

# Analytics de Defeitos por Mix de Produção em Oficina de Montagem

*Defect Analytics by Production Mix in an Assembly Workshop*

**Monique Tomaz<sup>1</sup>**

 [orcid.org/0000-0002-5234-6789](https://orcid.org/0000-0002-5234-6789)

**Antonio Netto<sup>1</sup>**

 [orcid.org/0009-0006-1366-7666](https://orcid.org/0009-0006-1366-7666)

**Diogo Henrique Prado<sup>1</sup>**

 [orcid.org/0009-0000-9680-5601](https://orcid.org/0009-0000-9680-5601)

**Thiago de Santana<sup>1</sup>**

 [orcid.org/0009-0005-7893-6233](https://orcid.org/0009-0005-7893-6233)

**Alexandre M. A. Maciel<sup>1</sup>**

 [orcid.org/0000-0001-5727-2427](https://orcid.org/0000-0001-5727-2427)

<sup>1</sup>Escola Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, Brasil.  
E-mail: [moniquesuellen.tomaz@upe.br](mailto:moniquesuellen.tomaz@upe.br)

**DOI: 10.25286/rep.v9i1.2779**

Esta obra apresenta Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.

Como citar este artigo pela NBR 6023/2018: Monique Tomaz; Antonio Netto; Diogo Henrique Prado; Thiago de Santana; Alexandre M. A. Maciel. Analytics de Defeitos por Mix de Produção em Oficina de Montagem. Revista de Engenharia e Pesquisa Aplicada, v.9, n. 1, p. 60-68, 2024. DOI: 10.25286/rep.v9i1.2779

## RESUMO

Este artigo apresenta uma investigação aprofundada do padrão de análise de defeitos associados à classificação de problemas nos veículos produzidos, com ênfase em uma empresa específica do setor automotivo. O objetivo principal deste estudo consiste em aprimorar a qualidade e segurança dos veículos fabricados, por meio da identificação de padrões e correlações nos dados coletados relativos aos defeitos. Para alcançar esse objetivo, são aplicadas técnicas avançadas de análise de dados e ferramentas de inteligência artificial, em conjunto com outras soluções especializadas nessa área.

**PALAVRAS-CHAVE:** Análise de defeito; Padrões; Setor Automotivo;

## ABSTRACT

This article presents an in-depth investigation of the defect analysis pattern associated with the classification of problems in produced vehicles, with emphasis on a specific company in the automotive sector. The main objective of this study is to improve the quality and safety of manufactured vehicles, through the identification of patterns and correlations in the collected data related to defects. To achieve this goal, advanced data analysis techniques and artificial intelligence tools are applied, together with other specialized solutions in this area.

**KEY-WORDS:** Defect analysis; Standards; Automotive Sector;

## 1 INTRODUÇÃO

O presente estudo tem como foco a análise de defeitos no contexto da indústria automotiva. Nesse setor altamente competitivo, a qualidade e segurança dos veículos fabricados desempenham um papel crucial na satisfação dos clientes e no êxito das empresas. Com o aumento das regulamentações, a identificação e correção de defeitos tornam-se ainda mais relevantes.

A compreensão do padrão de análise de defeitos é fundamental para otimizar a qualidade e segurança dos veículos, proporcionando uma vantagem competitiva no mercado automotivo. A identificação e correção efetivas de falhas são aspectos críticos para garantir o desempenho adequado dos veículos, abrangendo diversos componentes, desde os mecânicos até os eletrônicos.

Aprofundar-se na análise de defeitos permite obter *insights* valiosos que podem resultar em melhorias significativas nos processos de produção. Essa contribuição impulsiona o avanço científico e tecnológico na indústria automotiva. Neste contexto, realizamos a análise e visualização dos dados coletados sobre defeitos, utilizando ferramentas de análise de dados e técnicas de inteligência artificial para identificar padrões e correlações.

Nosso objetivo é avaliar os impactos dos defeitos nas operações e nos clientes, além de propor ações corretivas e preventivas para aprimorar os processos da empresa em estudo. Os resultados obtidos serão fundamentais para embasar a tomada de decisão estratégica e implementar soluções eficazes.

Este estudo propõe a utilização de uma solução de extração de informações associada a um mecanismo de mineração de dados para a predição de resultados. O objetivo é estabelecer padrões e otimizar o acompanhamento de defeitos. Para alcançar esse objetivo, será desenvolvida uma solução algorítmica que terá a capacidade de ler a base de dados, realizar pesquisas, extrair informações relevantes, estruturar os dados e implementar a predição de resultados.

A estrutura deste trabalho é dividida da seguinte maneira: a introdução apresenta o contexto e a problemática abordada. Na seção 2, é apresentada a fundamentação teórica, que explora os conceitos de mineração de dados e revisa trabalhos relacionados que aplicam técnicas de mineração e aprendizado de máquina. Em seguida, na seção 3, são descritos os materiais e métodos utilizados,

incluindo detalhes sobre a preparação e transformação dos dados, bem como a técnica escolhida para a análise. A seção 4 discute os experimentos realizados e apresenta os resultados obtidos. Por fim, na seção 5, são apresentadas as conclusões do estudo, sugestões para pesquisas futuras e considerações finais.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 ÁREA DO NEGÓCIO

Ao possuir um grande impacto na economia mundial, a indústria automotiva possui visibilidade e destaque com sua capacidade de gerar empregos diretos e indiretos em todos os continentes e, conseqüentemente movimentar bilhões de dólares em negociações internacionais. De acordo com o Ministério da Economia do Brasil, o setor representa 4% do Produto Interno Bruto (PIB) do país e gera cerca de 1,3 milhão de empregos diretos e indiretos [1].

Estima-se que cerca de 70% de todo o seu processo são realizados por robôs, tendo, também, etapas com maior atuação humana, sendo as três principais a estruturação, a pintura e a montagem. Passadas as fases de soldagem, estamparia, carroceria, funilaria e testes de motor, o veículo, já com respectivos chassis, adentra a montagem final, em que todos os equipamentos internos e externos são inseridos.

Sendo uma das etapas de maior atuação humana, a montagem está suscetível ao lançamento de defeitos observados pelo operacional na linha de produção. Ao identificar presença de anomalia, o operador, com auxílio de um sistema computacional, abre e sinaliza o local do defeito. Esse procedimento gera um código denominado TESIS capaz de especificar o componente defeituoso, a anomalia propriamente dita e sua localização no automóvel. Após aberto, o defeito pode ser corrigido no mesmo posto de trabalho ou no ponto de reparo específico da linha, todavia, só poderá ser certificado e fechado pelo setor de qualidade.

Nessa perspectiva, identificar padrões nos códigos TESIS surge como uma oportunidade promissora para aplicação de técnicas de ciência de dados e *analytics* na operação de montagem do setor automotivo e, por conseguinte, propor melhorias e traçar objetivos orientados a dados [4][6][10].

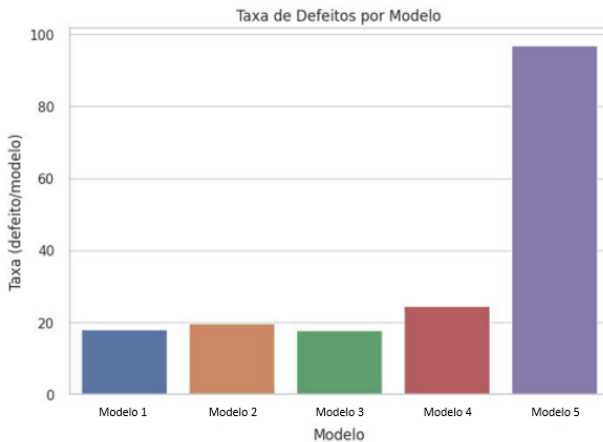
## 2.2 MINERAÇÃO DE DADOS

O processo de mineração de dados foi iniciado com a implementação do ETL (*Extract Transform Load*), possibilitando a segregação eficaz do código TESIS. Posteriormente, os dados foram exportados para o *Metabase*, onde foram concebidas e refinadas consultas especializadas.

As consultas foram elaboradas para extrair informações específicas, abrangendo desde a incidência de componentes defeituosos até a identificação de anomalias, a localização de problemas na planta, o cálculo do percentual de defeitos e a contagem individual dos defeitos por cliente.

Entre as análises realizadas, destacam-se a incidência diária por modelo, que permitiu avaliar a distribuição temporal dos defeitos em cada veículo. Além disso, a relação entre a incidência de defeito e a quantidade de veículos proporcionou identificar a extensão dos problemas em diferentes contextos de produção. A Taxa de Defeito foi calculada, oferecendo uma medida quantitativa da qualidade global do sistema TESIS, como pode ser visto na Figura 1.

**Figura 1** – Taxa de defeitos por modelo



**Fonte:** Os Autores.

A avaliação apontou que o Modelo 5 evidenciou a mais elevada taxa de defeitos, ressaltando a necessidade de concentrar esforços em melhorias e otimizações no sistema.

Em resumo, a integração e a preparação dos dados foram conduzidas por meio da plataforma *Pentaho*, enquanto o *Metabase* serviu como uma interface intuitiva para análise e visualização dos dados. Isso não apenas facilitou a exploração detalhada das informações, mas também

possibilitou a identificação de padrões e a obtenção de insights valiosos para o contexto analisado.

## 2.3 TRABALHOS RELACIONADOS

Nos últimos anos, a área de pesquisa da Indústria 4.0 tem sido amplamente explorada, recebendo inúmeras contribuições no contexto do uso de Big Data. Com a chegada da Indústria 4.0, que busca maior eficiência, flexibilidade e personalização na produção, a aplicação de tecnologias como *Machine Learning* e ciência de dados tornou-se cada vez mais relevante.

Diversos estudos têm explorado essas tecnologias e suas aplicações no contexto industrial, como na detecção e correção de falhas em processos de produção [1][2]. Essas soluções baseadas em *Machine Learning* permitem identificar falhas de forma rápida e eficiente, resultando em redução de custos e aumento da produtividade [1].

A manutenção preditiva tem sido um dos focos de pesquisa nesse campo, especialmente na indústria automotiva [4]. O uso de *Machine Learning* nessa área possibilita a previsão de falhas e a realização de manutenção preventiva, o que reduz custos e maximiza o tempo de atividade das máquinas [4]. Além disso, a análise de dados e ciência de materiais aplicadas à Indústria 4.0 têm se mostrado promissoras para a otimização de processos e melhoria da eficiência na produção [5].

Outras abordagens incluem a utilização de redes neurais profundas para análise de dados em processos de fabricação [6] e a integração de tecnologias como *blockchain* e IoT (Internet das Coisas) para controle de qualidade e segurança na manufatura inteligente [7][8]. Os estudos revisados também enfatizam a importância da análise de dados de qualidade e da expertise em ciência de dados para a implementação bem-sucedida dessas tecnologias [9][10].

Além disso, a detecção e classificação de falhas elétricas usando *Machine Learning* têm sido objeto de pesquisa, com potencial para melhorar a eficiência e a segurança dos sistemas [11].

No contexto específico de diagnóstico e prognóstico de falhas mecânicas em ambientes de fabricação industrial, técnicas de *Machine Learning* têm sido exploradas para auxiliar na detecção e previsão de falhas, contribuindo para a melhoria dos processos e a redução de custos [12]. Além disso, algoritmos de *Machine Learning* têm sido

utilizados para detecção de defeitos em processos de fabricação aditiva a laser em metais [13].

Em resumo, os artigos destacam a importância da aplicação de tecnologias de *Machine Learning* e ciência de dados na Indústria 4.0. Essas tecnologias têm o potencial de melhorar a eficiência, reduzir custos e aprimorar a qualidade dos produtos e processos industriais. No entanto, sua implementação enfrenta desafios, como a necessidade de dados de qualidade.

### 3 MATERIAIS E MÉTODOS

#### 3.1 DESCRIÇÃO DA BASE DE DADOS

Durante o processo de preparação dos dados para a mineração de dados, foram executadas etapas cruciais para garantir a qualidade e integridade das informações. A base de dados utilizada neste estudo é composta por três tabelas que armazenam informações importantes sobre a linha de produção automotiva. A Tabela 1 contém atributos como a Ordem de Produção/Identificação do Veículo (CIS), Modelo do Veículo e Código da Característica do Veículo, representados por valores inteiros.

A Tabela 2 desempenha um papel importante ao armazenar o atributo de identificação do terminal associado ao lançamento do defeito. Esse atributo é representado por valores em formato de *string* (texto). Através da identificação precisa da origem dos defeitos, essa tabela viabiliza a análise de padrões e correlações relacionadas aos terminais envolvidos, permitindo uma compreensão mais aprofundada dos fatores que contribuem para a ocorrência desses defeitos.

Além disso, a Tabela 3 desempenha um papel crucial na análise dos defeitos, uma vez que registra informações fundamentais, tais como o código do defeito, o tipo do defeito (aberto/fechado) e o instante de lançamento do defeito. Esses atributos são representados por *strings* e *datetimes*, respectivamente, e estão localizados. Essa tabela proporciona uma visão detalhada dos defeitos registrados, possibilitando a análise da natureza, frequência e evolução temporal dessas ocorrências.

Com o objetivo de aprimorar a análise completa dos dados, as tabelas foram combinadas de forma harmoniosa, formando uma fonte única de informações. Isso permitiu uma abordagem analítica integral e eficaz.

Ao unificar as tabelas, criou-se uma fonte centralizada de dados, permitindo uma abordagem

mais coesa na análise. A integração possibilitou a identificação de padrões, tendências e correlações entre os atributos, fornecendo uma visão holística da eficiência e qualidade da linha de produção.

A base de dados em questão possui características de *big data* devido à sua extensão e complexidade. É fundamental destacar que todas as informações mencionadas anteriormente estão minuciosamente descritas e organizadas no dicionário de dados apresentado no Quadro 1.

Esse dicionário oferece uma visão completa dos atributos, incluindo suas descrições e tipos de dados e nas diferentes tabelas da base de dados. Ele desempenha um papel essencial como referência para a compreensão e exploração dos dados contidos na base.

**Quadro 1** – Dicionário de Dados

ATRIBUTO	DESCRIÇÃO	TIPO
Model	Modelo do veículo	Integer
Tesis	Código do defeito	String
Productionorder	Ordem de produção	Integer
Date	Instante de lançamento do defeito	datetime
Codcor	Código de cor	Integer
workplace	Identificação do posto de trabalho na planta	string
component	Componente em questão defeituoso	String
Anomaly	Indica a anomalia/defeito	String
Position	Posição da anomalia	String
Version	Versão do veículo	String
motorization	Tipo de motorização do veículo	String

**Fonte:** Os Autores.

Dentro desse dicionário de dados, é possível identificar diversos elementos que descrevem a natureza dos dados. Isso engloba informações que abrangem datas associadas, ordens de produção, tipologias de veículos, componentes inerentes, ocorrências de anomalias, coordenadas de posicionamento, iterações de versões, códigos de coloração e tipificações de motorização. Além disso, a utilização deste dicionário de dados oferece uma visão abrangente e estruturada das características dos dados, permitindo uma compreensão mais profunda dos atributos, possibilitando a extração de essenciais.

#### 3.2 PRÉ-PROCESSAMENTO DOS DADOS

No contexto da preparação dos dados para análise, um conjunto de passos foi implementado visando garantir a qualidade e a integridade da base de dados. Essa etapa crucial precedeu a análise descritiva e possibilitou uma exploração mais aprofundada de informações

Inicialmente, foi realizado um pré-processamento dos dados para garantir a qualidade e usabilidade da base de dados. Primeiramente, foi conduzida uma investigação relativa à possibilidade de duplicidade nos registros do conjunto de dados. Em seguida, foram excluídas colunas com muitos dados ausentes e/ou sem valor relevante. Após essa etapa, as linhas com valores ausentes foram removidas.

Visando preparar os dados para análises subsequentes. A abordagem adotada consistiu na conversão de todos os valores para o formato de *string*. Essa transformação permitiu uniformizar a estrutura dos dados, fazendo com que todos os valores tivessem o mesmo formato.

Na condução da análise exploratória, a atenção foi direcionada às colunas específicas do TESIS, Model e Anomalia. Com o intuito de compreender a distribuição de valores e padrões associados a esses atributos, foram adotados procedimentos específicos.

A convergência das estratégias de preparação e exploração dos dados resultou no aprofundamento e compreensão das características subjacentes dos atributos TESIS, Model e Anomalia, enriquecendo consideravelmente a interpretação do conjunto de dados em estudo.

Por fim, a abordagem adotada consistiu na conversão de colunas com dados em formato de texto para números inteiros, utilizando a técnica de codificação ordinal. Essas transformações permitem a representação numérica dos dados, facilitando análises estatísticas e algoritmos de aprendizado de máquina.


### 3.3 ANÁLISE DESCRITIVA DOS DADOS

Foi conduzida uma análise descritiva por meio da criação do mapa de calor de valores ausentes para a tabela, permitindo visualizar a distribuição e padrões de dados ausentes. Essa análise foi essencial para avaliar a integridade dos dados e tomar decisões sobre o tratamento de valores faltantes, garantindo a confiabilidade das análises subsequentes de um mapa de calor de correlação.

Em seguida, foi construída a matriz de correlação para avaliar as relações entre as variáveis, com a

visualização através de um mapa de calor de correlação apresentado na Figura 2. Essa abordagem revela padrões e interdependências entre as variáveis, permitindo uma exploração mais aprofundada das relações existentes. Facilitando assim a seleção de características relevantes e a obtenção de insights para investigações estatísticas e modelagens subsequentes.

Figura 2 – Matriz de Correlação



Fonte: Os Autores.

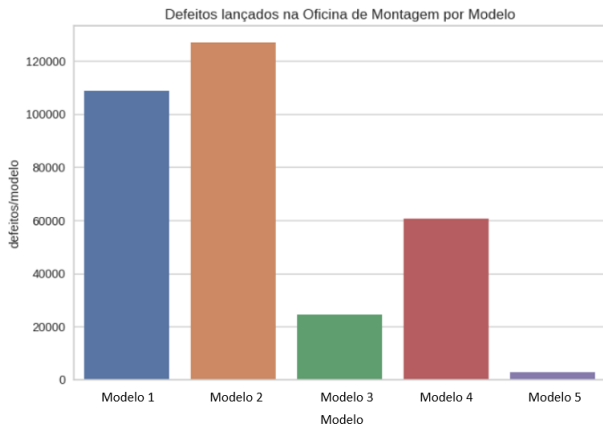
A representação visual da matriz de correlação por meio do mapa de calor ofereceu uma compreensão abrangente das relações entre as variáveis do conjunto de dados. Assim, foi possível a representação gráfica da distribuição de defeitos em relação a diferentes modelos de veículos. Com isso foi possível a identificação de padrões e incidências entre os modelos.

O gráfico a exposto na Figura 3 mostra a contagem de defeitos abertos para cada modelo específico de veículo. Nele é possível identificar quais modelos apresentam maior ou menor incidência de defeitos abertos.

Ao analisar o gráfico, os dados fornecem informações valiosas sobre a ocorrência de defeitos em cada modelo de veículo ao longo de um mês. Isso permite uma análise comparativa do desempenho e da confiabilidade dos diferentes modelos, em relação aos defeitos encontrados.

O modelo 2 apresentou uma quantidade maior de defeitos em comparação aos outros modelos. Isso ressalta a importância de uma análise detalhada dos dados para identificar variações significativas e possíveis áreas de melhoria específicas para cada modelo de veículo.

Figura 3 – Defeitos lançados na planta por Modelo



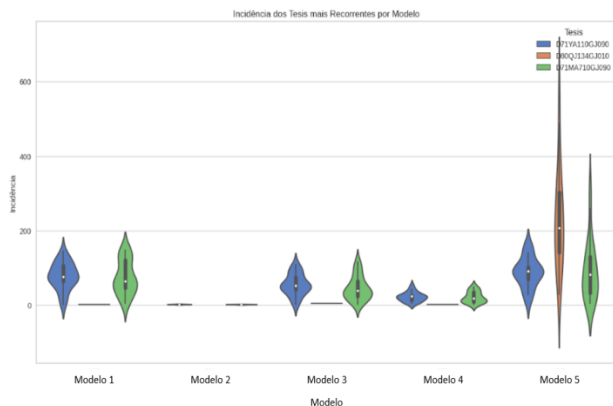
Fonte: Os Autores.

Em seguida, foi realizada uma análise de frequência específica no código TESIS. Com o intuito de obter uma visão preliminar das teses mais proeminentes nos dados e verificar as principais tendências e a representatividade dessa variável dentro do conjunto de dados considerado.

Nesse contexto, foi calculado o número de valores únicos existentes código dos defeitos. O resultado evidencia a presença de um total de 5201 TESIS únicas, ou seja, uma variedade significativa na base de dados.

Além disso, essa abordagem permitiu verificar a incidência das teses mais recorrentes em relação aos diferentes modelos. Ao observar as teses mais frequentes dentro de cada modelo, tornou-se possível identificar qual deles tem uma presença mais significativa em cada categoria, como podemos verificar na Figura 4.

Figura 4 – TESIS mais Recorrente por Modelo




Fonte: Os Autores.

Outra fase da análise foi direcionada a segmentar as informações relacionadas às características associadas a cada modelo em particular. Como por exemplo, verificar a ocorrência

de defeito por tipo de motor, para contagem de incidências como pode ser visualizado na Figura 5.

Figura 5 – Defeitos por Motorização



Fonte: Os Autores.

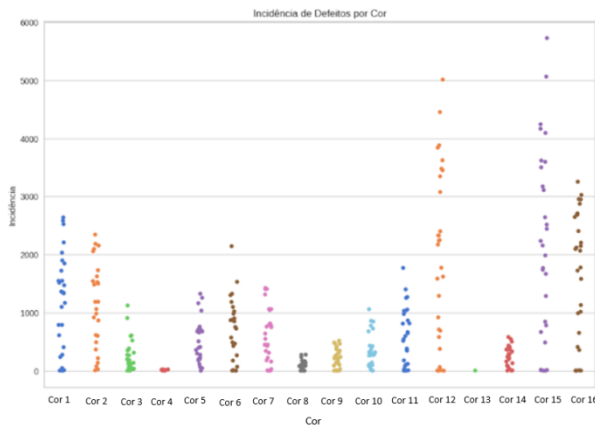
Com a visualização gráfica, é possível identificar a predominância dos componentes defeituosos mais recorrentes no modelo 5. Além disso, foi observado que o motor do tipo 2 apresenta uma incidência mais elevada, revelando uma associação relevante entre o tipo de motor e a frequência de defeitos.

Vale ressaltar, que foi feito uma análise da para identificar a distribuição das ocorrências com relação às diferentes localizações de trabalho para visualizar o panorama das áreas de trabalho com maior incidência dentro do conjunto de dados. Em que foi identificado 25 unidades mais frequentes.

Da mesma forma, uma abordagem análoga foi adotada para analisar a incidência de cores defeituosas. Através da visualização gráfica, foi possível identificar padrões notáveis na prevalência de cores defeituosas. Observou-se que determinadas cores apresentam uma incidência mais pronunciada do que outras, fornecendo insights valiosos sobre as tendências de defeitos em relação às diferentes cores empregadas. Como mostra a Figura 6.

Posteriormente, foi realizada a normalização dos dados, especialmente útil em algoritmos de aprendizado de máquina que são sensíveis às escalas das variáveis, pois ajuda a evitar que as variáveis com maiores valores dominem o processo de modelagem.

Figura 6 – Defeitos por Cor



Fonte: Os Autores.

### 3.4 METODOLOGIA EXPERIMENTAL

Inicialmente, a análise foi realizada com a aplicação do MLP *Regressor*, possibilitando uma exploração detalhada das capacidades intrínsecas desse modelo em relação às peculiaridades dos dados.

Em uma etapa subsequente, a investigação foi expandida para incorporar outros quatro modelos distintos para análise de series temporais: AR (*AutoRegressive*), ARIMA (*AutoRegressive Integrated Moving Average*), MLP (*Multilayer Perceptron*) e SVR (*Support Vector Regressor*).

A seleção de cada modelo foi com base em sua capacidade de lidar com características específicas dos dados e oferecer previsões precisas. Essa seleção foi guiada pela necessidade de explorar diferentes abordagens e estratégias de modelagem para avaliar sua eficácia na previsão da quantidade total de defeitos.

A abordagem sequencial adotada neste estudo possibilitou uma análise sistemática do desempenho dos modelos preditivos. Cada modelo foi submetido a avaliações criteriosas, considerando sua capacidade de generalização, ajuste aos dados e contribuição singular para a precisão preditiva. Realizaram-se testes específicos, fixando as quantidades de *lags* em 8 e 13. A divisão do conjunto de dados em treino (60%), validação (20%) e teste (20%) foi estratégica, proporcionando robustez no treinamento dos modelos, ajuste de hiperparâmetros e avaliação do desempenho em dados não observados.

A escolha da MAPE (Métrica de Erro Percentual Absoluto Médio) durante a fase de teste revelou-se fundamental, fornecendo uma medida interpretável do erro médio percentual entre as previsões dos modelos e os valores reais. Posteriormente, os

modelos foram submetidos a treinamento e testes, e os resultados foram meticulosamente analisados com base na MAPE. A discussão abordou a variação nas quantidades de *lags* e o desempenho diferenciado dos modelos, destacando a adaptabilidade singular de cada um às características específicas dos modelos de veículos analisados.

Os resultados obtidos revelaram insights valiosos sobre a eficácia de cada abordagem na previsão da quantidade total de defeitos. Abaixo, no Quadro 2 estão os MAPEs (Erro Percentual Absoluto Médio) para cada modelo e suas respectivas configurações de *lags*.

Quadro 2 – Desempenho dos modelos

MODELO	LAG = 8	LAG = 13
AR	0,518	0,566
ARIMA	0,864	0,864
MLP	0,361	0,441
SVR	0,472	0,289
MLPRegressor	0,202	

Fonte: Os Autores.

Os resultados apresentam a variação no desempenho dos modelos, destacando o MLPRegressor com um MAPE significativamente inferior. A análise desses resultados será discutida na próxima seção, fornecendo insights adicionais sobre características específicas dos modelos de veículos analisados.

## 4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

### 4.1 RESULTADOS

Os resultados obtidos foram integrados a um BI (*Business Intelligence*), proporcionando visualizações específicas dos defeitos com base no perfil do veículo. Este perfil compreende informações cruciais, incluindo modelo, versão, motorização, tipo de combustível, tração e caixa de marcha.

A visualização dos defeitos por perfil do veículo permitiu a identificação do veículo mais produzido com defeitos. Além disso, possibilitou comparações entre versões, destacando variações na incidência de defeitos e direcionando estratégias de melhoria.

Foi integrado ao BI o mapa de calor de versões, o qual possibilitou uma representação visual gráfica intuitiva da distribuição de defeitos. A análise

aprofundada por componente, anomalia e posição permitiu identificar os principais pontos de falha nos veículos. Essa abordagem detalhada viabiliza a implementação de ações corretivas direcionadas, otimizando os esforços de melhoria.

Por fim, a análise temporal incorporada no BI possibilitou a identificação de padrões sazonais ou eventos específicos, desempenhando um papel crucial na antecipação e prevenção de potenciais problemas.

## 4.2 DISCUSSÃO

Considerando a relevância dos resultados obtidos, é importante ressaltar que a aplicação eficiente da abordagem integrada de modelos preditivos e ferramentas de BI não apenas aprimora a gestão de qualidade na empresa em estudo, mas também fornece insights valiosos para o cenário mais amplo da indústria automotiva.

Além disso, a abordagem integrada não apenas otimiza a eficiência operacional e a satisfação do cliente na empresa em questão, mas também estabelece um precedente para a adoção de melhores práticas na indústria como um todo. A disseminação dessas abordagens pode contribuir para uma melhoria contínua nos processos de produção, qualidade e inovação em diferentes empresas automotivas.

Portanto, os resultados deste estudo não só têm implicações imediatas e diretas para a empresa analisada, mas também sugerem uma contribuição significativa para a indústria automotiva em termos de eficiência, qualidade e, por conseguinte, competitividade no mercado global.

## 5 CONCLUSÕES

Em síntese, esta pesquisa ofereceu uma visão abrangente e aprofundada sobre a análise de defeitos em veículos, concentrando-se na etapa de montagem da produção automotiva. A abordagem integrada de técnicas de análise de dados, inteligência artificial e ferramentas especializadas revelou-se fundamental na identificação de padrões, correlações e pontos críticos na produção automotiva.

A eficácia demonstrada pelos modelos preditivos, aliada à análise do *Business Intelligence Analytics*, sugere que a combinação de análise de dados e inteligência artificial pode ser um diferencial crucial para impulsionar a qualidade e eficiência na produção automotiva.

Por fim, este estudo não apenas contribui para a gestão de qualidade no setor automotivo, mas a disseminação dessas abordagens inovadoras pode catalisar melhorias contínuas nos processos de produção, elevando padrões de qualidade e inovação em diferentes empresas do setor.

## REFERÊNCIAS

- [1] ANGELOPOULOS, Angelos et al. Tackling faults in the industry 4.0 Era—A survey of machine-learning solutions and key aspects. **Sensors**, v. 20, n. 1, p. 109, 2019.
- [2] KANG, Ziqiu; CATAL, Cagatay; TEKINERDOGAN, Bedir. Machine learning applications in production lines: A systematic literature review. **Computers & Industrial Engineering**, v. 149, p. 106773, 2020.
- [3] AMARASINGHE Sanduni L et al. Opportunities and challenges in long-read sequencing data analysis. *Genome Biol.* 2020.
- [4] THEISSLER, Andreas et al. Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry. **Reliability engineering & system safety**, v. 215, p. 107864, 2021.
- [5] SAJID, Sufiyan. et al. Data science applications for predictive maintenance and materials science in context to Industry 4.0. *Materials Today: Proceedings*, v. 45, n. 6, p. 4898-4905, 2021.
- [6] WANG, Qiyue et al. A tutorial on deep learning-based data analytics in manufacturing through a welding case study, *Journal of Manufacturing Processes*, v. 63, p. 2-13, 2021.
- [7] SHAHBAZI, Zeinab; BYUN, Yungcheol. Smart Manufacturing Real-Time Analysis Based on Blockchain and Machine Learning Approaches. *Applied Sciences*, v. 11, n 8, 2021.
- [8] SHAHBAZI, Zeinab; BYUN, Yung-Cheol. Integration of blockchain, IoT and machine learning for multistage quality control and enhancing security in smart manufacturing. **Sensors**, v. 21, n. 4, p. 1467, 2021.
- [9] SARIYER, Gorkem. et al. Data analytics for quality management in Industry 4.0 from a MSME perspective. *Annals of Operations Research*, 2021.



- [10] WANG, Junliang et al. Big data analytics for intelligent manufacturing systems: A review. *Journal of Manufacturing Systems*, v. 62, p. 738-752, 2022.
- [11] JANARTHANAM, K. et al. Electrical faults-detection and classification using machine learning. In: **2022 International Conference on Electronics and Renewable Systems (ICEARS)**. IEEE, 2022. p. 1289-1295.
- [12] FERNANDES, Marta; CORCHADO, Juan Manuel; MARREIROS, Gustavo. Machine learning techniques applied to mechanical fault diagnosis and fault prognosis in the contexto of real industrial manufacturing use-cases: a systematic literature review. **Applied Intelligence (Dordrecht, Netherlands)**, v. 52, n. 52, p. 14246-14280, 2022.
- [13] FU, Yanzhou et al. Machine learning algorithms for defect detection in metal laser-based additive manufacturing: A review. **Journal of Manufacturing Processes**, v. 75, p. 693-710, 2022.
- [14] TAN, Jinbiao et al. Automobile Component Recognition Based on Deep Learning Network with Coarse-Fine-Grained Feature Fusion. **International Journal of Intelligent Systems**, v. 2023, 2023.