminando desperdícios e melhorando continuamente os processos de produção (Ohno, 1988);

c) *Lean Manufacturing* se concentra na melhoria contínua e no respeito pelas pessoas, promovendo um ambiente de trabalho que incentiva a inovação, a eficiência e a redução de desperdícios (Liker, 2021);

O principal objetivo do *Lean Manufacturing* é maximizar a performance de uma empresa por meio da aplicação estruturada de suas ferramentas em processos produtivos e administrativos, visando combater desperdícios e tornar os processos mais autônomos e flexíveis, de modo que a organização possa atender, de maneira eficiente e consistente, o fluxo de pedidos puxado por seus clientes.

De acordo com Ohno (1988), existem sete tipos de desperdícios que não agregam valor ao produto no contexto do *Toyota Production System* (TPS): transporte, estoque, movimentação desnecessária, tempo de espera, produção excessiva, processos excessivos e produtos defeituosos. Tendo esses desperdícios como foco, foram desenvolvidas técnicas e recursos estratégicos voltados para sua mitigação ou eliminação. Segundo Costa (2021), a previsibilidade e a padronização dos processos permitem a aplicação eficaz das ferramentas enxutas, que são fundamentais para a redução de desperdícios. Nesse contexto, são empregadas ferramentas como:

a) Mapeamento do Fluxo de Valor (VSM): Ferramenta utilizada para mapear o valor dentro de todo o processo organizacional, identificando onde se encontram os ganhos mais significativos e orientando a aplicação das demais ferramentas enxutas para aumentar a produtividade e combater desperdícios (Rother; Shook, 2003).

b) *Just-In-Time* (JIT): Possui como princípio produzir apenas o necessário, na quantidade e no momento certos, eliminando estoques e desperdícios. Essa prática

sincroniza a produção com a demanda, tornando os processos mais eficientes e alinhados ao fluxo puxado (Ohno, 1988).

c) Programa 5S: Focado em conquistar e manter um ambiente de trabalho organizado e limpo, o programa 5S promove a adoção dos cinco sentidos: utilização, ordenação, limpeza, padronização e autodisciplina. Isso resulta em processos mais flexíveis, manutenção mais assertiva e maior engajamento dos colaboradores (Monden, 2011).

d) Manutenção Produtiva Total (TPM): Para assegurar que máquinas e equipamentos continuem operando e evitando investimentos estagnados, a TPM promove a estabilidade através de seus oito pilares, incluindo manutenção autônoma, planejada e da qualidade, melhorias específicas e treinamento (Nakajima, 1988);

e) *Kanban*: Sistema que facilita a movimentação e o fluxo de materiais por meio do controle visual dos estoques, permitindo que os operadores saibam exatamente o que deve ser produzido, em qual quantidade e no tempo certo, garantindo alinhamento com a demanda (Liker, 2021).

f) Diagrama de *Ishikawa* (Espinha de Peixe): Também conhecido como Diagrama de Causa e Efeito, é utilizada para a análise de causa raiz. Ele auxilia na identificação, categorização e análise dos fatores que contribuem para a ocorrência de um problema. As causas são geralmente agrupadas em categorias como métodos, materiais, mão de obra, máquinas, meio ambiente e medição, facilitando uma abordagem sistemática para a resolução de problemas (Ishikawa, 1993).

g) Metodologia *Kaizen*: Filosofia de gestão voltada para a melhoria contínua. Por meio de eventos estruturados, os próprios colaboradores identificam, analisam e solucionam problemas, promovendo o combate aos desperdícios, o aumento da produtividade e a melhoria dos processos (Imai, 1994).

h) PDCA(*Plan-Do-Check-Act*): Método de gestão que operacionaliza a melhoria contínua através de quatro etapas cíclicas: planejar, executar, verificar e agir. Segundo Ishikawa (1993), o ciclo PDCA é a base do gerenciamento da qualidade total, pois promove a análise sistemática das causas dos problemas e estimula a implementação de ações corretivas de forma consistente.

O *Lean Manufacturing* é uma filosofia de gestão que busca agregar valor ao cliente por meio da eliminação de desperdícios e da melhoria contínua. A partir da identificação do que o cliente valoriza, realiza-se o mapeamento do fluxo de valor,

visando identificar e remover atividades que não agregam valor ao processo. Os princípios do fluxo contínuo e da produção puxada garantem que os produtos avancem no processo produtivo sem interrupções e sejam produzidos apenas sob demanda, promovendo maior eficiência. O foco final é a busca constante pela perfeição por meio de práticas de melhoria contínua (Institute *Lean* Brasil, 2023).

## 2.2 ANDON

O *Andon* é um conceito originado do Sistema *Toyota* de Produção (TPS), que se refere a um sistema de sinalização visual ou auditiva utilizado para alertar a equipe de produção sobre problemas, defeitos ou interrupções no processo de produção. A palavra "*Andon*" vem do japonês e originalmente se referia a uma "lanterna de papel" comum no Japão. No contexto industrial, evoluiu para designar um sinal iluminado que notifica a equipe sobre problemas dentro dos fluxos de controle de qualidade ou de produção (Ohno, 1988) conforme o exemplo ilustrado pela figura 1, na qual indica visualmente que

Figura 1 - Sistema *Andon*



Fonte: KorosiFrancois (2022).

Legenda: ● **Produção parada - Cor Vermelha:**  
Indica um problema crítico que interrompeu o processo. Requer atenção imediata.

● **Atenção necessária - Cor Amarela:**  
Indica uma anomalia que ainda não parou o processo, mas precisa ser verificada.

● **Produção em funcionamento normal - Cor Verde:**  
O processo está fluindo como esperado, sem interrupções ou desvios.

O *Andon* é normalmente ativado por meio de uma corda de puxar ou botão, o que interrompe automaticamente a produção. Essa ação permite que a equipe se reúna rapidamente para aplicar o ciclo PDCA e realizar uma análise de causa raiz, seguida da implementação de uma solução. Existem dois tipos principais de *Andon*:

a) Manual: Ativado manualmente pelo operador na linha de montagem, seja pressionando um botão ou puxando um cabo;

b) Automático: Ativado automaticamente quando os critérios predefinidos na linha de montagem não são atendidos.

Dennis (2008) enfatiza a importância da eficácia do PDCA (*Plan-Do-Check-Act*) como um método central para a melhoria contínua nas organizações. A implementação eficaz de processos de controle e monitoramento de defeitos é essencial para manter a qualidade, a velocidade e a eficiência da produção. A frequência e a natureza desses problemas são analisadas como parte do programa de melhoria contínua da *Toyota* (Ohno, 1988). As luzes de advertência são incorporadas em uma placa visível, que identifica a área ou estação de trabalho específica que apresenta o problema, como ilustrado na Figura 2:

Figura 2 - Sistema *Andon* em operação



Fonte: Labone Consultoria (2019).

Embora originado na manufatura, o princípio do *Andon* pode ser adaptado para diversas outras situações. Na essência, trata-se de um método para interromper o processo, permitindo que a equipe aplique a análise de causa raiz e implemente contramedidas, impedindo que o processo continue a produzir itens defeituosos. Empresas como a *Amazon*, utilizam o *Andon* em seus processos de atendimento ao cliente.

Independentemente do setor, o *Andon* só funciona se os operadores estiverem capacitados para utilizá-lo, sendo essencial dar-lhes não apenas permissão, mas também a obrigação de interromper a linha quando surgirem problemas (Liker, 2021).

Essa abordagem não apenas melhora a qualidade do produto, mas também reduz desperdícios e aumenta a produtividade, conforme evidenciado por diferentes autores da literatura *Lean*:

a) "No Sistema *Toyota* de Produção, o *Andon* é uma ferramenta essencial para a visibilidade do processo e a resposta imediata aos problemas de produção, garantindo a qualidade e a eficiência desde o início" (Ohno, 1988).

b) O *Andon* exemplifica a filosofia de 'parar para corrigir' no Sistema *Toyota* de Produção. Ele capacita os operadores a interromper a produção ao identificar um problema, promovendo a resolução imediata e a melhoria contínua" (Liker, 2021).

c) "Utilizar o *Andon* de forma eficaz significa empoderar os trabalhadores a tomar ações imediatas e colaborar na resolução de problemas, o que é fundamental para a cultura de melhoria contínua no *Lean Manufacturing*" (Dennis, 2008).

Inicialmente, os *Andons* eram sinais luminosos para indicar o *status* da produção por cores. Atualmente, são sistemas visuais mais avançados que comunicam em tempo real o desempenho da linha de produção. Nas equipes, um líder atua auxiliando operadores diante de problemas para evitar paradas, acionando o *Andon* quando necessário. A linha só segue após a resolução inicial do problema, mas o foco é identificar e eliminar a causa raiz para evitar reincidências. O valor do sistema está na resposta rápida e nas melhorias contínuas, garantindo eficiência e qualidade no processo produtivo (Rother; Shook, 2003).

O valor de um sistema *Andon* reside na forma como as informações sobre problemas são utilizadas para criar soluções duradouras. Sem uma ação eficaz e imediata, o *Andon* torna-se apenas um dispositivo caro e ineficaz. Na *Toyota*, a implementação do *Andon* é acompanhada de uma filosofia de melhoria contínua e respeito pelas pessoas, garantindo que os operadores estejam empoderados e equipados para manter a eficiência e a qualidade da produção (Liker, 2021).

### 2.3 INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA

A Inteligência Artificial (IA) é um ramo da computação dedicado à criação de sistemas capazes de imitar habilidades humanas, como raciocínio, percepção, aprendizado e tomada de decisão. Segundo Russell e Norvig (2013), a IA envolve o

desenvolvimento de agentes inteligentes que interpretam o ambiente e realizam ações com base em objetivos predefinidos. Essa abordagem constitui um dos pilares da Indústria 4.0, ao lado da Internet das Coisas (IoT) e da computação em nuvem, possibilitando a automação inteligente e a integração entre sistemas físicos e digitais (Schwab, 2016; Kagermann *et al.*, 2013).

O aprendizado de máquina, um subcampo da IA, capacita sistemas a reconhecer padrões em dados e a aprimorar seu desempenho ao longo do tempo, sem a necessidade de reprogramação explícita. De acordo com Mitchell (1997), o aprendizado de máquina estuda algoritmos que permitem que computadores adquiram conhecimento a partir da experiência. Essa técnica é amplamente aplicada em ambientes industriais para previsão de demanda, detecção de falhas, análise de séries temporais e apoio a decisões automatizadas (Witten; Frank; Hall, 2016).

O aprendizado de máquina pode ser classificado em três categorias principais: aprendizado supervisionado, em que o modelo é treinado com dados rotulados; aprendizado não supervisionado, que busca identificar padrões em dados sem rótulos; e aprendizado por reforço, no qual agentes aprendem por tentativa e erro, sendo recompensados ou penalizados conforme suas ações (Alpaydin, 2021; Sutton; Barto, 2018). Cada abordagem possui aplicações específicas na indústria, como o monitoramento preditivo de qualidade, a análise de dados de manutenção e a otimização de processos em tempo real.

Com o aumento do volume de dados gerados em ambientes industriais, o aprendizado de máquina tornou-se uma ferramenta estratégica para converter grandes volumes de dados brutos em conhecimento acionável. Segundo Chui, Manyika e Miremadi (2018), a previsão baseada em aprendizado de máquina pode reduzir em até 20% o tempo de inatividade de equipamentos em fábricas inteligentes. Para lidar com essa complexidade, surgiram arquiteturas avançadas, como as redes neurais profundas (*deep learning*), que ampliam a capacidade de modelar fenômenos não lineares e analisar dados não estruturados (LeCun; Bengio; Hinton, 2015).

Esse avanço possibilitou o desenvolvimento de modelos baseados em *Transformers*, que abriram caminho para uma nova geração de aplicações em Processamento de Linguagem Natural (PLN).

## 2.4 PROCESSAMENTO DE LINGUAGEM NATURAL (PLN)

O Processamento de Linguagem Natural (PLN) é um subcampo da Inteligência Artificial (IA) dedicado ao estudo e ao desenvolvimento de sistemas capazes de compreender, interpretar e gerar linguagem humana de forma automática. Seu surgimento remonta às primeiras iniciativas de tradução automática realizadas antes mesmo do advento dos computadores digitais. Em 1948, foi desenvolvido no *Birkbeck College* um sistema de pesquisa de dicionário, marco inicial para as aplicações de PLN (Turney, 2010).

A proposta de Warren Weaver, em 1949, de tratar a linguagem como um código passível de tradução automática, impulsionou os primeiros experimentos. Na década de 1950, surgiram sistemas como o *IBM-Georgetown*, capazes de traduzir textos do russo para o inglês. A teoria da gramática generativa, proposta por Noam Chomsky em 1957, também influenciou significativamente o campo, ao estruturar a linguagem com base em regras sintáticas que facilitaram sua representação computacional (Hutchins, 2005).

Apesar da estagnação entre 1966 e 1980, causada pelas limitações tecnológicas da época, o interesse no PLN foi retomado com o avanço da capacidade computacional. Em 1982, surgiu o *chatbot Jabberwacky*, que buscava simular interações humanas com base em IA. A partir da década de 1990, o crescimento da internet e o aumento da produção textual impulsionaram o desenvolvimento de aplicações como extração de informações, sumarização automática e classificação textual com base em frequência de palavras (Vaswani *et al.*, 2017).

A partir dos anos 2000, o processamento de linguagem natural evoluiu com a adoção de algoritmos como *bag-of-words*, *Naive Bayes* e, posteriormente, redes neurais profundas. Essa nova fase ampliou o potencial dos modelos na compreensão semântica, análise de sentimentos, tradução automática e atendimento ao cliente, entre outras aplicações. A crescente disponibilidade de dados textuais e os avanços em modelos de linguagem baseados em *deep learning* têm consolidado o PLN como uma das tecnologias centrais da IA moderna (Turney, 2010; Jurafsky; Martin, 2021).

Para que os sistemas de PLN funcionem corretamente, diversos conceitos e técnicas são empregados. Os principais componentes tecnológicos que possibilitam o funcionamento de modelos de linguagem baseados em IA:

a) Tokenização: A tokenização é a etapa inicial do Processamento de Linguagem Natural (PLN) que consiste em dividir um texto em unidades menores chamadas de

*tokens*. Esses *tokens* podem ser palavras, sílabas ou até mesmo caracteres, dependendo da granularidade desejada pelo modelo. Essa divisão é essencial para que algoritmos de linguagem possam processar, analisar e aprender padrões a partir dos dados textuais (Jurafsky; Martin, 2021). Ferramentas modernas de tokenização, como o *Byte Pair Encoding (BPE)*, permitem representar vocabulários extensos com mais eficiência, reduzindo o número de palavras desconhecidas, o que melhora a generalização do modelo (Sennichen, 2020).

b) *Embeddings*: São representações vetoriais densas utilizadas para mapear palavras, sentenças ou documentos em um espaço contínuo de alta dimensionalidade, preservando propriedades semânticas e sintáticas, isso permite que palavras com significados semelhantes ocupem posições próximas no espaço vetorial, o que facilita a interpretação de relações linguísticas pelos algoritmos de aprendizado de máquina. No contexto de modelos de linguagem de grande escala, os *embeddings* desempenham papel central na compreensão contextual dos textos, sendo essenciais em tarefas como classificação, análise de sentimentos, tradução automática e recuperação de informações (Mikolov *et al.*, 2013).

c) Arquitetura *Transformer*: Revolucionou o PLN ao introduzir o mecanismo de atenção, que permite ao modelo identificar quais partes do texto são mais relevantes durante a análise. Proposto por Vaswani *et al.* (2017), o *Transformer* eliminou a necessidade de processamento sequencial, como nas redes recorrentes, permitindo paralelização e melhoria no desempenho em grandes volumes de dados. Essa arquitetura serve de base para modelos como BERT e GPT.

d) NER: O Reconhecimento de Entidades Nomeadas (*Named Entity Recognition*) é uma técnica do PLN voltada à identificação e categorização automática de elementos específicos em um texto, como nomes de pessoas, organizações, localizações, datas, entre outros. Essa técnica é essencial para transformar dados não estruturados em informações organizadas, com aplicações que incluem atendimento automatizado, análise de documentos jurídicos e monitoramento de mídias digitais. Os sistemas de NER podem empregar abordagens baseadas em regras linguísticas, estatísticas ou redes neurais profundas, geralmente treinados com corpora anotados – conjuntos de dados linguísticos preparados com marcações específicas (Jurafsky; Martin, 2021)

e) LLMs: Modelos de Linguagem de Grande Escala (*Large Language Models*) são redes neurais treinadas com grandes volumes de dados textuais para realizar tarefas

complexas de linguagem, como responder perguntas, traduzir textos, resumir conteúdos, entre outras. Eles se destacam pela capacidade de generalização e pela contextualização avançada das respostas (Brown *et al.*, 2020). Modelos como GPT, *LLaMA*, *Claude* e *Gemini* representam diferentes abordagens e empresas que dominam o mercado. Cada um possui particularidades quanto ao acesso, capacidade de customização, custo e desempenho.

f) *LLaMA*: É uma família de modelos de linguagem desenvolvida pela *Meta* com o objetivo de fornecer um modelo eficiente, acessível e de código aberto para a comunidade acadêmica e científica. Ao contrário de outros modelos comerciais, o *LLaMA* foi otimizado para rodar com menos recursos computacionais, mantendo um desempenho robusto em tarefas de linguagem natural. Lançado em 2023, se tornou referência entre os modelos com *software de código aberto* por sua leveza, adaptabilidade e escalabilidade (Touvron *et al.*, 2023).

g) Redes Neurais: São sistemas computacionais inspirados no funcionamento do cérebro humano, constituídos por camadas de nós (também conhecidos como "neurônios") que processam informações e aprendem padrões a partir de exemplos. Elas têm a habilidade de representar relações complexas entre entradas e saídas, servindo como alicerce para a criação de modelos de linguagem cada vez mais avançados. No âmbito do PLN, possibilitam que os sistemas aprendam estruturas linguísticas, padrões semânticos e relações contextuais a partir de grandes quantidades de dados textuais (Haykin, 2001).

h) TF-IDF: A técnica *Term Frequency – Inverse Document Frequency* (TF-IDF) é um método estatístico utilizado para avaliar a importância de uma palavra em um documento e de todo o conjunto de texto. Ela é estabelecida com base na frequência de ocorrência da palavra em um documento (TF) e na frequência inversa em outros documentos (IDF). Esta métrica é frequentemente empregada na indexação, recuperação de informações e classificação de textos, uma vez que confere maior importância a termos mais relevantes (Manning; Schüüze, 1999).

i) *Word2Vec*: É um método de vetorização criado pelo *Google* que emprega redes neurais simples para converter palavras em vetores numéricos contínuos. Esses vetores conseguem identificar com exatidão as relações semânticas entre palavras, tais como analogias e similaridades de significado (Mikolov *et al.*, 2013).

## 2.5 RECUPERAÇÃO AUMENTADA DE GERAÇÃO (RAG)

A Recuperação Aumentada de Geração (*Retrieval-Augmented Generation*) é um método que une a pesquisa de documentos pertinentes à criação de respostas contextualizadas. Isso possibilita que os modelos linguísticos consultem fontes externas antes de elaborar respostas. Esta estratégia tem como objetivo ampliar a veracidade, reduzir as alucinações e ajustar a resposta ao conteúdo mais recente e específico (Lewis *et al.*, 2020).

Ao contrário dos modelos convencionais que se baseiam exclusivamente em conhecimento previamente aprendido, o RAG funciona em duas fases: primeiramente, extrai partes pertinentes de uma base de documentos através de *embeddings* semânticos (representações numéricas vetoriais que capturam o significado de palavras, frases ou documentos, permitindo que modelos de IA processem e comparem textos de forma eficiente); posteriormente, produz a resposta com base nesse conteúdo obtido. Esta abordagem híbrida provou ser especialmente eficiente em campos técnicos, como diagnóstico médico ou análise de falhas industriais, onde é crucial assegurar a exatidão e a rastreabilidade (Gao *et al.*, 2023).

Nos últimos anos, várias variações da técnica RAG foram sugeridas. A versão inicial, denominada *naive RAG* (Lewis *et al.*, 2020), foi ampliada através de técnicas como *Hypothetical Document Embeddings* (HYDE) que criam descrições hipotéticas antes da pesquisa (Gao *et al.*, 2023), e o método *Rewrite-Retrieve-Read*, que altera a pergunta para aumentar a pertinência dos documentos pesquisados. Essas estratégias intensificam a resistência e adaptabilidade do modelo, particularmente em cenários com consultas abertas e vastas bases de conhecimento.

O uso de RAG em contextos produtivos representa uma opção promissora ao ajuste fino (*fine-tuning*), uma vez que diminui a exigência de retreinamento de modelos e possibilita a atualização constante das informações através da indexação de documentos. Contudo, Barnett *et al.* (2024) ressaltam sete aspectos cruciais a serem levados em conta na concepção de sistemas com RAG, que incluem a seleção da base documental, a consistência semântica entre consulta e contexto, além da integração entre os módulos de recuperação e geração.

Portanto, a Recuperação Aumentada de Geração se apresenta como uma estratégia eficaz para aprimorar o desempenho e a fiabilidade dos modelos linguísticos em usos técnicos, industriais e empresariais.

## 2.6 MODELO DE LINGUAGEM

Com o avanço da Inteligência Artificial e do Processamento de Linguagem Natural, o modelo de linguagem passou a representar uma ferramenta essencial na interpretação e geração de textos de forma automatizada. Ele é desenvolvido com diferentes arquiteturas e propósitos, sendo aplicado em diversos contextos, incluindo ambientes industriais. Esta seção apresenta o modelo utilizado como proposta neste estudo.

O modelo GPT (*Generative Pre-trained Transformer*) é uma família de modelos de linguagem desenvolvidos pela *OpenAI*, baseada na arquitetura *Transformer*, segundo Vaswani *et al.* (2017). Esses modelos são treinados com grandes volumes de dados textuais, sendo capazes de compreender e gerar linguagem natural com alto grau de coerência e contextualização. Desde o GPT-1 até o GPT-4, os modelos evoluíram significativamente em termos de capacidade de entendimento, generalização e desempenho em tarefas diversas de linguagem (*OpenAI*, 2023).

A principal característica do GPT é a sua abordagem autoregressiva, em que cada palavra é gerada com base nas anteriores, o que permite manter a fluidez e o contexto durante a geração de texto (Brown *et al.*, 2020). Atualmente, os modelos GPT são amplamente utilizados em aplicações como assistentes virtuais, análise de sentimentos, resumo automático, tradução, classificação de texto e, principalmente, na automação de tarefas em ambientes industriais que envolvam registros não estruturados.

Com o progresso das aplicações em Processamento de Linguagem Natural (PLN), várias estruturas desenvolveram modelos de linguagem, cada uma com suas próprias características em relação à arquitetura, performance, custo e acessibilidade. Atualmente, alguns dos modelos mais empregados incluem: GPT (*OpenAI*), *Gemini* (*Google*), *Claude* (*Anthropic*), *Mistral* (*Mistral AI*) e *LLaMA* (*Meta*).

Os modelos da série GPT, em particular o GPT-4, se sobressaem pela sua habilidade de generalização e integração extensa com ferramentas úteis, como APIs e assistentes personalizados. A arquitetura *Transformer*, combinada com o treinamento com um corpus extenso e diversificado, possibilita alta performance até mesmo em tarefas com poucos exemplos (Brown *et al.*, 2020).

O *Gemini*, desenvolvido pela *Google*, se destaca pela integração com ferramentas internas e com o sistema operacional Android. No entanto, sua disponibilidade ainda é limitada em certas situações. *Claude*, da *Anthropic*, se

concentra na segurança e na conformidade com as intenções humanas, direcionando-se para interações seguras com o usuário. O *Mistral* é um modelo *open-source* que busca equilíbrio entre leveza e desempenho, sendo útil para aplicações locais e personalizáveis. O *LLaMA*, da Meta, também segue a linha de código aberto, mas com restrições de uso e requisitos técnicos mais elevados para implementação eficiente.

Neste estudo, optou-se pelo modelo GPT-4, principalmente pelos seguintes motivos:

1. Praticidade e integração, particularmente através da plataforma *ChatGPT* e da API da *OpenAI*;
2. Personalização por meio do Assistente Customizado, possibilitando a adaptação a contextos industriais com documentos específicos;
3. Alta qualidade nas respostas geradas, tanto em coerência quanto em aplicabilidade prática;
4. Ampla documentação e suporte técnico, o que facilita testes, ajustes e validação de hipóteses em projetos acadêmicos e industriais.

Dessa forma, embora outros modelos apresentem características técnicas avançadas, a escolha do GPT-4 se justifica pela sua combinação de acessibilidade, eficiência e contextualização, elementos centrais para a aplicação proposta neste estudo.

## 2.7 POWER BI E VISUALIZAÇÃO DE DADOS

O *Power BI* é uma ferramenta de *Business Intelligence* (inteligência de negócios) desenvolvida pela empresa *Microsoft*, que permite a criação de relatórios interativos e *Dashboards* dinâmicos a partir de diferentes fontes de dados. Seu principal objetivo é transformar dados brutos em informações visuais de fácil interpretação, auxiliando na tomada de decisão estratégica (Microsoft, 2023).

No contexto de projetos que envolvem Inteligência Artificial e Processamento de Linguagem Natural, o *Power BI (BI)* pode ser utilizado para exibir visualmente os resultados obtidos por modelos, como frequência de palavras, sentimentos predominantes em textos ou desempenho de classificadores. Essa visualização facilita o acompanhamento dos dados em tempo real, bem como a comunicação dos resultados com outras áreas da empresa de forma clara e objetiva (Microsoft, 2023).

Esse recurso computacional pode ser integrado com linguagens programação, como *Python*, o que amplia seu potencial analítico. Isso permite gerar gráficos customizados com dados provenientes de scripts de análise de texto, além de oferecer filtros dinâmicos e painéis personalizados para monitoramento constante dos indicadores-chave do projeto. No estudo, é utilizado como uma ferramenta para que seja possível visualizar todo monitoramento, controle e análise dos acionamentos de *Andon*.

## 2.8 TRABALHOS CORRELATOS

Muitos pesquisadores vêm utilizando técnicas de *Natural Language Processing* (NLP) para automatizar a avaliação de redações, buscando solucionar desafios relacionados ao tempo, custo e confiabilidade no processo de correção. Essas soluções destacam a relevância do uso de PLN na análise automatizada de textos no ensino fundamental (Rosa; Mello, 2022).

Segundo Ifenthaler (2023), os sistemas de pontuação automatizada aplicam técnicas de PLN para analisar aspectos como conteúdo, estilo e organização, permitindo gerar feedback imediato e pontuações detalhadas. A integração do PLN nesses sistemas representa um avanço significativo na avaliação educacional, especialmente em larga escala.

De acordo com Jurafsky e Martin (2021), os modelos de PLN têm sido amplamente utilizados em sistemas de perguntas e respostas automáticas, capazes de compreender textos em linguagem natural e gerar respostas relevantes com base no contexto. Essas aplicações são particularmente eficazes em ambientes educacionais, plataformas de atendimento ao cliente e sistemas de suporte técnico.

Fundamentados em arquiteturas modernas, como os *Transformers*, esses sistemas analisam e interpretam as entradas textuais de forma contextualizada, possibilitando uma geração de respostas mais precisa e coerente. Essa evolução evidencia o papel central do PLN na automação de tarefas complexas que envolvem interpretação e geração de linguagem.

Além disso, estudos recentes vêm investigando a aplicação de modelos de linguagem natural em ambientes corporativos para suporte à comunicação interna e à análise de chamados. Um exemplo é o trabalho de Pereira (2024), que propõe o uso de inteligência artificial para interpretar e agrupar chamados abertos em sistemas internos, otimizando o tempo de resposta e organização das demandas em

instituições acadêmicas. A pesquisa evidenciou que o uso de técnicas como *embeddings* e classificação de texto pode reduzir significativamente o tempo de triagem e priorização.

Outro estudo relevante é o de Vitorassi *et al.* (2023), que explorou o uso do modelo *ChatGPT* para apoio à decisão em ambientes clínicos, mais especificamente na área da saúde. A proposta envolveu a utilização de modelos de linguagem para interpretar descrições clínicas e sugerir possíveis diagnósticos, demonstrando a versatilidade do Processamento de Linguagem Natural em contextos altamente técnicos e sensíveis. Os resultados indicam que, com ajustes e treinamento adequado, os LLMs podem se tornar ferramentas de suporte complementar valiosas em setores especializados.

## 2.9 RECURSOS COMPUTACIONAIS DE APOIO

j) *Python*: É uma linguagem de programação amplamente utilizada em projetos de Processamento de Linguagem Natural (PLN) e Inteligência Artificial (IA) devido à sua simplicidade, versatilidade e vasta gama de bibliotecas. Entre as bibliotecas mais populares estão o *Pandas*, *Toolkit*, *PyTorch* e *TensorFlow* que facilitam o desenvolvimento de modelos de aprendizado de máquina (*machine learning*) e aprendizado profundo (*deep learning*). Essas ferramentas permitem construir, treinar e avaliar modelos complexos para interpretar e gerar linguagem humana (Bird; Klein; Loper, 2009).

Esta linguagem é frequentemente utilizada em conjunto com ambientes de desenvolvimento integrados (Ide), como o *PyCharm*, que proporciona uma interface robusta, organizada e intuitiva para programação com recursos de autocompletar inteligente, depuração, controle de versão e gerenciamento de ambientes virtuais, otimizando o desenvolvimento de projetos em ciência de dados e inteligência artificial (JetBrains, 2024).

k) *Google Colab*: É uma plataforma gratuita baseada em nuvem que permite a execução de códigos em *Python*, oferecendo um ambiente interativo para desenvolvimento de projetos em ciência de dados, aprendizado de máquina e inteligência artificial. Seu principal diferencial está na possibilidade de utilizar recursos computacionais sem a necessidade de configuração local, proporcionando maior acessibilidade e desempenho na execução de tarefas que demandam alto processamento.

No ambiente de criação é possível a integração com bibliotecas, APIs e bancos de dados, facilitando o desenvolvimento colaborativo e a manipulação de grandes volumes de dados. De acordo com o próprio *Google* (2023), a plataforma foi projetada para permitir que usuários executem e compartilhem códigos de forma simples, diretamente na nuvem, eliminando a necessidade de infraestrutura própria.

1) *Assistant GPT*: A assistente GPT da *OpenAI* é um modelo de linguagem baseado em IA que gera texto de forma contextual e coerente, podendo ser customizado e ajustado para tarefas específicas (Brown *et al.*, 2020). Esse modelo é construído com redes neurais do tipo *Transformer*, que processam sequências de texto e entendem o contexto para produzir respostas ou gerar textos. A versão GPT-4 oferece maior capacidade de compreensão e geração de linguagem natural, possibilitando aplicações em diversas áreas, como atendimento, criação de conteúdo e análise de dados.

Na pesquisa em estudo, a assistente GPT é utilizada para interpretar textos extraídos, gerar respostas relevantes e auxiliar na análise das informações, integrando-se com ferramentas como o *Streamlit* (biblioteca *Python* de código aberto) para apresentação dos resultados.

Dessa forma, os recursos apresentados oferecem suporte técnico e operacional indispensável para o desenvolvimento das etapas deste projeto, desde a análise dos dados até a apresentação dos resultados.

### 3 MATERIAIS E MÉTODOS

#### 3.1 METODOLOGIA

Este trabalho caracteriza-se como um estudo de caso aplicado e quantitativo.

Segundo Yin (2015), o estudo de caso é uma abordagem que possibilita a investigação aprofundada de um fenômeno dentro de seu contexto real, sendo especialmente útil para pesquisas em ambientes organizacionais, sendo a empresa X localizada no PIM.

A pesquisa é aplicada, pois visa a resolução prática de um problema específico, conforme Gil (2008), que destaca que a pesquisa aplicada tem foco na aplicação direta dos conhecimentos para solucionar questões reais, que condiz com o objetivo do estudo, que é criar o *Dashboard* e configurar o modelo para consulta via RAG.

Além disso, o estudo é quantitativo, utilizando dados numéricos e textuais para análise, conforme Marconi e Lakatos (2022), que enfatizam a importância da pesquisa quantitativa para a obtenção de resultados objetivos e mensuráveis.

A empresa em estudo atua no segmento de eletroeletrônicos e a linha de produção selecionada fabrica módulos multimídia automotivos, destinada à parte sonora e visual do produto, que são aqueles componentes instalados no painel do carro responsáveis por funções como rádio, *Bluetooth*, *GPS* e conexão com o celular.

O processo produtivo está dividido em três etapas principais: montagem, inspeção e embalagem. A montagem compreende diversos postos, assim como o processo de inspeção, que ocorre em duas etapas distintas, a primeira com testes funcionais e de vibração, e a segunda focada na inspeção de qualidade.

Por fim, há o processo de embalagem e expedição do produto. As atividades seguem um fluxo contínuo, respeitando a sequência estabelecida entre os postos e máquinas. Para este estudo, foi utilizada a base de dados abrangendo todos os postos e máquinas da linha de produção mapeados com *Andon*.

#### 3.2 COLETA E ANÁLISE DE DADOS

O sistema *Andon* da linha de produção utiliza dispositivos de sinalização para alertas manuais de anomalias. Os alertas são classificados como *Warning* (atenção) ou *Stop* (parada de linha) e acionados por botões nos postos de trabalho.

Os acionamentos são registrados automaticamente, gerando uma base com dados como tipo de alerta, duração e descrição do problema. O sistema permite o monitoramento em tempo real e fornece dados quantitativos e qualitativos para análise de falhas e melhorias no processo.

### 3.2.1 Coleta de dados

A base de dados utilizada neste estudo abrange o período de fevereiro de 2024 a fevereiro de 2025, totalizando 955 registros de acionamentos do sistema *Andon*. Os dados foram coletados automaticamente e estão ordenados, conforme a Figura 3 e Figura 4, respectivamente, nas seguintes colunas em 18 colunas:

Figura 3 – Informações gerais dos dados 1

No	Chk	Status	Equipment Line	Andon Process	Andon No	Main/Sub	Start(Date)	Start(Hour)
----	-----	--------	----------------	---------------	----------	----------	-------------	-------------

Fonte: Elaborado pelo próprio autor (2025).

Figura 4 – Informações gerais dos dados 2

End(Date)	End(Hours)	Run Time(HH:MM:SS)	Run Time(Sec)	Warning /Stop	Andon Type	Cause Department	Date	Reason
-----------	------------	--------------------	---------------	---------------	------------	------------------	------	--------

Fonte: Elaborado pelo próprio autor (2025).

A base de dados foi composta majoritariamente por campos preenchidos de forma automática pelo sistema *Andon*, assegurando padronização na coleta das informações, como data, hora, tempo de execução, linha de equipamento, status e tipo de acionamento. Entretanto, existem três campos que exigem intervenção manual dos técnicos no momento do registro: *Reason*, que corresponde ao campo descritivo onde o técnico informa, em texto livre, o motivo ou descrição detalhada da ocorrência; *Andon Type*, que exige a classificação do tipo de *Andon* acionado; e *Cause Department*, que identifica qual setor ou departamento está associado à causa do problema.

Dentre esses, o campo *Reason* é o mais sensível, uma vez que, por ser textual e livre, está sujeito a variações linguísticas, abreviações, erros de digitação e falta de padronização, conforme pontos ilustrados no Anexo A, o que impacta diretamente na etapa de análise dos dados por meio de Processamento de Linguagem Natural (PLN).

Este campo segue uma estrutura definida como padrão: Sintoma → Causa Raiz → Ação → Responsável.

Contudo, na prática, nem sempre essa organização é seguida de forma rigorosa. É comum que o sintoma, que deveria indicar o que está acontecendo no momento da ocorrência, e a causa raiz, que representa o motivo real do problema, sejam informados de forma sobreposta ou até mesmo confundidos. Muitas vezes, o técnico registra diretamente a causa ou uma ação, sem necessariamente descrever o sintoma, ou vice-versa, o que gera inconsistências na construção do texto.

Esse comportamento, somado à natureza não estruturada do campo, reforça a necessidade de aplicar técnicas de PLN para tratamento, padronização e extração de informações relevantes. Ainda assim, quando bem preenchido, esse campo possibilita análises quantitativas e qualitativas robustas, permitindo identificar falhas recorrentes, avaliar tempos de resposta e mapear os setores responsáveis, contribuindo diretamente para a melhoria contínua dos processos.

### 3.2.2 Pré-processamento de Dados

Para garantir a consistência e a qualidade da análise, os dados passaram por um processo de pré-processamento. As etapas aplicadas foram:

a) Limpeza de dados: foram removidos registros duplicados, incompletos, acionamentos incorretos, teste de acionamentos, como linhas com campos vazios em informações essenciais (ex.: *Reason*, *Run Time*).

b) Padronização dos textos: o campo *Reason* foi padronizado para facilitar a separação entre Sintoma, Causa Raiz, Ação e Responsável, com base na estrutura estabelecida.

c) Conversão de formatos: datas e tempos foram convertidos para o formato adequado para permitir cálculos de duração e análises temporais.

d) Separação de campos textuais: o campo *Reason*, preenchido manualmente, foi dividido em quatro novos campos: Sintoma, Causa Raiz, Ação e Responsável, utilizando regras baseadas na pontuação e na ordem dos termos.

e) Criação de variáveis auxiliares: foram adicionadas variáveis como o tempo total de parada (em segundos) e a categorização do tipo de alerta (*Warning* ou *Stop*) para facilitar a análise.

Inicialmente, a base contava com 955 registros, dos quais 645 acionamentos válidos permaneceram após o processo de pré-processamento. Os registros

removidos correspondiam, principalmente, a acionamentos de teste, linhas em branco, dados inconsistentes ou preenchidos de forma incorreta. A realização dessa etapa foi essencial para garantir que a base estivesse limpa, consistente e adequada às análises subsequentes, proporcionando maior confiabilidade para o estudo proposto.

### 3.3 APLICAÇÃO DE RAG NO ASSISTENTE GPT

Para a etapa de interpretação automática dos registros, foi utilizado um modelo de linguagem baseado em GPT. O objetivo principal foi extrair, interpretar e analisar as informações dos registros do campo “*Reason*”, identificando automaticamente o Sintoma, a Causa Raiz e a Ação Corretiva de cada ocorrência.

A técnica de Recuperação Aumentada de Geração (RAG) foi utilizada para ampliar a capacidade interpretativa do modelo GPT-4 a partir do conteúdo dos registros históricos. Essa abordagem consiste em combinar um sistema de recuperação de informações com o modelo de geração de linguagem, permitindo que o GPT consulte documentos relevantes antes de formular uma resposta.

No contexto deste trabalho, o RAG foi aplicado por meio da inserção dos arquivos em PDF (gerados a partir dos registros do *Andon*) diretamente na interface do assistente, conforme Anexo B, que atuou como mecanismo de busca interno e gerador de respostas. Assim, ao invés de depender exclusivamente do conhecimento pré-treinado do modelo, as respostas foram baseadas no conteúdo real dos documentos fornecidos, garantindo maior contextualização, precisão e alinhamento com o cenário produtivo analisado.

O processo foi dividido nas seguintes etapas:

a) Conversão para PDF via *Google Colab*: Como os dados estavam inicialmente em uma planilha do *Excel* (.xlsx), foi utilizado o ambiente do *Google Colab* para realizar a conversão automatizada para o formato PDF. Essa transformação foi importante para melhorar a legibilidade dos dados pelo modelo de linguagem, simulando um relatório estruturado. A Figura 5 ilustra a interface do *Google Colab* com o código utilizado para essa conversão da base de dados em PDF, nota-se que no decorrer do código algumas partes confidenciais da empresa são omitidas.

Figura 5 - Código no Google Colab

```
[1] pip install pandas openpyxl reportlab
Mostrar saída oculta

[2] !pip install fpdf
Mostrar saída oculta

import pandas as pd
# Carregar o arquivo Excel
df = pd.read_excel('/content/oficial.xlsx')
# Converter as colunas de data completas
df['Start(Date)'] = pd.to_datetime(df['Start(Date)'], format='%d/%m/%Y', errors='coerce')
df['End(Date)'] = pd.to_datetime(df['End(Date)'], format='%d/%m/%Y', errors='coerce')
# Garantir que 'Run Time(HH:MM:SS)' seja timedelta
df['Run Time(HH:MM:SS)'] = pd.to_timedelta(df['Run Time(HH:MM:SS)'].astype(str), errors='coerce')
def gerar_frase(row):
    # Se não há duração, aborta
    if pd.isna(row['Run Time(HH:MM:SS)']):
        return "Dados insuficientes para gerar a frase."
    # Data (do início)
    data = row['Start(Date)'].strftime('%d/%m/%Y') if not pd.isna(row['Start(Date)']) else "data desconhecida"
    # Hora inicial e final (certa segundos de strings longas)
    start_hour = str(row['Start(Hour)'])[:5] if not pd.isna(row['Start(Hour)']) else "hora inicial desconhecida"
    end_hour = str(row['End(Hour)'])[:5] if not pd.isna(row['End(Hour)']) else "hora final desconhecida"
    # Extrair componentes da duração
    rt = row['Run Time(HH:MM:SS)']
    h, m, s = rt.components.hours, rt.components.minutes, rt.components.seconds
    return (
        f"[data] - Na linha de produção {row['Equipment Line']}, "
        f"o Andon de número {row['Andon No']}, localizado no posto {row['Andon Process']}, "
        f"na hora inicial de {start_hour} até a hora final de {end_hour}, "
        f"teve a duração de {h} horas, {m} minutos e {s} segundos, "
        f"o tipo de acionamento foi {row['Warning/Stop']}, "
        f"com a causa do departamento sendo o setor de {row['Cause Department']}, "
        f"ocorreu o seguinte evento: {row['Reason']}."
    )
# Gerar e testar
df['frase'] = df.apply(gerar_frase, axis=1)
print(df['frase'].iloc[0])
print(df['frase'].iloc[10])
print(df['frase'].iloc[66])

05/02/2024 - Na linha de produção [redacted] o Andon de número 2, localizado no posto CHASSI & PCB MAIN ASSEMBLY, na hora inicial de 12:40 até a hora final de 12:41, teve a duração de 0 horas, 0 minutos e 57 segundos, o
06/02/2024 - Na linha de produção [redacted] o Andon de número 2, localizado no posto CHASSI & PCB MAIN ASSEMBLY, na hora inicial de 10:58 até a hora final de 10:59, teve a duração de 0 horas, 1 minutos e 34 segundos, o
13/03/2024 - Na linha de produção [redacted] o Andon de número 5, localizado no posto TOP COVER AUTO SCREW MACHINE, na hora inicial de 10:36 até a hora final de 10:37, teve a duração de 0 horas, 0 minutos e 1 segundos, o

from fpdf import FPDF
# Criar uma instância do objeto FPDF
pdf = FPDF()
pdf.set_auto_page_break(auto=True, margin=15)
pdf.add_page()
# Definir o título
pdf.set_font('Arial', 'B', 16)
pdf.cell(200, 10, txt="Frases Andon", ln=True, align='c')
# Definir o estilo da fonte para as frases
pdf.set_font('Arial', '', 12)
# Adicionar as frases ao PDF
for frase in df['frase']:
    pdf.ln(10) # Nova linha
    pdf.multi_cell(0, 10, frase)
# Salvar o arquivo pdf
pdf.output("Frases_andon_completa.pdf")
```

Fonte: Elaborado pelo próprio autor (2025).

b) Inserção do PDF no Assistente GPT: Após a conversão, o PDF foi carregado em uma interface com Assistente baseado no modelo GPT-4, hospedado no site da *OpenAI*, que permite a análise contextualizada dos documentos. A ferramenta foi estruturada, para responder perguntas e gerar interpretações automáticas com base nas informações contidas no arquivo. O assistente foi instruído com o seguinte sistema de instrução:

“Você é um assistente técnico de manutenção. Sua função é analisar textos de registros *Andon* com foco em Sintoma, Causa Raiz e Ação. Gere respostas com termos técnicos, identifique padrões, falhas recorrentes, e sugira melhorias práticas baseadas nos dados. Sua prioridade é garantir que nenhuma informação importante seja ignorada. Responda de forma prática, objetiva e técnica, valorizando a conexão entre os sintomas, causa raiz e as ações corretivas, com foco nos materiais que causam o problema. Quando possível, quantifique os impactos ou ganhos com base

nos dados fornecidos. Caso o usuário pergunte sobre padrões, tendências ou sugestões de melhoria, use as informações contidas nos arquivos anexos para propor análises úteis, sempre focando em melhoria contínua e redução de falhas recorrentes, focando nos eventos ocorridos e postos”.

c) Execução e Análise das Respostas: A saída do modelo consistia em respostas organizadas, com interpretações consistentes e coerentes com os padrões definidos no processo de padronização anterior. As respostas geradas foram transferidas para uma planilha no *Excel*, na qual a primeira coluna representa a pergunta do usuário e a segunda corresponde à resposta produzida pelo modelo.

Esta etapa foi realizada utilizando o ambiente *Playground* da *OpenAI*, que permite testar, configurar e ajustar o modelo de linguagem antes de sua integração via API. Esta etapa foi fundamental para validar a estrutura das perguntas e respostas, bem como observar o comportamento do modelo em diferentes contextos, realizando perguntas de ajuste até alcançar um padrão satisfatório, conforme exposto no APÊNDICE A sobre as respostas do assistente GPT à análise do PDF.

d) Validação dos resultados: As respostas foram avaliadas manualmente para garantir a fidelidade ao conteúdo e a preservação de informações confidenciais nesta etapa de geração de dados pela plataforma. O modelo gerou respostas alinhadas às necessidades operacionais, reforçando seu potencial na tomada de decisão e na melhoria contínua.

### **3.3.1 Avaliação técnica do modelo de linguagem**

Para avaliar a hipótese 1, que propõe que o uso do modelo GPT-4 com aplicação da técnica de Recuperação Aumentada de Geração (RAG) permite interpretar os textos dos registros do sistema *Andon* e fornecer *insights* relevantes, foi realizada uma avaliação técnica individual com base nas respostas geradas pelo modelo, conforme exposto no APÊNDICE A.

A avaliação foi estruturada a partir de seis respostas produzidas pelo modelo GPT-4, cada uma relacionada a situações operacionais extraídas de registros históricos. O objetivo não foi avaliar a formulação das perguntas, mas sim analisar a qualidade técnica das respostas geradas. Essas respostas foram analisadas pelo autor com base em quatro critérios objetivos: clareza, coerência técnica, estrutura lógica (sintoma, causa e ação) e utilidade prática no contexto industrial.

Cada critério foi pontuado de 0 (inadequado) a 5 (*Exelente*), de modo a permitir uma análise sistemática da performance do modelo. O método adotado foi inspirado no estudo de Paula, Filho e Cypriano (2023), que utilizaram abordagem semelhante no domínio da programação, validando respostas geradas por IA com base em julgamento técnico dos próprios autores.

A Tabela 1 apresenta a avaliação utilizada na validação da hipótese, contendo as respostas analisadas e as respectivas pontuações atribuídas. As respostas completas encontram-se disponíveis no APÊNDICE A, enquanto a imagem aqui inserida visa facilitar a visualização da estrutura da avaliação realizada.

Tabela 1 – Tabela de avaliação técnica do GPT

Respostas do Modelo	Clareza	Coerência Técnica	Estrutura lógica	Utilidade Prática	Média
R1	5	5	5	4	4,75
R2	5	5	4	3	4,25
R3	5	4	4	4	4,25
R4	5	5	5	4	4,75
R5	4	4	4	4	4,00
R6	5	5	5	4	4,75

Fonte: Elaborado pelo autor (2025).

### 3.4 DESENVOLVIMENTO DO *DASHBOARD*

O *Dashboard* foi desenvolvido com o objetivo de transformar os dados do estudo de pesquisa em informações visuais de fácil interpretação, funcionando como uma ferramenta de gestão visual estratégica para melhorar o controle dos registros de acionamentos de *Andon*. É válido ressaltar que os valores obtidos neste *Dashboard* permitem verificar quantitativamente os resultados gerados a partir da mudança de linguagem aplicada pelo modelo customizado.

No entanto, a coluna de dados “*Reason*” não foi utilizada como parâmetro nesta análise devido às suas particularidades qualitativas e descritivas. Essa coluna apresenta diferentes formas de expressão para um mesmo problema, já que cada responsável pode descrevê-lo com termos diferentes, usando sinônimos, variações gramaticais ou mesmo abreviações. Isso limita a padronização e impede a contagem precisa no *Power BI*, diferentemente das demais colunas, que contêm dados estruturados e passíveis de quantificação, como data, hora, posto, tempo de parada, entre outros.

Portanto, este *Dashboard* tem caráter exclusivamente quantitativo e informativo. Os dados descritivos foram considerados apenas na etapa de alimentação do modelo de linguagem, onde puderam ser tratados e agrupados com base em similaridades semânticas. No entanto, no *Power BI*, essa etapa não é reproduzida, o que inviabiliza o uso direto da coluna “*Reason*” para análises visuais automatizadas.

Além dessas considerações, o *Dashboard* foi estruturado com indicadores-chave que permitem uma análise quantitativa detalhada dos acionamentos de *Andon* ao longo do tempo. Dentre os principais dados apresentados, destacam-se:

a) Total de acionamentos mensais: representa a quantidade de vezes que o sistema *Andon* foi ativado por mês, permitindo observar picos e padrões de recorrência;

b) Total de *Run Time* (em segundos): tempo total de parada convertido em minutos, mostrando o impacto temporal das ocorrências;

c) Acionamento por período: contempla o intervalo de fevereiro de 2004 a fevereiro de 2025, possibilitando comparações históricas;

d) Quantidade de acionamentos por posto e percentual total: indica o volume de acionamentos reconhecido em relação ao total registrado;

e) Tempo de parada por mês (em segundos): métrica fundamental para compreender os meses com maior impacto produtivo;

f) Tempo por posto pelo modelo e percentual por anual referente aos números de eventos;

g) Classificação por tipo de evento (“Warning/Stop”): com um filtro específico para este tipo de acionamento, permitindo segmentar os dados de acordo com categorias operacionais de relevância.

Essas visualizações foram integradas ao *Power BI* para garantir que a análise dos dados fosse dinâmica, clara e funcional. Com isso, gestores e analistas podem acompanhar, em tempo real, os impactos operacionais, tendências de acionamentos, eficiência da categorização automática e propor planos de ação baseados em evidências concretas. A seguir, o *Dashboard* desenvolvido, realizado na plataforma *Power BI*, com todos os dados consolidados, conforme a Figura 6.

Figura 6 - Dashboard completo



Fonte: Elaborado pelo autor (2025).

Essa separação permite uma análise mais segmentada e detalhada, facilitando a visualização de padrões específicos conforme a natureza do acionamento.

### 3.4.1 Avaliação técnica do *Dashboard* para hipótese 2

Com o objetivo de avaliar a segunda hipótese deste estudo, que propõe a eficácia do uso do *Power BI* como ferramenta de apoio à visualização e análise dos dados do sistema *Andon*, foi adotado o mesmo procedimento metodológico aplicado na hipótese anterior (seção 3.3.1). Assim como na primeira etapa, realizou-se uma avaliação técnica individual, com base em julgamento do autor, considerando critérios objetivos aplicados às visualizações desenvolvidas.

A avaliação foi estruturada em sete perguntas específicas, formuladas com base nas diferentes visões do painel, com o intuito de verificar a clareza, a coerência dos dados, a gestão visual e a interatividade oferecida pelas representações gráficas. Cada resposta foi pontuada em uma escala de 0 (inadequado) a 5 (*Excelente*), conforme julgamento técnico individual.

Os critérios adotados foram: clareza visual, coerência dos dados, gestão visual e interatividade, os quais seguem exatamente a mesma lógica de análise aplicada na validação da hipótese 1. A Tabela 2 apresenta os resultados obtidos na avaliação técnica individual, contendo as pontuações atribuídas a cada visualização analisada. As perguntas utilizadas como base para essa avaliação estão disponíveis integralmente no Apêndice B, com o objetivo de facilitar a consulta sem comprometer a fluidez da leitura nesta seção.

Tabela 2 – Tabela de avaliação técnica do *Dashboard*

Pergunta	Clareza Visual	Coerência dos Dados	Gestão Visual	Interatividade	Média
P1	5	5	5	5	5,00
P2	5	5	5	5	5,00
P3	5	5	4	5	4,75
P4	4	5	4	5	4,50
P5	5	5	5	5	5,00
P6	5	4	5	5	4,75
P7	5	5	5	5	5,00

Fonte: Elaborado pelo autor (2025).


## 4 ANÁLISE DOS RESULTADOS

### 4.1 VALIDAÇÃO DAS HIPÓTESES

A avaliação da hipótese 1 resultou em uma média geral de 4,46. Esse valor sintetiza o desempenho técnico das respostas geradas pelo modelo GPT-4 em conjunto com a técnica de Recuperação Aumentada de Geração (RAG). As pontuações atribuídas variaram entre 4.00 e 4.75, revelando consistência e aplicabilidade prática no contexto industrial.

A Figura 7 apresenta as médias individuais atribuídas às seis respostas analisadas. Observa-se que quatro respostas atingiram a média de 4.75, o que demonstra uniformidade de qualidade em diferentes situações avaliadas. A menor média registrada foi 4.00, atribuída à Resposta 5, ainda assim considerada satisfatória dentro da escala adotada.

Figura 7 - Resultados para a hipótese 1.




Fonte: Elaborado pelo autor (2025).

Esse resultado, com 95% de aprovação, demonstra que o modelo de linguagem, aliado à técnica RAG, é capaz de organizar informações ambíguas e não padronizadas de maneira adequada. Conclui-se que o modelo de linguagem apresentou desempenho técnico adequado para a tarefa proposta, a avaliação evidenciou que o conteúdo gerado é claro, coerente e funcional, reforçando sua utilidade como ferramenta de apoio na interpretação dos registros textuais do sistema *Andon*.

A avaliação da hipótese 2 resultou em uma média geral de 4.86. Esse valor reflete o desempenho das visualizações do *dashboard* desenvolvido no *Power BI*, avaliadas segundo os critérios de clareza visual, coerência dos dados, gestão visual e interatividade, conforme descrito na Seção 3.4.1.

A Figura 8 apresenta as médias atribuídas às sete perguntas analisadas. Observa-se que quatro das sete perguntas (P1, P2, P5 e P7) alcançaram a média máxima de 5.00, indicando alto nível de aprovação quanto à apresentação das informações, organização visual e aplicabilidade prática. As demais perguntas obtiveram médias de 4.75 (P3 e P6) e 4,50 (P4), também refletindo avaliações positivas. Não houve nenhuma média inferior a 4.5, o que evidencia consenso favorável em todos os aspectos considerados.

Figura 8 – Resultados para a hipótese 2



Fonte: Elaborado pelo autor (2025).

Esses resultados reforçam que o *dashboard* atendeu aos critérios propostos e se mostrou eficiente como ferramenta de apoio à análise dos dados do sistema *Andon*. Com 96% de aprovação média, a clareza nas visualizações, combinada à organização gráfica e à interatividade das informações, contribuiu para uma leitura estratégica e integrada dos eventos registrados, alinhando-se aos objetivos propostos pela hipótese 2

## 4.2 RESULTADOS DO MODELO DE LINGUAGEM REALIZADO

A aplicação do modelo de linguagem baseado em GPT, configurado com dados históricos por meio de RAG, do sistema *Andon* em formato PDF, proporcionou uma nova abordagem interpretativa aos dados descritivos dos acionamentos, organizados originalmente em planilhas *Excel*. Esses dados foram estruturados com foco nas colunas sintoma, causa e ação responsável, o que permitiu a modelagem de uma base textual sólida para uso customização do assistente. O modelo foi testado com perguntas reais relacionadas ao contexto da produção, gerando respostas contextualizadas, coerentes e alinhadas com os registros operacionais.

Os principais ganhos observados foram:

a) Agilidade na interpretação textual: O modelo interpreta automaticamente registros que, anteriormente, exigiam leitura manual individual. Essa automatização proporcionou economia de tempo e maior fluidez no processo de análise;

b) Padronização de respostas e linguagem técnica: Apesar da diversidade de descrições registradas, o modelo forneceu respostas organizadas, com termos consistentes, facilitando a comunicação entre as áreas envolvidas;

c) Compreensão de variações linguísticas: O GPT foi capaz de entender registros com erros ortográficos leves, abreviações e diferentes formas de relatar o mesmo problema, algo que dificultava a análise tradicional em *Excel*;

d) Suporte à tomada de decisão: As respostas geradas forneceram recomendações diretas, como sugerir ações de manutenção, revisão de layout ou necessidade de padronização em pontos específicos, como determinados postos ou sintomas;

e) Redução da subjetividade na análise: Ao estruturar as respostas com base nos dados históricos, o modelo ajudou a eliminar interpretações pessoais ou inconsistentes presentes no base de dados, promovendo uniformidade nas análises.

São destacados, as limitações observadas:

a) Ambiguidade em colunas específicas (“*Reason*”): Registros muito vagos, mal preenchidos ou com termos genéricos dificultaram a interpretação precisa. Em alguns casos, o modelo forneceu respostas mais genéricas, baseando-se apenas em padrões anteriores.

b) Dependência da qualidade da base textual: Textos incompletos ou registros de teste resultaram em menor assertividade nas respostas, exigindo atenção no momento de preparar os dados para futuras aplicações.

Durante o processo de validação, com base nos resultados quantitativos obtidos pelo modelo, foram feitas perguntas diretas com base nos registros tratados. A quinta pergunta realizada resulta no total acumulado em segundos de acionamentos com valor de 204.587 mil segundos, principal posto identificado como *DTC/WIFI INSPECTION* e menciona outros postos de forma geral assim como os acionamentos por período, como exposto no APÊNDICE A sobre as respostas do assistente GPT à análise do PDF.

As respostas demonstraram coerência contextual, como a correta identificação do principal posto com maior tempo de parada, além da recorrência de causas operacionais que impactam diretamente o desempenho da linha, como falhas de sensor, ajustes operacionais e problemas mecânicos. O modelo também sugeriu ações voltadas à padronização de processos e melhorias em áreas críticas, apresentando respostas com frases completas, bem estruturadas e diretamente alinhadas ao contexto dos dados analisados. Isso evidencia que o modelo compreendeu o conteúdo de forma ampla e foi capaz de gerar recomendações operacionais baseadas nos registros históricos.

Vale destacar que o modelo foi utilizado com recursos gratuitos e limitados, disponibilizados pela própria plataforma da *OpenAI* para usuários individuais. Mesmo com essas restrições de capacidade, volume e processamento, o desempenho alcançado foi expressivo e suficiente para validar a proposta deste estudo. Contudo, para alcançar resultados ainda mais robustos, seria necessário investir em treinamentos adicionais com uma base mais ampla, limpa e estruturada, além de utilizar recursos profissionais da própria plataforma, que permitem ajustes de parâmetros avançados, maior retenção de contexto, personalização de respostas, elevando significativamente a assertividade.

Em síntese, a aplicação do modelo de linguagem demonstrou não apenas capacidade de interpretar e estruturar informações complexas, mas também de se adaptar ao contexto operacional do usuário. Isso reforça sua viabilidade como ferramenta de apoio à tomada de decisão no ambiente produtivo, desde que alimentado com dados organizados, claros e alinhados à realidade dos processos.

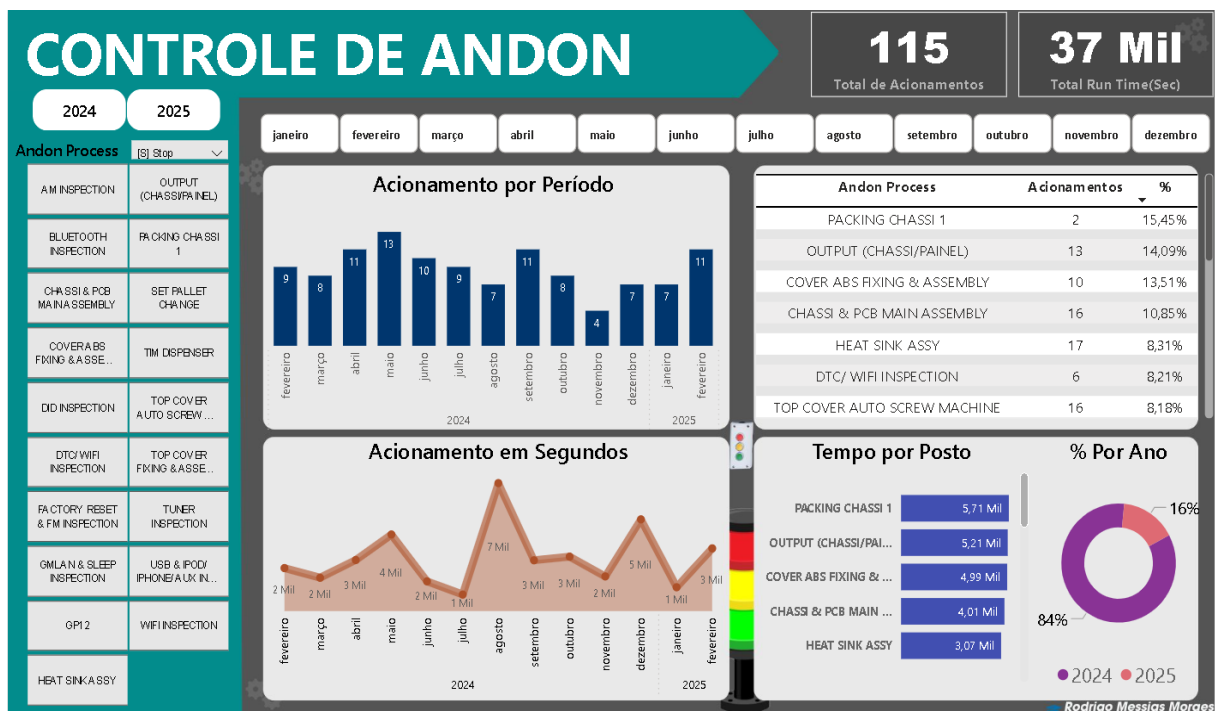
### 4.3 ANÁLISE QUANTITATIVA DO DASHBOARD

A análise quantitativa foi realizada a partir da visualização dos registros do sistema *Andon* em painéis interativos no *Power BI*, permitindo explorar indicadores estratégicos, identificar os postos mais críticos e interpretar tendências ao longo do período de análise. Foram utilizados três painéis principais: a visão geral completa, e versões filtradas com foco nos acionamentos classificados como *Stop* (falhas que causam paralisação da linha) e *Warning* (alertas que não interrompem a linha, mas indicam anomalias).

A análise tem como base os dados visuais apresentados na Figura 5 (ver seção Metodologia), que resume o painel desenvolvido com os registros do sistema *Andon* tratados no BI.

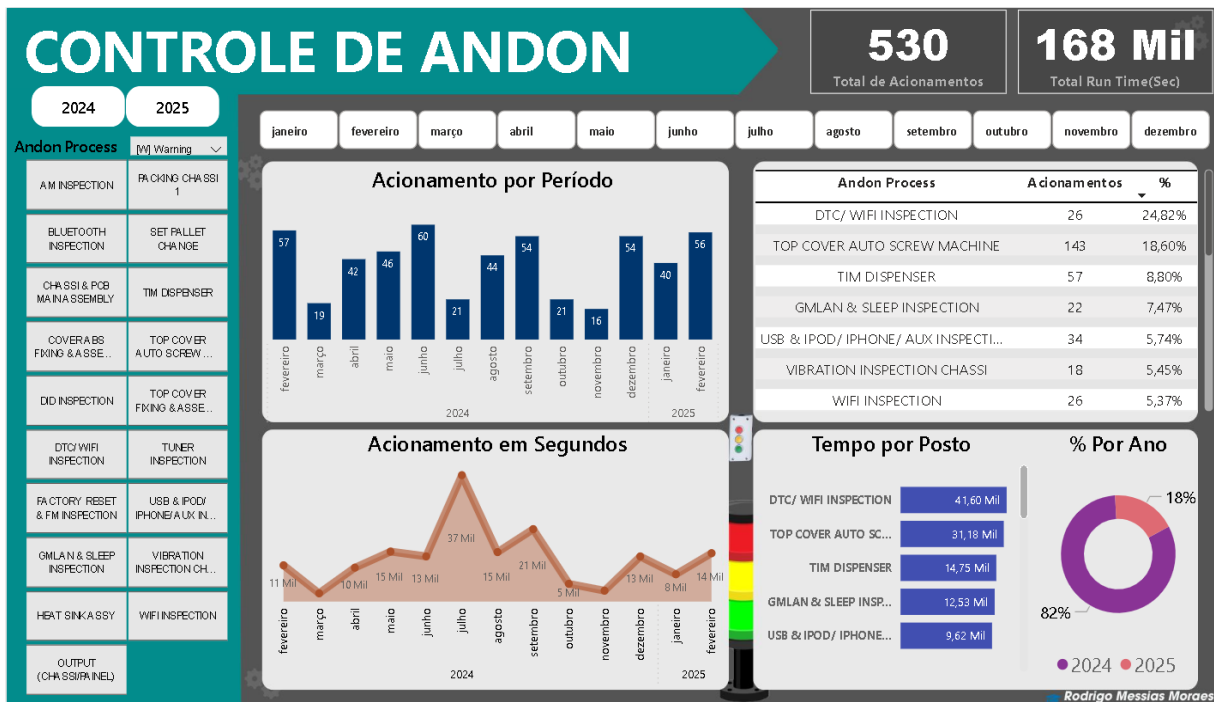
Esses painéis facilitaram o entendimento do comportamento das falhas ao longo do tempo. Os gráficos foram explorados com filtros por tipo de acionamento *Stop* e *Warning*, conforme a Figura 9 e 10, respectivamente. Isso permitiu segmentar as análises e comparar comportamentos específicos — por exemplo, visualizando apenas os acionamentos que causaram paradas de linha em determinado período, posto, acionamentos contáveis e percentuais.

Figura 9 - Dashboard filtrado em *Stop* (parada de linha)



Fonte: Elaborado pelo autor (2025).

Figura 10 - Dashboard Filtrado em Warning (Atenção)



Fonte: Elaborado pelo autor (2025).

Com base nesses painéis, foram identificados alguns indicadores de destaque, que ajudam a compreender os padrões de acionamento, os impactos operacionais e os pontos críticos da linha de produção:

a) Quantidade de acionamentos por mês: Os dados apontam junho (70 acionamentos) de 2024 como o mês com maior número de registros. Isso está relacionado a aumentos de produção e validação de um novo modelo no processo.

b) Tempo total de parada acumulado: O painel indica um total aproximado de 205 mil segundos de parada no período analisado, valor arredondado pelo próprio sistema para uma melhor gestão visual. Valor que coincide com o informado pelo modelo de linguagem, reforçando a consistência entre as abordagens.

c) Maior tempo de parada:

1. *DTC/WIFI INSPECTION*  $\cong$  44.640 segundos.
2. *TOP COVER AUTO SCREW MACHINE*  $\cong$  34.200 segundos.
3. *TIM DISPENSER*  $\cong$  15.650 segundos.

d) Distribuição percentual por tipo de erro: Os dados são divididos entre alertas do tipo *Stop* e *Warning*. A ferramenta permite visualizar quais postos mais contribuíram para cada tipo de ocorrência, possibilitando a análise comparativa por severidade.

Apesar de os acionamentos do tipo *Warning* (Figura 7) não interromperem o processo produtivo, os dados revelam um alto volume e reincidência dessas ocorrências. Isso indica que no processo produtivo em análise, os acionamentos representam, na sua maioria, falhas corrigidas rapidamente, sem gerar parada imediata, no entanto, essas pequenas falhas podem ser o gatilho para futuras falhas críticas. Sua recorrência constante demonstra fragilidades no processo que, se não tratadas com antecedência, podem resultar em paradas de linha, perda de produtividade e aumento de custos operacionais.

É válido ressaltar novamente que a análise da coluna descritiva como “*Reason*” revelou inconsistência para este cenário nos preenchimentos, com termos genéricos, erros ortográficos e falta de padronização. Isso dificulta a segmentação automática e reforça a necessidade de padronização de dados na fonte, por isso foi utilizada na etapa de configuração do assistente.

O acompanhamento detalhado dos acionamentos do tipo *Warning* deve ser priorizado na rotina da fábrica, mesmo que seu impacto direto pareça menor. Eles funcionam como sinais precoces de falha.

#### 4.4 ANÁLISE DOS RESULTADOS DO MODELO COM O *DASHBOARD*

A união entre os dados extraídos pelo modelo de linguagem baseado em GPT e os gráficos construídos no *Power BI* demonstrou forte alinhamento. Embora utilizem abordagens distintas — uma qualitativa, baseada em texto, e outra quantitativa, baseada em indicadores visuais —, os resultados apontam para as mesmas ocorrências críticas, reforçando a confiabilidade do diagnóstico.

Com base nesses painéis, foram identificados alguns indicadores de destaque, que ajudam a compreender os padrões de acionamento, os impactos operacionais e os pontos críticos da linha de produção:

a) Posto crítico em comum: o modelo de linguagem destacou o DTC/WIFI INSPECTION como o ponto de maior impacto no processo, o mesmo identificado no *Power BI* como o posto com maior tempo de parada acumulado (aproximadamente 44.640 segundos);

b) Consistência no volume total de acionamentos: A resposta gerada pelo modelo indicou 204.587 segundos, valor que coincide com o número exibido nos gráficos do *Power BI*, com arredondamento visual para cerca de 205 mil segundos;

c) Outros postos com recorrência: TOP COVER AUTO SCREW MACHINE e TIM DISPENSER também foram destacados por ambas as ferramentas como pontos relevantes, confirmando a correspondência nas análises;

d) O modelo de linguagem contextualizou os sintomas, interpretando descrições ambíguas ou mal preenchidas e sugerindo melhorias com base em padrões históricos;

e) O *Power BI* apresentou a dimensão quantitativa dos impactos, permitindo visualizar picos de ocorrência, tempo acumulado de parada e variações por período.

A convergência entre as análises demonstra que a combinação de uma ferramenta de inteligência artificial com uma plataforma de *business intelligence* (BI) proporciona uma visão mais robusta e eficiente do processo produtivo. Essa integração permite diagnósticos completos, unindo compreensão semântica e análise numérica, além de auxiliar na priorização de ações corretivas com base em evidências consistentes. A continuidade da aplicação integrada entre modelo de linguagem e *Dashboard* é recomendada para o monitoramento contínuo do sistema *Andon*, especialmente diante do crescimento constante do volume de dados operacionais e da necessidade de decisões rápidas e assertivas.

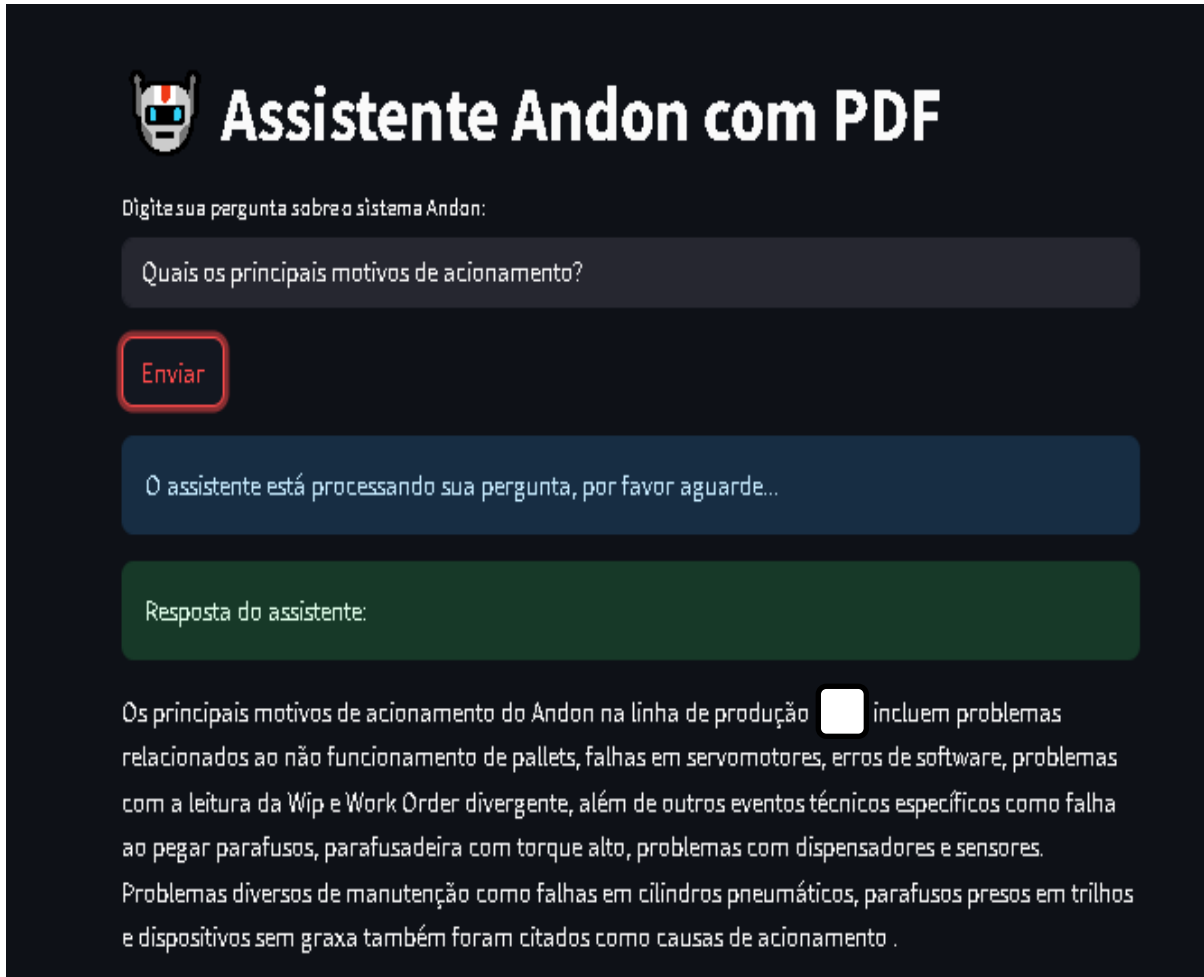
#### 4.5 PROPOSTA INTERATIVA COM *STREAMLIT*

Além das análises desenvolvidas no BI, foi proposta a construção de um assistente virtual interativo utilizando a biblioteca *Streamlit*, com integração direta à API da *OpenAI*. Esta proposta teve como objetivo explorar alternativas para automatizar a interpretação dos registros históricos do sistema *Andon*, permitindo consultas em linguagem natural sobre os dados previamente tratados.

Diferente de abordagens convencionais que utilizam modelos isolados no ambiente local, o desenvolvimento foi realizado de forma vinculada diretamente aos recursos configurados no ambiente da própria *OpenAI*, especialmente através do recurso de *Assistants API*, onde foi criado um agente personalizado alimentado pelos documentos em PDF previamente preparados. Isso significa que o código desenvolvido no *PyCharm* não executa o modelo localmente nem consulta bancos de dados internos, mas estabelece uma comunicação direta com o agente customizado na plataforma da *OpenAI*, utilizando identificadores específicos (como o vector store ID) para fazer a leitura e recuperação dos dados no servidor.

A Figura 11 apresenta a interface desenvolvida no *Streamlit*, onde o usuário insere perguntas em linguagem natural sobre os registros do *Andon* e recebe respostas geradas diretamente pelo modelo customizado na API da *OpenAI*.

Figura 11 – Interface do assistente no *Streamlit* – Pergunta 1



Fonte: Elaborado pelo próprio autor, 2025.

Nota: Figura adaptada para não aparecer informações confidenciais da empresa

Já a Figura 12 ilustra outro exemplo de interação, onde foi questionado sobre os principais equipamentos que apresentam falhas na linha de produção. O assistente retorna as informações de forma estruturada, evidenciando a capacidade de gerar *insights* contextualizados com base nos dados.

Figura 12 – Interface do assistente no *Streamlit* – Pergunta 2



Fonte: Elaborado pelo próprio autor, 2025.

O código, pode ser visualizado no Anexo C, desenvolvido em *Python*, utilizando as bibliotecas *Streamlit*, *OpenAI* e integração com variáveis de ambiente para a autenticação da API. O código realiza a conexão com o assistente na *OpenAI*, envia as perguntas do usuário, aguarda o processamento e retorna as respostas no ambiente interativo.

A principal vantagem deste modelo está na facilidade de configuração da lógica conversacional e na robustez da compreensão textual oferecida pelo modelo GPT. No entanto, durante a execução, foram identificadas limitações importantes, que inviabilizaram a continuidade da solução como uma proposta definitiva:

a) Dependência dos recursos pagos da *OpenAI*: Para acessar funcionalidades mais avançadas, como maior capacidade de memória, persistência contextual, aumento de limite de dados e uso contínuo, seria necessário contratar planos superiores, o que não foi viável no escopo atual.

b) Limitações técnicas do próprio *Streamlit*: A plataforma, embora muito útil para protótipos rápidos, apresenta restrições gráficas e de usabilidade. A cada interação, há recarregamento completo da página, o que compromete a fluidez da navegação. A interface, apesar de funcional, não atinge o mesmo nível de usabilidade de plataformas como o Playground da *OpenAI*.

c) Tentativas de buscar alternativas: Foram explorados outros fluxos, como a integração direta do GPT no *Power BI*, mas estes também exigiam assinaturas premium ou serviços adicionais para liberar as funcionalidades completas.

Ainda assim, a proposta serve como uma prova de conceito funcional, demonstrando que é possível utilizar modelos de linguagem treinados, configurados e customizados sobre dados internos da empresa para responder perguntas específicas, como:

a) "Quais os principais motivos de acionamento?"

b) "Quais os principais equipamentos que geram falhas no processo?"

Este modelo oferece respostas contextualizadas, diretamente extraídas do histórico dos acionamentos, o que reforça seu potencial para ser aplicado como ferramenta de apoio na supervisão de processos e na tomada de decisão.

Portanto, embora não tenha sido implementado como solução definitiva, a construção deste protótipo reforça a aplicabilidade futura de modelos de linguagem natural na indústria, especialmente quando houver viabilidade financeira para contratação dos recursos necessários, integração a novos sistemas e recursos e a integração com plataformas mais robustas.

#### 4.6 ANÁLISES DE MELHORIA DO PROCESSO DE PRODUÇÃO

As melhorias apresentadas nesta seção foram desenvolvidas com foco direto na redução de acionamentos específicos do sistema *Andon*, vinculados a falhas recorrentes no processo produtivo. Cada ação de melhoria foi fundamentada na análise dos dados extraídos do sistema, buscando resolver problemas que, embora sejam eventos pontuais, possuem caráter recorrente e impactam significativamente o desempenho operacional.

As causas que originaram esses acionamentos foram mapeadas, analisadas e tratadas por meio de intervenções direcionadas. Embora cada melhoria tenha como origem um problema específico, os impactos são visíveis de forma macro, refletindo diretamente nos indicadores de desempenho monitorados no *Dashboard* desenvolvido. As melhorias aplicadas foram:

a) Melhoria na estrutura no trilho na *autoscrew* (*máquina de fixação de parafuso automática*) para eliminação de parafuso não conforme ao processo: Essa solução foi aplicada para resolver falhas relacionadas à utilização de parafusos incorretos no processo de montagem. Ocorria parada de linha devido a máquina ser alimentado com parafusos NG (Não Conforme) que era depositado na caixa do dispensador e passava pelo trilho da máquina e travando a operação automática.

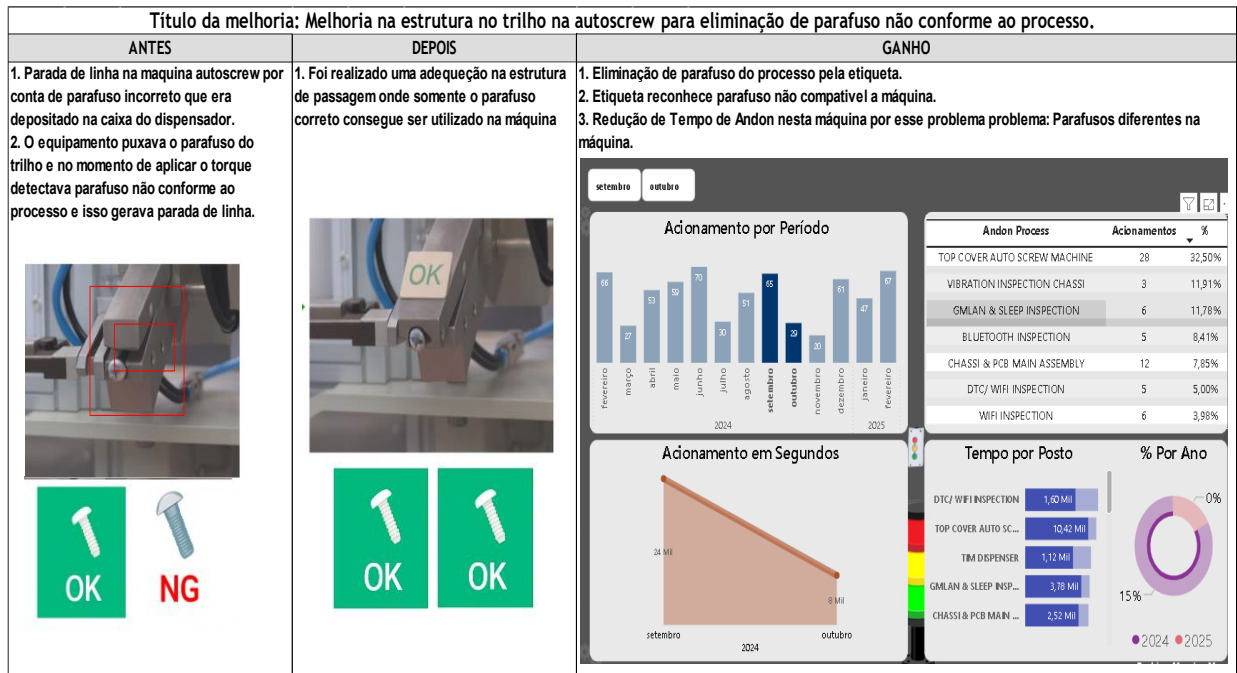
b) Dispensador substituto para reposição mais ágil: O acionamento recorrente estava relacionado à falha do dispensador de peças, que, quando ocorria, gerava parada no posto até que um novo dispensador fosse trazido manualmente da manutenção. A implementação do suporte para um dispensador reserva no próprio posto eliminou esse tempo de deslocamento e de espera, reduzindo consideravelmente os acionamentos desse tipo.

c) Instalação de mangueira de sopro de ar nos conectores: Foi identificado que o acúmulo de resíduos nos conectores gerava acionamentos do *Andon* por falhas de encaixe e contato. A aplicação de um sistema de sopro de ar contínuo nos pontos críticos resolveu o problema, evitando que resíduos impactassem a montagem e, conseqüentemente, reduzindo esse tipo de acionamento.

Essas intervenções foram direcionadas a problemas específicos, mas os efeitos se tornam visíveis na análise geral do processo, validada por meio dos *Dashboards*. A redução dos acionamentos nas categorias associadas às melhorias

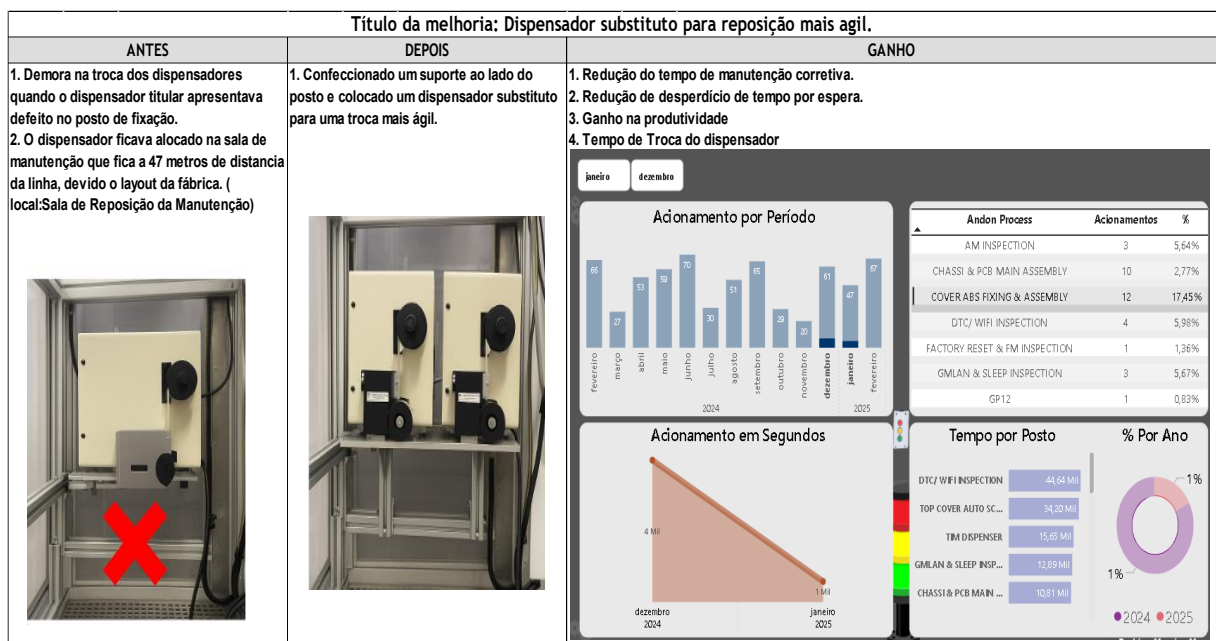
implementadas confirma que ações simples, porém bem direcionadas, têm impacto direto na estabilidade e eficiência do processo. As Figuras 13, 14 e 15 ilustram cada uma das melhorias aplicadas, com registro visual do antes e depois no processo produtivo.

Figura 13 – Melhoria na estrutura do trilho



Fonte: Elaborado pelo autor (2025).

14 – Melhoria na reposição de dispensador



Fonte: Elaborado pelo autor (2025).

Figura 15 – Instalação de mangueira de sopro de ar nos conectores



Fonte: Elaborado pelo autor (2025).

Esses resultados comprovam que o monitoramento sistemático dos acionamentos do *Andon*, associado à análise via *Dashboard*, permite não só identificar gargalos operacionais, mas também implementar soluções assertivas que impactam diretamente na performance do processo produtivo.

As imagens apresentadas nas Figuras 13, 14 e 15 foram geradas por meio de ferramentas de inteligência artificial da *OpenAI*, especificamente desenvolvidas para representar visualmente as melhorias implementadas no processo produtivo. As ilustrações foram elaboradas com o objetivo de proporcionar uma representação fiel e didática das intervenções realizadas, sem utilizar registros fotográficos reais da empresa, garantindo, assim, a preservação de informações confidenciais. Dessa forma, as imagens cumprem uma função exclusivamente acadêmica, integrando-se ao contexto do próprio trabalho, que faz uso das tecnologias e recursos da *OpenAI* para desenvolvimento de soluções aplicadas à indústria.

## 5 CONCLUSÃO

Este trabalho teve como propósito propor uma abordagem inovadora para a análise dos registros do sistema *Andon*, fundamentada na aplicação de técnicas de Processamento de Linguagem Natural (PLN) e na utilização de ferramentas de inteligência de dados. A proposta emergiu da identificação de limitações no processo convencional de análise, que, até então, era conduzido por meio de planilhas eletrônicas, com elevada dependência de interpretação manual, dificultando a identificação de padrões, causas recorrentes a implementação de ações corretivas efetivas e perdas de informações na base de dados.

Além disso, a abordagem tradicional não garantia uma análise abrangente, uma vez que parte significativa dos registros, especialmente aqueles que não resultavam em paradas críticas ou defeitos, acabava não sendo considerada nos processos formais de tratamento e análise de dados. Soma-se a isso a existência de registros inconsistentes, como acionamentos com os campos de registro dos acionamentos vazios ou informações incompletas, os quais precisaram ser descartados a fim de assegurar a qualidade e a fidedignidade dos resultados obtidos no presente estudo.

Através da modelagem dos dados e do emprego de um modelo de linguagem baseado na arquitetura GPT, disponibilizado pela *OpenAI*, foi possível transformar registros textuais não estruturados em informações relevantes e contextualizadas, auxiliando na tomada de decisão e na gestão operacional do processo produtivo. Simultaneamente, a construção de *Dashboards* interativos no *Power BI* proporcionou uma visualização macro dos principais indicadores relacionados aos acionamentos do *Andon*, permitindo uma análise ágil, assertiva e orientada por dados.

Adicionalmente, destaca-se como contribuição deste estudo a proposta de desenvolvimento de uma interface interativa por meio do *Streamlit*, que, embora não tenha sido consolidada como uma solução definitiva, se demonstrou viável enquanto prova de conceito.

Os resultados obtidos demonstraram que a integração entre inteligência artificial e análise de dados contribuiu para uma compreensão mais aprofundada dos fenômenos produtivos.

Além da análise qualitativa dos acionamentos do sistema *Andon*, o trabalho permitiu avaliar com maior precisão os impactos de melhorias físicas previamente

implementadas no processo, como a adequação na estrutura do trilho para eliminação de parafusos não conformes, a inclusão de um dispensador reserva para reposição imediata e a instalação de um sistema de sopro de ar nos conectores. Essas intervenções foram fundamentais na mitigação das causas de acionamentos específicos, refletindo na redução de falhas, na otimização do tempo de operação e no aumento da estabilidade do processo produtivo.

No âmbito acadêmico e científico, este estudo reforça a relevância da interdisciplinaridade entre engenharia de produção, ciência de dados e inteligência artificial, oferecendo uma metodologia aplicável e replicável em diferentes contextos industriais. Trata-se de uma contribuição que evidencia o potencial da transformação digital na indústria, alinhada aos princípios da Indústria Moderna.

Por fim, conclui-se que a aplicação de modelos de linguagem natural, associada à análise de dados e à inteligência operacional, constitui uma estratégia eficiente e alinhada às demandas contemporâneas da indústria, promovendo ganhos expressivos em termos de controle, eficiência e melhoria contínua dos processos produtivos.

## 6 RECOMENDAÇÕES

É importante reconhecer as limitações observadas durante a pesquisa, dentre as quais destacam-se a dependência de dados bem estruturados, as restrições inerentes às plataformas gratuitas da *OpenAI* e as limitações operacionais da ferramenta *Streamlit*, especialmente no que tange à usabilidade e à personalização da interface.

Diante disso, sugere-se, como continuidade deste trabalho, o aprofundamento na personalização dos modelos de linguagem por meio de técnicas de processamento de linguagens, bem como a integração com sistemas corporativos, bancos de dados internos e soluções de automação industrial. Ademais, recomenda-se expandir a aplicação da metodologia proposta para outros setores produtivos, com o intuito de validar sua aderência e potencializar seus resultados em diferentes ambientes operacionais.

## REFERÊNCIAS

ALPAYDIN, E. **Machine learning**. [S. l.]: Mit Press, 2021.

BARNETT, S. *et al.* **Seven Failure Points When Engineering a Retrieval-Augmented Generation System**. In: Proceedings of the 3rd International Conference on AI Engineering — Software Engineering for AI (CAIN 2024). New York: ACM, 2024. Disponível em: <https://arxiv.org/abs/2401.05856>. Acesso em: 20 mar. 2024.

BIRD, S.; KLEIN, E.; LOPER, E. **Natural language processing with Python: analyzing text with the natural language toolkit**. Beijing: O'Reilly Media, 2009.

BROWN, T. *et al.* **Language models are few-shot learners**. In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS – NEURIPS 2020, v. 33. San Francisco: Curran Associates, 2020. Disponível em: [https://papers.nips.cc/paper\\_files/paper/2020/file/1457c0d6bfcb4967418bfb8ac142f64a-Paper.pdf](https://papers.nips.cc/paper_files/paper/2020/file/1457c0d6bfcb4967418bfb8ac142f64a-Paper.pdf). Acesso em: 26 maio 2025.

CASTRO, J. C. M. de B. e. **Sistema Andon**. 2016. 112 f. Dissertação (Mestrado em Engenharia de Produção) — Universidade do Porto, Porto, 2016. Disponível em: <https://hdl.handle.net/10216/88136>. Acesso em: 25 c 2024.

CHUI, M.; MANYIKA, J.; MIREMADI, M. **What AI can and can't do (yet) for your business**. McKinsey Quarterly, 2018. Disponível em: <https://www.mckinsey.com>. Acesso em: 03 mar. 2025.

COSTA, L. A. **O uso de ferramentas de Lean Manufacturing na otimização de estoque na indústria metalúrgica**. Jataí-GO, 2021. 47 f. Monografia (Bacharelado em Engenharia Civil) — Instituto Federal de Goiás, Jataí, 2021. Acesso em: 25 abr. 2024.

DENNIS, P. **Produção Lean Simplificada: um Guia para Entender o Sistema de Produção mais Poderoso do Mundo**. 2ª. ed. Porto Alegre: Bookman, 2008.

GAO, Y. *et al.* **Retrieval-Augmented Generation for Large Language Models: A Survey**. 2023. Disponível em: <https://arxiv.org/abs/2312.10997>. Acesso em: 04 mar. 2025.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.

GOOGLE. **Google Colaboratory**. 2023. Disponível em: <https://colab.research.google.com/>. Acesso em: 28 mar. 2025.

GOOGLE. **Sobre o Google**. 2023. Disponível em: <https://about.google/>. Acesso em: 26 mar. 2025.

HUTCHINS, W. J. **The history of machine translation in a nutshell**. In: EAMT CONFERENCE, 2005, Budapest. Proceedings... Budapest: EAMT, 2005. Disponível em: <https://aclanthology.org/2005.eamt-1.3.pdf>. Acesso em: 26 mar. 2025.

IFENTHALER, D. (2023). Automated essay grading systems. In O. Zawacki-Richter & I. Jung (Eds.), *Hanboock of open, distance and digital education* (pp. 1057–1071). Springer. [https://doi.org/10.1007/978-981-19-2080-6\\_59](https://doi.org/10.1007/978-981-19-2080-6_59). Acesso em: 27 mar. 2025

IMAI, M. **Kaizen: a estratégia para o sucesso competitivo**. São Paulo: IMAM, 1994.

INSTITUTO LEAN BRASIL. **O que é Lean?** São Paulo: Instituto *Lean* Brasil, 2023. Disponível em: <https://www.Lean.org.br/o-que-e-Lean>. Acesso em: 20 maio 2025.

ISHIKAWA, K. **Controle de qualidade total: à maneira japonesa**. Rio de Janeiro: Campus, 1993.

JETBRAINS. **PyCharm**. 2024. Disponível em: <https://www.jetbrains.com/pycharm/>. Acesso em: 20 fev. 2025.

JURAFSKY, D.; MARTIN, J. H. **Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition**. 3rd. ed. Upper Saddle River, N.J.: Prentice Hall., 2021. Acesso em: 24 maio 2025.

KAGERMANN, H.; WAHLSTER, W.; HELBIG, J. **Recommendations for implementing the strategic initiative INDUSTRIE 4.0: Securing the future of German manufacturing industry**. Frankfurt: Acatech, 2013.

KOROSIFRANCOIS. **Sistema Andon para linha de produção, luz de alerta sobre manufatura enxuta**. [ilustração]. 2022. Disponível em: [https://br.freepik.com/vetores-premium/sistema-Andon-para-linha-de-producao-luz-de-alerta-sobre-manufatura-enxuta\\_34900907.htm](https://br.freepik.com/vetores-premium/sistema-Andon-para-linha-de-producao-luz-de-alerta-sobre-manufatura-enxuta_34900907.htm). Acesso em: 13 abr. 2025.

LABONE CONSULTORIA. **Sistema Andon: o que é e como funciona essa ferramenta?** [ilustração]. 2019. Disponível em: <https://www.laboneconsultoria.com.br/o-que-e-Andon/>. Acesso em: 13 abr. 2025.

LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep learning**. *Nature*, v. 521, p. 436–444, 2015. DOI: <https://doi.org/10.1038/nature14539>.

LEWIS, P. *et al.* **Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks**. *Advances in Neural Information Processing Systems*, v. 33, p. 9459–9474, 2020. Disponível em: <https://arxiv.org/abs/2005.11401>. Acesso em: 20 mar. 2024.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Tradução de Paulo Martins Engel. Porto Alegre: Bookman, 2001.

LIKER, J. K. **O modelo Toyota: 14 princípios de gestão do maior fabricante do mundo**. Porto Alegre: Bookman, 2021.

MANNING, C. D.; SCHÜTZE, H. **Foundations of Statistical Natural Language Processing**. Cambridge: MIT Press, 1999. Acesso em: 14 maio 2025.

MARCONI, M. A.; LAKATOS, E. M. **Metodologia do trabalho científico: procedimentos básicos, pesquisa bibliográfica, projeto e relatório, publicações e trabalhos científicos**. 9. ed. São Paulo: Atlas, 2022.

MIKOLOV, T. *et al.* **Efficient Estimation of Word Representations in Vector Space**. arXiv preprint arXiv:1301.3781, 2013. Disponível em: <https://arxiv.org/abs/1301.3781>. Acesso em: 04 maio 2025.

MITCHELL, T. M. **Machine learning**. New York: McGraw-Hill, 1997. Disponível em: <https://www.cs.cmu.edu/~tom/files/MachineLearningTomMitchell.pdf>. Acesso em: 4 abr. 2025.

MONDEN, Y. **Toyota Production System: An Integrated Approach to Just-in-Time**. Boca Raton, FL: CRC Press. 2011.

NAKAJIMA, S. **Introduction to TPM: total productive maintenance**. Portland: Productivity Press, 1988.

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

OPENAI. **GPT-4**. San Francisco: *OpenAI*, 2023. Disponível em: <https://OpenAI.com/gpt-4>. Acesso em: 06 maio 2025.

OPENAI. **GPT-4 technical report**. San Francisco: *OpenAI*, 2023. Disponível em: <https://OpenAI.com/research/gpt-4>. Acesso em: 06 maio 2025.

PAULA, F.; FILHO, L. R.; CYPRIANO, A. **Análise das respostas do ChatGPT em relação ao conteúdo de programação para iniciantes**. Revista de Educação, Ciência e Tecnologia, v. 10, n. 2, p. 55–68, 2023.

PEREIRA, D.F. **Aplicação de modelos de linguagem natural para classificação de chamados em instituições acadêmicas**. 2024. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Escola Politécnica, Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2024. Disponível em: <https://hdl.handle.net/10923/27083>. Acesso em: 3 mar. 2025.

ROSA, B. A. B.; MELLO, R. F. **Análise automatizada de coesão em redações do ensino fundamental por meio de técnicas de natural language processing**. In: CONGRESSO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO (CBIE), 2022, Recife. Anais... Porto Alegre: Sociedade Brasileira de Computação, 2022. Disponível em: [https://sol.sbc.org.br/index.php/cbie\\_estendido/article/view/22608](https://sol.sbc.org.br/index.php/cbie_estendido/article/view/22608). Acesso em: 4 mar. 2025.

ROTHER, M.; SHOOK, J. **Aprendendo a enxergar: mapeando o fluxo de valor para agregar valor e eliminar o desperdício**. 1. ed. São Paulo: Lean Institute Brasil, 2003.

RUSSELL, S.; NORVIG, P. **Inteligência artificial**. Rio de Janeiro: Grupo GEN, 2013.

SANTOS, V. M. **Andon**: o que é esse sistema e como funciona? FM2S, 2025. Disponível em: <https://www.fm2s.com.br/blog/Andon-no-sistema-Toyota-Lean>. Acesso em: 2 fev. 2025.

SCHWAB, K. **A quarta revolução industrial**. Trad. Daniel Moreira. São Paulo: Edipro, 2016.

SILVA, G. S. B. da. **Estudo e implementação de um sistema Andon em uma indústria de vasos de pressão não-seriados**. 2024. 43 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Controle e Automação) — Universidade Estadual Paulista, Sorocaba, 2024. Disponível em: <https://hdl.handle.net/11449/255868>. Acesso em: 2 mar. 2025.

SUFRAMA. **Polo Industrial de Manaus fatura R\$ 151 bilhões até setembro**. 2024. Disponível em: <https://www.gov.br/suframa/pt-br/assuntos/noticias/polo-industrial-de-manaus-fatura-r-151-bilhoes-ate-setembro>. Acesso em: 12 maio 2025.

SUFRAMA. **Suframa faz balanço positivo de 2023 e destaca conquistas para a ZFM**. 2023. Disponível em: <https://www.gov.br/suframa/pt-br/assuntos/noticias/suframa-faz-balanco-positivo-de-2023-e-destaca-conquistas-para-a-zfm>. Acesso em: 12 maio 2025.

SUTTON, R. S.; BARTO, A. G. **Reinforcement learning: An introduction**. 2. ed. Cambridge: MIT Press, 2018. Acesso em: 18 mar. 2024.

TOUVRON, H. *et al.* **LLaMA: Open and Efficient Foundation Language Models**. Meta AI, 2023. Disponível em: <https://arxiv.org/abs/2302.13971>. Acesso em: 20 mar. 2024.

VASWANI, A. *et al.* **Attention is all you need**. In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS – NEURIPS 2017, v. 30. [S. l.]: Curran Associates, 2017. Disponível em: [https://papers.nips.cc/paper\\_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf](https://papers.nips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf). Acesso em: 26 mar. 2025.

VITORASSI, B. *et al.* **Uma análise das possibilidades do ChatGPT como sistema de apoio à decisão na área da saúde**. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE (SBCAS), 23., 2023, Porto Alegre. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2023. Disponível em: <https://sol.sbc.org.br/index.php/sbcas/article/view/28831>. Acesso em: 3 mar. 2025.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining: Practical machine learning tools and techniques**. 4. ed. Burlington: Morgan Kaufmann, 2016

WOMACK, J. P.; JONES, D. T.; ROOS, D. **A máquina que mudou o mundo**. 2. ed. Rio de Janeiro: Elsevier, 2004.

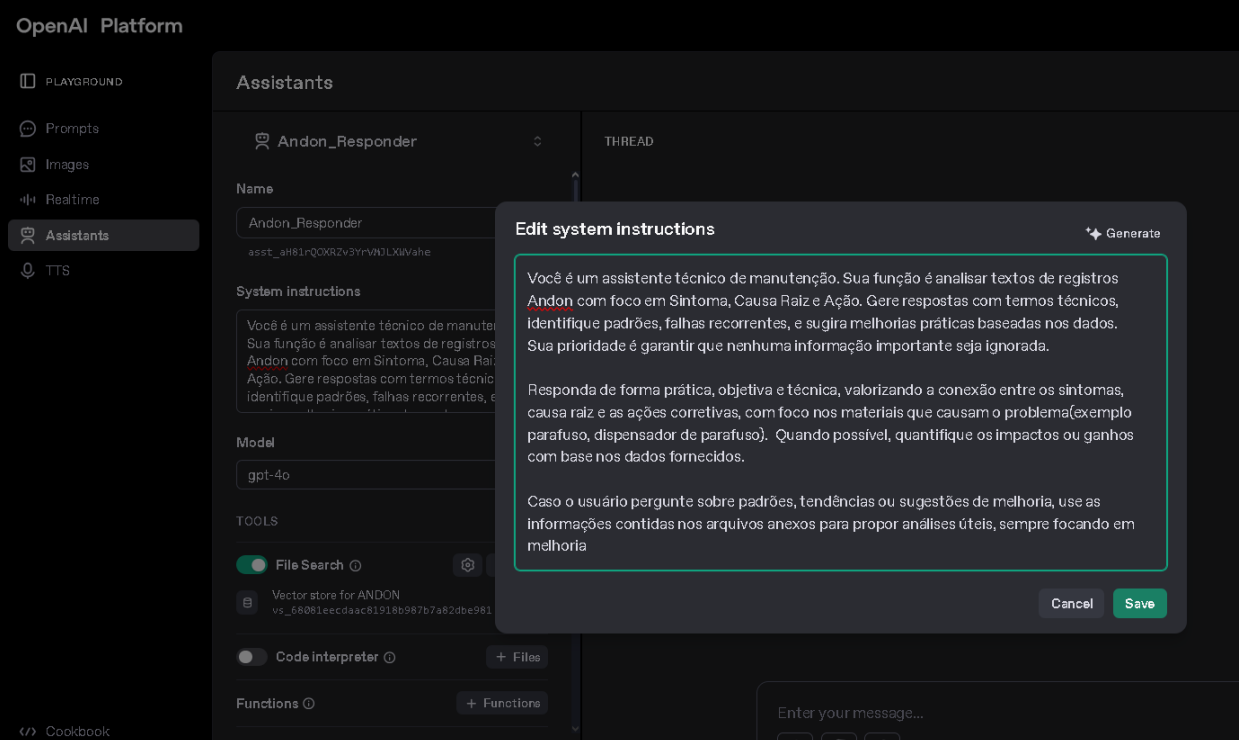
YIN, R. K. **Estudo de caso: planejamento e métodos**. 5. ed. Porto Alegre: Bookman, 2015.

**ANEXOS**

ANEXO A – EXEMPLO DE DIVERGÊNCIAS NOS REGISTROS TEXTUAIS DO SISTEMA ANDON

Reason	Divergência
Screw jaw sem parafus	Escrita incorreta
Erro no Software	Com espaçamento
trilho com Impureza	Com espaçamento
Técnico realizando análise Tecnico realizando analise	Com acento / Sem acento
Erro ao grava WIP ID Sen leitura da Wip	Escrita incorreta / Escrita diferente
Jig com suport danificado	Escrita incorreta
Gmes sem comunicação ... Gms sem comunicação ...	Escrita incorreta
Parafuso retirad no trilho do dispensador	Escrita incorreta
Scanner mal posicionado	Escrita incorreta
Pallet não liberado para posto seguinte Pallet não vai para proximo posto	Mesmo sintoma, escritas diferentes
Cilindro sem funcionamento Cilindro não funciona	Mesmo sintoma, escritas diferentes
pallet com chassi desligado ... Pallet desligado com chassi ...	Mesmo sintoma, escritas diferentes
Sem graxa na header Sem graxa na heade	Escrita incorreta
jaw d do cilindro fora de posição	Escrita incorreta

## ANEXO B – TELA DE CUSTOMIZAÇÃO NA PLATAFORMA OpenAI



**OpenAI Platform**

PLAYGROUND

Prompts

Images

Realtime

**Assistants**

TTS

Assistants

Andon\_Responder

THREAD

Name

Andon\_Responder

asst\_ah81rQ0XRZV3YrVNDLXWVah

System instructions

Você é um assistente técnico de manutenção. Sua função é analisar textos de registros Andon com foco em Sintoma, Causa Raiz e Ação. Gere respostas com termos técnicos, identifique padrões, falhas recorrentes, e sugira melhorias práticas baseadas nos dados. Sua prioridade é garantir que nenhuma informação importante seja ignorada.

Responda de forma prática, objetiva e técnica, valorizando a conexão entre os sintomas, causa raiz e as ações corretivas, com foco nos materiais que causam o problema (exemplo parafuso, dispensador de parafuso). Quando possível, quantifique os impactos ou ganhos com base nos dados fornecidos.

Caso o usuário pergunte sobre padrões, tendências ou sugestões de melhoria, use as informações contidas nos arquivos anexos para propor análises úteis, sempre focando em melhoria

Generate

Cancel Save

Enter your message...

File Search

Vector store for ANDON

vs\_68081eecdac81918b987b7a82d8e981

Code interpreter

Functions

Cookbook

## ANEXO B – CÓDIGO EM PYTHON PARA CONFIGURAÇÃO DO STREAMLIT

```

1 import openai
2 import time
3 import streamlit as st
4 from dotenv import load_dotenv
5 import os
6 # Carrega a chave da OpenAI do arquivo .env
7 load_dotenv()
8 openai.api_key = os.getenv("OPENAI_API_KEY")
9 def main(): 1 usage
10     st.set_page_config(page_title="Assistente Andon")
11     st.title("🤖 Assistente Andon com PDF")
12
13     # IDs fixos
14     file_id = "vs_68081eecdaac81918b987b7a82dbe981" # Seu vector store ID
15
16     if 'client' not in st.session_state:
17         # Inicializa cliente
18         st.session_state.client = openai.OpenAI()
19
20         # Cria o Assistente
21         st.session_state.assistant = st.session_state.client.beta.assistants.create(
22             name="Assistente Andon",
23             instructions=(
24                 "Você é um especialista no sistema Andon de uma fábrica. "
25                 "Use os dados carregados para responder de forma clara e precisa."
26             ),
27             model="gpt-4-1106-preview",
28             tools=[{"type": "file_search"}],
29             tool_resources={
30                 "file_search": {
31                     "vector_store_ids": [file_id]
32                 }
33             }
34         )
35     # Cria uma Thread (conversa)
36     st.session_state.thread = st.session_state.client.beta.threads.create()
37     # Entrada do usuário + exemplo de pergunta na caixa boz
38     user_query = st.text_input("Digite sua pergunta sobre o sistema Andon:", "Quais os principais motivos de acionamento?")
39     if st.button("Enviar"):
40         # Envia mensagem do usuário
41         st.session_state.client.beta.threads.messages.create(
42             thread_id=st.session_state.thread.id,
43             role="user",
44             content=user_query
45         )
46         # Roda o assistente
47         run = st.session_state.client.beta.threads.runs.create(
48             thread_id=st.session_state.thread.id,
49             assistant_id=st.session_state.assistant.id,
50             instructions="Responda de forma clara para o usuário que está analisando os dados de Andon."
51         )
52         # Espera o processamento (mostra spinner e texto uma única vez)
53         st.info("O assistente está processando sua pergunta, por favor aguarde...")
54         with st.spinner("Processando resposta..."):
55             while True:
56                 time.sleep(5)
57                 run_status = st.session_state.client.beta.threads.runs.retrieve(
58                     thread_id=st.session_state.thread.id,
59                     run_id=run.id
60                 )
61                 if run_status.status == 'completed':
62                     messages = st.session_state.client.beta.threads.messages.list(
63                         thread_id=st.session_state.thread.id
64                     )
65                     # Mostra a última resposta do assistente
66                     for msg in reversed(messages.data):
67                         if msg.role == "assistant":
68                             st.success("Resposta do assistente:")
69                             st.write(msg.content[0].text.value)
70                             break
71                     break
72                 elif run_status.status in ['failed', 'cancelled']:
73                     st.error("Erro ao processar a resposta.")
74                     break
75 if __name__ == "__main__":
76     main()

```

## APÊNDICE

APÊNDICE A – RESPOSTA DO ASSISTENTE GPT À ANÁLISE DO PDF

Pergunta User:	Resposta Andon_Modelo:
<p>Liste os principais sintomas registrados nos acionamentos de Andon e as causas mais recorrentes associadas.</p>	<p>Os principais sintomas registrados nos acionamentos de Andon e as causas mais recorrentes identificadas incluem:</p> <p><b>Sintomas Principais:</b></p> <ol style="list-style-type: none"> <li><b>1. Erro ao fixar parafusos:</b> Este sintoma aparece frequentemente, indicando problemas de fixação ou desalinhamento no sistema de parafusamento[1].</li> <li><b>2. Testes não inicializando:</b> Falhas no início dos testes, muitas vezes atribuídas a componentes danificados, como agulhas[2][3].</li> <li><b>3. Cilindro travado:</b> Indica problemas mecânicos, como desalinhamentos ou cabos desconectados[4][5].</li> <li><b>4. Pc em erro:</b> Problemas relatados com falhas de software que requerem reinicialização[6].</li> <li><b>5. Sem parafusos no trilho:</b> Indica problemas de fornecimento ou alimentação de peças nas máquinas[7].</li> </ol> <p><b>Causas Recorrentes:</b></p> <ol style="list-style-type: none"> <li><b>1. Desalinhamento de componentes:</b> Como cilindros e trilhos, resultando em falhas mecânicas e de fixação[8][9].</li> <li><b>2. Danos a componentes:</b> Agulhas ou conectores frequentemente danificados impactam na execução dos testes[10].</li> <li><b>3. Falhas de comunicação:</b> Entre sistemas ou componentes, como cabos desconectados, que interrompem a operação[11].</li> <li><b>4. Erro de software:</b> Requer ação corretiva, como reset ou reconfiguração[12].</li> </ol> <p>Esses sintomas e causas destacam áreas críticas a serem abordadas para reduzir o tempo de inatividade e melhorar a eficiência do processo de produção. Recomendo revisões regulares de alinhamento e manutenção preventiva para mecanismos frequentemente desalinhados ou danificados, além de testes rigorosos de software para evitar falhas recorrentes.</p> <p>[1][2][3][4][5][6][7][8][9][10][11][12]</p>
<p>Com base nos dados, quais ações poderiam ser implementadas para reduzir falhas recorrentes?</p>	<p>Com base nos dados dos registros Andon, aqui estão algumas ações que poderiam ser implementadas para reduzir falhas recorrentes:</p> <ol style="list-style-type: none"> <li><b>1. Manutenção Regular e Prevenção de Danos:</b> Implementar um cronograma de manutenção preventiva regular para componentes críticos como agulhas e conectores, que são frequentemente danificados e causam falhas no teste[1][2][3].</li> <li><b>2. Verificação de Alinhamento dos Componentes:</b> Realizar verificações de alinhamento regulares para sistemas de parafusamento e cilindros. Desalinhamentos foram causas comuns de falhas[4][5].</li> <li><b>3. Reforço do Controle de Qualidade:</b> Aumentar o controle de qualidade sobre as entradas do sistema, como parafusos e peças que possam ter problemas como travamentos ou falta de fornecimento adequado[6][7].</li> <li><b>4. Melhoria dos Sistemas de Software:</b> Melhorar os testes de software e processos de reset para identificar rapidamente e corrigir automaticamente falhas de software que exigem reinicialização, como os erros frequentes de software relatados[8][9].</li> <li><b>5. Treinamento Contínuo dos Operadores:</b> Oferecer treinamento contínuo e específico para operadores sobre manuseio correto das máquinas e identificação de problemas antes de causar paradas prolongadas[10].</li> <li><b>6. Monitoramento de Parâmetros de Operação:</b> Implementar sistemas de monitoramento em tempo real para parâmetros críticos como torque de parafusadeiras e luminosidade de controladores para ajustes automáticos e preventivos[11][12].</li> </ol> <p>Essas ações podem ajudar a reduzir falhas, melhorar a eficiência da linha de produção e minimizar o tempo de inatividade associado a acionamentos de Andon.</p> <p>[1][2][3][4][5][6][7][8][9][10][11][12]</p>

<p>Existe algum padrão de falha identificado na estação DTC/WIFI INSPECTION?</p>	<p>Na estação DTC/WIFI INSPECTION, foram identificados alguns padrões de falha recorrentes:</p> <p><b>1. Falha nos Sensores e Componentes:</b> Um problema frequente é a falha dos sensores e componentes danificados, como o sensor indutivo e agulhas, que requerem substituição para garantir o correto funcionamento dos testes[1][2].</p> <p><b>2. Problemas na Execução dos Testes:</b> Alguns registros indicam que bandejas de teste não completam o ciclo, ou o aparelho desliga devido à falta de alimentação elétrica ou problemas de tensão, o que requer intervenções no sistema de alimentação[3][4].</p> <p><b>3. Conectividade e Configuração de Software:</b> Foram registradas falhas de conexão Wi-Fi e problemas com o sistema operacional dos computadores, exigindo reinicializações frequentes e ajustes nos módulos de comunicação[5].</p> <p>Para mitigar essas falhas, as seguintes ações podem ser sugeridas:</p> <p><b>Implementar checagem e substituição regular dos sensores e componentes danificados para evitar paradas no ciclo de teste.</b></p> <p><b>Aumentar a verificação e manutenção da infraestrutura elétrica e de conectividade para garantir funcionamento contínuo dos equipamentos.</b></p> <p><b>Realizar atualizações do software de controle e treinamento das equipes para detectar rapidamente possíveis falhas de configuração.</b></p> <p>Essas medidas poderiam contribuir para melhorar a eficiência e a confiabilidade da estação DTC/WIFI INSPECTION, reduzindo o tempo de inatividade e aumentando a produtividade[6][7].</p> <p>[1][2][3][4][5][6][7]</p>
<p>QUANTOS ACIONAMENTOS TEVE POR MÊS, O TOTAL DE SEGUNDOS POR MÊS E POR POSTO, E O TOTAL GERAL DE ACIONAMENTOS</p>	<p>Total Geral de Acionamentos: null.</p> <p><b>Acionamentos por Mês:</b> <b>Janeiro a Dezembro de 2024:</b> Indica que os acionamentos variaram ao longo dos meses, com um pico em torno dos meses de julho, setembro e dezembro.</p> <p>Há uma sequência de crescimento no meio do ano, em março e abril, atingindo o ponto mais alto em julho.</p> <p><b>Total em Segundos por Mês e por Posto:</b> <b>Total em Segundos (Tempo de Execução Corrido):</b> 204587 mil segundos</p> <p><b>Os maiores tempos em segundos estão no período de julho, indicando um acúmulo significativo de tempo de manutenção ou paradas nesse mês.</b></p> <p>Tempo por Posto: DTC/WIFI INSPECTION: 44.96 mil segundos BLUETOOTH INSPECTION: 4.29 mil segundos <b>Outros postos comuns incluem CHASSI P2 MAIN ASSEMBLY e GM-LINE MP INSP P2, entre outros.</b></p> <p><b>Ações para Mitigação:</b> Com base nessas informações, seria benéfico: <b>Foco em DTC/WIFI:</b> Como o posto registrara números altos de acúmulo de tempo, um plano de manutenção preventiva pode reduzir as paradas.</p> <p><b>Revisão de Processos em Meses com Pico de Atividades:</b> Meses como julho e dezembro poderiam passar por análise detalhada para reavaliação de cargas e sistemas operacionais para aliviar pontos de pressão.</p> <p><b>Análise Detalhada por Posto:</b> Relação de tempo por posto pode sugerir áreas críticas para treinamento de pessoal e melhoria de processos operacionais.</p> <p><b>Otimização das Ferramentas e Equipamentos:</b> Recomenda-se um monitoramento e calibração dos instrumentos nos postos com maior incidência de acionamentos para reduzir falhas subsequentes.</p> <p>Estas informações ajudam a identificar áreas críticas e priorizar melhorias e recursos para alavancar a eficiência da produção.</p>

<p>Gere um resumo técnico das falhas mais frequentes com suas causas e ações corretivas. Use linguagem técnica de manutenção.</p>	<p>Aqui está um resumo técnico das falhas mais frequentes registradas nos acionamentos de Andon, suas causas e ações corretivas correspondentes:</p> <p><b>1. Erro de Fixação de Parafusos:</b>  <b>Sintoma:</b> Parafusadeira não realiza fixação ou perde o ponto de referência.  <b>Causa:</b> Defeito na parafusadeira ou perda de parâmetros do controlador.  <b>Ação Corretiva:</b> Ajuste do controlador para restauração de parâmetros e substituição do equipamento defeituoso[1]`[2].</p> <p><b>2. Teste Não Inicializando:</b>  <b>Sintoma:</b> Início de teste falha, interrompendo o ciclo de produção.  <b>Causa:</b> Agulhas danificadas ou contato elétrico defeituoso.  <b>Ação Corretiva:</b> Substituição das agulhas e reparo dos contatos elétricos[3]`[4].</p> <p><b>3. Pallet ou Bandeja com Mau Funcionamento:</b>  <b>Sintoma:</b> Bandeja não sobe ou desliga inesperadamente.  <b>Causa:</b> Válvulas pneumáticas travadas.  <b>Ação Corretiva:</b> Desbloqueio manual das válvulas e ajuste de tensão[5]`[6].</p> <p><b>4. Erro de Danos em Componentes:</b>  <b>Sintoma:</b> Componente como sensor ou bucha desgastados.  <b>Causa:</b> Desgaste natural ou desalinhamento de componentes.  <b>Ação Corretiva:</b> Troca de componentes danificados e ajustes nos trilhos[7]`[8].</p> <p><b>5. Conexão e Erro de Comunicação:</b>  <b>Sintoma:</b> Problemas de conexão em inspeções Wi-Fi.  <b>Causa:</b> Cabo de antena ou conectores danificados.  <b>Ação Corretiva:</b> Substituição de cabos e conectores avariados[9]`[10].</p> <p><b>Análise e Sugestões:</b>  Implementação de manutenções preventivas pode reduzir a frequência dessas falhas.  Calibração regular do equipamento e treinamento dos operadores poderiam minimizar a recorrência de erros operacionais.  Ações corretivas rápidas facilitadas por um melhor monitoramento em tempo real podem ajudar a evitar paradas prolongadas na produção.  Esse resumo técnico ajuda a entender melhor onde focar esforços para a melhoria contínua da eficiência da linha de produção e na redução do tempo de inatividade</p>
<p>E ações de melhorias mensais, com essa base de dados, quais pontos seriam baseados no sintoma e causa raiz, não so corretiva e sim preventiva</p>	<p>Com base na análise dos registros de Andon, apresento ações de melhorias preventivas relacionadas aos sintomas e causas raízes identificadas:</p> <p><b>1. Parafusadeiras com Problemas de Torque:</b>  <b>Sintoma:</b> Torque alto ou baixo.  <b>Causa Raiz:</b> Controlador de torque com perda de parâmetros.  <b>Ação Preventiva:</b> Implementar calibrações mensais nos controladores de torque e verificar regularmente as especificações do torque para identificar e corrigir quaisquer discrepâncias antes que causem falhas[1].</p> <p><b>2. Erro de Reconhecimento de Peças:</b>  <b>Sintoma:</b> Parafusadeiras falham ao identificar componentes.  <b>Causa Raiz:</b> Desalinhamento de sensores ou coordenadas não calibradas.  <b>Ação Preventiva:</b> Verificações diárias dos sensores e realinhamento sistemático dos equipamentos para garantir que a sincronização adequada seja mantida[2].</p> <p><b>3. Componentes Desgastados:</b>  <b>Sintoma:</b> Agulhas ou peças de fixação danificadas.  <b>Causa Raiz:</b> Desgaste natural ou má manutenção.  <b>Ação Preventiva:</b> Estabelecer um cronograma de substituição para componentes conhecidos por desgastar-se rapidamente, potencialmente se beneficiando de um inventário rotativo que minimize o tempo de manutenção[3].</p> <p><b>4. Falta de Graxa ou Recursos:</b>  <b>Sintoma:</b> Dispensadores sem aplicação de graxa.  <b>Causa Raiz:</b> Válvulas ou tubulações entupidadas ou mal abastecidas.  <b>Ação Preventiva:</b> Realizar verificações mensais de abastecimento e limpeza das linhas de graxa para assegurar um fluxo operacional contínuo e sem interrupções[4].</p> <p><b>5. Falhas na Conectividade e Comunicação:</b>  <b>Sintoma:</b> Erros de comunicação do sistema.  <b>Causa Raiz:</b> Cabos desconectados ou módulos de comunicação falhos.  <b>Ação Preventiva:</b> Inspeções de rotina e testes funcionais dos sistemas de comunicação e conectorização, além de implementar verificações após qualquer intervenção para garantir a reconexão correta[5].</p> <p>Essas ações preventivas têm como objetivo garantir que os equipamentos operem com eficiência máxima, reduzindo a necessidade de intervenções corretivas e minimizando o tempo de inatividade na linha de produção[6]`[7].</p> <p>[1][2][3][4][5][6][7]</p>

**APÊNDICE B – PERGUNTAS UTILIZADAS NA AVALIAÇÃO TÉCNICA DO  
DASHBOARD (HIPÓTESE 2)**

<b>PERGUNTA</b>	<b>DESCRIÇÃO</b>
Pergunta 1	<b>O painel completo apresenta uma visão clara e resumida do desempenho geral dos acionamentos Andon?</b>
Pergunta 2	<b>A separação entre os diferentes anos e meses está visível e facilita a comparação temporal dos dados?</b>
Pergunta 3	<b>É possível identificar, de forma intuitiva, os picos de acionamento do sistema Andon em períodos críticos?</b>
Pergunta 4	<b>As visualizações por tipo de alerta (Stop, Warning) são bem separadas e contribuem para o entendimento das ocorrências?</b>
Pergunta 5	<b>A disposição dos gráficos e filtros está organizada de forma lógica e facilita a navegação?</b>
Pergunta 6	<b>Os dados estão coerentes com o cenário em estudo e permitem extrair conclusões úteis?</b>
Pergunta 7	<b>As informações exibidas sobre os tempos (em segundos) estão legíveis e contextualizadas para análise?</b>