

UNIVERSIDADE FEDERAL DO PARANÁ

RICARDO DE MORAES SEIXAS

ESTRATÉGIAS DE MANUTENÇÃO DE EQUIPAMENTOS ATRAVÉS DA ANÁLISE
DOS DADOS DE OPERAÇÃO

CURITIBA
2022

RICARDO DE MORAES SEIXAS

ESTRATÉGIAS DE MANUTENÇÃO DE EQUIPAMENTOS ATRAVÉS DA
ANÁLISE DOS DADOS DE OPERAÇÃO

Dissertação apresentada como requisito parcial à
obtenção do título de Mestre, do programa de Pós-
Graduação em Engenharia de Manufatura, Setor de
Tecnologia da Universidade Federal do Paraná.

Orientador: Prof. Dr. Christian Strobel
Coorientador: Prof. Dr. Fernando Deschamps

CURITIBA
2022

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA CIÊNCIA E TECNOLOGIA

Seixas, Ricardo de Moraes.

Estratégias de manutenção de equipamentos através da análise dos dados de operação. / Ricardo de Moraes Seixas. – Curitiba, 2022.

1 recurso on-line : PDF.

Dissertação (Mestrado) – Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Manufatura.

Orientador: Prof. Dr. Christian Strobel.

Coorientador: Prof. Dr. Fernando Deschamps.

1. Engenharia. 2. Estratégia de manutenção. 3. Análise de dados. 4. Indústria 4.0. I. Strobel, Christian. II. Deschamps, Fernando. III. Universidade Federal do Paraná. Programa de Pós-Graduação em Engenharia Manufatura. IV. Título.

Bibliotecário: Nilson Carlos Vieira Júnior CRB-9/1797



MINISTÉRIO DA EDUCAÇÃO
SETOR DE TECNOLOGIA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA DE
MANUFATURA - 40001016171P2

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA DE MANUFATURA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **RICARDO DE MORAES SEIXAS** intitulada: **ESTRATÉGIAS DE MANUTENÇÃO DE EQUIPAMENTOS ATRAVÉS DA ANÁLISE DOS DADOS DE OPERAÇÃO**, sob orientação do Prof. Dr. CHRISTIAN SCAPULATEMPO STROBEL, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 26 de Agosto de 2022.

Assinatura Eletrônica

27/09/2022 09:25:16.0

CHRISTIAN SCAPULATEMPO STROBEL

Presidente da Banca Examinadora

Assinatura Eletrônica

13/10/2022 23:47:06.0

MARIANO PACHOLOK

Avaliador Externo (PETRÓLEO S.A.)

Assinatura Eletrônica

27/09/2022 10:16:38.0

MARCIO FONTANA CATAPAN

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

27/09/2022 09:19:51.0

PABLO DEIVID VALLE

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

11/10/2022 12:08:06.0

FERNANDO DESCHAMPS

Coorientador(a) (UNIVERSIDADE FEDERAL DO PARANÁ)

Avenida Coronel Francisco Heráclito dos Santos, 100 - Curitiba - Paraná - Brasil

CEP 81531-980 - Tel: (41) 3361-3123 - E-mail: ufprppgem@gmail.com

Documento assinado eletronicamente de acordo com o disposto na legislação federal Decreto 8539 de 08 de outubro de 2015.

Gerado e autenticado pelo SIGA-UFPR, com a seguinte identificação única: 225229

Para autenticar este documento/assinatura, acesse <https://www.prppg.ufpr.br/siga/visitante/autenticacaoassinaturas.jsp>
e insira o código 225229

Dedico este trabalho primeiramente a Deus;
aos mestres e mentores pelos ensinamentos e dedicação;
aos colegas e amigos pela caminhada em conjunto;
e a família e amigos pelo suporte e incentivo em todos os momentos,
principalmente a minha esposa Danielli e nossos filhos maravilhosos, Leticia e
Leonardo, que são uma fonte de inspiração e coragem.

“Nada do que resiste ao tempo é permanente, mas, sim, tudo o que se altera prudentemente com ele”.

(Autor Desconhecido)

RESUMO

No setor de veículos comerciais pesados, a disponibilidade da frota é um fator importante e que impacta na produtividade e competitividade das empresas. Apesar disto, o elemento central das estratégias de manutenção aplicadas no setor ainda é baseado somente na quilometragem percorrida ou tempo de uso dos componentes. Por outro lado, a evolução da indústria, em particular o avanço das tecnologias habilitadoras da indústria 4.0 como a sensorização presente nos componentes, disponibiliza hoje um grande volume de dados operacionais. Os níveis de severidade da aplicação, influência do estilo de condução e condições da operação dos veículos podem ser indicados pelo tratamento destes dados. No entanto, ainda se nota pouca aplicação prática do uso desses dados para a tomada de decisão efetiva quanto à estratégia de manutenção no setor, correlacionando o nível de severidade com a possibilidade de falha de componentes. Buscando uma abordagem disruptiva para este cenário onde a análise de dados suporte decisões relacionadas à estratégia de manutenção de componentes, foi realizada revisão de literatura, para entender como aspectos da indústria 4.0 e da análise de dados podem influenciar nas estratégias de manutenção. Como resultado desta revisão é proposta uma metodologia para aplicação da análise de dados estruturada sobre um robusto pilar estatístico. Um estudo de caso da aplicação desta metodologia é apresentado, com a análise de dados operacionais de um determinado componente instalado em uma frota de veículos comerciais pesados. Por meio da aplicação de técnicas estatísticas correlaciona-se uma variável que represente o desgaste dos componentes com variáveis que descrevam a severidade da aplicação demonstrando-se que o aprimoramento das estratégias de manutenção com base na análise de dados é possível e que a maior assertividade nos critérios de manutenção dos componentes pode elevar sua vida útil em cerca de 10%.

Palavras-chave: manutenção preventiva; indústria 4.0; análise de dados; servitização.

ABSTRACT

In the heavy commercial vehicle sector, the availability of the fleet is an important factor that impacts the productivity and competitiveness of companies. Despite this, the central element of the maintenance strategies applied in the sector is still based only on total mileage or time of use of the components. On the other hand, the evolution of the industry, in particular the advancement of enabling technologies of Industry 4.0 such as the sensorization present in the components, today makes available a large volume of operational data. The different application's severity levels, driving style influence and vehicle operating conditions can be indicated by the treatment of this data. However, there is still no practical application of the use of these data for effective decision making regarding the maintenance strategy in the sector, correlating the level of severity with the possibility of component failure. Seeking a disruptive approach to this scenario where data analysis supports decisions related to the component maintenance strategy, a literature review was carried out to understand how aspects of industry 4.0 and data analysis can influence maintenance strategies. As a result of this review, a methodology is proposed for the application of structured data analysis on a robust statistical pillar. A case study of the application of this methodology is presented, with the analysis of operational data of a certain component installed in a fleet of heavy commercial vehicles. Through the application of statistical techniques, a variable that represents the wear of the components is correlated with variables that describe the severity of the application, demonstrating that the improvement of maintenance strategies based on data analysis is possible and that higher assertiveness in the component maintenance criteria can increase their useful life by about 10%.

Key-words: Preventive maintenance; industry 4.0; data analytics; servitization.

LISTA DE ILUSTRAÇÕES

Figura 1 - Representação da curva de banheira na manutenção.....	13
Figura 2 - Eixos de pesquisa e palavras chave	17
Figura 3 - Termos com maior número de citações	18
Figura 4 - Evolução e interconexão das palavras ao longo do tempo	20
Figura 5 - Classificação dos principais conceitos	26
Figura 6 - Estratégias de manutenção - CORRETIVA	28
Figura 7 - Estratégias de manutenção - PREVENTIVA.....	29
Figura 8 - Estratégias de manutenção - PREDITIVA	30
Figura 9 - Estrutura conceitual para análise sistemática de dados	33
Figura 10 – Metodologia para seleção de variáveis e análise de dados	36
Figura 11 - Planejamento de etapas para análise de dados	38
Figura 12 – Distribuição da quilometragem na amostra de dados	40
Figura 13 - Representação manutenção preventiva convencional.....	41
Figura 14 - Representação manutenção baseada no nível de severidade	43
Figura 15 – Classificação das variáveis disponíveis	44
Figura 16 – Método Pearson para correlação das variáveis com o Índice D	45
Figura 17 – Variáveis selecionadas para o modelo de regressão 1	46
Figura 18 - Gráficos de resíduos Índice D para o modelo de regressão 1	47
Figura 19 – Variáveis selecionadas para o modelo de regressão 2	50
Figura 20 - Gráficos de resíduos Índice D para o modelo de regressão 2	51
Figura 21 – Efeito fatorial das variáveis com relação ao índice de desgaste modelo 2	52
Figura 22 – Variáveis selecionadas para o modelo de regressão 3	54
Figura 23 - Gráficos de resíduos Índice D para o modelo de regressão 3	55
Figura 24 – Efeito fatorial das variáveis com relação ao índice de desgaste modelo 3	56
Figura 25 – Reordenamento manutenção preventiva com fator severidade	58

LISTA DE TABELAS

Tabela 1 – Sumário do modelo de regressão 1.....	47
Tabela 2 – Avaliação variáveis com p de Pearson $> [0,4]$	48
Tabela 3 – Sumário do modelo de regressão 2.....	50
Tabela 4 – Análise de variância das variáveis.....	52
Tabela 5 – Sumário do modelo de regressão 3.....	53
Tabela 6 – Análise de variância das variáveis.....	55
Tabela 7 – Níveis de severidade de acordo com índice de desgaste calculado	57

SUMÁRIO

1	INTRODUÇÃO	12
1.1	FORMULAÇÃO DO PROBLEMA	14
1.2	OBJETIVO GERAL	14
1.2.1	Objetivos específicos	14
1.3	PRODUTO TECNOLÓGICO	14
1.4	CONTRIBUIÇÕES DO TRABALHO	15
2	REVISÃO BIBLIOGRÁFICA	16
2.1	METODOLOGIA DE PESQUISA	16
2.2	REVISÃO DA LITERATURA	19
2.2.1	Visão geral da Indústria 4.0	19
2.2.2	Conectividade e geração de dados por IoT	20
2.2.3	Manutenção preditiva e indústria 4.0	21
2.2.4	Internet of things in the industry (IIoT)	23
2.2.5	Conceito de análise de dados	23
2.2.6	Data Generation	24
2.2.7	Análise sistemática de dados aplicada a estratégia de manutenção de equipamentos	26
2.2.8	Estrutura para análise sistemática	31
3	METODOLOGIA	32
3.1	ESTRUTURA CONCEITUAL PARA ANÁLISE SISTEMÁTICA DE DADOS	32
3.2	METODOLOGIA PARA SELEÇÃO DE VARIÁVEIS E ANÁLISE DE DADOS	35
3.2.1	Seleção de variáveis para o modelo	36
3.2.2	Regressão estatística	36
4	ESTUDO DE CASO	38
4.1	ABORDAGEM METODOLÓGICA	38
4.2	BASE INSTALADA DE COMPONENTES	39
4.3	REPRESENTAÇÃO DA ESTRATÉGIA DE MANUTENÇÃO PREVENTIVA CONVENCIONAL	40
4.4	REPRESENTAÇÃO DA ESTRATÉGIA DE MANUTENÇÃO PREVENTIVA COM BASE NA SEVERIDADE	42
4.5	SELEÇÃO DE VARIÁVEIS	42

4.5.1	Análise e classificação das variáveis	42
4.5.2	Correlação entre as variáveis e o índice de desgaste	44
4.6	ANÁLISE DE DADOS ATRAVÉS DE REGRESSÃO	45
4.6.1	Estudo de regressão 1:	45
4.6.2	Estudo de regressão 2:	48
4.6.3	Estudo de regressão 3:	54
4.6.4	Nível de severidade através do modelo de regressão	56
5	CONCLUSÃO	59
5.1	RECOMENDAÇÕES PARA TRABALHOS FUTUROS	59
	REFERÊNCIAS BLIOGRÁFICAS	61
	APÊNDICE 1 – LISTA DE ARTIGOS PESQUISADOS NA REVISÃO	66

1 INTRODUÇÃO

Como em outros setores da indústria no setor de transportes especificamente no segmento de veículos comerciais pesados a disponibilidade dos veículos para operação (Viana, PCM, Planejamento e Controle da Manutenção, 2014) é um fator importantíssimo visando-se a maximização da produção que neste caso é o transporte de cargas ou passageiros.

Esta disponibilidade é diretamente afetada pela estratégia de manutenção adotada com relação aos componentes. Manutenções não programadas ocorrem devido à quebra comprometendo a disponibilidade geral do veículo devido ao tempo de reparo envolvido como também do custo do reparo em si. Já as manutenções programadas ou preventivas minimizam estes fatores, porém podem acarretar em diminuição de vida útil do componente já que o reparo é antecipado para se mitigar o risco de quebra.

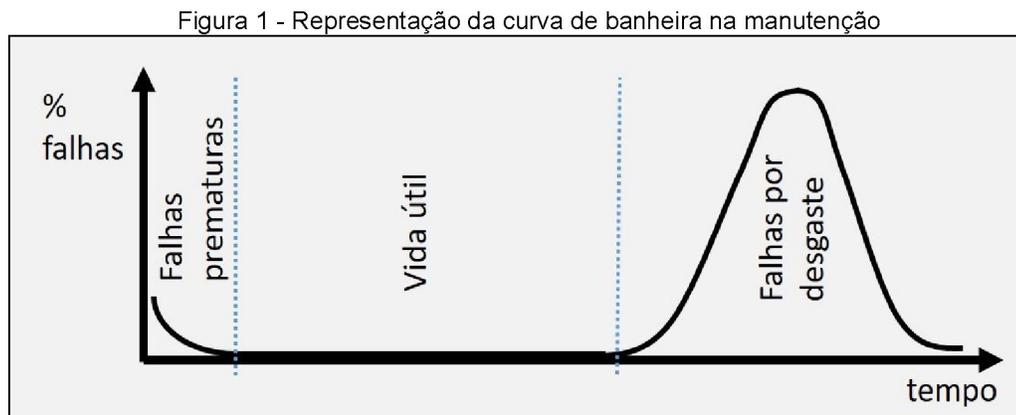
Dentro deste contexto os principais fatores para definição da estratégia de manutenção de veículos e componentes são a disponibilidade da frota (influenciada pela quantidade de veículos de reserva e pelas manutenções não programadas de componentes) e o custo de reparo dos componentes (corretivo ou preventivo). Tendo como objetivo o aumento da disponibilidade da frota e a redução do custo de reparo a estratégia de manutenção a ser adotada para veículos e componentes é um fator competitivo importante no setor (MOBLEY, 2014).

Apesar desta relevância grande parte das empresas do setor adotam manutenção corretiva (Teles, 2019) ou manutenção preventiva de componentes com base em dados históricos de falhas. Esta base de dados históricos de falhas pode ser descrita de maneira genérica através da curva de banheira apresentada na Figura 1.

Nesta representação (Ebeling, 2019, 2010, 1997) apresenta-se a distribuição de falhas de uma base instalada de um certo componente (eixo vertical) ao longo de sua vida útil que pode ser indicada por unidade de tempo ou de quilometragem percorrida (eixo horizontal).

No período inicial de operação do componente ocorrem falhas de maneira prematura normalmente não relacionadas a severidade da aplicação, mas sim ligadas a defeitos pontuais dos componentes (falhas de material de produção etc). Após este breve período de falhas pontuais temos o período caracterizado como vida útil do componente onde as falhas acontecem de maneira aleatória e constante, porém em

nível muito baixo. Por fim os componentes entram no período denominado de falhas por desgaste influenciado diretamente pela severidade das condições de uso. A distribuição de falhas aumenta devido ao do desgaste dos componentes e a probabilidade de falha torna-se cada vez maior com o passar do tempo.



Fonte: Adaptado de Ebeling (1997)

Ao adotarem este modelo como base da estratégia de manutenção preventiva as empresas determinam como objetivo fazer a manutenção dos componentes antes da entrada no período de falhas por desgaste. De maneira bastante generalista o modelo atende a necessidade de se controlar o risco das falhas não programadas antecipando-se o reparo para antes do componente entrar na área indicada como falhas por desgaste.

Por outro lado, a real condição de cada componente desta base instalada pode se comportar de maneira diferente a esta distribuição histórica. Com isto a adoção deste modelo genérico acarreta na perda de parte da vida útil que os componentes ainda poderiam operar ao se considerar que todos terão o mesmo comportamento de desgaste e probabilidade de falhar ou no risco de que o componente falhe mesmo antes da entrada na área de maior probabilidade de falha.

O grande problema da abordagem através da curva de banheira para determinar uma estratégia de manutenção é que só se considera o fator tempo de uso ou quilometragem percorrida para se correlacionar com a falha do componente. E na verdade existem diversos outros fatores na operação dos veículos e componentes que influenciam seu desgaste durante sua vida útil.

Estes outros fatores de influência para o desgaste de maneira subjetiva poderiam ser descritos por exemplo através do tamanho do veículo ou da carga transportada pelo mesmo da velocidade média de operação dos ciclos de arrancada e parada devido as condições de operação etc. Por outro lado, graças a indústria 4.0 veículos e seus componentes possuem cada vez mais sensorização como base para seu funcionamento. Tecnologias habilitadoras como IoT permitem que se tenha acesso a uma quantidade de dados cada vez maior com relação ao funcionamento destes componentes fazendo com que o nível de severidade a que estão expostos possa ser quantificado de maneira objetiva.

1.1 FORMULAÇÃO DO PROBLEMA

Tendo em vista o setor de veículos comerciais pesados e a relevância das estratégias de manutenção em termos de fator competitivo formulou-se o seguinte problema: aumentar a disponibilidade/vida útil dos componentes através do entendimento da influência da severidade no desgaste.

1.2 OBJETIVO GERAL

Analisar a aplicabilidade da análise de dados de operação de componentes para o refinamento das estratégias de manutenção ou até mesmo da servitização de produtos.

1.2.1 Objetivos específicos

- Desenvolver metodologia para análise de dados com abordagem incremental;
- Estabelecer procedimento para a seleção e tratamento variáveis de uma base de dados;
- Estudo de caso aplicando a metodologia desenvolvida e o procedimento de seleção e tratamento de variáveis.

1.3 PRODUTO TECNOLÓGICO

O produto tecnológico deste trabalho será o desenvolvimento de uma metodologia replicável que permita analisar dados de operação de um componente

com objetivo de estabelecer a relação entre a severidade da aplicação no desgaste do componente gerando informações para o refinamento de estratégias de manutenção de maneira replicável.

1.4 CONTRIBUIÇÕES DO TRABALHO

A relevância do tema pesquisado consiste em explorar o potencial relacionado a análise de dados de operação para influenciar de maneira positiva a assertividade das estratégias de manutenção em componentes de veículos comerciais pesados. Esta maior assertividade se traduz em maior disponibilidade dos equipamentos para operação. Além disto com maior confiabilidade existe impacto positivo nos operadores e usuários do setor e até mesmo no meio ambiente com a redução do uso de matérias primas.

Esta pesquisa também busca inspirar o desenvolvimento de novos modelos de negócios tendo como centro não o componente em si mas sim possibilidades avançadas de serviço baseadas no monitoramento dos componentes explorando a servitização dos produtos (Qvist-Sorensen 2020) ou produto como serviço.

2 REVISÃO BIBLIOGRÁFICA

Objetivando o estabelecimento de portfólio bibliográfico como base para esta pesquisa buscou-se na literatura artigos onde houvesse convergência de 3 eixos principais: indústria 4.0, análise de dados e manutenção preditiva. Além destes eixos estabeleceu-se também um conjunto de palavras-chaves que garantissem a aderência do resultado de busca com o contexto onde a indústria 4.0 e suas tecnologias habilitadoras em conjunto com as técnicas de análise de dados são a fundação das técnicas de análise preditiva.

Na revisão bibliográfica descreve-se detalhadamente o método de pesquisa utilizado como também os principais resultados da pesquisa na revisão da literatura.

2.1 METODOLOGIA DE PESQUISA

A metodologia de pesquisa como também a base da revisão da literatura foi desenvolvida em conjunto com outros autores para o artigo publicado em evento da INCOM de 2021 (Lisboa, et al., 2021).

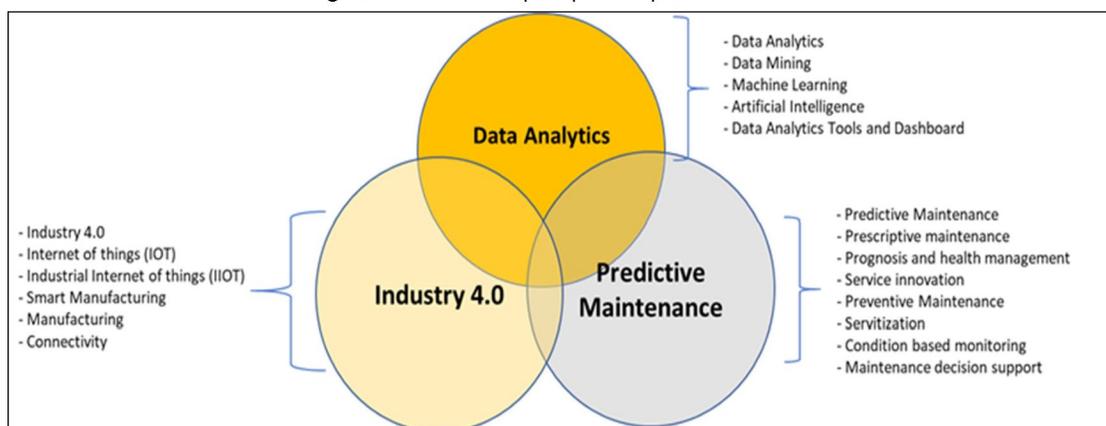
Considerando o avanço sistemático e dinâmico das tecnologias e desde a criação do conceito de *industry 4.0* (Zhe, Yi, & Ke-Sheng, 2017) do conceito de *data analytics* e da evolução das estratégias de manutenção (Zhang, Wang, & Yang, 2019) definiu-se estes termos como eixos centrais da pesquisa acadêmica (*INDUSTRY 4.0; DATA ANALYTICS; PREDICTIVE MAINTENANCE*).

Realizando-se a busca nas fontes de base acadêmicas (Web of Science e Scopus) dos termos de maneira isolada o termo: “Industry 4.0” resultou em 2.753 e 6.238 artigos respectivamente em cada base o termo “Data Analytics” resultou em 5.007 e 16.248 artigos e o termo “Predictive Maintenance” resultou em 1.094 e 7.378 artigos. Explorar os 3 eixos de maneira isolada não seria possível devido a grande quantidade de artigos disponíveis. Buscou-se então direcionar a pesquisa através da combinação dos 3 eixos e além disto incluir palavras-chaves conforme indicado na Figura 2 com a finalidade de garantir a aderência dos artigos pesquisados ao tema central de maneira que os artigos não mencionassem somente um aspecto ou outro mas sim as 3 abordagens em conjunto. Realizou-se a busca combinando os 3 termos

e o resultado da pesquisa obtido limitou-se a 51 e 72 artigos nas bases Web of Science e Scopus respectivamente.

Aplicou-se uma análise bibliométrica nesta base de resultados fazendo uso do software Vos-Viewer para verificar de maneira geral a aderência obtida com a seleção dos eixos e palavras-chaves. Como resultado os termos mais citados nesta base de artigos foram *maintenance framework lot e industry* demonstrando ótimo alinhamento com nossa linha de pesquisa central (Figura 3Figura 3).

Figura 2 - Eixos de pesquisa e palavras chave



Fonte: (Lisboa, et al., 2021)

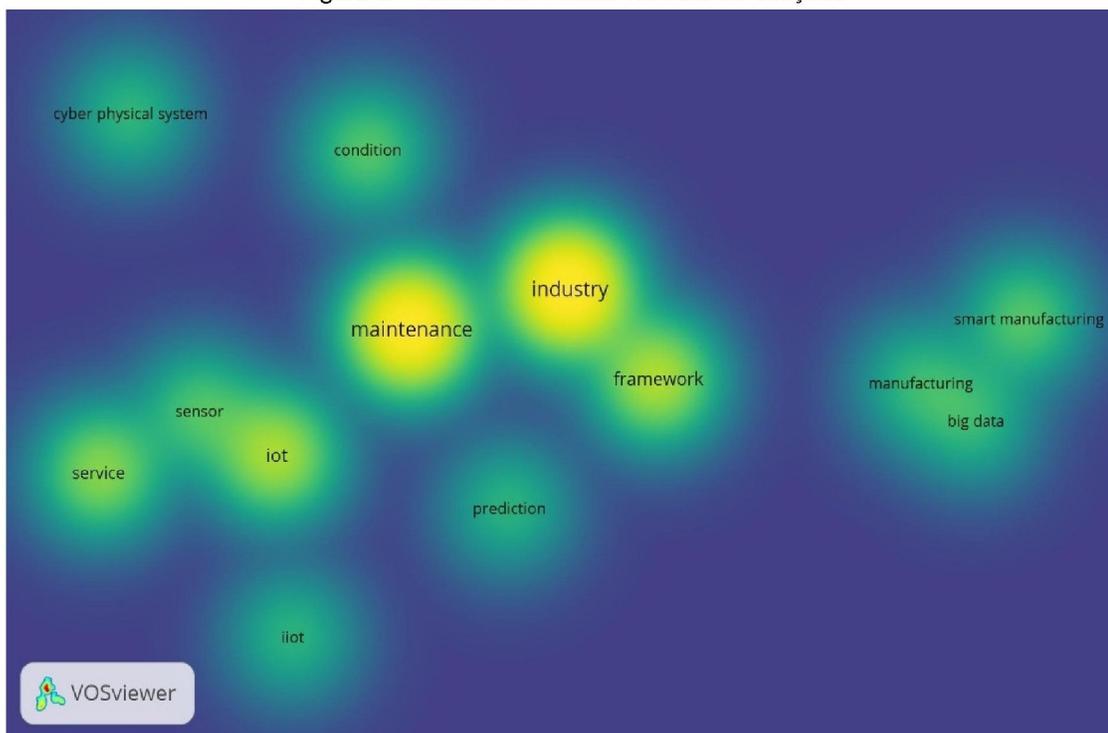
Ainda fazendo uso do software Vos Viewer na Figura 4 podem-se ver a evolução dos termos mais citados nesta seleção de artigos em uma linha do tempo estabelecida com a data de publicação dos mesmos. Nota-se que os termos *CPS (Cyber Physical System) Manufacturing e sensor* foram mais citados nos artigos no ano de 2018 e se conectam aos termos *framework IOT e service* citados no início de 2019. Estes por fim se conectam aos termos *predictive e IIOT* citados no final de 2019. A linha do tempo é bastante curta nesta análise, mas a interconexão entre os termos é bastante relevante e indica o processo de surgimento e desenvolvimento das tecnologias habilitadoras suportadas pela análise sistemática de dados como base da prática de manutenção preditiva como estratégia de manutenção.

Objetivando uma análise aprofundada desta base inicial de artigos e garantir uma abordagem mais precisa com relação aos eixos de pesquisa para elaboração desta revisão como também evitar que reflexões pessoais e/ou qualquer tipo de

intuição influenciasse o filtro de seleção da base final de artigos utilizou-se a metodologia de seleção do referencial bibliográfico PROKNOW-C (*Knowledge Development Process – Constructivist*) desenvolvido pelo Laboratório de Metodologias Multicritério em Apoio à Decisão – LabMCDA que consiste em uma série de etapas sequenciais e essenciais que se iniciam na definição do mecanismo de busca de artigos científicos a ser utilizado seguindo por uma série de etapas até um filtro final definindo a seleção do portfólio bibliográfico relevante sobre o tema que se deseja obter entendimento.

Como execução da primeira etapa deste método excluiu-se os artigos repetidos reduzindo a base de 123 artigos (51 Web of Science e 72 Scopus) para 85 artigos. Em um segundo passo do método realizou-se uma análise objetiva de conteúdo classificação dos artigos de acordo com seu nível de aderência com o objetivo da pesquisa. Os artigos foram classificados através de critérios objetivos como número de citações contagem de palavras-chave encontradas nos tópicos: título resumo introdução e conclusão além da leitura detalhada destes tópicos visando classificar a aderência geral ao tema central pesquisado.

Figura 3 - Termos com maior número de citações



Fonte: (Lisboa, et al., 2021)

Desta forma tendo como base a abordagem objetiva de análise do método Proknow-C chegou-se a uma seleção de 29 artigos (este portfólio encontra-se listado no apêndice 1). Os artigos representam o maior nível de aderência ao tema central pesquisado compondo o portfólio bibliográfico base deste estudo.

2.2 REVISÃO DA LITERATURA

Na revisão da literatura apresentam-se os principais resultados da pesquisa como base para a metodologia que será desenvolvida a seguir.

2.2.1 Visão geral da Indústria 4.0

A indústria 4.0 compreende o desenvolvimento e integração das tecnologias de informação e comunicação em processos de negócios (Dalenogare, Benitez, Ayala, & Frank, 2018); (Wagire, Rathore, & Jain, 2019) e ainda está se desenvolvendo.

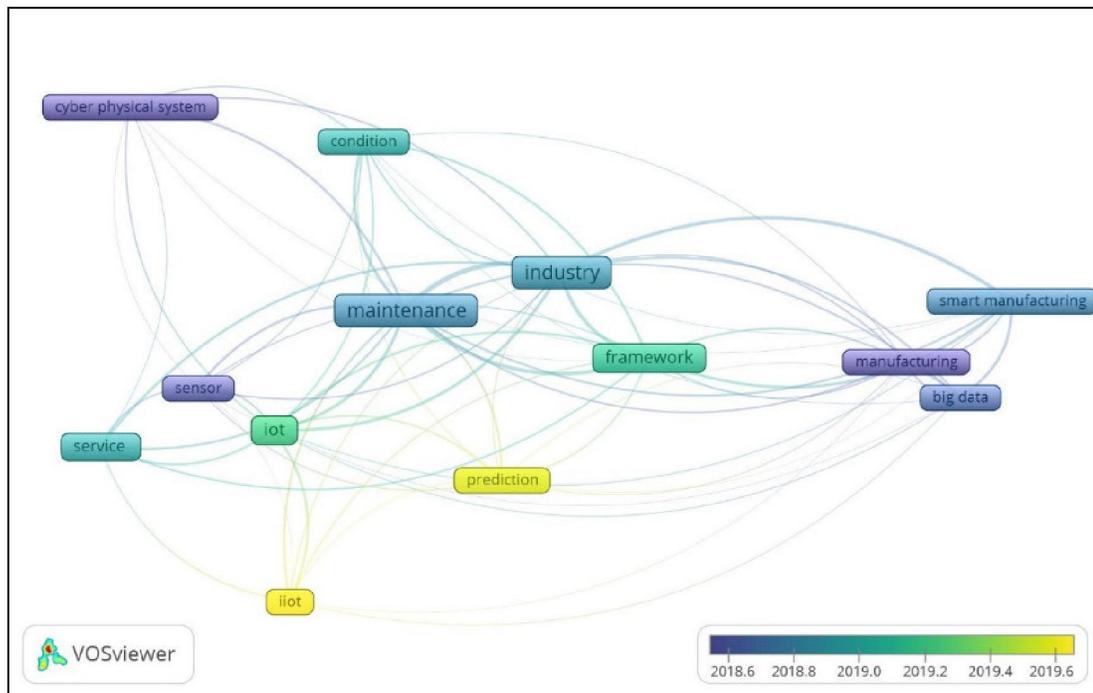
O termo Indústria 4.0 é uma denominação para a quarta revolução industrial que está em andamento nos dias atuais. Observando as três revoluções vemos que a primeira revolução industrial que ocorreu no final do século XVII foi impulsionada pela evolução dos motores a vapor da energia da água e da mecanização como um todo já a segunda revolução industrial foi impulsionada pelas linhas de montagem pioneiras por Henry Ford que oficializou pela primeira vez a produção em massa há quase um século. A terceira revolução industrial ocorrida na década de 1970 foi impulsionada pelo uso de computador e automação nos processos de fabricação.

Na última década a indústria manufatureira vem evoluindo e concretizando o conceito de Indústria 4.0 (Zhe, Yi, & Ke-Sheng, 2017) proposto pela Alemanha para modernizar a tecnologia da sua manufatura e desenvolver fábricas inteligentes para maior competitividade e flexibilidade.

A partir deste momento as indústrias de todo o mundo partiram para uma corrida sem saber a que distância exata estavam da linha de chegada ou se existe linha de chegada. Grandes indústrias mundiais desenvolveram programas de implementação de Indústria 4.0 muitas delas sem saber o que realmente estavam buscando e o que deveria ser feito (Wagire, Rathore, & Jain, 2019) com o avanço expressivo da chamada Internet das Coisas (IoT) (XU HE e LI 2014) ou o equivalente

na indústria chamado de Industrial Internet das Coisas (IIoT) (Qvist-Sorensen, 2020) em que a conexão com as máquinas é um conceito que a General Electric define como "... a rede de uma infinidade de dispositivos conectados por tecnologias de comunicação que resulta em sistemas que podem monitorar coletar trocar analisar e fornecer valiosas novas informações como nunca antes".

Figura 4 - Evolução e interconexão das palavras ao longo do tempo



Fonte: (Lisboa, et al., 2021)

2.2.2 Conectividade e geração de dados por IoT

Em busca de competitividade redução de custos aumento da produtividade e eficiência em suas instalações os diversos setores da indústria estão continuamente em busca de soluções para alcançar seus objetivos. Com o aumento considerável da aplicação de máquinas dotadas de comando numérico computadorizado (CNC) e Controladores Lógicos Programáveis (CLP) principalmente nos setores automotivo aeroespacial de moldes e outras indústrias (ZHE YI e KE-SHENG 2017) em substituição às máquinas convencionais nas últimas décadas foi tirado da mão do operador decisões de rotina com foco nos comandos de operação e

consequentemente houve melhoria da repetitividade e da produtividade. Já por outro lado houve um aumento da complexidade da mecânica e da eletrônica dessas máquinas. Este mesmo efeito ocorreu do ponto de vista de desenvolvimento de produtos e equipamentos cada vez mais o funcionamento baseado em comandos eletrônicos e sensorização.

Do ponto de vista das características das peças fabricadas também houve um aumento da demanda por peças de melhor qualidade fazendo com que cada vez mais os equipamentos tenham que corresponder à altura com as exigências por qualidade produtividade e baixo custo de operação.

Para que todas as demandas dos clientes sejam atendidas a indústria busca produzir continuamente produtos de alta qualidade menor preço e em último nível produtos personalizados. A personalização está embutida cada vez mais nos produtos buscando a individualização dos clientes (Aheleroff, et al., 2020). Uma revolução denominada Manufatura Inteligente mostra crescimento na indústria e exige mudanças na forma de obter gerenciar e processar as informações geradas no processo produtivo para que se possa tirar proveitos traduzidos em ações de melhoria contínua nos processos em que os dados foram coletados.

2.2.3 Manutenção preditiva e indústria 4.0

Na indústria 3.0 a abordagem da manutenção foi e ainda tem sido a manutenção preventiva buscando evitar falhas que se traduzam em paradas e garantir a disponibilidade. No entanto esse tipo de manutenção é baseado em eventos do passado que na maioria das vezes se traduzem numa parada inesperada causando uma manutenção corretiva. De acordo com os autores (Calabrese, et al., 2020) a manutenção preventiva pode trazer benefícios desde que seu planejamento seja impecável. Esse tipo de manutenção é geralmente realizada separadamente para cada componente com base em seu uso e/ou em programação fixa. Por outro lado, esta técnica de manutenção sempre trará certa perda produtiva pela antecipação da manutenção quando ainda existe vida útil disponível no equipamento. Os autores (Calabrese, et al., 2020) indicam que esta perda deve estar entre 5 e 20%.

Já a manutenção preditiva (PdM) presente como uma tecnologia da Indústria 4.0 está um passo à frente da manutenção preventiva pois se baseia no monitoramento por condição (CBM). Aproveitamento da vida útil do equipamento é maximizada pois se baseia em análises estatísticas de dados coletados por sensores para determinar o tempo de vida útil restante do equipamento. Apesar de tantos estudos mostrarem e evidenciarem os benefícios da manutenção preditiva frente aos principais objetivos das empresas (redução de custo e aumento da produtividade e confiabilidade) esta estratégia de manutenção ainda não tem sido utilizada de maneira ampla. Mesmo com toda a sensorização já presente em equipamentos e a geração cada vez maior de dados com relação a operação dos mesmos. Seria possível coletar dados da condição dos equipamentos históricos ou em tempo real através de IoT e de tecnologias de IT disponíveis. Toda essa massa de dados gerando informações e conhecimento com relação a operação dos equipamentos seria de extremo valor com aplicação em diversos aspectos em um primeiro nível trazendo conhecimento para o operador dos equipamentos, mas também abrindo a possibilidade de que o fabricante do equipamento pudesse com base nestes dados melhorar desde o processo de fabricação até mesmo do desenvolvimento dos produtos adequando produtos e equipamentos de maneira mais precisa a realidade de seu uso. Existiria até mesmo espaço para uma parceria cliente-fornecedor numa relação de mútua colaboração de longo prazo traduzindo-se em benefícios para ambos pela troca de informações.

A predição de falhas para evitar danos mais críticos ou paradas não programadas através da integração e monitoramento dos equipamentos é na prática um caminho sem volta. A busca de dados para gestão de processos e operação de equipamentos através da conectividade por sensores inteligência artificial *machine learning etc* está cada vez mais frequente nos processos industriais. Através deste monitoramento constante se torna possível a manutenção baseada em condição (CBM) que prevê quando a falha vai acontecer conhecida por manutenção preditiva. Esta estratégia de manutenção tem por objetivo principal otimizar o uso da vida útil do equipamento aumentando sua disponibilidade para operar. Também se baseia nos mesmos princípios a manutenção conhecida como prescritiva que tem como diferencial não só indicar que a falha acontecerá, mas também propor alternativas que permitam o aumento da vida útil do equipamento como por exemplo correção de algum parâmetro de operação. Todas estas estratégias são iniciativas que permitem

a previsão de uma falha potencial permitindo o planejamento da intervenção antes da quebra (Zhe, Yi, & Ke-Sheng, 2017) ou seja antes da necessidade de manutenção corretiva.

2.2.4 Internet of things in the industry (IIoT)

A internet das coisas (IoT) foi introduzida pela primeira vez por Kevin Ashton em 1998 como um conceito para conectar coisas ou objetos à Internet (Khan, et al., 2020) que coleta dados que exigem seu armazenamento em servidores ou nuvem que gerenciam Big Data (Aheleroff, et al., 2020). A internet das coisas na indústria (IIoT) atua como um subconjunto da IoT operando monitoramento em tempo real possibilitando a automação e conexão de equipamentos industriais para detecção coleta processamento e comunicação de eventos em tempo real possibilitando alta eficiência e produtividade operacional.

Estimativas recentes indicam que 70 bilhões de dispositivos estarão conectados à Internet em 2025. Em 2023 a IIoT terá uma participação de 142 trilhões de dólares no mercado global (Khan, et al., 2020). Devido ao aumento da coleta de dados em tempo real nos processos industriais através da IIoT o armazenamento em nuvem (Big Data) e a Segurança de Dados (Segurança Cibernética) estão na agenda e sendo tratados com alta prioridade nos departamentos de tecnologia da informação (TI) (Khan, et al., 2020) porque exigem níveis de proteção segurança e comunicação confiável para que as operações não sejam interrompidas

2.2.5 Data Generation

Muitos sistemas da indústria ainda não estão prontos para gerenciar Big Data devido às altas demandas de acesso e pela qualidade dos dados. Para aumentar essa qualidade para que os dados sejam utilizados com eficiência sendo reflexo verdadeiro da realidade amostral um aspecto extremamente importante é a mineração de dados (Data Mining) que terá papel de extrema importância para garantir correta identificação de padrões possibilitando previsões aplicadas em diagnósticos e prognósticos de falhas (Zhe, Yi, & Ke-Sheng, 2017).

A aplicação de efetiva análise de dados e *machine learning* para estruturar planejamentos e métodos de otimização para processos é utilizada com o objetivo de prever efetivamente comportamentos anormais nos equipamentos. O prognóstico baseado na análise de dados é visto cada vez com atenção especial e ganhando popularidade nos diversos setores com foco na capacidade de estimar eventos dos equipamentos e o processo de operação como um todo possibilitando que o processo de monitoramento seja capaz de antecipar a ocorrência de eventos anormais (Diez-Olivan, Del Ser, Diego, & Sierra, 2018). Isso é de fundamental importância e essencial para o planejamento de melhoria contínua e conseqüente impactar no aumento da produtividade e na redução de custos de operação fazendo com que o desempenho do equipamento seja crescente.

A conexão entre o mundo real e o físico está no centro da quarta revolução industrial. Não há como separar o físico e o real se realmente a estratégia de uma empresa estiver alinhada para seguir rumo à Indústria 4.0 ou Manufatura Inteligente (Diez-Olivan, Del Ser, Diego, & Sierra, 2018).

2.2.6 Conceito de análise de dados

Como não pensar em análise de dados sem buscar os conceitos de estatística muitos observavam a estatística como uma ciência desconhecida e imprecisa muitas vezes devido ao fato de que a resolução de alguns problemas exigem o auxílio computacional mas com o avanço da ciência da computação e a evolução de algoritmos de resolução de problemas a estatística passou a estar presente em todas as áreas como alicerce importante de soluções de problemas que envolvam interpretação e confiabilidade de dados. Atualmente não há quem não tenha ouvido falar em *Data Science Data analytics Data mining Machine learning Artificial Intelligence* e outros termos que emergem no ambiente da análise e tratamento de dados. Portanto é importante entender o conceito e relação por trás destes termos (Xu, He, & Li, 2014). A Figura 5 classifica de maneira esquemática estes diversos conceitos. Estatística análise de dados e mineração de dados agrupados como modelos onde a estatística seria o modelo mais genérico e a mineração o modelo mais específico. Da mesma forma a ciência da computação inteligência artificial e *machine learning* (aprendizado) são agrupados como algoritmos técnicos onde ciência da

computação seria o algoritmo mais genérico e *machine learning* o mais específico. (Cattaneo, Fumagalli, Macchi, & Negri, 2018). O esquema também indica a inter-relação existente entre os modelos de análise e mineração de dados como também os coloca como premissa para algoritmos de *machine learning* (aprendizado) e inteligência artificial. Para o autor (Cattaneo, Fumagalli, Macchi, & Negri, 2018) existe certa sobreposição entre estes dois últimos como conceito.

A base estatística é fundamental para modelagem genéricas também sendo a base para elaboração de algoritmos técnicos suportados pela ciência da computação mas para se aplicar o conceito de *machine learning* (Rafique & Velasco, 2018) é necessário desenvolver algoritmos técnicos que possam suportar atividades autônomas com base em inteligência artificial (AI) (Peres, Rocha, Leitão, & Barata, 2018).

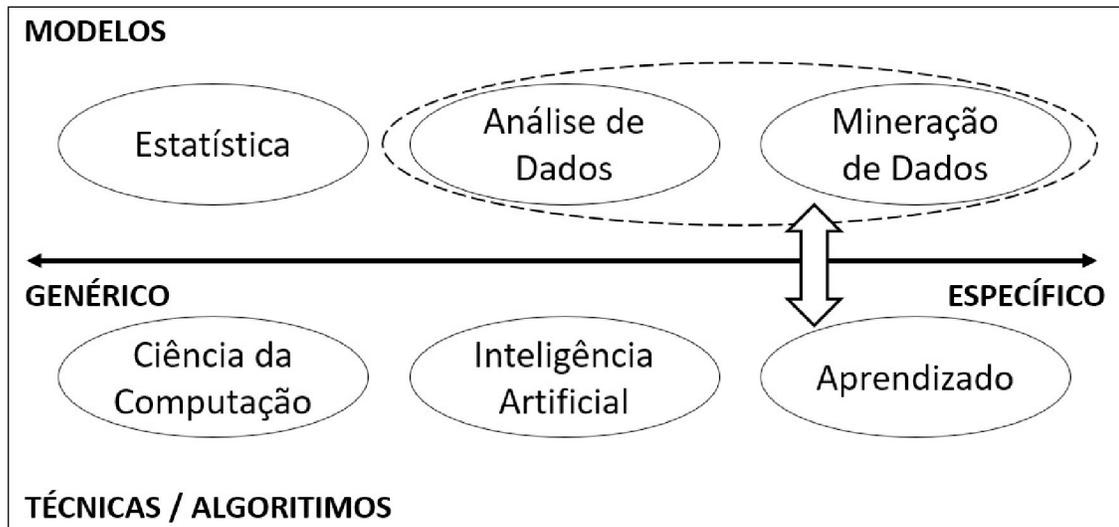
Diretrizes para a implementação de análises de dados escaláveis flexíveis e plugáveis e sistemas de supervisão em tempo real para ambientes de manufatura através do modelo proposto apresentou em IDARTS (Análise Inteligente de Dados e Supervisão em Tempo Real). Frente a essa realidade os sistemas cyber físicos de produção (CPPS) podem ser vistos como uma tecnologia 4.0 emergente que veio para ficar evidenciando ainda mais a importância da coleta de dados seu armazenamento seguro a análise eficaz suportando as estratégias de manutenção preditiva descritiva e prescritiva suportando abordagem eficaz do que diz respeito ao gerenciamento de processos (Peres, Rocha, Leitão, & Barata, 2018). Para tanto é necessário coletar e processar com eficiência um grande número de dados heterogêneos vindos de diversas fontes para geração eficaz de um modelo de decisão. Um processo inteligente demanda soluções inteligentes com base em conhecimento automatizando as decisões de planejamento de manutenção (Ansari, Glawar, & Nemeth, 2019).

2.2.7 Análise sistemática de dados aplicada a estratégia de manutenção de equipamentos

Conforme descrito nas sessões acima a análise sistemática de dados com base em conhecimentos estatísticos e impulsionada pelas tecnologias habilitadoras para coleta análise e modelagem de dados pode ser aplicada a diversos ramos da indústria desde equipamentos de produção nas fábricas inteligentes até na inovação

competitiva com pacotes de serviços que incluem monitoramento de um produto em seu ciclo de vida (servitização) (QVIST-SORENSEN 2020).

Figura 5 - Classificação dos principais conceitos



Fonte: Adaptado de (Cattaneo, Fumagalli, Macchi, & Negri, 2018). Clarifying Data Analytics Concepts for Industrial Engineering.

O desenvolvimento deste tipo de inovação para o mercado é baseado em um primeiro nível na disponibilidade de um alto volume de dados relevantes e confiáveis da operação dos equipamentos. Em um segundo nível baseado em conhecimento estatístico para depuração os dados e estudo de correlações entre as informações um algoritmo bem calibrado capaz de analisar os dados que serão recebidos e indicar em termos de manutenção qual o estado do equipamento (MOENS BRACKE et al. 2020).

As empresas adotam diferentes estratégias de manutenção para seus equipamentos. Estas estratégias normalmente são guiadas tentando se estabelecer um balanceamento entre a disponibilidade do equipamento e seu custo de reparo.

Entre as estratégias de manutenção que podem ser adotadas tem-se:

- Manutenção corretiva: utilização do equipamento até sua falha. Normalmente se observam maiores custos de reparo neste método de manutenção e tempo de parada indeterminado de acordo com a gravidade da quebra. O maior custo de reparo se deve ao fato de que a quebra efetiva de componentes normalmente envolve a necessidade de substituição de chamados itens construtivos (não só de desgaste).

Importante mencionar que o conceito de quebra (Viana, 2020) para a referida manutenção corretiva ocorre no momento da pane completa do componente. Os eventos de defeito e falha que antecedem a pane seriam oportunidades para a manutenção preventiva ou preditiva que descreve-se abaixo.

- Manutenção preventiva: baseado em conhecimento prévio da performance do equipamento busca-se antecipar a manutenção com relação ao ponto de maior possibilidade de falha reduzindo-se custo e tempo de parada. Neste tipo de manutenção normalmente existe a necessidade de troca somente de itens de desgaste;

Porém existe uma perda relacionada a antecipação do reparo perdendo-se parte da vida útil que o equipamento ainda teria até o momento de sua falha efetiva;

- Manutenção preditiva: com base em técnica de monitoramento da condição do equipamento pode-se manter o equipamento operando até que se tenha indícios de que uma ruptura se aproxima. A redução do custo e tempo de reparo é similar ao obtido na manutenção preventiva com ganho relacionado a utilização completa do tempo de vida do equipamento. Neste tipo de manutenção a troca de componentes também se reduz a necessidade de troca de itens de desgaste somente.

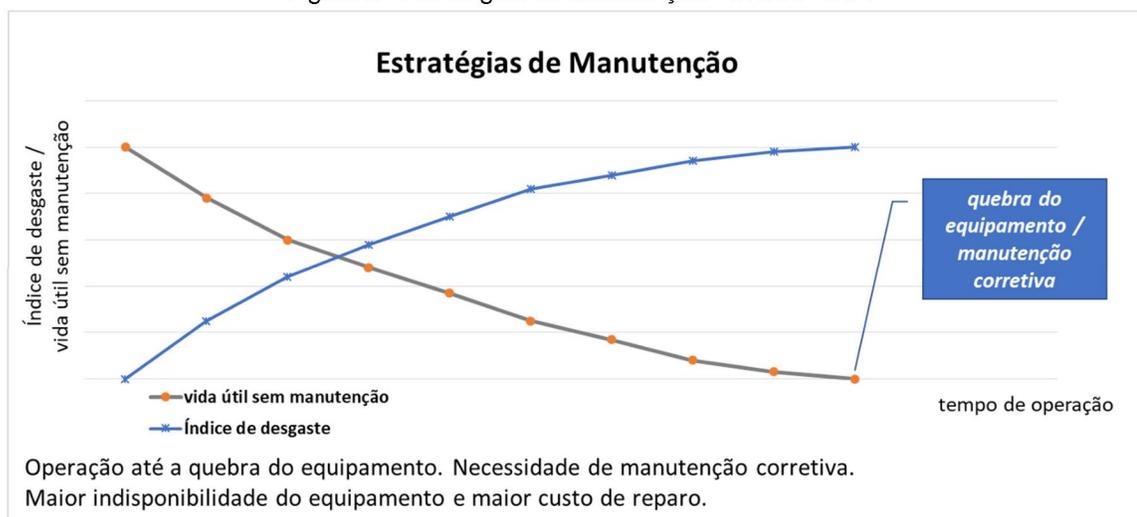
A manutenção preditiva seria uma das possíveis aplicações da análise sistemática de dados (generalizaremos ambos como equipamentos onde se busca oferecer o serviço de manutenção preditiva como produto, mas também aplicável a máquinas em um ambiente fabril) (ZHANG e DONG YANG 2019).

Além das estratégias de manutenção citadas acima também existe um próximo nível chamado de manutenção prescritiva que teria o mesmo conceito da manutenção preditiva porém indicando também que correções poderiam ser feitas para evitar a falha (controle de temperatura de um certo conjunto por exemplo) ou que reparo se faz necessário para condição de falha específica baseando-se em um sistema mais robusto de monitoramento e correlação do estado do equipamento (Ansari, Glawar, & Nemeth, 2019).

A manutenção preditiva (manutenção por condição) tem como objetivo reduzir o custo da operação do equipamento através da redução do custo de reparo (antecipando a quebra total e maiores danos) como também aumentando a disponibilidade do equipamento através da utilização efetiva do tempo de vida

disponível até a proximidade com o ponto de ruptura e também pelo menor tempo de reparo (pela prevenção de danos em itens construtivos). Outro ponto não menos importante é o aspecto de sustentabilidade com a diminuição dos recursos envolvidos e maior eficiência alcançada (Ajay Kuma, 2018).

Figura 6 - Estratégias de manutenção - CORRETIVA

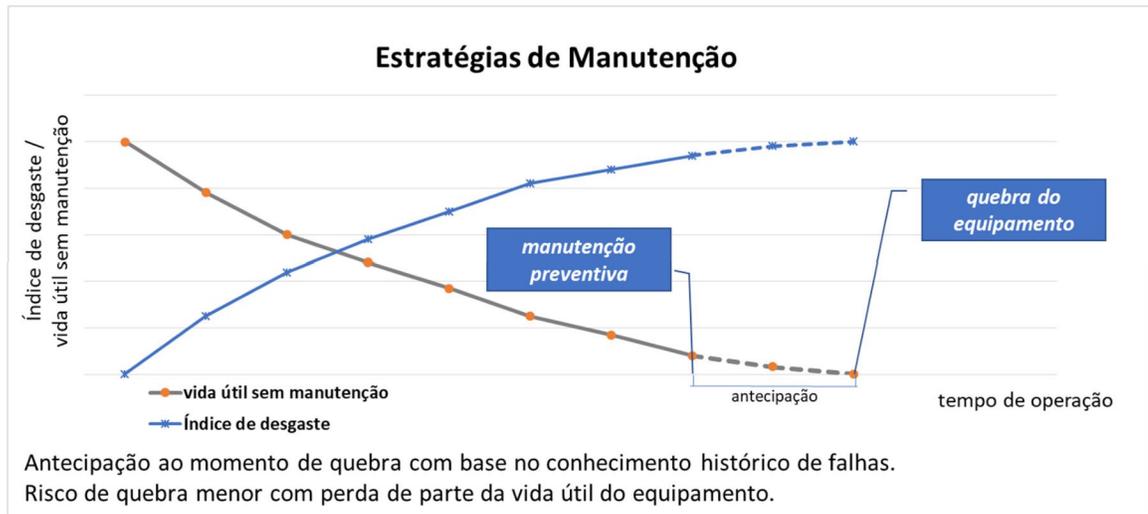


FONTE: O Autor baseado em NBR5462/1994 (ABNT, 1994)

A Figura 6 apresenta a evolução do índice de desgaste e da vida útil de um equipamento ao longo do tempo. O aumento do índice de desgaste levará o equipamento a uma falha onde manutenção não programada ou corretiva será necessária. Nesta estratégia de manutenção ocorre a maior indisponibilidade devido a parada não programada e o maior custo de reparo devido a quebra de componentes construtivos do equipamento.

Na Figura 7 ilustra-se a estratégia de manutenção com base em conhecimento histórico do comportamento do equipamento. Sabendo-se que o risco da falha acontecer aumenta com o tempo de operação devido ao aumento do índice de desgaste o ponto de manutenção é planejado antecipando esta falha. Risco de falha é reduzido mas ao custo da perda de parte da vida útil do equipamento (ilustrado de maneira esquemática pela linha tracejada).

Figura 7 - Estratégias de manutenção - PREVENTIVA

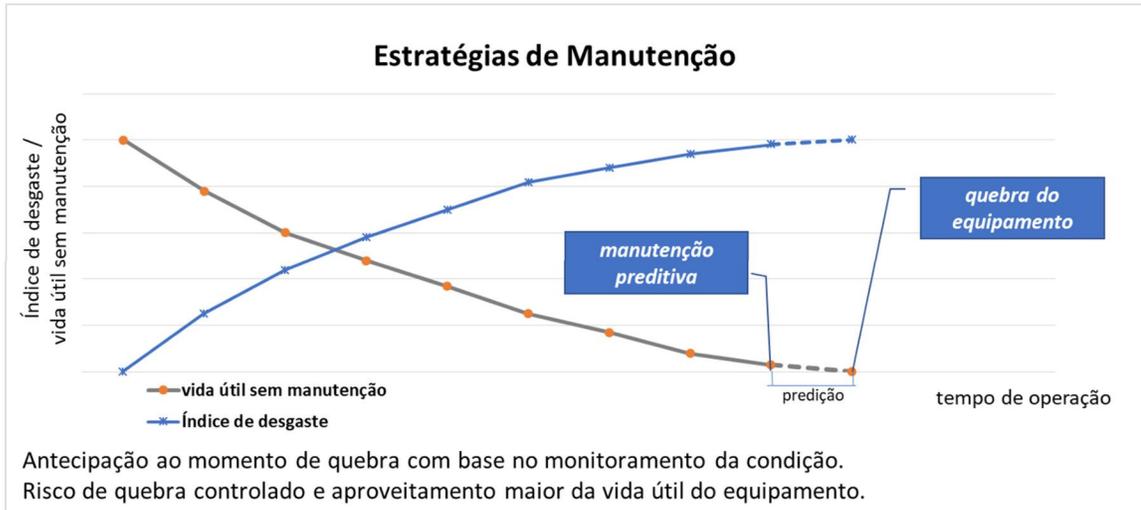


FONTES: O Autor baseado em NBR5462/1994 (ABNT, 1994)

Na Figura 8 ilustra-se a estratégia de manutenção preditiva que se baseia no monitoramento da condição desta forma o ponto de manutenção aproxima-se do ponto de quebra de maneira controlada. Risco de quebra é controlado e a utilização da vida útil otimizada.

Na tentativa de deixar ainda mais claro o conceito por trás das representações citadas anteriormente existe uma escolha a ser feita entre maximizar o tempo de operação do equipamento porém com isto aumentando também o risco de quebra devido ao aumento do índice de desgaste ou antecipar a manutenção do equipamento reduzindo o risco de quebra porém desperdiçando parte da vida útil que os componentes ainda poderiam operar até o momento de quebra efetiva (TRAINI, BRUNO, D'ANTONIO, & LOMBARDI, 2019).

Figura 8 - Estratégias de manutenção - PREDITIVA



FONTES: O Autor baseado em NBR5462/1994 (ABNT, 1994)

A análise sistemática de dados como meio de se implementar manutenção preditiva de um equipamento é possível através do monitoramento dos dados (KPIs) que permitam prever antecipadamente condições que levarão a um estado de falha do equipamento (estes estados de falha podem ser classificados por grau de severidade e influência na disponibilidade do equipamento e seu custo de reparo).

O monitoramento dos dados será utilizado por algoritmos para estimar o tempo remanescente de vida útil do equipamento até sua quebra. Porém o sucesso deste modelo para manutenção por condição dependerá do correto balanceamento entre a técnica de algoritmo utilizada a quantidade de dados confiáveis disponíveis para treinamento e validação do modelo considerando as diversas condições de operação que podem ocorrer e também os diversos modos de falhas. A complexidade em encontrar este correto balanceamento está relacionada ao custo de desenvolvimento da análise sistemática de dados (MOENS, ET AL., 2020).

O dimensionamento do sistema para monitoramento da condição do equipamento deve levar em conta o custo de desenvolvimento e implementação com relação ao retorno que a maior acuracidade na determinação do ponto de falha trará como benefício.

Os autores descrevem dois paradoxos da digitalização (David Sjödin, 2020) e que devem ser levados em conta ao se desenvolver sistema de monitoramento baseado em dados:

1) desenvolvedores de produtos inovadores com foco na servitização falham ao não considerar que o valor que se está gerando pode não ser percebido ou desenvolvem soluções muito específicas e conseqüentemente difíceis de ganhar escala ou até mesmo por subestimar o custo de operacionalização do sistema;

2) desconsiderar que a manutenção preditiva poderá canibalizar parte do serviço tradicional baseado em estratégias menos assertivas (preventivas ou corretivas) porém mais rentáveis do ponto de vista do fornecedor do serviço. Poderá ocorrer precificação acima da percepção de valor do mercado para compensar este risco (DAVID SJÖDIN, 2020).

2.2.8 Estrutura para análise sistemática

Os autores (Ansari, Glawar, & Nemeth, 2019) alertam com relação a necessidade de estruturação relacionada a gestão do conhecimento onde os aspectos do conhecimento humano orientados para as novas tecnologias devem ser explorados correlativamente considerando a nova divisão de tarefas (compartilhadas) entre a força de trabalho humana e a máquina. A transformação digital tem como objetivo gerar retorno tecnológico como também de produtividade e econômico. O aspecto relacionado ao treinamento e qualificação especializada do pessoal em todos os níveis é de extrema importância. Os resultados esperados só serão obtidos se houver priorização da habilitação técnica voltada às tecnologias da Indústria 4.0 das pessoas.

3 METODOLOGIA

3.1 ESTRUTURA CONCEITUAL PARA ANÁLISE SISTEMÁTICA DE DADOS

Tendo como base a revisão sistemática da literatura e baseado nas afirmativas dos autores citados nos capítulos anteriores apresenta-se uma estrutura conceitual para aplicação da análise de dados sistemática tendo como objetivo contribuir com pesquisadores e aqueles que pretendem implementar algum tipo de análise sistemática de dados seja na área de refinamento de estratégias de manutenção de componentes ou não.

Baseado no conceito dos autores (Cattaneo, Fumagalli, Macchi, & Negri, 2018) para se ter sucesso na implementação do processo de análise de dados é necessário propor resultados tangíveis. Mudanças em grandes partes da organização são necessárias e isso não é uma tarefa fácil. Geralmente são necessários vários anos desde planejamento até efetiva implementação para transformar a empresa possibilitando a transferência do conhecimento necessário para gerar ganhos significativos. Estes resultados tangíveis podem se traduzir em se ter um objetivo a ser alcançado com o processo de análise de dados.

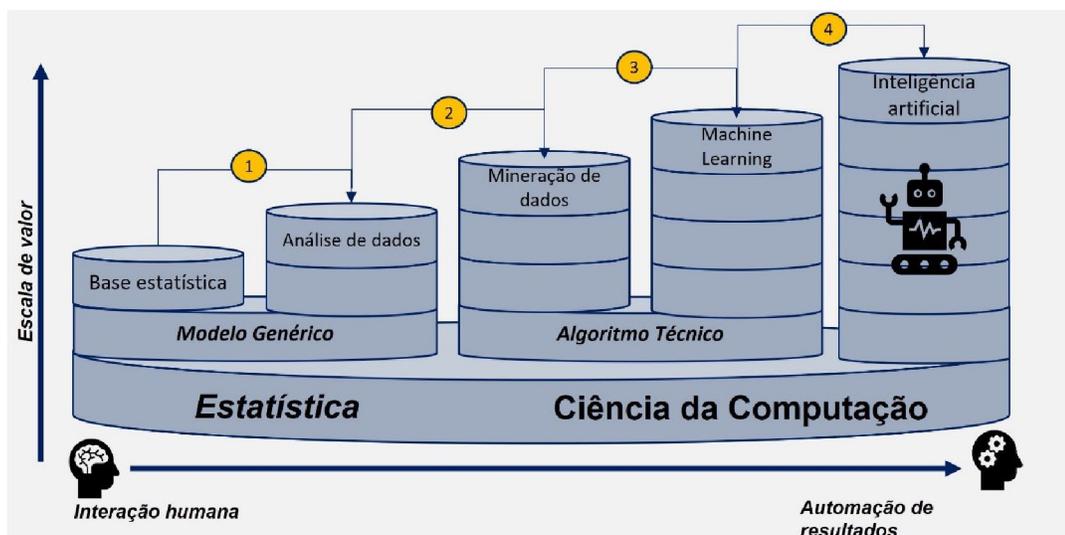
Com o objetivo de garantir impactos positivos nos processos devemos observar esta transformação como uma estratégia que exige uma abordagem passo a passo. Como parte do estudo desenvolveu-se uma visão que tem como alicerce os requisitos básicos da estatística e da ciência da computação suportando a transição de organizações ágeis e de aprendizado em organizações baseadas em dados. O percurso sugerido compreende quatro estágios de desenvolvimento. Cada estágio é incremental baseando-se como premissa o estágio anterior descrevendo os recursos necessários para atingi-lo e os benefícios resultantes de sua implementação conforme apresentado na O objetivo da estrutura conceitual proposta na Figura 9 é apresentar de maneira estruturada o processo de implementação de uma análise sistemática de dados indicando como cada etapa complementa a etapa anterior através da geração de valor incremental aos processos existentes. Neste estudo nos limitamos a estabelecer conceitos sem aprofundamento das diversas técnicas citadas levando em consideração que existe literatura específica com esta finalidade.

Figura 9 objetivando gerar valor e transformar os processos de dependência humana em processos autônomos. Em termos de estratégia de manutenção isto significa criar uma base de conhecimento através das análises mais simples dos dados que permitam avaliar o potencial em termos de transformar dados em informação relevante para o refinamento das estratégias de manutenção. Uma vez identificado o potencial das informações que podem ser geradas pode-se evoluir o modelo para algoritmos de maior complexidade buscando até mesmo a autonomia em termos de tomada de decisão.

Grande parte das empresas ainda enfrentam o desafio de criar as condições básicas para um sistema de análise de dados robusta conseqüentemente o caminho do desenvolvimento começa com uma base em estatística e ciência da computação.

O objetivo da estrutura conceitual proposta na Figura 9 é apresentar de maneira estruturada o processo de implementação de uma análise sistemática de dados indicando como cada etapa complementa a etapa anterior através da geração de valor incremental aos processos existentes. Neste estudo nos limitamos a estabelecer conceitos sem aprofundamento das diversas técnicas citadas levando em consideração que existe literatura específica com esta finalidade.

Figura 9 - Estrutura conceitual para análise sistemática de dados



Fonte: Adaptado de Lisboa, et al. (2021)

A estrutura conceitual foi dividida em 4 etapas:

Etapa 1: está ligada a base estatística e seus conceitos teóricos básicos. Considerando-se um viés ligado a processos produtivos as empresas devem se concentrar em termos de treinamento e desenvolvimento investindo em capacitação básica como por exemplo CEP (Controle Estatístico de Processos) FMEA (Failure Mode and Effect Analysis) MSA (Measurement System Analysis ou Análise e Sistema de Medição) e outros métodos ligados a solução de problemas e garantia da qualidade apoiando-se em conceitos estatísticos para identificar analisar e prevenir falhas proporcionando uma evolução positiva baseada em conhecer os fundamentos da estatística de base. Por outro lado, para um viés mais genérico relacionado ao reconhecimento de uma base de dados nesta primeira etapa é importante selecionar variáveis determinar níveis de correlação tendo primeiro contato com a qualidade das informações que podem ser geradas através desta base de dados através de análises estatísticas básicas. Em ambas as abordagens nesta primeira etapa um certo nível de transformação de dados em informação ocorrerá ao se identificar de maneira estatística variáveis que são relevantes para o processo que está investigando;

Etapa 2: tendo como base a etapa inicial um aperfeiçoamento baseado no entendimento de análise de dados será necessário conectado diretamente a fase de modelagem estatística permitindo a materialização apenas dos dados ou *big data* em “fonte de dados” através da limpeza dos dados e observação de padrões e comportamentos para gerar modelos que possibilitarão uma análise mais profunda (ZHANG REN et al. 2017) baseada na análise de dados como conceito descrito em *The Elements of Statistical Learning. Data Mining Inference and Prediction* (HASTIE TIBSHIRANI e FRIEDMAN 2013). Nesta etapa busca-se visualizar os dados selecionar atributos identificar desvios descartar dados que não são significativos objetivando a construção de um modelo validado por testes estatísticos;

Etapa 3: Mineração de dados. Muitas vezes análise de dados e mineração de dados são consideradas como o mesmo processo, mas como apresentado pelo modelo (Cattaneo, Fumagalli, Macchi, & Negri, 2018) mineração de dados tem como objetivo principal a extração dos dados de forma a garantir a confiabilidade através de modelos estatísticos. Muitas vezes utilizando-se do suporte computacional através de softwares que são plataformas computacionais programáveis de padrões matemáticos e testes estáticos. Por este motivo temos como premissa desta etapa as

etapas 1 e 2 para finalmente modelar o algoritmo que fará a mineração dos dados baseados em padrões especificados. Existem vários softwares atualmente que executam com eficiências mineração de dados como por exemplo R IBM SPSS Statistics (SPSS) DataMelt Orange SAS e outros. Conforme descrito anteriormente a intenção desta estrutura conceitual é servir como guia de princípios gerais da ciência de dados sem descrever as instruções ou indicar qual software deve ser utilizado.

Etapa 4: Com relação a ML, Arthur Samuel descreveu-a em 1959 como “campo de estudos que permite aos computadores aprender sem terem sido explicitamente programados” (SAMUEL 1959) que é uma definição mais clássica. Em 1997 Tom Mitchell fornece uma definição mais moderna: “Um programa de computador é dito para aprender com a experiência E com a relação a alguma classe de tarefas T e medida de desempenho P se o seu desempenho em tarefas em T medida pelo P melhora com a experiência E” (MITCHELL 1997) e conforme abordado por GE et al. em Data Mining and Analytics in the Process Industry: The Role of Machine Learning Machine Learning pode ser dividido em 4 (quatro) categorias diferentes:

- I. aprendizado não supervisionado “Unsupervised Learning Methods”
- II. aprendizado semisupervisionado “Semi-Supervised Learning Methods”
- III. aprendizado supervisionado “Supervised Learning Methods”
- IV. aprendizado reforçado “Reinforcement learning”

Observando as etapas descritas no modelo e ao ponto que se incrementa o conhecimento gera-se valor e pode-se atribuir tarefas que ao serem padronizadas tornam-se algoritmos que permitem que as máquinas tomem suas decisões. Estes padrões a serem seguidos pelas máquinas devem ser estabelecidos levando em consideração análise crítica que garanta que ao se tomarem decisões autônomas não representarão riscos danos ou perdas. O ganho com a implementação desta etapa está na rapidez para as decisões autônomas ou supervisionadas fazendo com que tarefas não padronizáveis possam estar em foco. Essencial dentro do contexto de se aprimorar estratégias de manutenção de máquinas e equipamentos.

Esta estruturação conceitual que foi apresentada não pretende esgotar o assunto, mas sim servir como guia básico para discussões e processos de implementação.

buscando explicar através do método ou através de método de correlação para se descartar ou não algumas das variáveis.

Um método para estudo de correlação entre as variáveis deve ser aplicado em seguida para que se conheça a força de correlação entre elas. O método de Pearson determina correlação que pode variar de -1 a +1 (força de correlação direta ou indireta) (Taguchi). Quanto mais próximo destes valores mais forte será a correlação entre as variáveis que estão sendo testadas. O número de variáveis a ser selecionado para o método de regressão deve ter como critério o grau de complexidade que se espera da equação resultante. Obviamente quanto menos variáveis mais simples será o método e mais fácil sua aplicação (Deming, 1982). Porém um limitante na busca da menor complexidade possível será a validação através de testes estatísticos dos resultados.

3.2.2 Regressão estatística

Uma vez selecionadas as variáveis com maior grau de correlação com a variável resposta através do software Minitab pode-se executar a regressão dos dados (Campos, 2003). Uma equação de regressão será obtida com resultados relacionados ao grau de explicação da equação com relação aos dados. Além da análise deste grau de explicação é importante que também se aplique teste de validação da equação como por exemplo de normalidade de resíduos validando a modelagem. Para esta validação ajustes podem ser necessários com relação aos dados de entrada e variáveis selecionadas.

No modelo proposto na Figura 10 indicamos uma retroalimentação do modelo através do refinamento da quantidade de variáveis escolhidas ajustando o nível de complexidade do modelo tendo como parâmetro principal o grau de explicação obtido em cada etapa de retroalimentação.

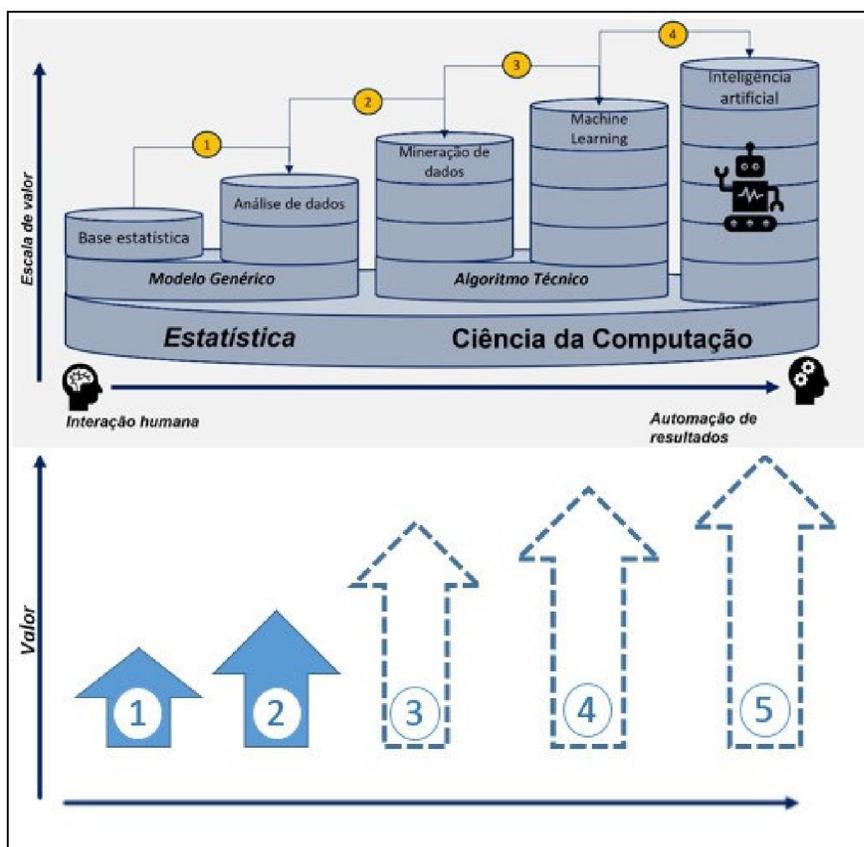
Conforme indicado anteriormente a metodologia sugerida é para que possa haver replicabilidade do método. Os conceitos estatísticos não foram aprofundados neste trabalho por não ser este o objetivo, porém existe ampla literatura para conhecimento do assunto.

4 ESTUDO DE CASO

4.1 ABORDAGEM METODOLÓGICA

Um estudo de caso da análise de dados de um certo componente em busca de se determinar nível de severidade das condições de operação e com isto refinar a estratégia de manutenção é proposto. Nosso objetivo é aplicar a estrutura conceitual para análise de dados desenvolvida durante a revisão da literatura promovendo o ganho incremental de valor das informações geradas. Na Figura 11 indicamos as etapas a serem executadas de maneira esquemática.

Figura 11 - Planejamento de etapas para análise de dados



Fonte: Adaptado de Lisboa, et al. (2021)

Dados históricos de operação do componente serão coletados de uma base instalada em operação em uma capital brasileira. A base instalada será composta por

veículos comerciais pesados de diferentes tipos e em operação em diferentes sistemas para que se tenha diversidade com relação ao nível de severidade a que estão expostos.

Neste estudo de caso se ilustrará a estratégia de manutenção atual que leva em conta dados históricos de falhas para determinar a janela onde manutenção preventiva deve ser feita com objetivo de mitigar o risco de quebras não programadas com base somente na quilometragem percorrida pelos equipamentos.

Em seguida se executará um ensaio do processo de análise de dados utilizando-se a estrutura conceitual para análise sistemática de dados apresentada anteriormente. O objetivo é partir de uma análise estatística básica dos dados avaliando correlação entre variáveis e avançar até um processo de análise de dados através de método de regressão. A complexidade do modelo será ajustada levando-se em conta o grau explicação resultante e o número de variáveis selecionadas.

Finalmente será realizada avaliação das informações resultantes do processo de análise de dados se estas poderiam otimizar a estratégia de manutenção preventiva estabelecida somente na quilometragem percorrida pelos equipamentos resultando em maior disponibilidade da frota.

4.2 BASE INSTALADA DE COMPONENTES

A base instalada de componentes selecionados para este estudo de caso é composta por 428 equipamentos. Estes equipamentos podem ser divididos pelo tipo de aplicação (modelo do veículo onde estão instalados) da seguinte forma:

Aplicação tipo 1: 198 equipamentos;

Aplicação tipo 2: 123 equipamentos;

Aplicação tipo 3: 107 equipamentos.

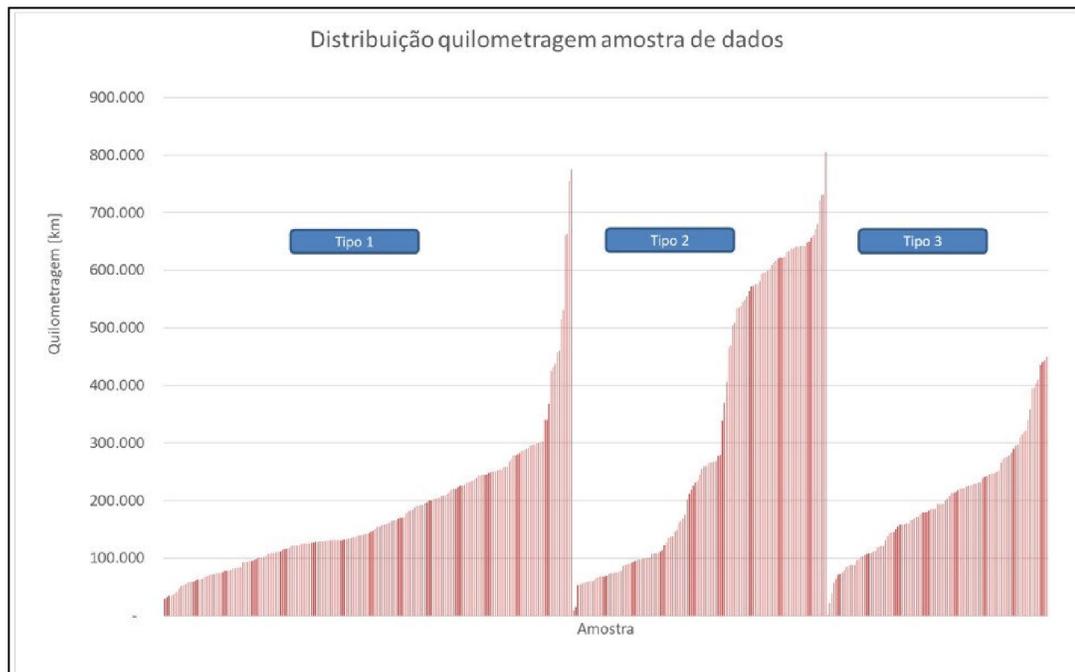
A distribuição de quilometragem destes componentes está ilustrada na Figura 12. É esperado que estes equipamentos estejam sujeitos a diferentes condições de operação influenciadas não somente pelos tipos de veículos, mas também condições de tráfego e condução resultando em diferentes níveis de severidade.

4.3 REPRESENTAÇÃO DA ESTRATÉGIA DE MANUTENÇÃO PREVENTIVA CONVENCIONAL

Para evitar quebras não programadas dos componentes o departamento de manutenção das empresas que operam estes veículos estabelece um plano de manutenção preventiva para os equipamentos baseado na quilometragem percorrida.

Nesta estratégia estabelece-se uma quilometragem alvo para a manutenção (com base em dados históricos de falhas de acordo com o tipo de aplicação) e executa-se a manutenção dos equipamentos dentro de uma janela de quilometragem determinada pelo tempo de reparo para os equipamentos.

Figura 12 – Distribuição da quilometragem na amostra de dados



Fonte: o Autor (2022)

De maneira ilustrativa para facilitar o entendimento do conceito na Figura 13 temos representados 50 veículos da base instalada. A esquerda temos a distribuição atual de quilometragem percorrida dos equipamentos. Consideremos as seguintes premissas:

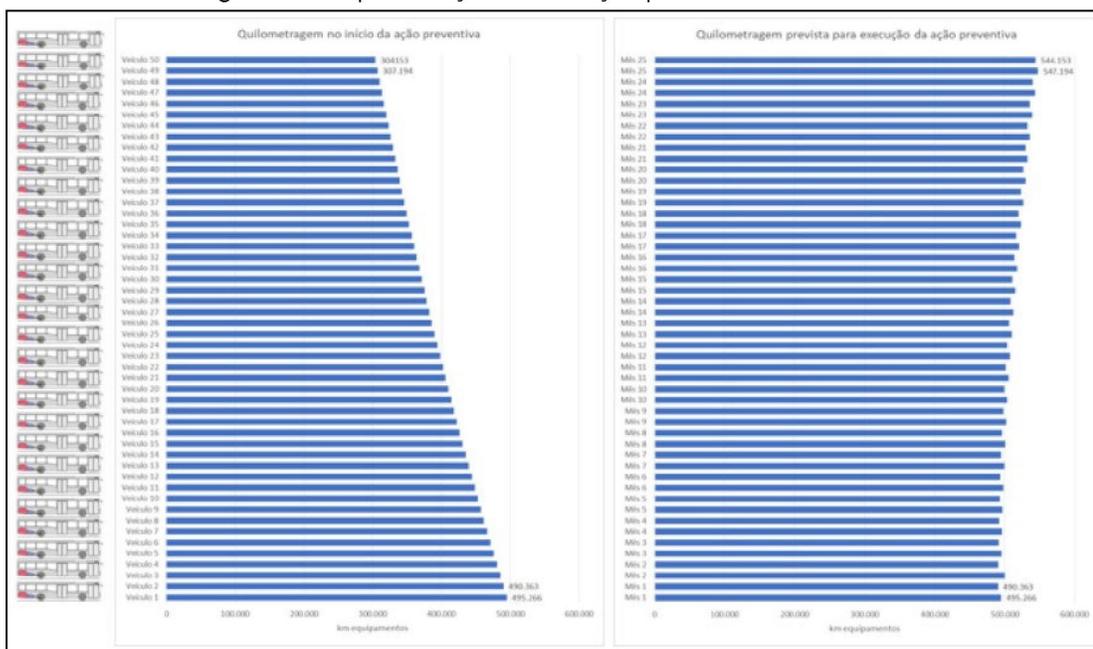
- a) empresa adota manutenção preventiva aos 500.000 km;
- b) capacidade da oficina de reparo preventivo de 2 equipamentos por mês;

c) quilometragem média que os veículos percorrem por mês de 10.000 km.

Com este cenário que é muito próximo da realidade a ação de manutenção preventiva dos 50 equipamentos levaria 25 meses. No mês 1 os primeiros equipamentos seriam retirados para manutenção com 495.266 km e 490.363 km respectivamente para os veículos de número 1 e 2. No mês 25 seria executada a manutenção dos veículos 49 e 50 com quilometragem de 547.194 km e 544.153 km respectivamente conforme ilustrado no lado direito da Figura 13.

Como o critério adotado para a manutenção preventiva convencional é por quilometragem o sequenciamento de equipamentos para oficina obedeceria a ordem indicada na Figura 13, no lado esquerdo.

Figura 13 - Representação manutenção preventiva convencional



FONTE: O Autor (2022)

O grande risco desta estratégia convencional para manutenção preventiva é que somente o fator quilometragem ou tempo de operação para determinar o sequenciamento para manutenção pode não ser suficiente para evitar manutenções não programadas (corretivas) por quebra de equipamentos.

4.4 REPRESENTAÇÃO DA ESTRATÉGIA DE MANUTENÇÃO PREVENTIVA COM BASE NA SEVERIDADE

Na Figura 14 representou-se o cenário que seria possível obter caso houvesse além da quilometragem percorrida também uma informação do nível de severidade a que o componente foi exposto até o momento. Na ilustração se sugerem 3 níveis de severidade: verde como o mais leve amarelo como intermediário e vermelho como o mais severo.

Se esta informação do nível de severidade estivesse disponível desta forma seria possível sequenciar a manutenção preventiva dos componentes não só pela quilometragem, mas também e principalmente pelo nível de severidade. Representou-se a direita da Figura 14 este novo sequenciamento. Note-se que o componente do veículo 31 indicado como nível vermelho de severidade levando-se em consideração somente quilometragem seria enviado para oficina no mês 16 conforme Figura 13. Porém conhecendo-se a severidade de seu uso a estratégia de manutenção pode ser refinada e seu envio para oficina adiantado para o mês 6 conforme Figura 14. Já o componente do veículo número 5 identificado como severidade nível verde na Figura 14 pode ter seu envio para oficina atrasado para o mês 14 dando espaço para que se priorize os de maior severidade e quilometragem antes. A adição do nível de severidade da operação dos componentes é a informação que se busca neste estudo de caso para refinamento da estratégia de manutenção.

4.5 SELEÇÃO DE VARIÁVEIS

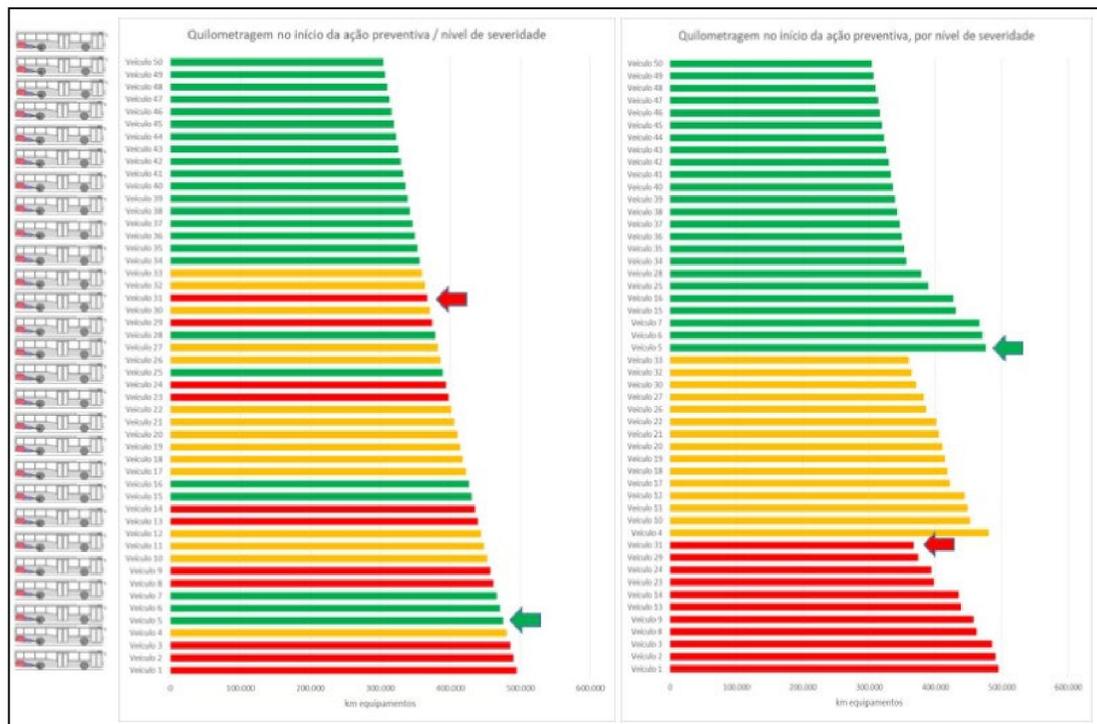
Os equipamentos investigados neste estudo de caso possuem unidade eletrônica que armazena informações históricas da operação durante a vida útil do veículo. Estas informações estão armazenadas em 433 variáveis. Considere-se para este estudo de caso que uma das variáveis possui comportamento conhecido e pode ser utilizada como índice de desgaste para estudo das demais variáveis.

4.5.1 Análise e classificação das variáveis

Como ponto inicial deste estudo de caso realizou-se uma análise preliminar das variáveis disponíveis no conjunto de dados disponíveis do componente. Cada conjunto de dados é composto por 433 variáveis sendo uma delas a variável conhecida e chamada de Índice D representando um índice de desgaste dos componentes e que pode ser utilizada como parâmetro comparativo na tentativa de

se medir nível de desgaste menor ou maior a que os componentes estão expostos. Para preservar o *knowhow* relativo a severidade das aplicações e demais correlações renomeamos as variáveis de maneira sequencial (Variável 1 Variável 2 etc) ocultando o nome e a grandeza que a variável representa. Importante também mencionar que os dados disponíveis para análise neste estudo de caso correspondem a dados históricos dos componentes, ou seja, são dados acumulados ao longo da vida útil do componente.

Figura 14 - Representação manutenção baseada no nível de severidade



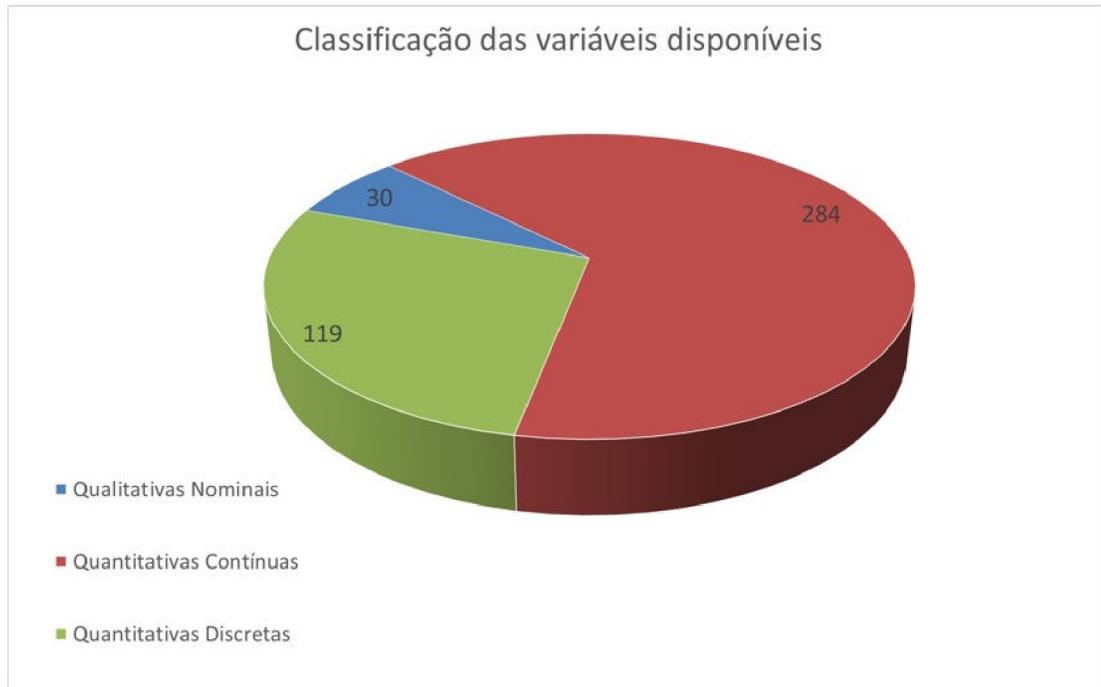
FONTE: O Autor (2022)

Aplicando a metodologia apresentada na Figura 10 primeiramente realizamos classificação das variáveis por tipo para determinar quais seriam aplicáveis no estudo.

Das 433 variáveis disponíveis 30 correspondem a dados qualitativos nominais 119 correspondem a dados quantitativos discretos e 284 quantitativos contínuos conforme apresentado na Figura 15. As variáveis qualitativas nominais e quantitativas discretas descrevem dados relativos ao funcionamento do componente não necessariamente representando o nível de severidade a que o componente está exposto. Portanto selecionamos para análise as variáveis quantitativas discretas que

representam dados históricos acumulados de diversas grandezas medidas através de sensores internos do componente e de sua unidade eletrônica.

Figura 15 – Classificação das variáveis disponíveis



FONTE: O Autor (2022)

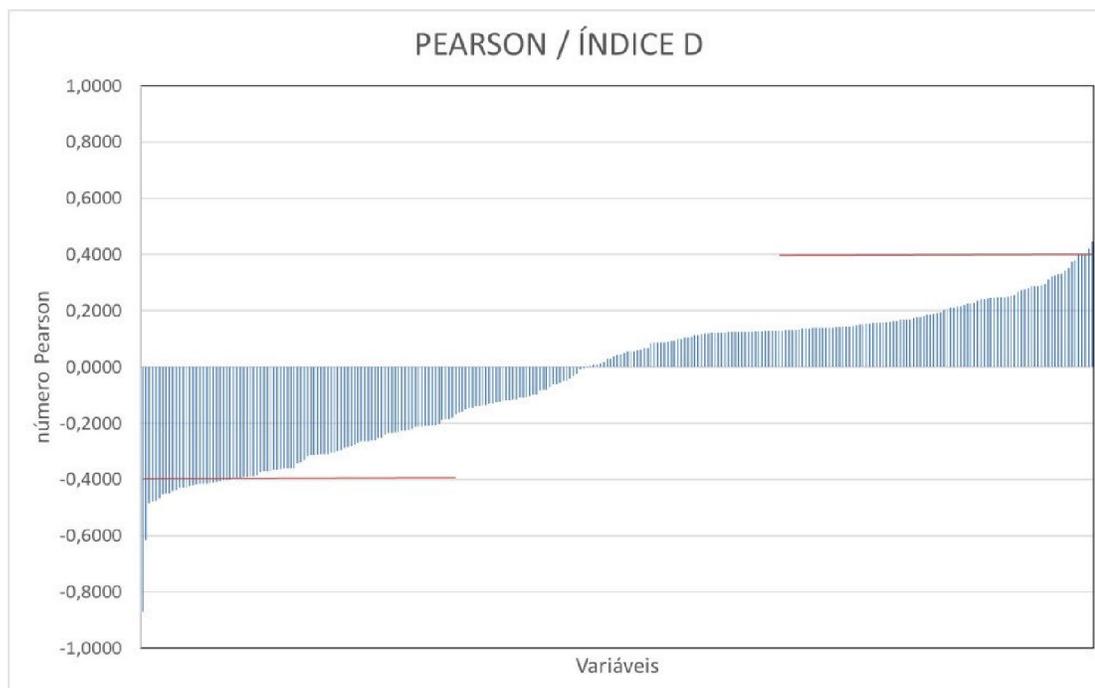
4.5.2 Correlação entre as variáveis e o índice de desgaste

Seguindo a metodologia proposta na Figura 10 realizou-se um estudo de correlação entre as variáveis selecionadas na primeira etapa e o índice de desgaste conhecido buscando compreensão com relação que variáveis teriam correlação mais forte ou fraca com este índice. Para este estudo utilizou-se o método de Pearson que mede um número ρ de correlação entre -1 e +1. Quanto mais próximo for o número ρ de -1 ou +1 maior a força de correlação entre as variáveis.

Na Figura 16 apresenta-se o resultado deste estudo de correlação. Objetivo é determinar as variáveis que possuem nível de correlação mais forte com o índice de desgaste D. Traçou-se uma linha de corte com relação ao nível de correlação entre -0,4 e +0,4. Das 284 variáveis analisadas somente 30 possuem número $\rho > [0,4]$.

Selecionamos estas 30 variáveis com número $\rho > [0,4]$ para o estudo de regressão com relação ao índice D indicadas na Figura 17.

Figura 16 – Método Pearson para correlação das variáveis com o Índice D



FONTE: O Autor (2022), com Minitab

4.6 ANÁLISE DE DADOS ATRAVÉS DE REGRESSÃO

Com o primeiro grupo de variáveis selecionadas executou-se o estudo de regressão utilizando estas variáveis como preditoras considerando como variável resultado o índice de desgaste D através do software Minitab.

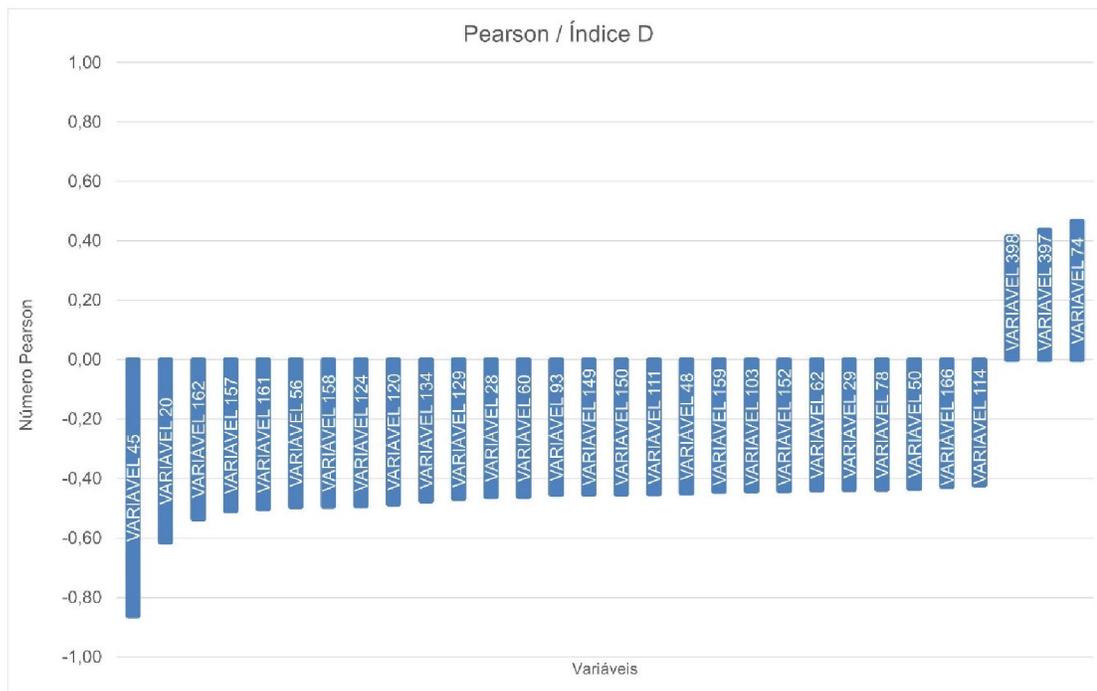
4.6.1 Estudo de regressão 1:

O modelo do estudo de regressão resultou na seguinte equação:

$$\begin{aligned}
 \text{ÍNDICE D} = & 317,4 - 2,600 \text{ VARIÁVEL 45} - 0,0033 \text{ VARIÁVEL 56} \\
 & - 0,0576 \text{ VARIÁVEL 28} - 0,0492 \text{ VARIÁVEL 111} + 0,000006 \text{ VARIÁVEL 157} \\
 & + 0,0419 \text{ VARIÁVEL 120} + 0,000002 \text{ VARIÁVEL 158} + 0,000001 \text{ VARIÁVEL 134} \\
 & - 0,000003 \text{ VARIÁVEL 150} - 0,0367 \text{ VARIÁVEL 20} - 0,1465 \text{ VARIÁVEL 103} \\
 & - 0,000002 \text{ VARIÁVEL 162} - 0,67 \text{ VARIÁVEL 124} - 0,000008 \text{ VARIÁVEL 161} \\
 & - 0,52 \text{ VARIÁVEL 60} + 0,1249 \text{ VARIÁVEL 74} - 0,075 \text{ VARIÁVEL 397} \\
 & + 0,000000 \text{ VARIÁVEL 93} + 0,000001 \text{ VARIÁVEL 48} - 0,000001 \text{ VARIÁVEL 129} \\
 & + 0,000005 \text{ VARIÁVEL 149} + 0,000007 \text{ VARIÁVEL 159} - 0,000013 \text{ VARIÁVEL 152}
 \end{aligned}$$

$$- 0,000203 \text{ VARIÁVEL } 62 + 0,000185 \text{ VARIÁVEL } 29 - 0,000012 \text{ VARIÁVEL } 50 + 0,000033 \text{ VARIÁVEL } 78 - 0,000000 \text{ VARIÁVEL } 166 + 0,537 \text{ VARIÁVEL } 114 + 0,098 \text{ VARIÁVEL } 398$$

Figura 17 – Variáveis selecionadas para o modelo de regressão 1



FONTE: O Autor (2022), com Minitab

Na Tabela 1 apresenta-se o grau de explicação do modelo de regressão com relação a Índice D através dos valores de R-quadrado (grau da força de relacionamento entre o modelo a variável resposta). Tanto o R-quadrado quanto o R-quadrado ajustado e predito apresentam valores bastante satisfatórios em termos de explicação do comportamento do Índice D através do modelo proposto (R-quadrado >80%).

A Figura 18 representa os gráficos de resíduos resultantes dos ajustes realizados pelo software para determinar a equação de regressão. A análise destes dados é importante e complementar as informações mencionadas anteriormente do grau de explicação R2 na Tabela 1. Para garantir que o modelo está ajustado de maneira satisfatória é necessário observar distribuição normal dos resíduos. No histograma indicado na parte inferior da Figura 18 a esquerda visualmente é possível constatar a distribuição normal de resíduos como também o valor-p >0,005 indica que

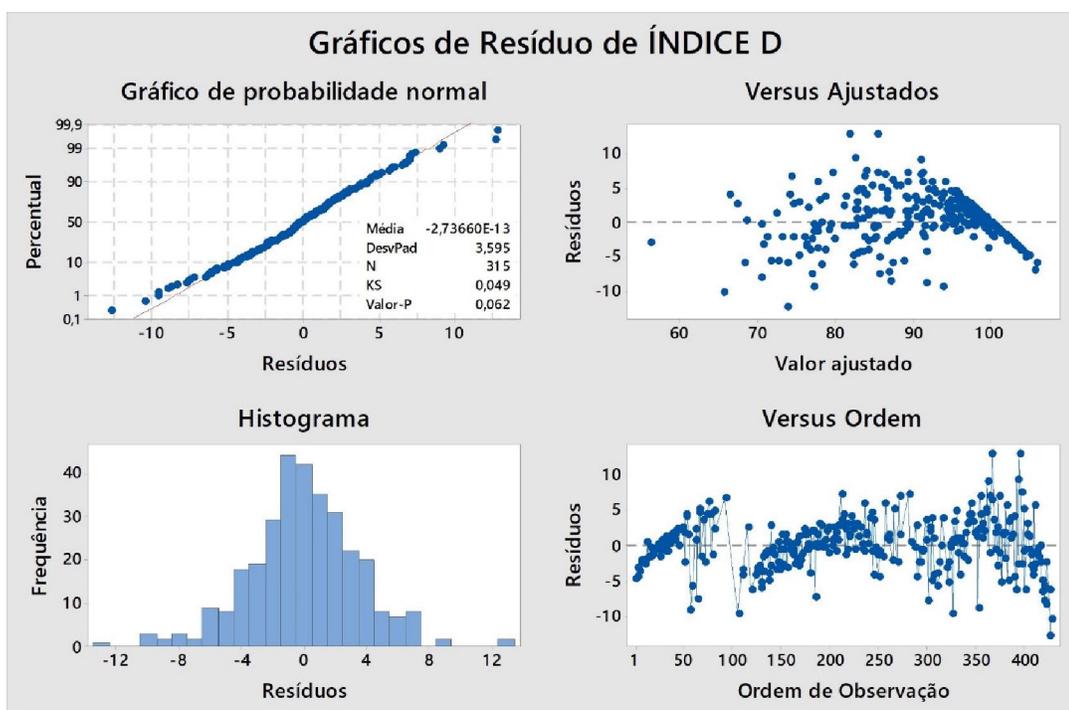
a hipótese de normalidade pode ser aceita. Em outras palavras significa dizer que o modelo é válido do ponto de vista estatístico.

Tabela 1 – Sumário do modelo de regressão 1

R2	R2(ajustado)	R2(predito)
87,40%	86,07%	82,88%

FONTE: O Autor (2022), com Minitab

Figura 18 - Gráficos de resíduos Índice D para o modelo de regressão 1



FONTE: O Autor (2022), com Minitab

Com este modelo é possível prever o nível de severidade a que está exposto o componente com base no comportamento destas 30 variáveis selecionadas. Apesar do resultado positivo obtido do ponto de vista da elevada aderência do modelo para esta predição e da validação estatística do mesmo considerou-se que seria importante realizar novo ensaio reduzindo a complexidade do modelo através da redução do número de variáveis.

Com este modelo é possível prever o nível de severidade a que está exposto o componente com base no comportamento destas 30 variáveis selecionadas. Apesar do resultado positivo obtido do ponto de vista da elevada aderência do modelo para esta predição e da validação estatística do mesmo considerou-se que seria importante realizar novo ensaio reduzindo a complexidade do modelo através da redução do número de variáveis.

4.6.2 Estudo de regressão 2:

Um segundo nível de análise foi conduzido com relação as 30 variáveis selecionadas para o primeiro modelo. Conforme a Tabela 2 a maior parte das grandezas representadas pelas variáveis estão duplicadas de alguma forma. Por exemplo a grandeza temperatura do componente pode estar sendo representada de maneira cumulativa sendo medida em horas de operação (com veículo em movimento) ou quilômetros percorridos. E esta mesma informação pode estar sendo apresentada novamente em termos percentuais por exemplo porcentagem do tempo total operando em certo range de temperatura ou porcentagem da quilometragem total operando em certo range de temperatura.

Levando em consideração este critério excluindo as variáveis que representam a medição da mesma grandeza é possível reduzir o número de variáveis que apresentaram número ρ de Pearson (correlação) $> [0,4]$ de 30 para 12 variáveis indicadas na Figura 19.

$$\begin{aligned} \text{ÍNDICE D} = & 332,70 - 2,6944 \text{ VARIÁVEL 45} - 0,02487 \text{ VARIÁVEL 56} + 0,000001 \text{ VARIÁVEL 48} \\ & + 0,02847 \text{ VARIÁVEL 28} + 0,000000 \text{ VARIÁVEL 93} - 0,0467 \text{ VARIÁVEL 111} \\ & - 0,000001 \text{ VARIÁVEL 157} + 0,00865 \text{ VARIÁVEL 120} - 0,000018 \text{ VARIÁVEL 158} \\ & + 0,000001 \text{ VARIÁVEL 134} - 0,000001 \text{ VARIÁVEL 129} - 0,000003 \text{ VARIÁVEL 150} \end{aligned}$$

Na Tabela 3 apresenta-se o grau de explicação do modelo de regressão com relação ao Índice D através dos valores de R-quadrado (grau da força de relacionamento entre o modelo a variável resposta). Tanto o R-quadrado quanto o R-quadrado ajustado e predito apresentam valores bastante satisfatórios em termos de explicação do comportamento do Índice D através do modelo proposto (R-quadrado ~80%).

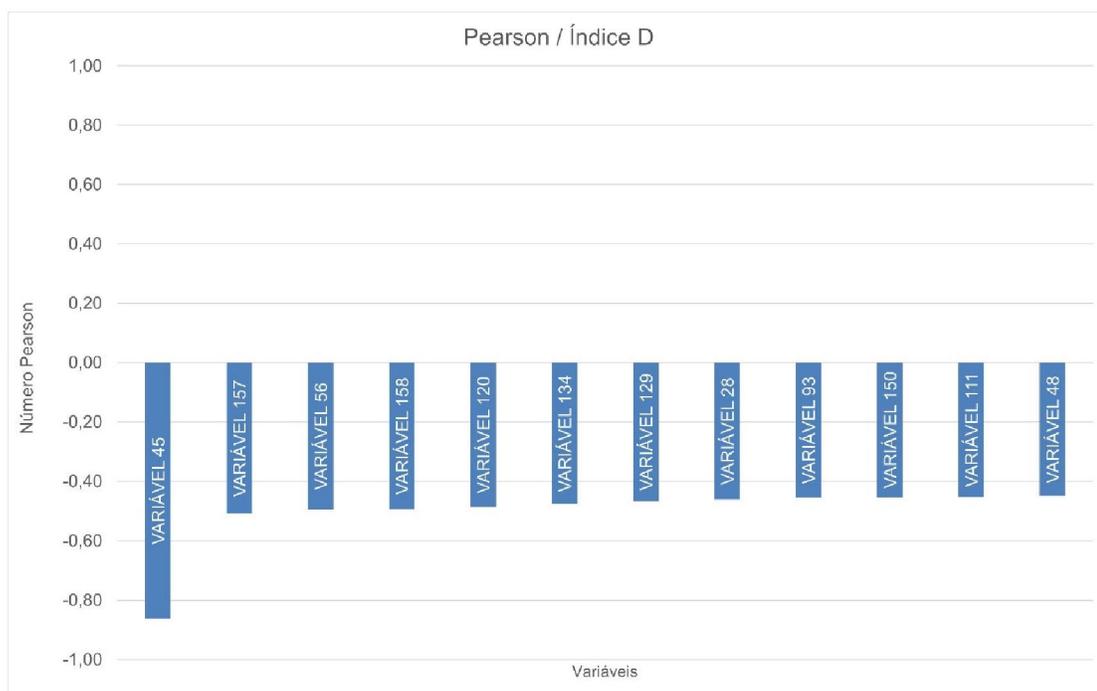
Tabela 2 – Avaliação variáveis com ρ de Pearson > [04]

VARIÁVEL NUMBER	Pearson	Regressão 1	Observação	Regressão 2
VARIÁVEL 45	-0,8613	x		x
VARIÁVEL 20	-0,6138	x	Grandeza da variável já representada	
VARIÁVEL 162	-0,5360	x	Grandeza da variável já representada	
VARIÁVEL 157	-0,5085	x		x
VARIÁVEL 161	-0,5021	x	Grandeza da variável já representada	
VARIÁVEL 56	-0,4940	x		x
VARIÁVEL 158	-0,4937	x		x
VARIÁVEL 124	-0,4925	x	Grandeza da variável já representada	
VARIÁVEL 120	-0,4855	x		x
VARIÁVEL 134	-0,4752	x		x
VARIÁVEL 129	-0,4663	x		x
VARIÁVEL 28	-0,4600	x		x
VARIÁVEL 60	-0,4598	x	Grandeza da variável já representada	
VARIÁVEL 93	-0,4533	x		x
VARIÁVEL 149	-0,4526	x	Grandeza da variável já representada	
VARIÁVEL 150	-0,4522	x		x
VARIÁVEL 111	-0,4518	x		x
VARIÁVEL 48	-0,4486	x		x
VARIÁVEL 159	-0,4432	x	Grandeza da variável já representada	
VARIÁVEL 103	-0,4420	x	Grandeza da variável já representada	
VARIÁVEL 152	-0,4408	x	Grandeza da variável já representada	
VARIÁVEL 62	-0,4380	x	Grandeza da variável já representada	
VARIÁVEL 29	-0,4364	x	Grandeza da variável já representada	
VARIÁVEL 78	-0,4361	x	Grandeza da variável já representada	
VARIÁVEL 50	-0,4331	x	Grandeza da variável já representada	
VARIÁVEL 166	-0,4266	x	Grandeza da variável já representada	
VARIÁVEL 114	-0,4222	x	Grandeza da variável já representada	
VARIÁVEL 398	0,4136	x	Grandeza da variável já representada	
VARIÁVEL 397	0,4358	x	Grandeza da variável já representada	
VARIÁVEL 74	0,4658	x	Grandeza da variável já representada	

FONTE: O Autor (2022)

A Figura 20 representa os gráficos de resíduos resultantes dos ajustes realizados pelo software para determinar a equação de regressão. Também neste caso o histograma indicado na parte inferior da Figura 20 a esquerda visualmente é possível constatar a distribuição normal de resíduos como também o valor-p >0,005 indica que a hipótese de normalidade pode ser aceita o modelo é válido do ponto de vista estatístico.

Figura 19 – Variáveis selecionadas para o modelo de regressão 2



FONTE: O Autor (2022), com Minitab

Mesmo com a redução significativa do número de variáveis os resultados obtidos neste segundo exercício de modelagem através de regressão indicam que seria possível prever o nível de severidade a que está exposto o componente com base no comportamento destas 12 variáveis selecionadas.

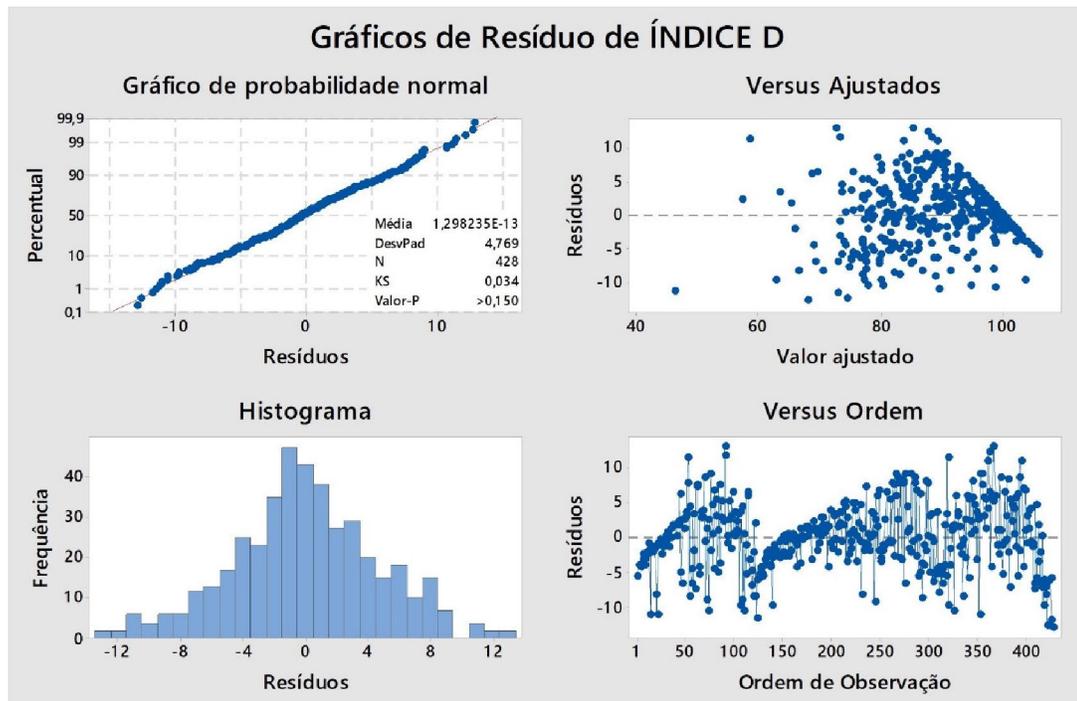
Tabela 3 – Sumário do modelo de regressão 2

R2	R2(ajustado)	R2(predito)
80,57%	80,01%	78,29%

FONTE: O Autor (2022), com Minitab

Adicionalmente na Figura 21 gerou-se também através do software Minitab o efeito fatorial das variáveis com relação ao índice de desgaste. Este gráfico indica a influência positiva ou negativa do comportamento das variáveis com relação ao índice de desgaste.

Figura 20 - Gráficos de resíduos Índice D para o modelo de regressão 2

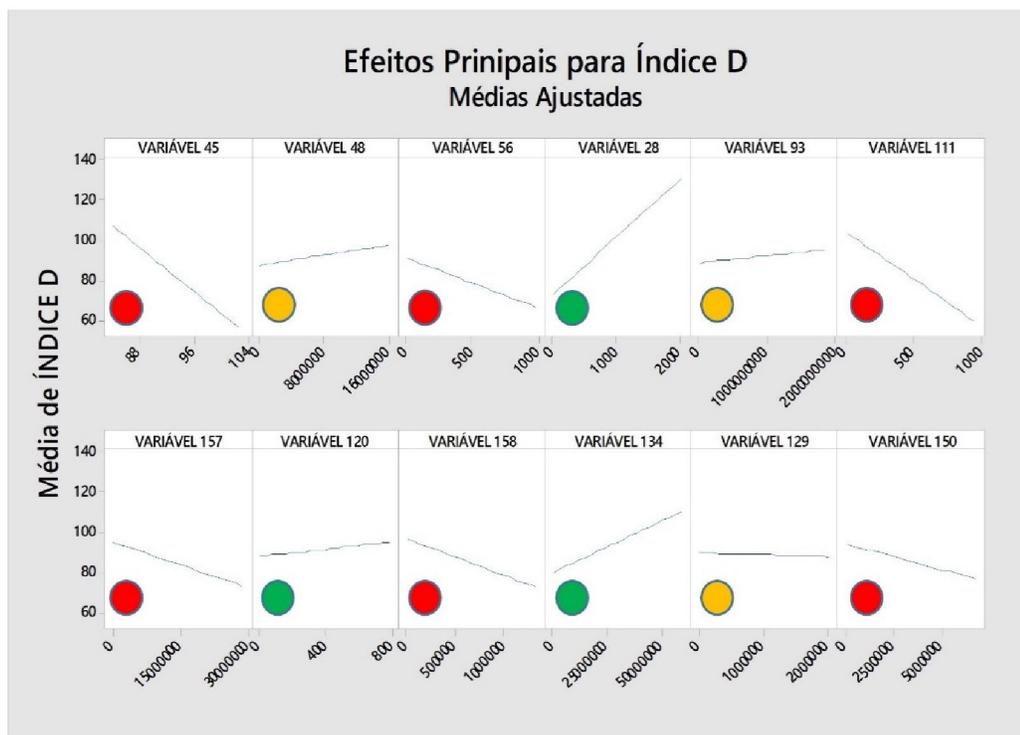


FONTE: O Autor (2022), com Minitab

Nota-se que as variáveis 28, 120, e 134 demonstram importante influência positiva com relação ao índice de desgaste (quanto maior seu valor menor o índice de desgaste). Por outro lado, as variáveis 45, 56, 111, 157, 158 e 150 demonstram importante influência negativa (quanto maior seu valor maior o índice de desgaste). As variáveis 48, 93 e 129 apresentam influência negativa discreta.

De maneira complementar com o objetivo de confirmar se existe possibilidade de diminuir ainda mais a complexidade do modelo com a retirada das variáveis que possuem influência discreta no resultado realizou-se a análise de variância das variáveis através do Minitab.

Figura 21 – Efeito fatorial das variáveis com relação ao índice de desgaste modelo 2



FONTE: O Autor (2022), com Minitab

Tabela 4 – Análise de variância das variáveis

Tabela 1 – Sumário do modelo de regressão	Valor-P
1Constante	
VARIÁVEL 45	0,000
VARIÁVEL 56	0,000
VARIÁVEL 48	0,349
VARIÁVEL 28	0,003
VARIÁVEL 93	0,563
VARIÁVEL 111	0,002
VARIÁVEL 157	0,004
VARIÁVEL 120	0,132
VARIÁVEL 158	0,000
VARIÁVEL 134	0,006
VARIÁVEL 129	0,695
VARIÁVEL 150	0,005

FONTE: O Autor (2022), com Minitab

A coluna Valor-p representa os resultados com relação ao teste de hipótese nula (valor-p baixo < 0,005 rejeita a hipótese nula). Valores < 0,005 adicionam significância ao modelo e valores >0,005 são insignificantes, ou seja, mudanças na preditora não estão associadas a mudanças na resposta.

Confirma-se o que a análise fatorial apresentada na Figura 21 havia indicado as variáveis 48, 93 e 129 poderiam ser retiradas por não trazer significância ao modelo.

4.6.3 Estudo de regressão 3:

Realizou-se um terceiro exercício de modelagem através do método de regressão reduzindo desta vez o número de variáveis para 9 conforme indicado na Figura 22 retirando do modelo as variáveis citadas anteriormente que não traziam significância para o modelo.

O modelo do estudo de regressão resultou na seguinte equação:

$$\begin{aligned} \text{ÍNDICE D} = & 331,31 - 2,6780 \text{ VARIÁVEL 45} - 0,02444 \text{ VARIÁVEL 56} + 0,03619 \text{ VARIÁVEL 28} \\ & - 0,0462 \text{ VARIÁVEL 111} - 0,000001 \text{ VARIÁVEL 157} + 0,00440 \text{ VARIÁVEL 120} \\ & - 0,000018 \text{ VARIÁVEL 158} + 0,000000 \text{ VARIÁVEL 134} - 0,000002 \text{ VARIÁVEL 150} \end{aligned}$$

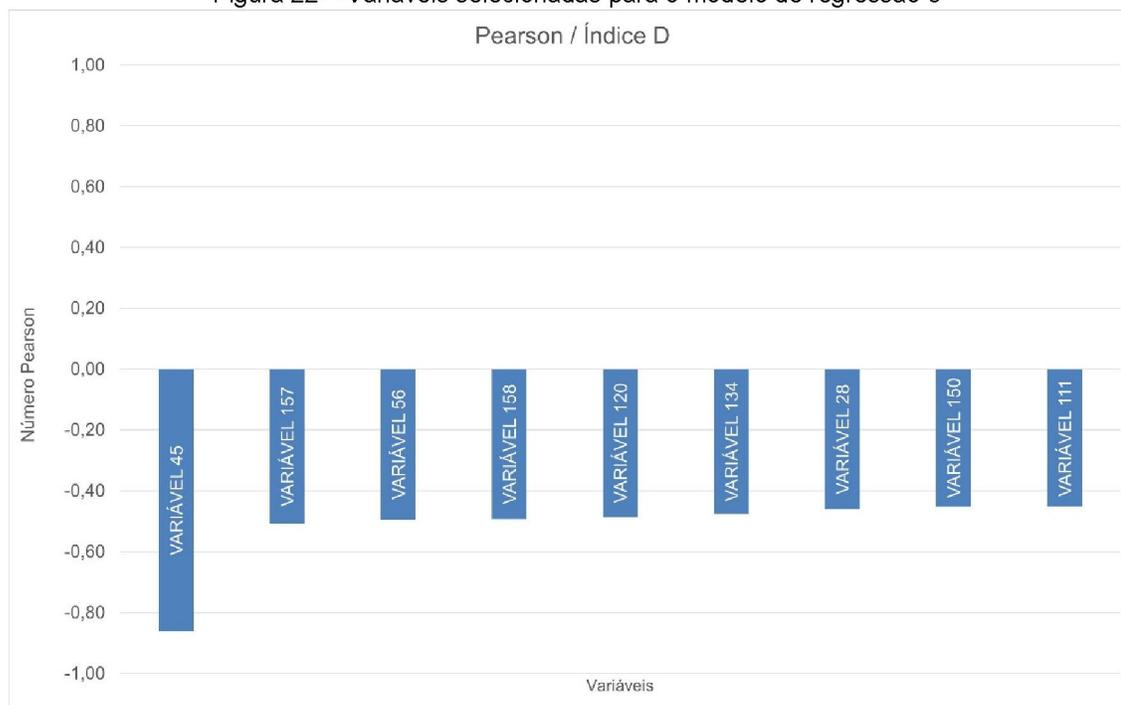
Na Tabela 5 apresenta-se o grau de explicação do modelo de regressão com relação ao Índice D através dos valores de R-quadrado (grau da força de relacionamento entre o modelo a variável resposta). Tanto o R-quadrado quanto o R-quadrado ajustado e predito apresentam valores bastante satisfatórios em termos de explicação do comportamento do Índice D através do modelo proposto (R-quadrado ~80%).

Tabela 5 – Sumário do modelo de regressão 3

R2	R2(ajustado)	R2(predito)
80,48%	80,06%	78,88%

FONTE: O Autor (2022), com Minitab

Figura 22 – Variáveis selecionadas para o modelo de regressão 3



FONTE: O Autor (2022), com Minitab

A Figura 23 representa os gráficos de resíduos resultantes dos ajustes realizados pelo software para determinar a equação de regressão. Também neste caso o histograma indicado na parte inferior da Figura 23 a esquerda visualmente é possível constatar a distribuição normal de resíduos como também o valor-p $>0,005$ indica que a hipótese de normalidade pode ser aceita o modelo é válido do ponto de vista estatístico.

Conforme previsto a retirada das variáveis 48, 93 e 129 por não trazer significância ao modelo praticamente não alterou a qualidade de explicação do mesmo (R-quadrados) nem mesmo a validação estatística de resíduos através do teste de normalidade.

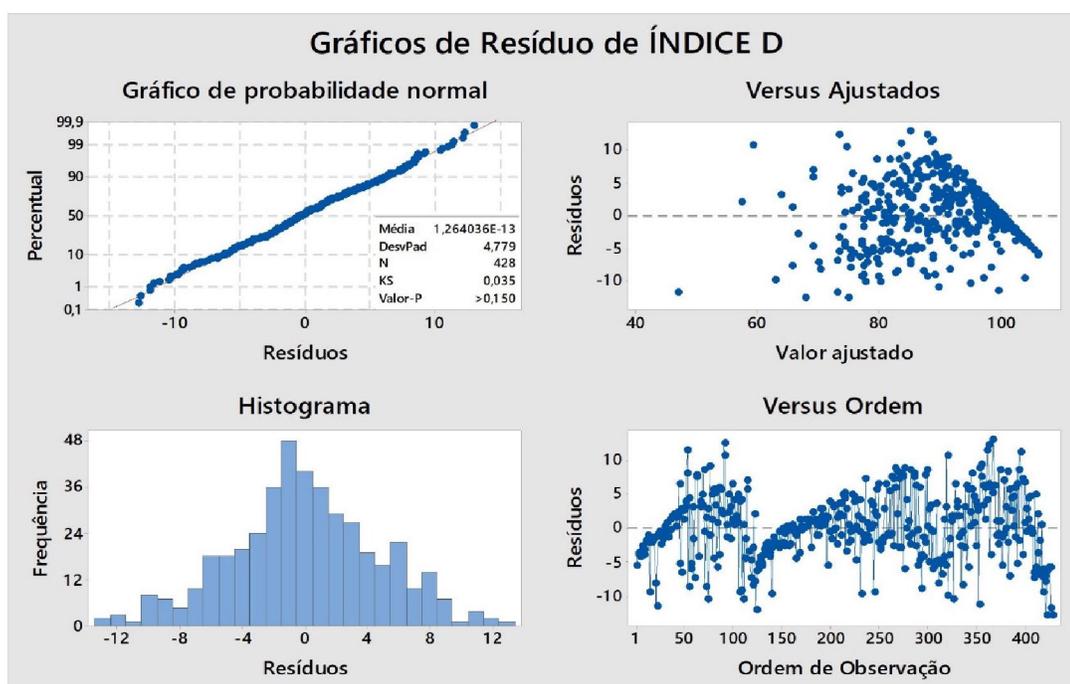
Adicionalmente na Figura 24 gerou-se através do software Minitab o efeito fatorial das variáveis com relação ao índice de desgaste. Este gráfico indica a influência positiva ou negativa do comportamento das variáveis com relação ao índice de desgaste.

Os comportamentos das variáveis se mantiveram inalterados conforme já visto no segundo estudo de regressão. Neste estágio das tentativas de modelagem

percebe-se que todas as variáveis selecionadas influenciam o comportamento do índice de desgaste de maneira significativa com exceção da variável 120.

Realizou-se novamente a análise de variância das variáveis através do Minitab resultados apresentados na Tabela 6.

Figura 23 - Gráficos de resíduos Índice D para o modelo de regressão 3



FONTE: O Autor (2022), com Minitab

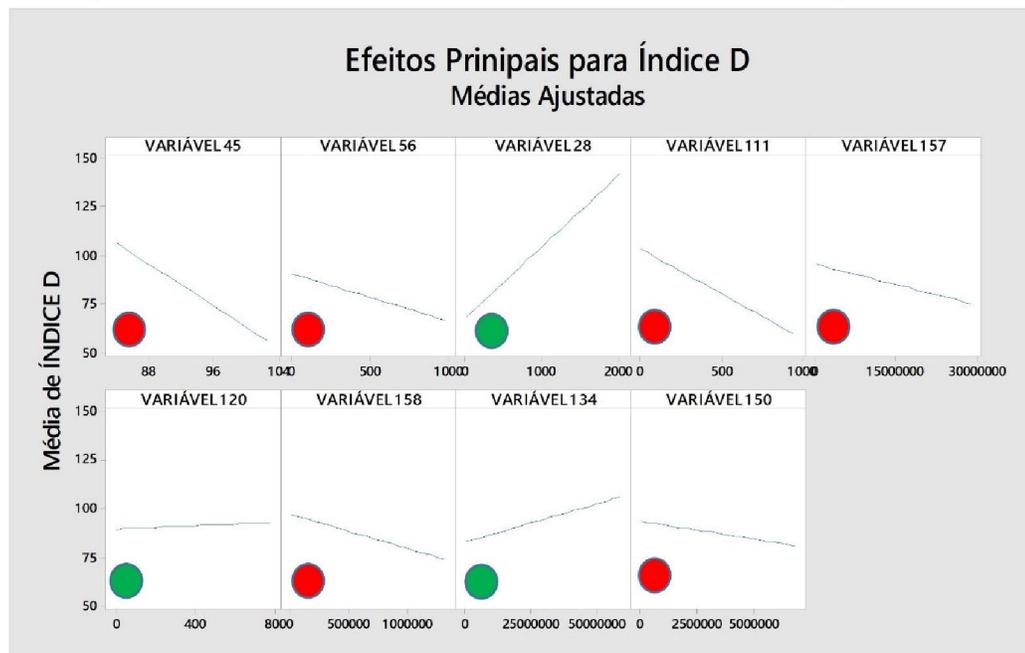
Tabela 6 – Análise de variância das variáveis

	Valor-P
Constante	
VARIÁVEL 45	0,000
VARIÁVEL 56	0,000
VARIÁVEL 28	0,000
VARIÁVEL 111	0,002
VARIÁVEL 157	0,008
VARIÁVEL 120	0,306
VARIÁVEL 158	0,000
VARIÁVEL 134	0,015
VARIÁVEL 150	0,011

FONTE: O Autor (2022), com Minitab

Confirma-se novamente o indicado na análise fatorial apresentada na Figura 24. Variável 120 apresenta variância Valor-p >0,005 indicando não ter significância para o modelo. Mesmo assim por consideramos que o nível de complexidade do modelo obtido através da regressão está bastante adequado mesmo com 9 variáveis e que a qualidade da predição que será obtida está bastante aceitável encerramos o processo nesta etapa.

Figura 24 – Efeito fatorial das variáveis com relação ao índice de desgaste modelo 3



FONTE: O Autor (2022), com Minitab

4.6.4 Nível de severidade através do modelo de regressão

Com o modelo de regressão ajustado pode-se prever o índice de desgaste do componente através com base no comportamento das 9 variáveis selecionadas. Ranges de severidade com base na variação do Índice D calculado podem ser estabelecidos para adaptar diferentes estratégias de manutenção do componente de acordo com o range de severidade ao qual ele pertence.

De maneira ilustrativa concluímos este estudo de caso sugerindo a criação de 3 ranges de severidade para os componentes estudados conforme ilustrado na Tabela 7.

Conhecendo-se o range de severidade a que o componente pertence seria possível determinar um fator de aumento da vida útil deste componente com relação ao ponto de manutenção convencional permitindo uma reordenação da ordem para manutenção preventiva. O fator de aumento da vida útil precisaria ser calibrado levando-se em conta o peso que o fator quilometragem percorrida teria com relação a severidade e a capacidade da oficina para executar manutenções preventivas. Neste ensaio levando em consideração os fatores indicados na Tabela 7 a aplicação do fator nível de severidade na estratégia de manutenção dos componentes traria um aumento da vida útil médio de 9,2%.

O reordenamento dos componentes para manutenção preventiva está representado na Desta forma executou-se um estudo de caso de uma base de componentes em operação no setor de veículos pesados em particular no transporte urbano de passageiros.

A relação estabelecida entre a variável de desgaste e as variáveis representativas da severidade da operação pode ser validada estatisticamente e reduzida em termos de complexidade através da redução do número de variáveis.

Figura 25. Os componentes com severidade nível A poderiam estender em 20% sua vida útil retardando o ponto de manutenção preventiva. Componentes do nível B estenderiam em 10% sua vida útil. Componentes do nível C sofreriam manutenção no ponto previsto pelo fator quilometragem por serem os de aplicação mais severa. Com isto a ordenamento dos componentes para manutenção não seria executado somente com o fator quilometragem percorrida, mas levando em conta estes fatores de acordo com o nível de severidade.

Tabela 7 – Níveis de severidade de acordo com índice de desgaste calculado

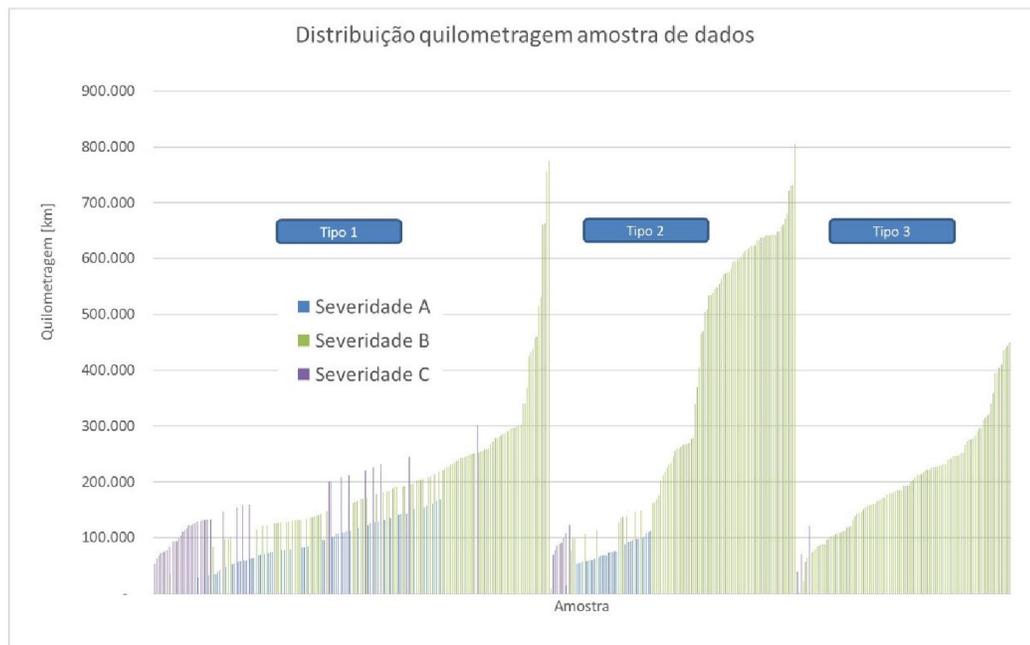
	Número de componentes	Aumento da vida útil antes da manutenção
Severidade nível A	50	+20%
Severidade nível B	293	+10%
Severidade nível C	85	=
Total	428	+9,20%

FONTE: O Autor (2022)

Desta forma executou-se um estudo de caso de uma base de componentes em operação no setor de veículos pesados em particular no transporte urbano de passageiros.

A relação estabelecida entre a variável de desgaste e as variáveis representativas da severidade da operação pode ser validada estatisticamente e reduzida em termos de complexidade através da redução do número de variáveis.

Figura 25 – Reordenamento manutenção preventiva com fator severidade



FONTE: O Autor (2022)

O estabelecimento de níveis de severidade da base de componentes permitiu um reordenamento na estratégia de manutenção preventiva que primariamente havia sido planejada com base somente na quilometragem total dos componentes proporcionando um ganho importante em termos de aproveitamento da vida útil disponível dos componentes.

5 CONCLUSÃO

Ao final do presente estudo pode-se afirmar que os objetivos estabelecidos foram alcançados já que através do estabelecimento de metodologia para análise de dados foi possível correlacionar o desgaste de um componente com dados relativos a sua operação aumentando a vida útil de um componente com base no refinamento de sua estratégia de manutenção.

Os resultados do estudo de caso confirmam a relevância do problema formulado e dos objetivos estabelecidos. Mesmo na etapa de seleção de variáveis com o entendimento da correlação entre variáveis e o nível de severidade a que os componentes estão expostos durante a operação como também na modelagem de uma equação de regressão que possibilitasse prever o nível de severidade com base no comportamento de um número bastante reduzido de variáveis. Foi possível determinar e validar este modelo matemático com sucesso.

A aplicabilidade prática e direta do modelo foi confirmada ao se determinar níveis de severidade na operação dos componentes e com isto sugerir uma nova ordem para a sua manutenção não mais limitada a quilometragem, mas também por um critério de desgaste. Este método pode auxiliar a priorização do reparo de equipamentos que mesmo com quilometragem percorrida abaixo da estratégia de manutenção preventiva adotada pode ter sido operado em condição de severidade extrema e com maior probabilidade de falha e manutenção não programada do que outros que operaram em condições menos severas.

5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Com a conclusão do trabalho existem alguns aspectos que podem ser aprofundados futuramente trazendo ainda mais robustez para o estudo ou até mesmo abrindo outros campos de desenvolvimento:

- O estudo de caso aplicado a um componente específico pode ser replicado para outros componentes de veículos do setor de veículos comerciais pesados;
- A análise fatorial das variáveis possibilitou estabelecer de maneira bastante ilustrativa certos níveis influência positiva ou negativa das variáveis com relação ao índice de desgaste dos componentes. Existe

bastante aplicação prática desta informação em termos de causa/efeito entre o uso do equipamento e a consequência em desgaste. Modelos de negócios baseados na servitização dos componentes poderiam ser estabelecidos a partir do entendimento desta influência;

- No cálculo do ganho com a aplicação do método para reordenar a manutenção dos componentes utilizou-se o viés de maior disponibilidade para operação. Outras abordagens são possíveis por exemplo custo do reparo custo da indisponibilidade levando em consideração o valor do veículo como um todo ou até mesmo da diminuição do risco de quebra pela ordenação correta dos componentes para manutenção.

REFERÊNCIAS BLIOGRÁFICAS

- ABNT. (1994). *NBR 5462: Confiabilidade e manutenibilidade*. Rio de Janeiro: ABNT.
- Aheleroff S. Xu X. Lu Y. Aristizabal M. Velásquez J. Joa B. & Valencia Y. (2020). IoT-enabled smart appliances under industry 4.0: A case study. *Advanced Engineering Informatics*.
- Ajay Kuma R. S. (2018). A big data driven sustainable manufacturing framework for condition-based maintenance prediction. *Journal of Computational Science* 27 428–439.
- Ansari F. Glawar R. & Nemeth T. (2019). PriMa: a prescriptive maintenance model for cyber-physical production systems. *International Journal of Computer Integrated Manufacturing* 32:4-5 482-503.
- Bartmann F. (1986). *Ideias Básicas do Controle Moderno de Qualidade*. Campinas: Unicamp.
- Calabrese M. Cimmino M. Fiume F. Manfrin M. Romeo L. Ceccacci S. . . . Kapetis D. (2020). SOPHIA: An Event-Based IoT and Machine Learning Architecture for Predictive Maintenance in Industry 4.0. *Information* 11 202.
- Campos M. S. (2003). *Desvendando o Minitab*. Rio de Janeiro: Qualitymark.
- Cattaneo L. Fumagalli L. Macchi M. & Negri E. (Junho de 2018). Clarifying Data Analytics Concepts for Industrial Engineering. *IFAC-PapersOnLine* 51(11) 820-825. Fonte: <https://www.sciencedirect.com/science/article/pii/S2405896318315672>
- Dalenogare L. S. Benitez G. B. Ayala N. F. & Frank A. G. (2018). The expected contribution of Industry 4.0 technologies for industrial performance. *International Journal of Production Economics* 204 383 - 394. doi:<https://doi.org/10.1016/j.ijpe.2018.08.019>
- David Sjödin V. P. (2020). An agile co-creation process for digital servitization: A micro-service innovation approach. *Journal of Business Research* 112 478–491.
- Deming W. (1982). *Out of the crisis*. Cambridge University Press - Syndicate of the University of Cambridge.

Diez-Olivan A. Del Ser J. Diego G. & Sierra B. (oct de 2018). Data Fusion and Machine Learning for Industrial Prognosis: Trends and Perspectives towards Industry 4.0. *Information Fusion* 50.

Ebeling C. E. (2019 2010 1997). *An Introduction to Reliability and Maintainability Engineering*. Long Grove: Waveland Press Inc.

Ge Z. Song Z. Ding S. X. & Huang B. (Setembro de 2017). Data Mining and Analytics in the Process Industry: The Role of Machine Learning. *IEEE Access* 5 20590 - 20616. Fonte: <https://ieeexplore.ieee.org/document/8051033>

Guo Y. Wang N. Xu Z.-Y. & Wu K. (2020). The internet of things-based decision support system for information processing in intelligent manufacturing using data mining technology. *Mechanical Systems and Signal Processing* 142 106630. Fonte: <https://www.sciencedirect.com/science/article/abs/pii/S0888327020300169>

Hastie T. Tibshirani R. & Friedman J. (2013). *The elements of statistical learning: data mining inference and prediction*. Standfort-CA-USA: Springer Science & Business Media. Fonte: <https://books.google.com.br/books?id=yPfZBwAAQBAJ>

Khan W. Z. Rehman M. H. Zangoti H. M. Afzal M. K. Armi N. & Salah K. (Jan de 2020). Industrial internet of things: Recent advances enabling technologies and open challenges. *Computers & Electrical Engineering*.

Lisboa M. Seixas R. d. Jesus E. R. Deschamps F. Valle P. & Strobel C. (2021). Improve Industrial Performance Based on Systematic Analyses of Manufacturing Data. *IFAC-PapersOnLine*.

Mann N. (1992). *Deming. As Chaves da Excelência*. São Paulo: Makron Books do Brasil Editora Ltda.

Marr B. (9 de march de 2015). *Big Data: Using SMART Big Data Analytics and Metrics To Make Better Decisions and Improve Performance*. New York New York USA: John Wiley & Sons. Fonte: https://books.google.com.br/books?id=p_glBgAAQBAJ

Mitchell T. (1997). *Machine Learning* (1 ed. Vol. 1). McGraw-Hill Science.

MOBLEY R. K. (2014). Manual de Engenharia de Manutenção. Em R. K. MOBLEY *Manual de Engenharia de Manutenção*. Nova Iorque Chicago São Francisco Lisboa Londres Madrid Cidade do México Milão Nova Deli San Juan Seul Singapura Sydney e Toronto.: McGrawhill. 8 ed.

Moens P. Bracke V. Soete C. Vanden Haute S. Avendano D. N. Ooijevaar T. . . .
Hoecke S. V. (2020). Scalable Fleet Monitoring and Visualization for Smart

Machine Maintenance and Industrial IoT Applications. *MDPI and ACS Style* 20 4308.

Montgomery D. (1991). *Introduction to Statistical Quality Control*. John Wiley & Sons.

Peres R. S. Rocha D. A. Leitão P. & Barata J. (Oct de 2018). IDARTS – Towards intelligent data analysis and real-time supervision for industry 4.0. *Computers in Industry* 101 13-146.

PROVOST F. & FAWCETT T. (2013). *Data Science for Business: What you need to know about data mining and data-analytic thinking* (2 ed. Vol. 1). Sebastopol California: O'Reilly Media Inc. Fonte:
https://books.google.com.br/books?id=EZAAtAAAAQBAJ&lr=&hl=pt-BR&source=gbs_navlinks_s

Qvist-Sorensen P. (Jun de 2020). Applying IIoT and AI - Opportunities Requirements and Challenges for Industrial Machine and Equipment Manufacturers to Expand Their Services. *Central European Business Review* 9 46-77.

Rafique D. & Velasco L. (2018). Machine Learning for Network Automation: Overview Architecture and Applications [Invited Tutorial]. *J. Opt. Commun. Netw.* D126--D143.

Ross S. (1987). *Introduction to Probability and Statistics for Engineers and Scientists*. John Wiley & Sons Inc.

Samuel A. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development* 3:3 210–229.

Shrouf F. Ordieres J. & Miragliotta G. (2014). Smart factories in Industry 4.0: A review of the concept and of energy management approached in production based on the Internet of Things paradigm. (I. E. (IEEM) Ed.) *IEEM International Industrial Engineering and Engineering Management* 697-701.
doi:10.1109/IEEM.2014.7058728

Taguchi G. (s.d.). *INTRODUCTION TO QUALITY ENGINEERING Designing Quality into Products and Process*. New York: Asian Productivity Organization Kraus International Publications.

Tan L. & Wang N. (2010). Future internet: The Internet of Things. *2010 3rd international conference on advanced computer theory and engineering (ICACTE)(IEEE) V5-376-V5-380*. Fonte:
<https://ieeexplore.ieee.org/document/5579543>

Teles J. (2019). Planejamento e controle da manutenção descomplicado: uma metodologia passo a passo para implantação do PCM. Em J. Teles *Planejamento e controle da manutenção descomplicado: uma metodologia passo a passo para implantação do PCM* (p. 240). Brasília: Engeteles.

Traini E. Bruno G. D'Antonio G. & Lombardi F. (2019). Machine learning framework for predictive maintenance in milling. *IFAC PapersOnLine 52-13* 177–182.

Viana H. R. (2014). PCM Planejamento e Controle da Manutenção. Em H. R. Viana *PCM Planejamento e Controle da Manutençã* (p. 192). Rio de Janeiro: Qualitymark Editora.

Viana H. R. (2020). Manual da gestão de manutenção. Em H. R. Viana. Brasília: Engeteles.

Wagire A. A. Rathore A. S. & Jain R. (2019). Analysis and synthesis of Industry 4.0 research landscape: Using latent semantic analysis approach. *Journal of Manufacturing Technology Management* 31-51. doi:10.1108/JMTM-10-2018-0349

Xu L. D. He W. & Li S. (Janeiro de 2014). Internet of Things in Industries: A Survey. *IEEE Transactions on Industrial Informatics* 10(4) 2233-2243. Fonte: <https://ieeexplore.ieee.org/document/6714496>

Zhang W. Wang H. & Yang D. (SEPTEMBER de 2019). Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. *IEEE SYSTEMS JOURNAL VOL. 13 NO. 3* 13 2213:2217.

Zhang Y. Ren S. Liu Y. & Si S. (January de 2017). A big data analytics architecture for cleaner manufacturing and maintenance processes of complex products. *Journal of Cleaner Production* 142(part 2) 626-641. Fonte: <https://www.sciencedirect.com/science/article/pii/S0959652616310198>

Zhe L. Yi W. & Ke-Sheng W. (2017). Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario. *Advances in Manufacturing*(n.4) pp. 377-387.

APÊNDICE 1 – LISTA DE ARTIGOS PESQUISADOS NA REVISÃO

Título do artigo	Autores	Contagem de citações	Ano de publicação	Fonte
Data fusion and machine learning for industrial prognosis: Trends and perspectives towards Industry 4.0	Díez-Oliván, A.; Del Ser, J.; Galar, D.; Sierra, B	218	2019	WebofScience
Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey	Zhang, WT.; Yang, D.; Wang, HC	113	2019	WebofScience
PrIMA: a prescriptive maintenance model for cyber-physical production systems	Ansari, F.; Glawar, R.; Nemeth, T	80	2019	WebofScience
Machine Learning for Network Automation: Overview, Architecture, and Applications (Invited Tutorial)	Rafique, D., Velasco, L.	74	2018	Scopus
APPLYING IIOT AND AI - OPPORTUNITIES, REQUIREMENTS AND CHALLENGES FOR INDUSTRIAL MACHINE AND EQUIPMENT MANUFACTURERS TO EXPAND THEIR SERVICES	Qvist-Sorensen, P	69	2020	WebofScience
An agile co-creation process for digital servitization: A micro-service innovation approach	Sjodin, D.; Parida, V.; Kohtamaki, M.; Wincent, J	65	2020	WebofScience
Data-driven predictive maintenance planning framework for MEP components based on BIM and IoT using machine learning algorithms	Cheng, JCP.; Chen, WW.; Chen, KY.; Wang, Q	58	2020	WebofScience
A big data driven sustainable manufacturing framework for condition-based maintenance prediction	Kumar, A.; Shankar, R.; Thakur, LS	56	2018	WebofScience
An Integrative Machine Learning Method to Improve Fault Detection and Productivity Performance in a Cyber-Physical System	Chiu, MC.; Tsai, CD.; Li, TL	53	2020	WebofScience
A Decision-Making Tool Based on Exploratory Visualization for the Automotive Industry	Redondo, R.; Herrero, A.; Corchado, E.; Sedano, J	50	2020	WebofScience
IoT-enabled smart appliances under industry 4.0: A case study	Aheleroff, S.; Xu, X.; Lu, YQ.; Aristizabal, M.; Velasquez, JP.; Joa, B.; Valencia, Y	49	2020	WebofScience
Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario	Li, Z.; Wang, Y.; Wang, KS	40	2017	WebofScience
Industrial Data-Driven Monitoring Based on Incremental Learning Applied to the Detection of Novel Faults	Saucedo-Dorantes, J.J.; Deigado-Prieto, M.; Osorio-Rios, RA.; Romero-Trocoso, RD	39	2020	WebofScience
SOPHIA: An Event-Based IoT and Machine Learning Architecture for Predictive Maintenance in Industry 4.0	Calabrese, M.; Cimmino, M.; Fiume, F.; Manfredi, M.; Romeo, L.; Ceccacci, S.; Paolanti, M.; Toscano, G.; Ciandrini, G.; Carrotta, A.; Mengoni, M.; Frontoni, E.; Kapetis, D	39	2020	WebofScience
IDARTS - Towards intelligent data analysis and real-time supervision for industry 4.0	Peres, RS.; Rocha, AD.; Leitao, P.; Barata, J	37	2018	WebofScience
Development of Advanced Manufacturing Cloud of Things (AMCoT)-A Smart Manufacturing Platform	Lin, Y.-C., Hung, M.-H., Huang, H.-C., Chen, C.-C., Yang, H.-C., Hsieh, Y.-S., Cheng, F.-T.	36	2017	Scopus
A Cloud-to-Edge Approach to Support Predictive Analytics in Robotics Industry	Panicucci, S.; Nikolakis, N.; Cerquitelli, T.; Ventura, F.; Proto, S.; Macii, E.; Makris, S.; Bowden, D.; Becher, P.; O'Mahony, N.; Morabito, L.; Napolone, C.; Marguglio, A.; Coppo, G.; Andolina, S	36	2020	WebofScience
Scalable Fleet Monitoring and Visualization for Smart Machine Maintenance and Industrial IoT Applications	Moens, P.; Bracke, Y.; Soete, C.; Vanden Haute, S.; Avendano, DN.; Ooljevaar, T.; Devos, S.; Volckaert, B.; Van Hoedle, S	36	2020	WebofScience
An Imbalanced Data Handling Framework for Industrial Big Data Using a Gaussian Process Regression-Based Generative Adversarial Network	Oh, E.; Lee, H	33	2020	WebofScience
Big data and stream processing platforms for Industry 4.0 requirements mapping for a predictive maintenance use case	Sahal, R.; Breslin, JG.; Ali, MI	33	2020	WebofScience
Industrial internet of things: Recent advances, enabling technologies and open challenges	Khan, WZ.; Rehman, MH.; Zangoti, HM.; Afzal, MK.; Armi, N.; Salah, K	31	2020	WebofScience
Deep digital maintenance	Rodseth, H.; Schjolberg, P.; Marhaug, A	30	2017	WebofScience
A Global Manufacturing Big Data Ecosystem for Fault Detection in Predictive Maintenance	Yu, WJ.; Dillon, T.; Mostafa, F.; Rahayu, W.; Liu, YH	28	2020	WebofScience
Predictive maintenance architecture development for nuclear infrastructure using machine learning	Gohel, HA.; Upadhyay, H.; Lagos, L.; Cooper, K.; Sanzetea, A	27	2020	WebofScience
Tool wear monitoring of a retrofitted CNC milling machine using artificial neural networks	Hesser, D.F., Markert, B.	15	2019	Scopus
Intelligent Choice of Machine Learning Methods for Predictive Maintenance of Intelligent Machines	Becherer, M.; Zipferle, M.; Karduck, A	15	2020	WebofScience
A hidden-Gamma model-based filtering and prediction approach for monotonic health factors in manufacturing	Susto, G. A., Schirru, A., Pampuri, S., Beghi, A., De Nicolao, G.,	12	2018	Scopus
Machine learning framework for predictive maintenance in milling	Traini, E., Bruno, G., D'Antonio, G., Lombardi, F.,	1	2019	Scopus
Enhancing maintenance with a data-driven approach	Ostrowski, J., Menyhart, J.	0	2019	Scopus