



INSTITUTO TECNOLÓGICO VALE



**Programa de Pós-Graduação em Instrumentação, Controle e
Automação de Processos de Mineração (PROFICAM)
Escola de Minas, Universidade Federal de Ouro Preto (UFOP)
Associação Instituto Tecnológico Vale (ITV)**

Dissertação

**APRENDIZADO DE MÁQUINA APLICADO A PREDIÇÃO DE FALHAS EM
CAMINHÃO FORA DE ESTRADA**

Aldilene Oliveira Maia Dias

**Ouro Preto
Minas Gerais, Brasil
2020**

Aldilene Oliveira Maia Dias

**APRENDIZADO DE MÁQUINA APLICADO A PREDIÇÃO DE FALHAS EM
CAMINHÃO FORA DE ESTRADA**

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. D.Sc. Frederico Gadelha Guimarães.

Coorientador: Prof. D.Sc. Agnaldo José da Rocha Reis.

Coorientador: Prof. D.Sc. Jodelson Aguilár Sabino.

Ouro Preto

2020

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

D541a Dias, Aldilene Oliveira Maia .

Aprendizado de máquina aplicado a predição de falhas em caminhão fora de estrada. [manuscrito] / Aldilene Oliveira Maia Dias. - 2020.
76 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Frederico Gadelha Guimarães.

Coorientadores: Prof. Dr. Agnaldo José da Rocha Reis, Prof. Dr. Jodelson Aguilar Sabino.

Dissertação (Mestrado Profissional). Universidade Federal de Ouro Preto. Programa de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração. Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração.

Área de Concentração: Engenharia de Controle e Automação de Processos Mineraiis.

1. Manutenção Preditiva. 2. Falhas de sistemas de computação - Caminhões - Caminhão Fora de Estrada. 3. Aprendizado do computador .
I. Guimarães, Frederico Gadelha. II. Reis, Agnaldo José da Rocha. III. Sabino, Jodelson Aguilar. IV. Universidade Federal de Ouro Preto. V. Título.

CDU 681.5:622.2

Bibliotecário(a) Responsável: Maristela Sanches Lima Mesquita - CRB-1716



FOLHA DE APROVAÇÃO

Aldilene Oliveira Maia Dias

Aprendizado de Máquina Aplicado a Predição de Falhas em Caminhão Fora de Estrada

Membros da Banca

Frederico Gadelha Guimarães – Doutor – Universidade Federal de Minas Gerais
Agnaldo José da Rocha Reis – Doutor - Universidade Federal de Ouro Preto
Jodelson Aguilar Sabino – Doutor – Vale SA
Rodrigo César Pedrosa Silva – Ph.D. - Universidade Federal de Ouro Preto
Roberto Gomes Ribeiro – Doutor – Bolsista do Instituto Tecnológico Vale
Petrônio Cândido de Lima e Silva – Doutor - Instituição Federal do Norte de Minas Gerais

Versão final

Aprovada em 11 de Setembro de 2020

De acordo,

Agnaldo José da Rocha Reis (p/ Frederico Gadelha Guimarães).



Documento assinado eletronicamente por **Agnaldo Jose da Rocha Reis**, **COORDENADOR(A) DO CURSO DE PÓS-GRADUAÇÃO EM INSTRUMENTAÇÃO, CONTROLE E AUTOMAÇÃO DE PROC DE MINERAÇÃO**, em 10/12/2020, às 22:43, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0113879** e o código CRC **44D52FEE**.

Referência: Caso responda este documento, indicar expressamente o Processo nº 23109.007768/2020-53

SEI nº 0113879

R. Diogo de Vasconcelos, 122, - Bairro Pi lar Ouro Preto/MG, CEP 35400-000
Telefone: - www.ufop.br

*A Deus, meu amor, meu temor,
meu respeito, meu guia e
minha luz.*

*Ao meu amado pai (in
memoriam), caráter inspirador.*

*À minha amada mãe, minha
guerreira, meu sinônimo de
amor.*

*A meus irmãos e sobrinhos,
alegrias constantes.*

*Ao meu marido, presente de
Deus.*

*A meus sogros, carinho e
acolhimento permanentes.*

A meus cunhados.

*A meus amigos de curso e de
vida.*

Agradecimentos

Agradeço à Deus pela vida e pela saúde. Meu grande e verdadeiro Amor.

Aos meus pais, valiosos seres humanos, meus maiores e melhores orientadores na vida.

Ao meu esposo, Marcelo Bruno Dias, por seu amor incondicional. Sou muito grata pelo seu apoio nas horas difíceis, bem como nas felizes. Você é muito importante para mim.

Aos meus irmãos e cunhados, por serem verdadeiros amigos e grandes companheiros.

Aos meus sobrinhos, que me mostram a cada dia a maneira mais simples de ser feliz. Eterna gratidão, ao meu orientador Frederico Gadelha e aos meus coorientadores Agnaldo Reis e Jodelson Sabino, pelo acompanhamento, pelas correções enriquecedoras e pela atenção prestada.

Aos professores do curso, que me orgulho de ter sido aluna, pelo brilhantismo ao me ensinarem a base teórica desta dissertação, particularmente, ao professor Thiago Euzébio, por todo apoio e ajuda na definição do tema dessa pesquisa.

Aos membros da banca examinadora, pela contribuição.

Ao Amaury de Mello, Júlio Correa, Fagner Feitosa e Chuquerth Oliveira, pela disponibilização dos dados utilizados neste trabalho, pelos esclarecimentos e atenção doados.

Em especial, aos amigos Marcello Araújo, Rodrigo Pastl, André Santos, Danielle Furtado, Patricia Meireles e Júlio César Moreira (in memoriam) por terem compartilhado seu conhecimento e contribuir no meu desenvolvimento.

A todos que de alguma forma contribuíram positivamente para esta conquista.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código de Financiamento 001; do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); e da Vale SA.

*“Àquele que, pela virtude que
opera em nós, pode fazer
infinitamente mais do que tudo
quanto pedimos ou
entendemos”
(Efésios 3:20).*

Resumo

Resumo da Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

APRENDIZADO DE MÁQUINA APLICADO A PREDIÇÃO DE FALHAS EM CAMINHÃO FORA-DE-ESTRADA

Aldilene Oliveira Maia Dias

Setembro, 2020

Orientadores: Frederico Gadelha Guimarães

Agnaldo José da Rocha Reis.

Jodelson Aguilar Sabino.

No setor mineral, o caminhão fora de estrada é o meio mais difundido de transporte de minério. Trata-se de um equipamento composto por vários componentes, tornando complexas atividades de manutenção. Este trabalho navega no campo da análise preditiva, como apoio na tomada de decisão do processo de manutenção destes ativos. A proposta envolve modelar um preditor de falhas, que subsidie o planejamento e a programação de eventos de manutenção. Isso reduz a indisponibilidade não programada do equipamento, aumenta o tempo médio entre falhas e embasa a manutenção por condição. Esta estratégia gera ganhos de confiabilidade, aumento no desempenho operacional, financeiro e na competitividade do negócio. Definiu-se a variável-alvo como “tempo para falha do caminhão” e assumiu-se a referência de 20 dias. Diversos algoritmos foram experimentados (RNA, XG Boost AS, C&R Tree, C5.0, CHAID 1) e obteve-se o melhor resultado com o XG Boost AS. O modelo experimental indica a falha no caminhão 20 dias antes, com uma precisão média de 97,90% e recall de 64,17%.

Palavras-chave: manutenção preditiva, caminhão fora de estrada, aprendizado de máquina.

Macrotema: Mina; **Linha de Pesquisa:** Tecnologias da Informação, Comunicação e Automação Industrial; **Tema:** Manutenção Preventiva, Preditiva e Corretiva; **Área Relacionada da Vale:** Mina de Carajás.

Abstract

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and Automation of Mining Process as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

MACHINE LEARNING APPLIED TO FAULT PREDICTION IN OFF-ROAD TRUCKS

Aldilene Oliveira Maia Dias

September, 2020

Advisors: Frederico Gadelha Guimarães

Agnaldo José da Rocha Reis.

Jodelson Aguilar Sabino.

In the mining sector, the off-road truck is the most widespread means of transporting ore. It is an equipment composed of several components, making maintenance activities complex. This work navigates in the field of predictive analysis, as support in the decision making of the maintenance process of these assets. The proposal involves modeling a failure predictor, which supports the planning and scheduling of maintenance events. This reduces unscheduled equipment downtime, increases the average time between failures and supports maintenance by condition. This strategy generates revenue gains, improves operational and financial performance and business results. The target variable was defined as “time for truck failure” and was used as a 20-day reference. Several algorithms were tried (RNA, XG Boost AS, C&R Tree, C5.0, CHAID 1) and the best result was obtained with XG Boost AS. The experimental model indicates failure of the truck 20 days earlier, with an average accuracy of 97.90% and recall of 64,17%.

Keywords: predictive maintenance, off-road truck, machine learning.

Macrotheme: Mine; **Research Line:** Information Technologies, Communication and Industrial Automation; **Theme:** Preventive, Predictive and Corrective Maintenance;

Related Area of Vale: Mine of Carajás.

Lista de Figuras

Figura 2.1: Estrutura visual de uma árvore de decisão genérica.....	24
Figura 2.2: Pseudo-código de implementação da Smote.....	30
Figura 2.3: Matriz de confusão	31
Figura 4.1: Análise descritiva do atributo dias para falhar.....	53
Figura 5.1: Registros de falha e de operação no conjunto de dados após tratamento inicial.	56
Figura 5.2: Partições de treinamento e teste e proporções de classes de registros.....	56
Figura 5.3: Divisão de classes de dados entre partições de treinamento e teste.....	56
Figura 5.4: Distribuição de amostras segundo atributo “dias para falhar”.	57
Figura 5.5: Base de dados após execução do balanceamento.....	58

Lista de Tabelas

Tabela 4.1: Códigos de diagnóstico com gravidade da condição anormal do sistema.....	49
Tabela 4.2: Código do evento com sua descrição e apresentação das possíveis causas e respostas recomendadas.....	50
Tabela 4.3: CID – Código de identificação do componente relacionado a falha.....	50
Tabela 4.4: FMI - Identificação dos modos de falha e a exibição no display de mensagens.....	51
Tabela 5.1: Modeladores do nó <i>auto classifier</i>	59
Tabela 5.2: Ranking de modelos de nó <i>auto classifier</i>	64
Tabela 5.3: Configurações da árvore XGBOOST-AS para falha em até 10 dias e 20 dias.	65
Tabela 5.4: Resultados das configurações 1 a 8 na etapa de validação.....	66
Tabela 5.5: Resultados das configurações da Árvore XGBoost-AS nas etapas de validação e teste.....	67
Tabela 5.6: Matrizes de Confusão dos modelos RNA, CHAID e XGBoost.....	68
Tabela 5.7: Métricas consolidadas após validação dos modelos de CHAID, RNA e XGBoost-AS.....	68

Lista de Siglas e Abreviaturas

ACC: Precisão

AUC: Acurácia

AD: Árvores de Decisão

AM: Aprendizado de Máquina

CHAID: *Chi-Squared Automatic Interaction Detection*

CID: *Component Identifier* (Código de identificação do componente relacionado a falha)

CRT: *Classification and Regression Tree*

ECM: *Electronic Control Module*

FN: Falso negativo

FP: Falso positivo

FMI: *Fail Mode Identifier*

GBM: Máquinas de Aumento de Gradiente

IA: Inteligência Artificial

ITV: Instituto Tecnológico Vale

KNN: K Vizinhos mais próximos

LSVM: *Linear Support Vector Machine*

MID: *Module Identifier*

OM: Ordem de Manutenção

RNA: Redes Neurais Artificiais

REC: *Recall* ou Revocação ou Sensibilidade

SMOTE: Técnica para Sobre Amostragem de Minoritários Sintéticos

TAN: *Tree Augmented Naïve Bayes*

TDIDT: Árvore de Decisão com Indução de Cima para Baixo

SVM: Máquina de Vetores de Suporte

VP: Verdadeiro positivo

VN: Verdadeiro negativo

XGBoost: Aumento de Gradiente Extremo

Sumário

CAPÍTULO 1 : INTRODUÇÃO.....	15
1.1. Justificativa.....	17
1.2. Objetivos	19
1.2.1. Objetivo Geral	19
1.2.2. Objetivos Específicos.....	19
1.3. Estrutura do trabalho.....	19
CAPÍTULO 2 : REVISÃO BIBLIOGRÁFICA	21
2.1. Aprendizado de Máquina.....	21
2.2. Fundamentos de Árvores de Decisão (AD).....	23
2.3. Implementação de Árvores de Decisão (AD)	25
2.4. Árvore de decisão XGBoost.....	27
2.5. Balanceamento de Dados com SMOTE.....	29
2.6. Matriz de Confusão – Avaliação de Performance	31
2.6.1. Métricas da Avaliação	32
CAPÍTULO 3 : PROCESSO DE MANUTENÇÃO.....	34
3.1. Conceito e Tipos de Manutenção.....	34
3.1.1. Tipos de Manutenção.....	36
3.2. Predição de Falhas em Equipamentos Industriais	41
CAPÍTULO 4 : ESTUDO DE CASO.....	45
4.1. Entendimento do Negócio	45
4.2. Compreensão dos dados	47
4.3. Preparação dos Dados.....	51
4.4. Modelagem.....	54
CAPÍTULO 5 : RESULTADOS E DISCUSSÕES	55

5.1. Cenário 1: Treino com o <i>Auto Machine Learning</i>	55
CAPÍTULO 6 : CONCLUSÃO	70
6.1. Trabalhos Futuros	71
REFERÊNCIAS	73

CAPÍTULO 1 : INTRODUÇÃO

A sobrevivência nos mercados exige das empresas a constante busca pelo aprimoramento do desempenho de suas operações (HIPKIN & DE COCK, 2000). Neste contexto, um bom processo de manutenção representa um diferencial competitivo estratégico. Segundo a Associação Brasileira de Normas Técnicas, manutenção é a “combinação de todas as ações técnicas e administrativas, incluindo as de supervisão, destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida” (ABNT, 1994). Outra definição é de que manutenção é uma forma de “garantir a disponibilidade da função dos equipamentos e instalações de modo a atender a um processo de produção e à preservação do meio ambiente, com confiabilidade, segurança e custo adequados” (KARDEC & NASCIF, 2001).

No âmbito nacional brasileiro, segundo Xenos (1998) destaca-se que, apesar da atividade de manutenção em equipamentos e instalações industriais ser praticada há anos, em muitos negócios ainda é corriqueiro encontrar-se pessoas envolvidas no setor que não conhecem a essência de suas próprias atividades profissionais e atrapalham-se com termos relacionados à manutenção. Além disso, a falta de entendimento claro e uniforme das principais atividades de manutenção e do racional envolvido nelas, que se constituíram funções básicas por muito tempo nas organizações, serviram para gerar a submissão das atividades de manutenção a funções sem muita importância. Embora pareça algo secundário, está desvalorização das principais atividades de manutenção custa muito à organização por levar a práticas de manutenção ineficientes e inadequadas, que geram um custo maior e, por consequência, degradam o desempenho dos processos produtivos.

Uma grande mineradora brasileira se utiliza de muitas máquinas e equipamentos para uma produção bem-sucedida. Falhas nesses ativos geram as mais variadas consequências. Se em alguns casos o prejuízo resultante não passa do custo de manutenção do equipamento, em outros pode chegar a comprometer a lucratividade da empresa devido a perdas de produção, acidentes e agressões ambientais.

As atividades de manutenção necessitam assegurar que o equipamento continue a desempenhar as funções para as quais foram projetadas. Porém, a degradação do mesmo é inevitável, pois são causados pelo tempo de uso e o desgaste natural. Por outro lado, o gerenciamento das atividades de manutenção não deve ter seu escopo reduzido a apenas manter as condições originais dos equipamentos. As atividades de melhoria requerem ações específicas, tanto em nível técnico, como gerencial (MARÇAL, 2004).

A manutenção de equipamentos inclui atividades relacionadas ao tratamento de falhas, inspeções, reparos, investigações das causas e, também, estabelecimento de contramedidas para sua reincidência (BRITTO & PEREIRA, 2003). Estas atividades, porém, devem ser esporádicas e não podem se transformar na principal função do setor de manutenção.

A manutenção puramente corretiva há muito deixou de ser suficiente no ambiente competitivo de negócios, sendo necessário um grande e continuado esforço para aumento da confiabilidade e para a redução de custos na manutenção de todos os ativos. Desta forma, a manutenção deixou de ser uma simples atividade de reparo e se transformou em um meio essencial ao alcance dos objetivos e metas da organização. Coloca-se, estrategicamente, como parte fundamental do processo produtivo em um ambiente onde, cada vez mais, se utilizam equipamentos de última geração, com maior grau de complexidade, alto custo e muitas exigências de manutenção.

Como dito, equipamentos parados inoportunamente comprometem a produção e podem significar perdas irre recuperáveis frente a concorrência. A maior complexidade dos equipamentos e diversidade dos ativos fez da manutenção uma função igualmente complexa, levando ao desenvolvimento de novas técnicas e ferramentas modernas de monitoramento e de gestão, com abordagens inovadoras quanto à organização e à estratégia de manutenção. Gerenciar corretamente esses modernos meios de produção exige conhecimentos de métodos e sistemas de planejamento e de execução, que sejam ao mesmo tempo eficientes e economicamente viáveis. Além do caráter tecnológico envolvido neste processo, a mudança exige também novas atitudes e habilidades das equipes de manutenção. É preciso, sobretudo uma visão

sistêmica do negócio, espírito de equipe e disposição de mudar paradigmas e assumir desafios. Portanto, a manutenção bem planejada dos equipamentos traz benefícios relevantes para a organização, ampliando-se o ciclo de vida dos equipamentos e a eficiência da organização. Também, um equipamento bem conservado tem valor venal maior e uma aceitação mais rápida em caso de venda. Diante destas considerações, percebe-se que uma gestão adequada da manutenção se constitui em importante fator de competitividade organizacional, sobretudo para organizações mais sensíveis à confiabilidade de seus equipamentos.

Segundo Tavares (1999), a difusão da informática (a partir de 1966) possibilitou o desenvolvimento de sistemas de gerenciamento da manutenção e de critérios de previsão das falhas. Deste modo, os avanços tecnológicos ocorridos desde então possibilitaram a aplicação de novos métodos e a uma organização nos processos industriais, mais adequados à constante busca pela excelência em seus processos operacionais.

O baixo desempenho de alguns componentes de sistemas chave em caminhões fora de estrada resulta em diversos problemas, como o custo elevado de reforma já que a mesma tem seu valor aumentado quando o componente é substituído após uma quebra catastrófica (corretiva), assim como provoca um maior tempo de máquina parada resultando em indisponibilidade do equipamento para operação. Sendo o caminhão um dos equipamentos de grande valor para o processo de planejamento de lavra a céu aberto, para uma excelente gestão nestes ativos, este trabalho tem como objetivo desenvolver um algoritmo capaz de prever as falhas nestes ativos, resultando em grandes benefícios para o processo de gestão da manutenção de caminhões fora de estrada.

1.1. Justificativa

Um dos processos críticos na extração do minério de ferro em Serra Norte, na província mineral de Carajás, é o traslado do minério bruto da frente de lavra até a alimentação do processo de beneficiamento. Obviamente, interromper este processo prejudica a produção mineral. Ou seja, é necessário garantir a disponibilidade dos caminhões fora de estrada, utilizados para este transporte, de maneira confiável.

Por este motivo, este trabalho pode trazer benefícios ao negócio pelo auxílio a uma tomada de decisão de manutenção mais efetiva. O alto custo por perda de produção em função de imprevistas nestes equipamentos é cada vez mais inaceitável.

Alternativamente, se a degradação de desempenho dos equipamentos puder ser avaliada e o tempo até sua falha puder ser previsto, então uma decisão de manutenção *just-in-time* conservará a confiabilidade do ativo na entrega do minério ao processo de beneficiamento. Essa é a chamada "manutenção proativa" buscada há muito tempo pela indústria. Com a ajuda desta, as decisões de manutenção podem ser tomadas com precisão e eficácia, de modo que a perda de produção e a interrupção dos serviços possam ser minimizadas.

Além disso, investir em formas de prever as falhas nos equipamentos diretamente ligados a produção é de suma importância. Isso porque, além de reduzir os custos de produção, essa prática também possibilita uma produção mais eficiente e sustentável.

O conhecimento prévio quanto à utilização de aprendizado de máquina, para predição de falhas em equipamentos móveis de mineração, foi feita com uma revisão na literatura. A maior parte das pesquisas encontradas envolviam soluções em manutenção preditiva de equipamentos rotativos industriais usando ferramentas da indústria 4.0, para um monitoramento *on-line* do equipamento ou a utilização de técnicas de análise de vibrações mecânicas, que permitiam desenvolver métodos de antecipação à falha, realizar diagnósticos de operação das máquinas rotativas (PESTANA-VIANA, et al., 2016) ou usar classificadores *K-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM) e *Extreme Gradient Boosting* (XGBoost) para diagnosticar as falhas (ROCHA, 2018).

Importante destacar que, além da contribuição para o meio acadêmico na identificação de particularidades do processo de análise de ocorrência de falhas em caminhões fora de estrada com capacidade de 400 toneladas e sua relação com os sinais vitais do equipamento, esta dissertação também se justifica por apresentar resultados que colaboram com o planejamento das manutenções desses caminhões, podendo ser expandido para os demais modelos de equipamentos móveis de mina, replicando todos os ganhos relativos já citados.

1.2. Objetivos

1.2.1. Objetivo Geral

Analisar algoritmos de classificação na predição de falhas em caminhões fora de estrada com base nos sinais vitais de cada caminhão e o histórico de falhas ocorridos nestes ativos no mesmo intervalo de tempo com o objetivo de produzir um classificador capaz de indicar, com boa aproximação, se em 20 dias haverão falhas nos caminhões.

1.2.2. Objetivos Específicos

Os objetivos específicos são:

- Analisar diferentes configurações dos modelos de classificadores XGBoost, *Chi-Squared Automatic Interaction Detection* (CHAID), C5.0, Redes Neurais Artificiais (RNA) e *Classification and Regression Tree* (CRT) a fim de encontrar a configuração que conduz a melhores resultados na predição das falhas nos caminhões fora de estrada;
- Identificar qual dos modelos XGBoost, CHAID, C5.0, RNA, e CRT, apresentou maior competência em prever falhas nos caminhões fora de estrada;
- Identificar possíveis melhorias nos processos que envolvem as análises dos sinais vitais e os apontamentos de falhas dos caminhões fora de estrada;
- Contribuir com o planejamento futuro das manutenções dos caminhões fora de estrada.

1.3. Estrutura do trabalho

O trabalho é apresentado em 6 capítulos. O Capítulo 1 fornece um breve explicativo do problema a ser tratado ao longo da dissertação e os modelos que serão desenvolvidos. O Capítulo 2 apresenta um referencial teórico com o conteúdo básico necessário para a realização do trabalho. O Capítulo 3 relaciona trabalhos de

manutenção em equipamentos industriais. Já o Capítulo 4 descreve materiais e métodos para o levantamento e o tratamento de dados históricos, como as falhas ocorridas nos caminhões fora de estrada, correlacionando-os aos registros de sinais vitais. No Capítulo 5 são apresentados os resultados experimentais das análises das configurações investigadas: XGBoost, CHAID, RNA e a comparação entre os três modelos de predição. Por fim, no Capítulo 6 são apresentadas as conclusões e as possibilidades de trabalhos futuros.

CAPÍTULO 2 : REVISÃO BIBLIOGRÁFICA

Os conceitos de aprendizado de máquina são vastos e diversos. Este trabalho faz uma abordagem por meio da técnica de Árvores de Decisão (AD). Neste capítulo são apresentados os conceitos de AD, com enfoque no tipo XGBoost. Explica-se também a Synthetic Minority Over-sampling Technique (SMOTE) usada para balancear a proporção de amostras de diferentes classes de dados, nos conjuntos de dados selecionados (seja para treinamento ou teste). Além disso, explica-se como funciona a Matriz de Confusão (MC) usada para avaliação dos resultados do algoritmo de predição.

2.1. Aprendizado de Máquina

Algoritmos de Aprendizado de Máquina (AM) são úteis para solucionar diferentes problemas como: mineração em grandes conjuntos de dados para encontrar regularidades implícitas valiosas (exemplo, regras gerais para análise de crédito financeiro); domínios mal compreendidos, onde humanos não têm o conhecimento necessário para desenvolver algoritmos efetivos (caso do reconhecimento facial por imagens); e domínios em que o programa deve se adaptar dinamicamente a mudanças (MITCHELL, 1997).

Estes algoritmos convergem inúmeras áreas do conhecimento: Inteligência Artificial (IA), Probabilidade e Estatística, Complexidade Computacional, Teoria da Informação, Psicologia, Neurobiologia e Teoria de Controle. Unindo vários conceitos, constroem modelos capazes de adquirir conhecimento a partir de um conjunto de dados.

Um conjunto de dados é composto por registros (neste trabalho, também designados como dados, objetos, exemplos ou padrões) descritos individualmente por atributos (também denominados aqui como características, campos ou variáveis) observáveis e independentes, com domínios que podem ser contínuos (numéricos) ou discretos (categóricos). A cada um desses exemplos pode ser atribuída uma classe, de um conjunto finito de classes possíveis. A classe é uma variável dependente e seu valor é determinado a partir dos valores das respectivas características independentes.

Uma parte dos exemplos do conjunto de dados é selecionada para treinamento do algoritmo e desses “dados de treinamento” faz-se a inferência indutiva, que gera hipóteses verdadeiras e falsas (ALPAYDIN, 2004) (MONARD & BARANAUSKAS, 2003). Todo algoritmo de aprendizado, ou de indução (ou, simplesmente, “indutor”) possui um *bias* indutivo, que é a preferência de uma hipótese sobre outra dentre as hipóteses consistentes com os dados. Esse aprendizado indutivo pode ser dividido em supervisionado, não-supervisionado e semi-supervisionado (CHAPELLE, SCHOLKOPF, & ZIEN, 2006).

No aprendizado supervisionado, as classes dos objetos dos conjuntos de dados são conhecidas. Quando o domínio de classes é discreto define-se como um problema de classificação, quando é numérico como um problema de regressão (também conhecido como de aproximação de funções).

Classificação é a tarefa de aprender uma função alvo, relacionando cada conjunto de atributos (ou seja, cada exemplo) a uma das classes pré-definidas da função alvo (TAN, STEINBACH, & KUMAR, 2005). Em um problema deste tipo, cada um dos dados de entrada podem ser descritos pelo par ordenado (\bar{x}_n, y_p) , onde \bar{x}_n é um vetor que representa os atributos preditivos dos objetos, $\bar{x}_n = (\bar{x}_{n1}, \bar{x}_{n2}, \bar{x}_{n3} \dots \bar{x}_{nm})$, e y_p são os rótulos das classes a que esses objetos pertencem. Portanto, esta análise é capaz de gerar um mapeamento (através de uma função f) entre os exemplos de um conjunto de dados \bar{x}_n e um conjunto de classes y_p .

Conforme visto em Tan, Steinbach, & Kumar (2005), diferentes técnicas de aprendizado de máquina são aplicadas a problemas de classificação, através de diferentes algoritmos, para construir um modelo (classificador) capaz de inferir a classe dos objetos com base em atributos preditivos. O maior desafio é encontrar aqueles com boa capacidade de generalização, ou seja, que produzam modelos com altas taxas de acerto na classificação de exemplos que não compuseram o conjunto de dados de treinamento usado durante a modelagem.

Os classificadores também devem ser avaliados quanto a facilidade de interpretação das informações geradas no mapeamento. Quanto a isso, eles são tipificados como caixas-pretas ou como orientados a conhecimento. Os primeiros são mais difíceis de interpretar por terem acesso limitado a representação interna das

características que os levam a dedução das classes, enquanto os últimos criam estruturas simbólicas mais compreensíveis da lógica dedutiva utilizada. As RNA são um classificador tipo caixa-preta e as AD são um classificador orientado a conhecimento (MONARD & BARANAUSKAS, 2003).

O modelo de aprendizado pode ser descritivo ou preditivo. O descritivo é útil para gerar um modelo a ser usado como ferramenta de distinção de classes. Esta técnica serve para se conhecer os principais valores dos atributos (características) dos exemplos associados a determinadas classes. Nesta modelagem é muito importante uma classificação orientada a conhecimento, facilitando a visualização do motivo do objeto pertencer a certa classe.

O modelo preditivo é usado para exemplos de classes desconhecidas. A técnica preditiva consegue gerar modelos capazes de classificar objetos que não faziam parte dos dados de treinamentos. Dependendo da área de aplicação, a importância da facilidade de interpretação da classificação do objeto é menos determinante, podendo-se usar até mesmo classificadores tipo caixa-preta.

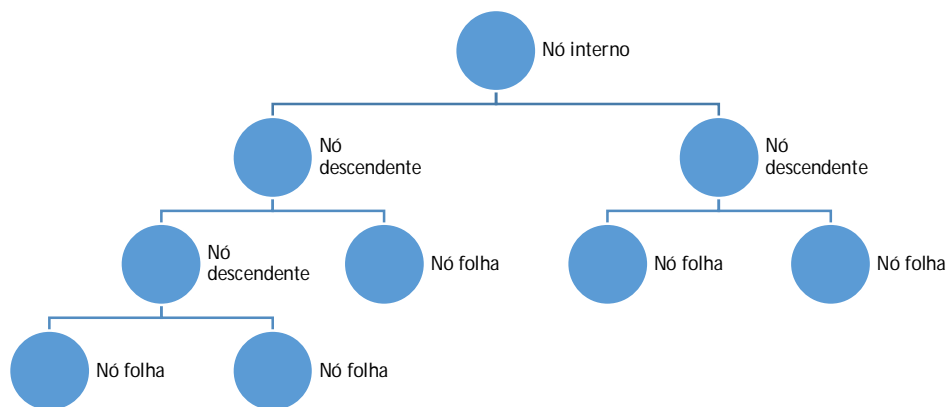
Existem inúmeras possibilidades de representação do conhecimento adquirido por um modelo de classificação. Alguns exemplos são as regras de decisão, as AD, o algoritmo Naive-Bayes, as redes bayesianas, o algoritmo k-vizinhos mais próximos (KNN), a Máquina de Vetor de Suporte (SVM) e as RNA. A AD foi a representação escolhida para o problema analisado neste trabalho.

2.2. Fundamentos de Árvores de Decisão (AD)

As AD são maneiras de representar conhecimentos formalizados. Por meio da concatenação de regras encadeadas de maneira clara e lógica, cria-se um modelo viável e capaz de prever o valor de uma classe desconhecida, apenas com base no conjunto de variáveis dos objetos de entrada. Estas representações são muito poderosas e têm sido amplamente utilizadas para criação de classificadores de predição. Uma das razões para isso é por elas apresentarem o conhecimento adquirido por meio de regras, que podem ser expressas em linguagem natural, o que facilita a interpretação e a análise dos seus resultados.

A AD soluciona um problema de classificação por meio da estruturação de uma hierarquia de regras, interconectadas por um conjunto de nós (Figura 2.1). Cada “nó interno” avalia um atributo de entrada com uma constante de decisão e determina para qual próximo “nó descendente” (ou “nó filho”) o atributo deve seguir, enquanto o “nó folha” é a saída da árvore, que classifica as instâncias que o atingem, conforme o rótulo associado a ele. Dessa maneira, o conhecimento em uma árvore de decisão é representado por cada nó, que ao serem testados, conduzem a busca por nós subsequentes, até chegarem em um “nó folha” (BORGES, 2013).

Figura 2.1: Estrutura visual de uma árvore de decisão genérica.



Fonte: O autor (2020)

As características mais relevantes da representação de AD, que estimulam seu uso, são a sua precisão, velocidade, robustez, escalabilidade, interpretabilidade e flexibilidade (BORGES, 2013). Ela gera modelos capazes de avaliar ou prever classes e agrupamentos de dados de modo ágil e com regras bem definidas, pois uma vez construídos requerem poucos recursos computacionais para serem executados, e modelos robustos o suficiente para interpretarem até mesmo dados ruidosos ou incompletos. Pode construir modelos eficientes mesmo a partir de grandes volumes de dados, de fácil interpretação e flexíveis o suficiente para serem particionados em subespaços de instâncias, cada um adaptado a diferentes modelos.

Por outro lado, no entanto, deve-se perceber e considerar os modelos demasiadamente complexos que as AD podem gerar, dependendo das regras definidas e do conjunto de dados de treinamento fornecidos a elas, ocasionando sobreajuste (*overfitting*) no algoritmo de aprendizado de máquina (BORGES, 2013).

Existem maneiras de se evitar isso, por meio de técnicas de revisão dos dados de treinamento e “poda” de determinados “nós folhas” da estrutura, em um processo de refinamento e ajuste do modelo de árvore gerado (BELL, 2020). No entanto, o tamanho da amostra de dados de treinamento fornecida para o processo de indução, pode requerer grande esforço computacional no processo de construção de árvores de decisão (BORGES, 2013).

2.3. Implementação de Árvores de Decisão (AD)

No sentido de manter o custo computacional em patamares que viabilizem a representação em árvores de decisão, são desenvolvidos algoritmos baseados em heurísticas que, apesar de não garantirem uma solução ótima, apresentam resultados satisfatórios em tempo factível.

O processo de indução de uma árvore baseia-se na estratégia “dividir para conquistar”, que particiona o espaço definido pelos atributos em subespaços menores e subdivide cada subespaço em novos subespaços ou associa-os a uma classe. No entanto, espaços com grandes quantidades de dados inserem complexidade nesse processo, provocando a necessidade de uma abordagem automática de indução por aprendizado supervisionado.

Um algoritmo muito conhecido, no qual se baseiam muitos dos algoritmos de indução de árvores, é o *Top-Down Induction of Decision Tree* (TDIDT). Este algoritmo constrói árvores de decisão a partir do processo conhecido como particionamento, adicionando em cada nó um teste baseado em um atributo, responsável por dividir o conjunto de treinamento, adicionando ainda ligações para cada um dos possíveis valores resultantes. Em seguida, cada novo nó criado é novamente selecionado e um novo atributo do particionamento do conjunto de treinamento é atribuído ao novo nó (HALMENSCHLAGER, 2002). Algumas das heurísticas utilizadas no desenvolvimento deste algoritmo, para construir a representação da AD, destacam-se o ganho de informação, o critério de Gini e os critérios de parada.

O **ganho de informação** mede a redução da entropia (aleatoriedade) causada com o particionamento do conjunto de dados. Comparando-se o grau de entropia do nó pai (antes da divisão) com o grau de entropia do nó filho (após a divisão), calcula-

se esta redução. Com isso, escolhe-se como condição de teste o atributo que gera uma maior diferença.

$$\text{ganho de informação} = \text{entropia}(\text{pai}) - \sum_{i=1}^n \frac{N(v_i)}{N} * \text{entropia}(v_i) \quad \text{Eq. 1}$$

Na equação 1, sendo $N(v_i)$ o número de objetos associados ao nó-filho v_i ; N o número total de objetos associados ao nó-pai; e n a quantidade de atributos de cada objeto.

O **índice de Gini** equivale ao grau de impureza de um nó. Quando todas as classes se distribuem de forma igual, ele é máximo; quando há apenas uma classe, ele é mínimo (HALMENSCHLAGER, 2002).

$$\text{índice_gini}(\text{nó}) = 1 - \sum_{j=1}^m p(C_j|\text{nó_pai})^2 \quad \text{Eq. 2}$$

sendo $p(C_j|\text{nó_pai})$ a probabilidade relativa da classe j em relação ao nó-pai; C_j a classe j ; e m o número total de classes.

Se uma árvore de decisão cresce demasiadamente, existe a tendência de ocorrer *overfitting* (sobreajuste). Este é o nome do fenômeno que se dá quando a árvore de decisão se torna tão específica que perde a capacidade de generalizar suas soluções, para exemplos diferentes dos usados no conjunto de dados de treinamento. Ele acontece quando “novos nós” dividem uma partição já pequena dos dados, em partições ainda menores, fazendo com a AD “memorize” os dados de treinamento. O *overfitting* pode ser evitado com o uso dos **critérios de parada** da pré-poda e da pós-poda.

A pré-poda é capaz de converter um “nó-filho” em um “nó-folha”, através da avaliação do ganho de informações, analisando quando todas as divisões possíveis usando um atributo A geram ganhos menores que um valor pré-definido, descartando ramificações para os nós que atenderem essa condição e transformando-os em folhas.

A pós-poda é capaz de substituir uma sub-árvore por um nó-folha que represente a classe com mais frequência no ramo. A pós-poda é realizada após a construção da árvore de decisão. Essa técnica calcula a taxa de erro, no caso de retirada de uma ramificação (sub-árvore), avaliando se com essa retirada a taxa se

torna menor que um valor pré-estabelecido, e mantendo a poda caso atendida essa condição.

2.4. Árvore de decisão XGBoost

Existem vários algoritmos de classificação tipo árvore de decisão. Dependendo do problema, um algoritmo se torna mais eficiente que outros. Dentre os vários podemos citar como exemplos o XGBoost, CHAID, C5.0, RNA, e CRT que foram os utilizados nesta pesquisa.

O algoritmo de classificação XGboost é uma melhoria do algoritmo Gradient Boosting Machine (GBM) (FRIEDMAN, 2001), cujas modificações são descritas em (CHEN & GUESTRIN, 2016), que otimiza uma função de perda diferente para criar um conjunto de modelos de previsão. O XGBoost é mais recente na literatura, apresenta bons resultados e seu princípio de árvore de decisão provou ser mais eficiente e escalável do que outros modelos de árvore de decisão baseadas em GBM (DE PISÓN, URRACA, QUINTIÁN, & CORCHADO, 2017) e (GEORGANOS, 2018).

Ao contrário de usar vetores de recursos para calcular a semelhança entre predição e histórico, o XGBoost usa o gradiente para aumentar a construção de árvores reforçadas. Assim, as pontuações de recursos são obtidas de forma inteligente, indicando a importância de cada característica para o modelo de treinamento. Quanto mais uma característica é usada para tomar decisões importantes com árvores impulsionadas, maior a pontuação.

Os métodos de tomada de decisão baseados em árvores são simples e úteis para interpretação (ROCHA, 2018), no entanto, geralmente não são competitivos em relação às melhores abordagens clássicas de aprendizagem supervisionada em termos de precisão (JAMES, 2018). Uma alternativa para melhorar é a combinação de várias árvores de decisão, tendo assim uma floresta, o que resulta em um classificador com alto poder preditivo.

Considere que X é o conjunto de entrada de treinamento e Y é a saída do classificador. O XGBoost é um modelo iterativo que a cada etapa tende a melhorar o modelo de árvore de decisão antecessora, o que pode ser descrito da seguinte forma:

$$h(x) = \sum_{b=1}^B f_k(x_i), f_k \in F \quad \text{Eq. 3}$$

onde $h(x)$ é a previsão; B é o número de árvores; e f é uma função no espaço funcional F e o conjunto de todas as florestas possíveis.

Desta forma, é necessário ter a função objetivo que pode ser descrita da seguinte forma:

$$obj(\theta) = \sum_i^n l(y_i, h(x)) + \sum_{b=1}^B \Omega(f_k) \quad \text{Eq. 4}$$

onde θ são os parâmetros de otimização; l é a função de perda; Ω é a função de regularização; e n é o número de amostras.

De acordo com a modelagem introduzida, pode-se explicar os passos do treinamento. Considerando a seguinte função objetivo modificada:

$$obj = \sum_{i=1}^n l(y_i, h(x)[t]) + \sum_{i=1}^t \Omega(f_i) \quad \text{Eq. 5}$$

onde t é o número de etapas de treinamento; e f_i são funções de aprendizagem.

É preciso ressaltar que cada uma dessas funções contém a estrutura da árvore de decisão e as pontuações dos nós folhas. Ao atribuir o valor da previsão $h(x)$ nas etapas t , resulta em:

$$\begin{aligned} h(x)[0] &= 0 \\ h(x)[1] &= f_1(x_i) = h(x)[0] + f_1(x_i) \\ h(x)[2] &= f_1(x_i) + f_2(x_i) = h(x)[1] + f_2(x_i) \dots \\ h(x)[t] &= \sum_{k=1}^t f_k(x_i) = h(x)[t-1] + f_t(x_i) \end{aligned} \quad \text{Eq. 6}$$

Assim, a árvore de decisão inserida em cada etapa, tem sua estrutura criada pela importância das características através de uma avaliação combinada e otimizada da função objetivo (CHO, KIM, & SHIN, 2017):

$$\begin{aligned} obj^t &= \sum_{i=1}^n l(y_i, h(x)[t]) + \sum_{i=1}^t \Omega(f_i) \\ obj^t &= \sum_{i=1}^n l(y_i, h(x)[t-1]) + f_t(x_i) + \Omega(f_t) \end{aligned} \quad \text{Eq. 7}$$

Com a inserção do erro quadrático médio na função de perda, ela terá a seguinte formulação:

$$obj^{(t)} = \sum_{i=1}^n \left(y_i - (h(x)[t-1] + f_t(x_i)) \right)^2 + \sum_{i=1}^n \Omega(f_i)$$

$$obj^{(t)} = \sum_{i=1}^n [2(h(x)[t-1] - y_i)f_t(x_i) + f_t(x_i)^2] + \Omega(f_i) \quad \text{Eq. 8}$$

2.5. Balanceamento de Dados com SMOTE

Os modelos complexos produzidos com a AD XGBoost podem sofrer *overfitting*, gerando indutores que apenas memorizam classificações e são incapazes de generalizar o aprendizado para classificar novos exemplos. Neste estudo, em função da característica da base de dados, a técnica chamada SMOTE (*Synthetic Minority Over-sampling Technique*) foi usada para evitar este problema.

A SMOTE funciona sintetizando novas amostras entre as amostras minoritárias existentes. Ela faz isso calculando por aproximação novas instâncias a partir das amostras minoritárias originais. Esse aumento de instâncias minoritárias reduz a diferença para a quantidade de amostras majoritárias, provocando um balanceamento entre os exemplos de diferentes classes dentro do espaço de dados.

Em comparação com a técnica de “*undersampling* com substituição de amostras”, a SMOTE gera árvores de decisão com tamanhos menores e melhor capacidade de reconhecimento de classes minoritárias, em maiores graus de replicação. Isso se deve ao fato de que, ao inserir dados extras no espaço amostral, a SMOTE provoca no classificador a criação de regiões de decisão maiores e menos específicas dentro do espaço amostral, ao invés de regiões menores e mais restritas. Assim, regiões mais gerais das amostras da classe minoritária são aprendidas, ao invés de serem ofuscadas pelas instâncias de classe majoritária em torno delas. Em outras palavras, as AD passam a generalizar melhor (CHAWLA, 2002).

Na Figura 2.2, tem-se um exemplo de um pseudo-código de implementação da SMOTE. Ele serve para balancear o conjunto de dados de treinamento do algoritmo XGBoost, que também será usado para modelagem do classificador preditivo foco desta dissertação.

Figura 2.2: Pseudo-código de implementação da Smote.

```
Algoritmo SMOTE(T, N, k)
Entrada: T amostras da classe minoritária; N% quantidade de SMOTE; k vizinhos mais próximos
Saída: (N/100) * T amostras de classe minoritária sintéticas
1. (* Se N é menor que 100%, sorteie as amostras de classe minoritária como apenas um percentual aleatório daquelas que serão “SMOTEadas”. *)
2. if N < 100
3.   then Sorteie as T amostras da classe minoritária
4.   T = (N/100) * T
5.   N = 100
6. endif
7. N = (int)(N/100) (* A quantidade de SMOTE é assumida estar em múltiplos inteiros de 100. *)
8. k = Número de vizinhos mais próximos
9. numattrs = Número de atributos
10. Sample[ ]: vetor para amostras de classe minoritária originais
11. newindex: contagem do número de amostras sintéticas geradas, iniciado em 0
12. Synthetic[ ]: vetor de amostras sintéticas
    (* Calcula k vizinhos mais próximos somente para cada amostra de classe minoritária. *)
13. for i ← 1 to T
14.   Calcule k vizinhos mais próximos de i, e salva os índices no nnarray
15.   Populate(N, i, nnarray)
16. endfor
    Populate(N, i, nnarray) (* Função para gerar as amostras sintéticas. *)
17. while N ≠ 0
18.   Escolha um número aleatório entre 1 e k, chame-o nn. Este passo escolhe um dos k vizinhos mais próximos de i.
19.   for attr ← 1 to numattrs
20.     Calcule: dif = Sample[nnarray[nn]][attr] - Sample[i][attr]
21.     Calcule: gap = número aleatório entre 0 e 1
22.     Synthetic[newindex][attr] = Sample[i][attr] + gap * dif
23.   endfor
24.   newindex++
25.   N = N - 1
26. endwhile
27. return (* Fim da População. *)
    Fim do Pseudo-código.
```

Fonte: (CHAWLA, 2002).

2.6. Matriz de Confusão – Avaliação de Performance

De acordo com (FACELI, LORENA, GAMA, & CARVALHO, 2019), a matriz de confusão é a ferramenta de avaliação de performance usada em modelos de predição construídos para problemas de classificação binária, como o estudado neste trabalho. Ela é uma matriz bidimensional que sintetiza a performance do classificador em relação aos dados de teste e validação (Figura 2.3). Essa matriz é configurada numa dimensão pelas classificações reais dos objetos (valores reais) e em outra pelas classificações previstas (valores previstos) que o classificador atribui (TING, 2017).

Figura 2.3: Matriz de confusão

		Classe predita	
		+	-
Classe verdadeira	+	VP	FN
	-	FP	VN

Fonte: (FACELI, LORENA, GAMA, & CARVALHO, 2019)

As classificações reais e previstas são combinadas para se quantificar os objetos que o modelo identifica corretamente e incorretamente, discriminando-os como verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN) (NOGARE, 2020).

Os conjuntos verdadeiros são os objetos do espaço amostral que o modelo classificou corretamente, enquanto os falsos são aqueles classificados incorretamente. Os casos positivos correspondem aos exemplos de amostras que se deseja detectar (por exemplo, doentes, anomalias, falhas, padrões alterados), enquanto os casos negativos são os exemplos de amostra em estado normal (ou seja, saudáveis, operando, dentro dos padrões) (RODRIGUES, 2019).

Para o estudo neste trabalho os valores positivos correspondem aos registros de falha nos caminhões fora-de-estrada; já os valores negativos se referem aos registros desses equipamentos em operação. Assim, VP são os casos que o modelo acerta a classificação dos exemplos de falha, VN os casos que o modelo acerta a classificação dos exemplos de operação, FP os casos que o modelo erra a

classificação dos exemplos de falha e FN os casos em que o modelo erra a classificação dos exemplos de operação.

Com essas distribuições quantificadas na Matriz de Confusão, calculam-se diferentes métricas de performance para a mesma que, numa análise combinada, são úteis para avaliar o classificador binário. As métricas de avaliação mais comuns são a precisão, a revocação, a acurácia e o *F1-Score*.

2.6.1. Métricas da Avaliação

A *precisão* (*precision*) é a proporção da quantidade positiva classificada corretamente (VP) em comparação a quantidade de classificações positivas corretas e incorretas (VP+FP) (NOGARE, 2020). Ou seja, dentre todas as classificações de positivo que o modelo fez, quantas estão corretas.

$$Precisão = \frac{VP}{VP + FP} \quad \text{Eq. 9}$$

A precisão é usada em situações onde os FP causam mais prejuízos que os FN. Ou seja, situações em que ser mais conservador é pior (RODRIGUES, 2019). Para o problema em estudo, seria como considerar que indicar manutenção para o caminhão, quando ele na verdade não precisa, seria pior que não indicar manutenção, quando ele na verdade precisa, e o equipamento vir a falhar sem previsibilidade. Esta situação é inaceitável. Assim, o modelo de classificador para o problema em análise não precisará ser tão preciso, uma vez que a situação do equipamento falhar sem planejamento e programação de manutenção é extremamente prejudicial ao processo.

A *recall* (revocação) ou sensibilidade é a proporção da quantidade positiva classificada corretamente (VP) em comparação a quantidade de positivos que haviam de fato na amostra (VP+FN) (NOGARE, 2020). Isso quer dizer, entre todas as situações de classe positivo como valor esperado quantas estão corretas.

$$Recall = \frac{VP}{VP + FN} \quad \text{Eq. 10}$$

É uma métrica usada em situações onde os FN são considerados mais prejudiciais que os FP (RODRIGUES, 2019). Para o estudo dessa dissertação, o modelo deve de qualquer maneira encontrar todos os caminhões que necessitam de

manutenção, mesmo que classifique assim alguns que na verdade não precisavam de manutenção (situação de FP). Ou seja, o modelo deve ter alto *recall*, pois classificar caminhões que precisam de manutenção como que “não precisam” poderá ser péssimo para o processo.

A acurácia (*accuracy*) é a quantidade de exemplos classificados corretamente como positivos e negativos (VP+VN) em comparação ao total de exemplos na amostra (NOGARE, 2020). Dessa forma, indica dentre todas as classificações quantas o modelo classificou corretamente.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad \text{Eq. 11}$$

Ela é uma boa indicação geral de como o modelo performou. Porém, pode haver situações em que ela é enganosa (RODRIGUES, 2019), como neste caso em que o número de amostras positivas (falhas) é bem menor que a quantidade de amostras negativas (operando), levando o modelo a classificar quase tudo como “em operação”. Para um modelo assim a acurácia calculada é alta, levando a se entender como ótimo um modelo que falha em classificar corretamente.

O *F1-Score* é a média harmônica entre a precisão e revocação. Ele calcula um valor médio harmônico de acertos do modelo entre todas as amostras que ele classifica como positivas (sejam verdadeiras ou falsas) e entre todas as amostras que de fato são positivas (NOGARE, 2020).

$$F1_{Score} = \frac{2 \times \text{Precisão} \times \text{Revocação}}{\text{Precisão} + \text{Revocação}} = \frac{2VP}{2VP + FP + FN} \quad \text{Eq. 12}$$

Através dessa métrica é possível observar-se os efeitos da precisão e da revocação combinadas. Por ser uma média harmônica, tende a se aproximar dos menores valores muito mais que uma média aritmética simples. Ou seja, um *F1-Score* baixo, indica que a precisão ou a revocação estão baixas, direcionando a análise a essas outras métricas (RODRIGUES, 2019).

CAPÍTULO 3 : PROCESSO DE MANUTENÇÃO

Este capítulo apresenta uma breve abordagem do processo manutenção e uma revisão bibliográfica dos trabalhos envolvendo modelos de predição de falhas em equipamentos industriais. O problema estudado envolveu a necessidade de prever falhas em caminhões fora de estradas.

Atualmente o planejamento da manutenção destes equipamentos é realizado por meio de um plano, denominado Estratégia de Manutenção, realizado de forma manual com base na experiência dos engenheiros e técnicos responsáveis.

3.1. Conceito e Tipos de Manutenção

Ao longo da história, a indústria evolui para atender as demandas humanas. Existem momentos de transição de processos e tecnologias, desenvolvidas e aplicadas conforme necessidade para atender à sociedade. Esses pontos de virada são marcados por mudanças nos meios de produção, nas relações de trabalho e de consumo.

Destacaram-se ao menos três revoluções na indústria: a da transição das manufaturas para a fabricação mecanizada movida à carvão, a do advento da produção em série em fábricas energizadas pelo petróleo e pela eletricidade e a do atendimento sob demanda em plantas industriais informatizadas e a automação das linhas de produção. O mercado evoluiu da fabricação objetivando troca e subsistência, passando pelo atendimento a uma “sociedade de consumo” até chegar a uma produção “*just in time*” (DIAS, 2010).

Hoje, vivenciamos um novo momento de quebra de paradigmas nos meios de produção, que vem se referindo como a quarta revolução industrial e tem caracterizado o surgimento da Indústria 4.0. Este termo foi cunhado em 2011 na Alemanha, após a iniciativa de um debate associado de políticos, pesquisadores e industriais denominada “Industrie 4.0” a respeito do aumento de competitividade da indústria alemã (HERMANN, PENTEK, & OTTO, 2016).

Dentro deste contexto, o processo de manutenção também evoluiu ao longo dos séculos, tornando-se um processo de fundamental importância para o aumento

da eficiência das máquinas de produção, assim como para a diminuição da incerteza sobre o estado de operação do equipamento.

Originalmente o termo manutenção era restrito ao vocabulário militar, no qual teria surgido e, apenas na década de 1950, começaria a ser utilizado pela indústria e incorporado à estrutura organizacional das empresas (MONCHY, 1989). Com o passar do tempo, novas definições foram sendo concebidas e aprimoradas, como as que serão apresentadas a seguir.

Na revisão de 1994, da mesma Norma, NBR 5462 (Confiabilidade e Manutenibilidade), a definição de Manutenção passou a ser a combinação de todas as ações técnicas e administrativas, incluindo as de supervisão, destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida (ABNT, 1994). Pode-se notar uma evolução no conceito, incorporando o sentido de preservação de função e não apenas conservação pura do ativo.

Outro ponto que merece ser ressaltado nas definições mais recentes é a preocupação com os custos. Nesse sentido, Levitt afirma que "[...] a função da manutenção é preservar um ativo ou preservar a habilidade de um ativo para, de modo seguro e econômico, produzir algo" (LEVITT, 1997).

Apesar de, no senso comum, a Manutenção tradicionalmente estar associada a reparos e consertos, ele lembra que a definição da palavra manutenção está na realidade relacionada à "ação de manter num preservado estado" e, assim, não há relações exclusivas com reparos (LEVITT, 1997). A partir dessa ideia presume-se que, ao se mencionar Manutenção, faça-se referência a ações que evitem a ocorrência de falhas, por meio da preservação da função do ativo, e não apenas efetuando consertos ou reparos.

Diante das definições pesquisadas percebe-se que as mais recentes já possuem essa nova visão da Manutenção, que se refere à preservação de um estado funcional e não apenas à preservação do equipamento, afastando-se, cada vez mais, do conceito clássico de conservação pura e simples do ativo.

3.1.1. Tipos de Manutenção

De acordo com Siqueira (2005), os tipos de manutenção são também classificados de acordo com a atitude dos usuários em relação às falhas. As três principais categorias são normalmente identificadas, sob este aspecto:

- Manutenção Corretiva ou Reativa;
- Manutenção Preventiva;
- Manutenção Preditiva;

A manutenção Corretiva ou Reativa destina-se a corrigir falhas que já tenham ocorrido. A manutenção Preventiva tem o propósito de prevenir e evitar as consequências das falhas. A manutenção Preditiva busca a previsão ou antecipação da falha medindo parâmetros que indiquem a evolução de uma falha a tempo de serem corrigidas. Similarmente, a manutenção detectiva procura identificar falhas que já tenham ocorrido, mas que não sejam percebidas. Na manutenção Proativa a experiência é utilizada para otimizar o processo e o projeto de novos equipamentos, em uma atitude proativa de melhoria contínua. Finalmente, a manutenção Produtiva objetiva garantir a melhor utilização e maior produtividade dos equipamentos (SIQUEIRA, 2005).

a. Manutenção Corretiva ou Reativa

A lógica da manutenção corretiva é simples e direta: quando uma máquina quebrar, conserte-a. Este método (“se não está quebrada, não conserte”) de manutenção de maquinário fabril tem representado uma grande parte das operações de manutenção das plantas industriais, desde quando a primeira fábrica foi construída e, aparentemente, parece razoável.

Uma planta industrial usando gerência por manutenção corretiva não gasta qualquer dinheiro com manutenção, até que uma máquina ou sistema falhe em operar.

A manutenção corretiva causa a paralisação do processo produtivo. Devido a isso, é bastante onerosa no ponto de vista econômico, em virtude da quebra de produção e do lucro cessante. Para as indústrias modernas, tal manutenção não é a

mais adequada, pois não possibilita segurança para o cumprimento de prazos num plano de produção (MARÇAL, 2004).

Os maiores custos associados com este tipo de manutenção são: altos custos de estoques de peças sobressalentes, altos custos de trabalho extra, elevado tempo de paralisação da máquina, e baixa disponibilidade de produção. Ela pode ser subdividida em:

- Manutenção corretiva não planejada: é a correção da falha de maneira aleatória. Marçal (2004) complementa Kardec & Nascif (2001) dizendo que a manutenção ocorre no fato já ocorrido ou no momento seguinte à identificação do defeito. Implicam na paralisação do processo, perdas de produção, perdas de qualidade e elevação de custos indiretos de produção. A manutenção objetiva colocar o equipamento nas condições de voltar a exercer sua função.
- Manutenção corretiva planejada: é a correção do desempenho menor do que o esperado ou da falha, por decisão gerencial. Marçal (2004) enfatiza que a manutenção é efetuada em um período programado, com intervenção e acompanhamento do equipamento, desde que o defeito não implique necessariamente na ocorrência de uma falha. Caso a decisão seja deixar o equipamento funcionando até quebrar, recomenda-se compartilhar com outros defeitos já relatados e tomar ação preventiva e naturalmente econômica. O planejamento é fundamental e deve considerar fatores diversos para o não comprometimento do processo produtivo.

Normalmente, a quebra ocorrerá quando as demandas de produção forem as maiores. O pessoal de manutenção deve então reagir à falha inesperada. Neste modo de manutenção reativa, a máquina é desmontada e inspecionada para determinar os reparos específicos requeridos para retorná-la ao serviço. Se as peças de reparo não estiverem no estoque, elas devem ser encomendadas, a custos de mercado, e deve ser solicitado o envio expedito. Mesmo quando as peças de reparo já estão no estoque da planta industrial, o tempo de mão de obra para reparo e o custo são muito maiores neste tipo de manutenção reativa. O pessoal de manutenção deve desmontar toda a máquina para localizar a fonte do problema ou problemas que forçaram a falha.

Admitindo que eles identifiquem corretamente o problema, o tempo requerido para desmontar, reparar, e remontar a máquina seria, pelo menos, maior do que teria sido requerido por um reparo planejado.

b. Manutenção Preventiva

Todos os programas de gerência de manutenção preventiva são acionados por tempo, ou seja, as tarefas de manutenção se baseiam em tempo gastos ou horas operacionais. A conhecida curva do tempo médio para falha (CTMF) indica que uma máquina nova tem uma alta probabilidade de falha, devido a problemas de instalação, durante as primeiras semanas de operação. Após este período inicial, a probabilidade de falha é relativamente baixa por um período prolongado. Após este período normal de vida da máquina, a probabilidade de falha aumenta abruptamente com o tempo transcorrido. Na manutenção preventiva, os reparos ou recondiçõamentos da máquina são programados baseados na estatística CTMF.

A implementação da manutenção preventiva real varia bastante. Alguns programas são extremamente limitados e consistem em lubrificação e ajustes menores. Os programas mais abrangentes de manutenção preventiva programam reparos, lubrificação, ajustes, e recondiçõamentos de máquinas para toda a maquinaria crítica na planta industrial. O denominador comum para todos estes programas de manutenção preventiva é o planejamento da manutenção x tempo.

Todas as máquinas irão se degradar em um determinado período de tempo, de acordo com suas características típicas.

A análise dos custos de manutenção tem mostrado que um reparo feito de uma forma reativa (isto é, após a falha) normalmente será três vezes mais caro do que o mesmo reparo feito numa base programada.

Segundo Marçal (2004) a manutenção preventiva se subdivide em:

- **Manutenção preventiva programada ou sistemática:** é quando os serviços de manutenção são efetuados de maneira periódica, através de intervalos pré-estabelecidos, dias de calendários, ciclos de operações, horas de operações e outros desprezando as condições dos componentes envolvidos.

- Manutenção preventiva de rotina: são as manutenções preventivas feitas com intervalos pré-determinados e de tempos reduzidos, com prioridades claramente definidas e curtas duração de execução, na maioria das vezes apoiadas apenas nos sentidos humanos, sem causar a indisponibilidade da instalação ou equipamento. Geralmente são conhecidas como inspeções e verificações sistemáticas apoiadas pelo uso de checklist ou demais controles.

c. Manutenção Preditiva

A manutenção preditiva é o monitoramento regular da condição mecânica real, do rendimento operacional, e outros indicadores da condição operativa das máquinas e sistemas de processo, fornecendo os dados necessários para assegurar o intervalo máximo entre os reparos. Ela também minimiza o número e os custos de paradas não-programadas criadas por falhas da máquina. Portanto, as peças corretas para reparo, ferramentas, e habilidades da mão de obra podem estar disponíveis para corrigir o problema da máquina antes da ocorrência de falha catastrófica. Talvez a diferença mais importante entre manutenção reativa e preditiva seja a capacidade de se programar o reparo quando ele terá o menor impacto sobre a produção. O tempo de produção perdido como resultado de manutenção reativa é substancial e raramente pode ser recuperado. A maioria das plantas industriais, durante períodos de produção de pico, opera 24 horas por dia. Portanto, o tempo perdido de produção não pode ser recuperado.

A manutenção preditiva não é meramente monitoramento de vibração ou análise de óleo lubrificante ou de imagens térmicas ou qualquer das outras técnicas de teste não destrutivo que tem sido marcada como ferramentas de manutenção preditiva. A manutenção preditiva é uma filosofia ou atitude que usa a condição operacional real do equipamento e sistemas da planta industrial para aperfeiçoar a operação total da planta industrial.

A manutenção preditiva é um programa de manutenção preventiva acionado por condições. Ao invés de se fundamentar em estatística de vida média na planta industrial (p.ex., tempo médio para falha) para programar atividades de manutenção, a manutenção preditiva usa monitoramento direto das condições mecânicas,

rendimento do sistema e outros indicadores para determinar o tempo médio para falha real ou perda de rendimento para cada máquina e sistema na planta industrial. Na melhor das hipóteses, os métodos tradicionais acionados por tempo garantem uma guia para intervalos “normais” de vida da máquina. Em programas preventivos ou corretivos, a decisão final sobre os programas de reparo ou de recondicionamento se baseia na intuição e experiência pessoal do gerente de manutenção. A adição de um programa de gerência preditiva abrangente pode fornecer dados sobre a condição mecânica real de cada máquina e o rendimento operacional de cada sistema de processo. Estes dados habilitarão o gerente de manutenção a programar atividades de manutenção muito mais efetivamente em termos de custo. Um programa de manutenção preditiva pode minimizar o número de quebras de todos os equipamentos mecânicos da planta industrial e assegurar que o equipamento reparado esteja em condições mecânicas aceitáveis. Ele pode identificar problemas da máquina antes que se tornem sérios já que a maioria dos problemas mecânicos pode ser minimizada se forem detectados e reparados com antecedência.

A manutenção preditiva utiliza uma ou mais técnicas de monitoração, como:

- Análise de vibrações de equipamentos rotativos e alternativos;
- Análise de corrente e fluxo magnético de motores elétricos;
- Análise de óleo lubrificante (tribologia e ferrografia);
- Termografia de sistemas elétricos e mecânicos;
- Ultrassom para detecção de vazamentos e defeitos de válvulas e purgadores.

Essas técnicas são capazes de detectar os defeitos de funcionamento sem interrupção do processo produtivo e com antecedência suficiente para programar as intervenções corretivas, de modo a atingir os seguintes benefícios:

- Aumento da segurança e da disponibilidade dos equipamentos, com redução dos riscos de acidentes e interrupções inesperadas da produção;
- Eliminação da troca prematura de componentes com vida útil remanescente ainda significativa;

- Redução dos prazos e custos das intervenções, pelo conhecimento antecipado dos defeitos a serem corrigidos;
- Aumento da vida útil das máquinas e componentes pela melhoria das condições de instalação e operação.
- A análise estatística dos dados coletados pela Manutenção Preditiva permite ainda:
- Identificar equipamentos com problemas crônicos e orientar a sua correção;
- Avaliar a eficácia e a qualidade dos serviços corretivos e propor programas de treinamento e a adoção de novas tecnologias, visando o seu aprimoramento.

De um modo geral, pode-se afirmar que a aplicação de programas de Manutenção Preditiva em indústrias de processo resulta, a médio e longo prazo, em reduções da ordem de 2/3 nos prejuízos com interrupções inesperadas de produção e de 1/3 nos gastos com a manutenção, após uma fase inicial de investimentos (NUNES, 2015).

3.2. Predição de Falhas em Equipamentos Industriais

Para obter bons resultados, é fundamental realizar o estudo bibliográfico com qualidade. Portanto, definir a base da pesquisa, escolher corretamente as palavras-chaves e avaliar os resumos dos estudos para que a seleção ocorra com os resultados mais relevantes é imprescindível para que o trabalho proposto contribua para o meio acadêmico e profissional.

Com este intuito foram realizadas diversas pesquisas para a revisão bibliográfica, utilizando combinações em português e inglês das seguintes palavras: predição de falhas, XGBoost, árvore de decisão aplicado a manutenção industrial, rede neural artificial e caminhos fora de estrada. As bases de pesquisa utilizadas foram: Periódicos CAPES, *Science Direct*, *Scorpus* e *Google Scholar*.

Houve dificuldade em encontrar estudos científicos envolvendo exatamente o tema proposto nesta dissertação Aprendizado de Máquina aplicado em equipamentos

de Mineração, e por este motivo foram selecionados estudos de 1988 a 2019, que abaixo serão apresentados.

Nos últimos anos, alguns estudiosos desenvolveram pesquisas para avaliação da degradação de equipamentos com o monitoramento das condições de operação. Para tomada de decisões estratégicas de manutenção utilizaram-se de técnicas preditivas e do aprendizado de máquina na detecção e no diagnóstico antecipado de falhas (BALDISSARELLI & FABRO, 2019), (ROCHA, 2018), (LEME, 2017), (GAMA, 2017).

Baldissarelli & Fabro (2019) desenvolveram uma solução em manutenção preditiva de equipamentos rotativos industriais com o objetivo de identificar vibrações no motor e mancais do conjunto do ventilador de um exaustor industrial usando ferramentas da indústria 4.0 para uma monitoração online do equipamento.

A análise de vibrações mecânicas tem sido uma importante técnica adotada nas empresas para avaliação do estado de operação das máquinas industriais. Essa análise permite desenvolver métodos de antecipação à falha e realizar diagnósticos de operação das máquinas rotativas (PESTANA-VIANA, et al., 2016).

Rocha (2018) utilizou-se de uma base de dados de sinais de vibrações mecânicas para classificar automaticamente falhas em máquinas rotativas. Ele fez uso dos três modelos de extração de características de sinais de vibrações mecânicas: (i) *RMS* (Root Means Squares), (ii) *Wavelet* de Haar e dimensão fractal e (iii) *FFT* (Fast Fourier Transform) com dados estatísticos e para o aprendizado de máquina fez uso dos classificadores *KNN* (Kvizinhos mais próximos), *SVM* (Máquina de Vetores de Suporte) e *XGBoost* (Extreme Gradient Boosting) para diagnosticar as falhas. Os resultados demonstraram eficiência de todas as técnicas, sendo que na abordagem *Wavelet* de Haar e dimensão fractal combinados com o *XGBoost* obteve os melhores resultados.

Leme (2017) desenvolveu uma metodologia de manutenção preditiva para motores elétricos, que utiliza a técnica de monitoramento de variáveis, transmissão de dados pela rede elétrica (*Powerline Communication*) e um tratamento com os métodos multicritério para classificação (ELECTRE TRI e AHPSort) e ordenação (ELECTRE II) dos motores que apresentam condição de falha incipiente.

Molinaro & Castanie (1995) realizaram classificação de padrões de processamento de sinais em sinais de vibração com sensores para melhorar a detecção de detonação em motores de ignição por centelha. Eles aplicaram uma técnica clássica de quatro etapas ao sinal de vibração modelado e aplicaram regras de classificação. Embora eles usassem apenas o sinal de vibração, a precisão da detecção da falta era de 100% a uma velocidade de 1500 rpm, enquanto, em velocidades mais altas, o resultado não era tão bom; isto é, a precisão foi de 75% a 5500 rpm. Já Thomas, Dubuisson, Agens, & Peltier (1997) também usaram uma técnica de reconhecimento de padrões para detectar a batida do motor, novamente usando o sinal de vibração.

Grimmelius et al (1999) desenvolveram um algoritmo de extração de características e reconhecimento de padrões para detectar erros de ignição de cilindros em um motor a diesel aplicando uma análise do sinal de flutuação no nível básico e uma análise do valor de pico de torção no sinal de torção do virabrequim.

Já a técnica de Análise de Óleo / Lubrificação é utilizada em monitoramento das condições e isso se deve ao fato de que os conteúdos (detritos) do óleo fornecem uma indicação superior da condição do motor. Isso ocorre porque o óleo entra em contato com a maioria das partes móveis do motor. A análise de óleo é particularmente útil quando não é fácil aplicar a técnica de vibração.

A análise do óleo fornece uma indicação da adequação do motor para uso contínuo e fornece resultados significativos sobre a condição dos componentes individuais no motor. Testes físicos e químicos de lubrificantes podem ser empregados para diagnóstico e detecção eficientes de falhas mecânicas iminentes no motor. Convencionalmente, a análise de óleo tem sido muito difícil de realizar on-line. Beck & Johnson (1984) relataram o uso de ferrografia para monitorar partículas presentes no lubrificante de um motor a diesel há mais de trinta anos. Desde então, tem havido muitos relatórios sobre a aplicação de ferrografia e espectrometria de óleo para muitos tipos de motores a diesel. Liu, Liu, Xie, & Yao (2000) desenvolveram um sistema para monitoramento de condições de desgaste on-line para um motor diesel marítimo. Este sistema consistiu em: detecção de partículas, avaliação da qualidade do lubrificante e medição do momento de torque do eixo e da velocidade de rotação instantânea. Este

sistema detectou partículas de desgaste no lubrificante com ferrografia on-line, de modo a avaliar a condição de desgaste do motor a diesel. Os métodos de análise de óleo também podem ser realizados para caixas de transmissão e muitas outras máquinas.

Uma outra técnica muito comumente utilizada é a emissão acústica, tendo ocorrido aplicações em testes de tubulações, avaliação de aeronaves obsoletas, testes de transformadores, testes de motores de foguetes, controle de qualidade de produção, inspeções de válvulas em linhas de vapor, monitoramento de turbinas eólicas, monitoramento de cascos de navios e previsão de terremotos.

Fog et al (1988) aplicaram com sucesso a análise de componentes principais aos sinais emissão acústica para detectar vazamentos nas válvulas de escapamento em um grande motor diesel marítimo. El-Ghamry, Reuben, & Steel (2003) usaram várias características estatísticas e técnicas de reconhecimento de padrões, como a média e a variância dos sinais de emissão acústica para identificar falhas no motor a diesel, como vazamento na vedação da cabeça do cilindro.

Nenhuma das citações acima fez a tentativa para prever a falha no equipamento através do desenvolvimento de um algoritmo de manutenção preditiva usando a ferramenta SPSS, que é um software de análise estatística avançada com uma vasta biblioteca de algoritmos de aprendizado de máquina. Para este trabalho será utilizado os classificadores XGBoost, CHAID, C5.0, RNA, e CRT, com o objetivo de prever o momento ideal para que a manutenção possa atuar antes da falha no caminhão permitindo encontrar novas oportunidades, melhorar a eficiência e minimizar o risco da Gestão da Manutenção.

CAPÍTULO 4 : ESTUDO DE CASO

Neste momento será explanado como este trabalho foi desenvolvido, e foi sob a ótica do modelo de processo O CRISP-DM por ser mais flexível e completo em comparação com outros modelos de processo tais como o (SEMMA) ou o (PMML), pois considera a aplicação dos resultados no ambiente de negócios e foca nas necessidades dos gestores e na resolução de seus problemas de gestão. O CRISP-DM fornece uma visão geral do ciclo de vida de mineração de dados.

Este consiste em seis fases: Entendimento do Problema; Compreensão dos Dados; Preparação dos Dados; Modelagem; Avaliação e Implementação dos Modelos. A sequência de fases não é rigorosa. Na verdade, a maioria dos projetos alternam entre fases conforme necessário e realmente nos deparamos com essa necessidade nesta pesquisa.

Em IBM (2019) é descrito com maior profundidade cada fase do modelo de processo CRISP-DM, os entregáveis e outras informações que permitirão uma melhor compreensão.

4.1. Entendimento do Negócio

Hoje em dia com o avanço da tecnologia, os equipamentos móveis para exploração mineral são modernos e providos de vários sensores que monitoram a condição de operação e desempenho deles. Os dados coletados por esses sensores são utilizados pela operação com o objetivo de alertar o operador para alguma condição anormal ou insegura e utilizados pela equipe de manutenção para diagnóstico pós-falhas e para relatórios de análise de desempenho do equipamento.

Segundo Furtado (2009), a análise bruta dos sinais registrados pela máquina, sem algum nível de processamento, torna praticamente impossível a avaliação do estado da mesma, a detecção de algum padrão pré-falha ou do estado de falha dos equipamentos.

A extração de informação desses sinais é essencial para a melhoria do processo de manutenção, passando de uma manutenção corretiva e não programada, cujo custo é alto, para uma manutenção preditiva programada

O Objeto de estudo neste trabalho é o caminhão fora de estrada, este é composto por vários componentes, onde o conjunto dos principais componentes são denominados como Trem de Força. Dentre eles, destacam-se o Motor; Transmissão; e o Comando Final que são componentes passíveis de monitoramento. Os Motores dos caminhões são formados por 16 cilindros e tem como função gerar toda a potência necessária para o deslocamento do equipamento e a movimentação da bascula. O motor exige um elevado consumo de Diesel por hora, é o componente mais caro do equipamento e portanto o mais monitorado. A Transmissão tem a função de transmitir a potência necessária do motor para o Comando Final, para que o equipamento consiga se deslocar dependendo da condição do terreno. O Comando Final tem a função de converter a potência transmitida pela transmissão para movimentação das rodas traseiras do caminhão.

Conforme descrito em Zheng, Xinyu, & Daoyuan (2006), o processo de manutenção é definido por rotinas de revisões, lubrificações, inspeções, manutenções de campo, análises de óleo e análises de dados do VIMS. Os processos de revisão, lubrificação e inspeção sensível são classificados como preventivas, a manutenção de campo como corretivas e a inspeção preditiva, as análises de óleo e de dados do VIMS são conhecidas como preditivas.

As atividades de lubrificação são realizadas para evitar desgaste acelerado das partes articuladas do equipamento, impedindo que o atrito ocasione danos em componentes capazes de originar falhas no caminhão.

As inspeções identificam defeitos ou tendências a defeitos, conforme uma rotina pré-estabelecida. Dependendo da complexidade, podem ser realizadas em diferentes periodicidades e serem, basicamente, de diferentes tipos: sensíveis e preditivas. Se identificadas anormalidades durante a inspeção, os inspetores geram as ordens de manutenção (OM) para correção dos problemas encontrados e decidem se a OM deverá ser executada de forma imediata ou aguardará a próxima revisão periódica do ativo.

Os problemas identificados pela inspeção sensível são limitados a sinais perceptíveis pelos sentidos humanos (tais como trincas, desgastes, vazamentos, peças fora de posição, barulhos anormais, entre outros dessa mesma natureza),

enquanto as tendências de falhas identificadas pela inspeção preditiva são detectadas através de equipamentos ou sistemas de medição e métodos de análise de sinais dos mais diversificados.

A análise de dados do VIMS é realizada em 2 etapas: o *download* dos dados do computador de bordo do caminhão (durante as inspeções) e a análise/diagnóstico do mecânico especialista (para abertura ou não de OM). A análise sistêmica desse grande volume de dados operacionais é de fundamental importância para se antecipar a falhas e, assim, se evitar a manutenção de campo (corretiva). O qual será o foco desta dissertação, obter a extração de informação desses sinais será essencial para a melhoria do processo de manutenção, passando de uma manutenção corretiva e não programada, cujo custo é alto, para uma manutenção preditiva programada.

O objetivo da modelagem neste estudo é produzir um classificador capaz de indicar, com boa aproximação, se em 20 dias haverá falhas nos caminhões. Ou seja, independentemente dos atributos de um registro apresentado a este modelador, ele deverá avaliar e ser capaz de definir, segundo as características apresentadas por este dado, se haverá ou não uma falha no caminhão no vigésimo dia após esta avaliação. Este período nasceu de um consenso com as equipes especialistas em planejamento e execução de manutenções de caminhões fora de estrada do negócio. Atualmente, uma previsão com margem de erro aceitável limita-se a no máximo 7 dias (ou menos), através de avaliações realizadas via inspeções periódicas. Não existem sistemas inteligentes capazes de prever consistentemente em um período maior. Isso acontece porque os processos de análise atuais (por exemplo, preditivos e sensitivos), baseiam-se em coletas sistemáticas de sinais e não existe a aplicação de coleta e análise de variáveis em tempo real, nestes ativos. Um período de 20 dias é um pouco mais que o mínimo necessário para a execução de processos de preparação para intervenções de manutenção como, por exemplo, o provisionamento de materiais.

4.2. Compreensão dos dados

Para o problema em questão, duas bases de dados foram combinadas para formar o conjunto de dados de entrada para o processo de aprendizado de máquina.

A primeira base de dados contém os sinais vitais dos caminhões fora de estrada. A segunda é composta pelo histórico de falhas desses equipamentos. Com a combinação das duas é possível identificar, para cada caminhão, o histórico de falhas e as respectivas condições dos sinais vitais.

Os dados utilizados para construção dos modelos foram os registros históricos dos sinais vitais de 26 caminhões fora de estrada do maior porte da mina em questão, correlacionados aos registros de falhas destas unidades ocorridas no mesmo período: 2018 a 2019.

Os históricos foram disponibilizados por uma grande mineradora brasileira, e esta autorizou a utilização destes seus dados operacionais em projetos acadêmicos, através de um acordo de confidencialidade. Assim, para manter o sigilo dos dados, os valores reais utilizados nessa dissertação foram transformados, fazendo uso de uma função específica, não divulgada.

O modelo de caminhão em questão é equipado com sistemas de sensoriamento avançados, com técnicas sofisticadas de processamento de dados, capazes de extrair informações não triviais dos registros e gerar um log de sinais vitais mais seletivo. Dessa maneira, conjuntos de dados destas máquinas foram coletados por meio desses dos sistemas de sensoriamento. Foi possível obter-se o histórico de vários parâmetros por meio da eletrônica embarcada existente, tais como Temperatura do Líquido de Arrefecimento do Motor, Temperatura do Óleo do Motor, Nível de Óleo do Motor, entre outros. Por meio de tratamento de dados, foi possível correlacionar os registros de sinais vitais aos registros de modos de falhas de uma base histórica de ocorrências de manutenção corretiva.

A primeira base de dados dos sinais vitais, é obtida do Vital Information Management System – VIMS (DIETZ, KIECH, & ALI, 1988). Este sistema foi desenvolvido para monitorar os equipamentos Caterpillar. Dentro do escopo de monitoramento das máquinas, é registrada uma ampla gama de informações de funções vitais da máquina e informações sobre a produção e desempenho do equipamento.

O VIMS monitora e armazena as numerosas informações dos sensores integrados no veículo. Ele tem a capacidade de alertar o operador se os valores

monitorados estão ultrapassando um limite pré-estabelecido, se estão atingindo níveis críticos ou se contribuem para que o equipamento se desligue em alguma emergência. Este sistema fica instalado no Electronic Control Module (ECM) do caminhão.

A segunda base de dados é formada pelas falhas que ocorreram no caminhão, armazenadas no formato de Ordem de Manutenção (OM), que são inseridas manualmente através de um sistema computacional de gerenciamento das atividades de manutenção. As OM são necessárias para que a equipe de manutenção registre a ocorrência de uma falha no equipamento e a inicie o procedimento de manutenção.

A base VIMS dos caminhões é baixada do ECM, que monitora os circuitos conectados aos componentes eletrônicos (sensores, switches, solenoides e outros). Qualquer problema detectado o ECM, através do VIMS, associa um código. Existem duas categorias de códigos: de diagnósticos e de eventos.

Os códigos de diagnósticos indicam uma falha elétrica (curto-circuito ou circuito aberto) no cabeamento ou num componente elétrico da malha de monitoramento do caminhão. Os códigos de eventos indicam uma condição anormal de operação do equipamento; de um modo geral, indica problemas mecânicos ao invés de problemas elétricos.

Os códigos de diagnósticos podem ser ativos ou logados e os códigos de eventos variam entre os níveis 1, 2 ou 3, segundo a gravidade da condição anormal do sistema (Tabela 4.1).

Tabela 4.1: Códigos de diagnóstico com gravidade da condição anormal do sistema.

OPERAÇÃO DE ADVERTÊNCIA					
Nível	O indicador de Alerta Picará ⁽²⁾	A Luz Indicadora de Ação Intermitente	O Alarme de Ação Soa	Ação Requerida do Operador	Possíveis Resultados se nenhuma ação for tomada
1	X			Nenhuma ação imediata é necessária, mas o sistema precisa ser verificado logo.	Nenhum efeito prejudicial ou causador de avarias
2	X	X		Mude a operação da máquina ou faça manutenção	Avarias severas nos componentes
2-5	X	X	X ⁽⁵⁾	Imediatamente mude a operação da máquina ou faça manutenção	Avarias severas nos componentes
3	X	X	X ⁽⁵⁾	Desligue o motor com segurança imediatamente	Lesões ao operador ou danos severos aos componentes

(2) A uma taxa de 10Hz

(5) Alarme pulsante

Fonte: (CATERPILLAR, 2019)

Portanto quando os sinais dos componentes elétricos estão fora da faixa operacional normal, o ECM cria o seguinte desdobramento de identificação do problema: MID, CID, FMI. A Module Identifier (MID) é a identificação do módulo relacionado a falha, a Component Identifier (CID) é a identificação do componente relacionado a falha e a Fail Modo Identifier (FMI) é a identificação do modo de falha.

Exemplificando com um dos atributos de entrada denominado Left Front Brake Oil Temperature, caso a temperatura do freio dianteiro esquerdo esteja excessiva (acima de 124°C) haverá um evento de nível 2-S registrado no ECM para o freio: E86(2-S) (Tabela 4.2). Em outro caso, havendo uma falha elétrica no sensor será gerado um código de diagnóstico com CID 853 (Tabela 4.3) e, dependendo do tipo de falha, um código FMI 3, 4 ou 8 (Tabela 4.4).

Tabela 4.2: Código do evento com sua descrição e apresentação das possíveis causas e respostas recomendadas

Código do Evento		
<i>Event Codes (EID) for Brake ECM (MID 116)</i>		
Code (Level)	Description	Possible Cause / Recommended Response
E86 (2s)	High Left Front Brake Oil Temperature	<p>Event activates when Left Front Brake Oil Temperature is $\geq 124^{\circ} C$ (255° F). Deactivates when Left Front Brake Oil Temperature is $\leq 113^{\circ} C$ (235° F).</p> <p>Confirm that the “Front Brake Enable” switch is in the OFF position. Event is commonly due to excessive braking; truck is being operated at too high of a speed for conditions or brake is dragging. Check for leaks in the cooling system of the brakes and check to see if the brake coolant is low. Repair any leaks that are discovered and add hoist and break tank oil to the system, as needed.</p> <p>Reference: “Symptom/Fault Code: Service Brakes Dragging/Overheating EID 86-89 (25.3)” and “Troubleshooting for Break Oil Overheating” found in Troubleshooting. KENR8738, “Brake System”.</p>

Fonte: (CATERPILLAR, 2019)

Tabela 4.3: CID – Código de identificação do componente relacionado a falha

CID 0853 – Brake Oil Temperature Sensor (Left Front)	
FMI 03	Voltage above normal, shorted high

FMI 04	Voltage below normal, bad connection
FMI 08	Abnormal frequency, pulse width, or period

Fonte: (CATERPILLAR, 2019)

Tabela 4.4: FMI - Identificação dos modos de falha e a exibição no display de mensagens

Failure Mode Identifier and Message Center Displays	
FMI	Description of Failure
0	"Data valid but above normal operating range"
1	"Data valid but below normal operating range"
2	"Data erratic, intermittent or incorrect"
3	"Voltage above normal"
4	"Voltage below normal"
5	"Current below normal"
6	"Current above normal"
7	"Mechanical system not responding properly"
8	"Abnormal frequency, pulse width, or period"
9	"Abnormal update"
10	"Abnormal rate of change"
11	"Failure mode not identifiable"
12	"Bad device or component"
13	"Out of calibration"
14	"Special instruction"

Fonte: (CATERPILLAR, 2019)

4.3. Preparação dos Dados

Após a etapa de aquisição e o entendimento dos dados o modelo de processo CRISP-DM propõe realizar a sua preparação, pois a qualidade dos dados submetidos no processo de aprendizado de máquina é essencial para a obtenção de resultados confiáveis. Segundo Louzada, Neto & Diniz (2000), dados limpos e compreensíveis são requisitos básicos para o sucesso do *Data Mining*. Esse passo consome até 80% do tempo e esforço de todo o processo de modelagem, devido às dificuldades de integração de bases de dados heterogêneas (MANNILA, 1996). Nesta dissertação, a fase de tratamento dos dados foi em parte manual, como por exemplo a exclusão de

dados desnecessários nas bases originais, e em outra parte foi realizado por meio de critérios de campos com:

- Percentual máximo de valores perdidos igual a 70%;
- Percentual máximo de registros em uma única categoria igual a 90%;
- Número máximo de categorias como percentual de registros de 95%;
- Coeficiente de variação mínimo igual a 0,1;
- Desvio padrão mínimo de 0;
- Exclusão de atributos com coeficiente de variação mínimo menor que 0,6;

Todos as transformações de dados apresentados neste capítulo foram validadas com especialistas das equipes de manutenção dos caminhões, e a escolha de cada um deles foi feita com base na relação com o problema e com a finalidade desta dissertação, sendo estes os dados a serem aplicados no método de predição. Para selecionar os dados observou-se a qualidade, a confiabilidade e a correlação dos campos de entrada com o campo de saída.

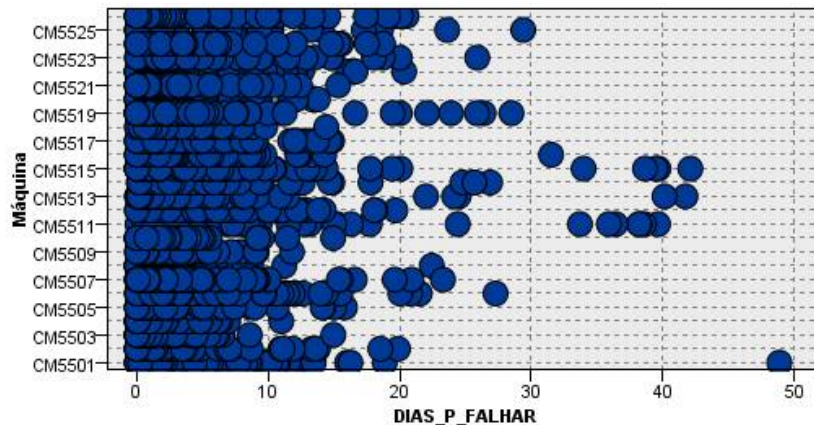
Além da exclusão de dados considerados desnecessários foi preciso padronizar as nomenclaturas, pois diversos campos de atributos de dados assumiam formatos diferentes. Por exemplo, para alguns caminhões o campo de identificação era um dado alfanumérico, enquanto em outros era numérico. Adequar esses desvios é fundamental para o modelador aprender corretamente a lógica dos dados.

Para correlacionar os registros das duas bases de dados utilizadas (isto é, base de sinais vitais e de falhas) foi necessário identificar campos comuns entre elas. Neste trabalho, esses campos foram o código de identificação do caminhão e a data de registro dos sinais vitais. Ou seja, os sinais vitais registrados em um determinado caminhão foram correlacionados às falhas deste mesmo caminhão, através do seu código de identificação e das datas de registro de seus sinais vitais.

O campo status do caminhão foi definido como alvo. Ele é uma variável que pode assumir os valores “falha” ou “em operação”. Esse comportamento direciona para um problema de classificação binária. A definição do campo alvo foi baseada no

histórico de falha. Pelo comportamento das mesmas, o grande volume acontecia antes de 20 dias (Figura 4.1). Conseguir um modelo que prediga se nos próximos 20 dias ocorrerá uma falha, possibilita à equipe de manutenção conhecer, num espaço de tempo maior que os 7 dias atualmente praticados, quais caminhões falharão e quais devem ter intervenções programadas.

Figura 4.1: Análise descritiva do atributo dias para falhar.



Fonte: O Autor, 2020

Após isto, foi realizado o balanceamento de classes nos conjuntos de treino e de teste. Em função da característica de distribuição dos exemplos com uma proporção bem menor de registros de falha em relação a registros de operação normal, utilizou-se a Synthetic Minority Over-sampling Technique (SMOTE) para sobre- amostrar (over-sampling) registros da classe em menor proporção dentro do conjunto de dados.

Antes do balanceamento havia 4.020 registros de falha contra 124.423 registros operando. Após o balanceamento com SMOTE, a quantidade de falhas cresceu para 88.295 para uma mesma quantidade de registros operando.

Realizando a união das duas bases de dados e efetuando todo o tratamento necessário dos dados chegou-se a um total de aproximadamente 129.000 registros para compor o modelo de predição. Porém, registros livres de valores nulos e espúrios não é garantia de que os dados sejam representados por uma distribuição normal padrão (gaussiana), ou seja, com média nula e desvio-padrão unitário. Quando os dados se encontram normalizados, eles podem ser facilmente comparados entre si, sem a influência das diferentes escalas dos valores de cada dado. Desta forma, foi

realizada uma normalização, utilizando a técnica *z-score*, em todos os campos numéricos.

Como citado em Prata (2020), a técnica *z-score* é uma variação de escala que representa o número de desvios-padrão (a partir) da média. Desta forma, é garantido que as distribuições terão média igual a zero e desvio-padrão igual a 1, após aplicação da técnica. A escolha da técnica *z-core* geralmente acontece quando existem valores discrepantes, mas não tão extremos que seja necessário eliminá-los.

4.4. Modelagem

Essa dissertação experimentou diferentes algoritmos, para identificar as melhores opções a serem aplicadas para o problema em voga. Os algoritmos que com os quais foram obtidos melhores resultados foram o algoritmo XGBoost, CHAID, C5.0, RNA, e CRT, estes serão apresentados no próximo capítulo.

Identificar qual o melhor algoritmo de análise preditiva a utilizar requer uma estratégia bem projetada para avaliar a condição de funcionamento da máquina e detectar falhas incipientes de maneira oportuna (THE MATHWORKS, 2020).

Para o modelo de predição é de suma importância a definição dos indicadores de condição para que a partir destes, os dados possam ser extraídos com o objetivo de discriminar estados saudáveis e com falhas. A importância da definição exata dos indicadores de condição se dá porque os modelos de aprendizado de máquina precisam ser treinados com essa premissa, para conseguir classificar diferentes tipos de falhas.

CAPÍTULO 5 : RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados dos testes realizados e as discussões da validação do sistema. Os resultados dos modelos foram avaliados em cada cenário treinado com base nas métricas de Precisão, revocação e *F-1Score*. Para as métricas, assumindo a classe Falha como a classe positiva na classificação, pode-se dizer que: A precisão representa a proporção de acerto nas predições realizadas da classe Falha pelos modelos. O *recall* representa a proporção de caminhões que foram classificados corretamente nas amostras que devem ser classificados como prestes a falhar.


Inicialmente desenvolveu-se um código utilizando a linguagem de programação *Python*, versão 3.7.6, usando funções as bibliotecas *NumPy*, e *Pandas*, versão 1.19.1 e 1.1.1, respectivamente, do pacote *PyCharm* versão 2019.3.3, onde foi realizado um tratamento inicial das bases de dados, bem como para a unificação das mesmas. Mas, como o objetivo ao final do trabalho seria implementar o estudo na empresa e este programa não consta na lista dos softwares autorizados pela TI. Definiu-se o uso do software de previsão *IBM SPSS Modeler* 18.1 sendo realizadas as etapas de construção dos modelos e treinamento.

A configuração do *hardware* utilizado foi Processador Intel Core i5-6200U @2,30 GHz, memória *RAM* 8GB e Sistema Operacional *Microsoft Windows* 10 *Enterprise* 64 bits.

5.1. Cenário 1: Treino com o *Auto Machine Learning*

Antes de realizar os experimentos, os dados foram divididos em amostras de treinamento e teste, onde tentou-se um particionamento temporal. Esta segregação, porém, não resultou em registros de “20 dias para falhar” na partição de dados de teste. Em seguida, foi realizado um particionamento aleatório dos dados de treinamento e teste. Neste caso, o conjunto de dados total tem aproximadamente 97% de registros da classe operando e 3% da classe falha (Figura 5.1).


Figura 5.1: Registros de falha e de operação no conjunto de dados após tratamento inicial.



Fonte: O Autor, 2020

Quando realizado o particionamento do conjunto de dados, cada partição (treinamento e teste) manteve proporções similares entre classes de registros de operação e falha (Figura 5.2).


Figura 5.2: Partições de treinamento e teste e proporções de classes de registros.




Fonte: O Autor, 2020.

O conjunto de dados foi dividido em 60% de registros para base de treinamento, 10% para a base de validação e 30% para base de testes (Figura 5.3).

Figura 5.3: Divisão de classes de dados entre partições de treinamento e teste.






Fonte: O Autor, 2020.

A distribuição populacional dos registros em termos da característica “dias para falhar” dentro do conjunto de dados também foi avaliada, para entender a quantidade de exemplos de registros no tipo “20 dias para falhar” (Figura 5.4).


Figura 5.4: Distribuição de amostras segundo atributo “dias para falhar”.



Fonte: O Autor, 2020.

Após o particionamento, o balanceamento de dados foi realizado com a técnica SMOTE (conforme explicado no tópico 2.5, desta dissertação), para equilibrar o número de amostras de classes positivas (falhas) e negativas (operação) dentro do conjunto de dados de treinamento (Figura 5.5). Neste problema, o número de registros de operação era muito maior do que registros de falha.

Figura 5.5: Base de dados após execução do balanceamento.



Fonte: O Autor, 2020.

Vários algoritmos de aprendizado de máquina foram testados, validando a possibilidade da aplicação de múltiplas técnicas para resolver o mesmo tipo de problema de mineração de dados. Os modelos testados foram o *Auto Classifier*, o C5.0, o RNA, o CRT, a CHAID e a árvore XG Boost-AS.

O experimento inicial desta dissertação foi com o nó *Auto Classifier* do software IBM SPSS Modeler 1.8, que oferece uma análise estatística avançada e uma vasta biblioteca de algoritmos que podem fornecer resultados de predição com apresentações em diferentes formatos (IBM, 2019). Este modelador, estima e compara modelos para metas nominais (definidas) ou binárias (sim/não), usando uma série de métodos diferentes, permitindo que seja experimentado uma variedade de abordagens em uma única modelagem.

É possível selecionar os algoritmos para usar e experimentar com várias combinações de opções. Por exemplo, em vez de escolher entre a Função radial base, métodos polinomial, sigmoide ou linear para um SVM, é possível experimentar todos. O nó explora todas as combinações possíveis de opções, classifica cada modelo candidato com base na medida que este é especificado e salva os melhores modelos para uso em pontuação ou análise suplementar.

No experimento, o nó *Auto Classifier* foi utilizado no modo padrão, onde todos os modelos são selecionados para serem construídos. Abaixo, segue os 17 modeladores utilizados com o objetivo de incluir na comparação e depois os 5 melhores foram experimentados de maneira individual (Tabela 5.1).

Mesmo tendo sido selecionados diversos modelos, o tempo de processamento foi adequado aos testes.

Tabela 5.1: Modeladores do nó *auto classifier*.

Algoritmos suportados no modelador <i>Auto Classifier</i>	
Modelador	
SVM (Support Vector Machine)	máquina vetorial de suporte) permite classificar os dados em um dos dois grupos sem superequipar. O SVM funciona bem com amplos conjuntos de dados, como aqueles com um número muito grande de campos de entrada
k-Near Neighbor (KNN)	associa um novo caso com a categoria ou valor dos objetos k mais próximos a ele no espaço do preditor, onde k é um inteiro. Casos semelhantes são próximos um do outro e casos diferentes estão distantes um do outro.
Análise discriminatória	Faz suposições mais rigorosas do que a regressão logística, mas pode ser uma alternativa valiosa ou complementar a uma análise de regressão logística quando essas suposições são cumpridas
Rede Bayesian	Permite a construção do modelo de probabilidade combinando evidências observadas e registradas com conhecimento do mundo real para estabelecer a probabilidade de ocorrências. O nó se concentra nas redes <i>Tree Augmented Naïve Bayes</i> (TAN) e Markov

	Blanket que são usadas principalmente para classificação.
Lista de decisão	Identifica subgrupos, ou segmentos, que mostram maior ou menor probabilidade de um determinado desfecho binário em relação à população em geral.
Regressão logística	É uma técnica estatística para classificar registros com base em valores de campos de insumos. É análogo à regressão linear, mas toma um campo alvo categórico em vez de uma faixa numérica.
CHAID	Gera árvores de decisão usando estatísticas qui-quadradas para identificar divisões ideais. Ao contrário dos nós da C&R Tree e DO QUEST, o CHAID pode gerar árvores não binárias, o que significa que algumas divisões têm mais de dois ramos. Os campos de destino e entrada podem ser de alcance numérico (contínuo) ou categórico.
QUEST	Fornece um método de classificação binária para construir árvores de decisão, projetado para reduzir o tempo de processamento necessário para grandes análises de árvores C&R, ao mesmo tempo em que reduz a tendência encontrada nos métodos de classificação de árvores para favorecer insumos que permitam mais divisões. Os campos de entrada podem ser intervalos numéricos (contínuos), mas o campo alvo deve ser categórico. Todas as divisões são binárias.

<p>Árvore de classificação e regressão (C&R)</p>	<p>Gera uma árvore de decisão que permite prever ou classificar observações futuras. O método utiliza <i>partitioning</i> recursivo para dividir os registros de treinamento em segmentos minimizando a impureza em cada etapa, onde um nó na árvore é considerado "puro" se 100% dos casos no nó se enquadrarem em uma categoria específica do campo alvo. Os campos de destino e entrada podem ser faixas numéricas ou categóricas (nominal, ordinal ou bandeiras); todas as divisões são binárias (apenas dois subgrupos).</p>
<p>C5.0</p>	<p>Constrói uma árvore de decisão ou um conjunto de regras. O modelo funciona dividindo a amostra com base no campo que fornece o máximo de ganho de informação em cada nível. O campo alvo deve ser categórico. Várias divisões em mais de dois subgrupos são permitidas</p>
<p>Rede Neural</p>	<p>Usa um modelo simplificado da forma como o cérebro humano processa informações. Ele funciona simulando um grande número de unidades de processamento simples interconectadas que se assemelham a versões abstratas de neurônios. Redes neurais são poderosos estimadores de funções gerais e requerem conhecimentos estatísticos ou matemáticos mínimos para treinar ou aplicar.</p>

XGBoost Tree	É uma implementação avançada de um algoritmo de aumento de gradiente com um modelo de árvore como modelo base. Impulsionando algoritmos iterativamente aprender classificadores fracos e, em seguida, adicioná-los a um classificador final forte. XGBoost Tree é muito flexível e fornece muitos parâmetros que podem ser esmagadores para a maioria dos usuários, de modo que o nó XGBoost Tree no SPSS Modeler expõe os recursos principais e parâmetros comumente usados. O nó é implementado em Python.
LSVM (Linear Support Vector Machine)	Permite classificar os dados em um dos dois grupos sem super equipar. O LSVM é linear e funciona bem com amplos conjuntos de dados, como aqueles com um número muito grande de registros.
Random Trees	Semelhante ao nó C&RT existente; no entanto, o nó Random Trees foi projetado para processar big data para criar uma única árvore e exibe o modelo resultante no visualizador de saída que foi adicionado no SPSS® versão Modeler 17
Árvore de Árvores Aleatórias	Gera uma árvore de decisão para prever ou classificar observações futuras. O método utiliza <i>partitioning</i> recursivo para dividir os registros de treinamento em segmentos minimizando a impureza em cada etapa, onde um nó na árvore é considerado puro se 100% dos casos no nó se enquadrarem em uma categoria

	<p>específica do campo alvo. Os campos de destino e entrada podem ser faixas numéricas ou categóricas (nominal, ordinal ou bandeiras); todas as divisões são binárias (apenas dois subgrupos).</p>
Tree-AS	<p>É semelhante ao nó CHAID existente; no entanto, o nó Tree-AS foi projetado para processar big data para criar uma única árvore e exibe o modelo resultante no visualizador de saída que foi adicionado na versão 17 do SPSS Modeler. O nó gera uma árvore de decisão usando estatísticas qui-quadradas (CHAID) para identificar divisões ideais. Este uso de CHAID pode gerar árvores não binárias, o que significa que algumas divisões têm mais de dois ramos. Os campos de destino e entrada podem ser de alcance numérico (contínuo) ou categórico. O CHAID exaustivo é uma modificação do CHAID que faz um trabalho mais minucioso de examinar todas as possíveis divisões, mas leva mais tempo para calcular</p>

XGBoost	É uma implementação avançada de um algoritmo de aumento de gradiente. Impulsionando algoritmos iterativamente aprender classificadores fracos e, em seguida, adicioná-los a um classificador final forte. O XGBoost é muito flexível e fornece muitos parâmetros que podem ser esmagadores para a maioria dos usuários, de modo que o nó XGBoost-AS no SPSS Modeler expõe os recursos principais e parâmetros comumente usados. O nó XGBoost-AS é implementado em Spark.
---------	--

Fonte: IBM, 2019.

Na Tabela 5.2 apresenta-se o resultado da análise das diferentes configurações dos modelos de classificadores XGBoost, Chi-Squared Automatic Interaction Detection (CHAID), C5.0, Redes Neurais Artificiais (RNA), Classification and e Regression Tree (CRT) a fim de encontrar a configuração que conduz a melhores resultados na predição das falhas nos caminhões fora de estrada.

Tabela 5.2: Ranking de modelos de nó auto *classifier*.

#run	Algoritmo	ACC	AUC	REC
1	Neural Network	0,76	0,74	0,60
2	CHAID	0,86	0,75	0,51
3	XGBoost Tree	0,92	0,77	0,39
4	C5.0	0,94	0,76	0,28
5	CRT	0,93	0,72	0,26

Fonte: O Autor, 2020.

Apesar destes terem alcançado resultados interessantes, eles ainda apresentavam um número alto de falsos negativos. Para reduzir este efeito foi experimentado o XGBoost-AS, onde é possível variar-se hiperparâmetros, como lambda e a profundidade. O mesmo conjunto de dados usados no treinamento, validação e teste dos modeladores citados na Tabela 5.2, foi utilizado na Árvore XGBoost para que os resultados pudessem ser comparados e os métodos avaliados.

O *software* IBM SPSS Modeler 1.8 foi o *software* utilizado para simulação da Árvore XGBoost-AS, assim como foi usado nas simulações dos demais modeladores, e com o mesmo objetivo, o de prever a falha nos caminhões fora de estrada em até 10 e 20 dias. No campo da pesquisa, houve a solicitação para realizar experimentos em até 10 dias.

Como citado em PRATA (2020), a árvore XGBoost é um modelo de árvore de decisão que melhora o desempenho do Gradient Boosting, incorporando mais estratégias de regularização para reduzir a complexidade do modelo e o excesso de ajustes. Na Tabela 5.3 apresenta-se as configurações da Árvore XGBoost para falha em até 10 dias e 20 dias.

Tabela 5.3: Configurações da árvore XGBOOST-AS para falha em até 10 dias e 20 dias.

Configuração	Período de análise da falha	Profundidade máxima	Lambda
1	Em até 10 dias	10	0
2		10	1
3		20	0
4		20	1
5	Em até 20 dias	10	0
6		10	1
7		20	0
8		20	1

Fonte: O autor, 2020.

Para treinamento e validação da Árvore XGBoost-AS foram utilizados os parâmetros e configurações default do SPSS Modeler 1.8, modificando-se somente os parâmetros profundidade máxima e lambda. As configurações 1, 2, 3 e 4 são destinadas a apresentar as predições em até 10 dias, e as configurações 5, 6, 7 e 8 para as predições em até 20 dias. O conjunto de dados utilizado foi o mesmo usado na criação dos demais modeladores, totalizando 51.311 registros para as fases de treinamento e validação para ambos os casos de predição, 10 e 20 dias. As métricas de análise dos resultados, para cada configuração, serão a acurácia e o recall.

Na Tabela 5.4 serão apresentados os resultados das configurações de 1 a 8, na qual é possível observar as colunas que descrevem as configurações, os períodos de análise da falha (10 e 20 dias), os valores selecionados para a profundidade máxima da Árvore XGBoost-AS, os resultados das acurácias e recall, de cada configuração na etapa de validação.

Tabela 5.4: Resultados das configurações 1 a 8 na etapa de validação.

Configuração	Período de análise da falha	Profundidade máxima	<i>Lambda</i>	Acurácia	<i>Recall</i>
1	10 dias	10	0	94,45%	30,41%
2		10	1	94,41%	29,20%
3		20	0	97,04%	37,47%
4		20	1	95,76%	31,03%
5	20 dias	10	0	95,39%	35,52%
6		10	1	94,98%	37,71%
7		20	0	98,41%	74,45%
8		20	1	97,43%	46,23%

Fonte: O Autor, 2020.

Nota-se que os melhores resultados de acurácia foram das configurações nas quais a profundidade máxima testada foi igual a 20. No caso do recall houve variações, mas ainda assim os melhores resultados, para o modelo gerado pelo XGboost-AS, com os hiperparâmetros em lambda igual a zero (0) e profundidade igual a vinte (20) na configuração 7 apresentou um melhor resultado.

Para a etapa de testes da Árvore XGBoost-AS foi utilizado o mesmo conjunto de dados que foi utilizado nos testes dos demais modeladores, totalizando 38.253 registros para predição de falha nos caminhões fora de estrada em até 10 e 20 dias. Importante ressaltar que os dados utilizados nessa etapa de teste ainda não foram apresentados para Árvore XGBoost-AS nas etapas anteriores e os resultados serão representados pela acurácia e pelo recall. A Tabela 5.5 apresentará as configurações com as respectivas acurácias e recall nas fases de validação e teste das Árvores XGBoost-AS.

Tabela 5.5: Resultados das configurações da Árvore XGBoost-AS nas etapas de validação e teste.

Configuração	Acurácia (validação)	Acurácia (teste)	Recall (validação)	Recall (teste)
1	94,45%	94,17%	0,30	0,28
2	94,41%	94,17%	0,29	0,28
3	97,04%	96,80%	0,37	0,32
4	95,76%	95,60%	0,31	0,30
5	95,39%	94,97%	0,36	0,27
6	94,98%	94,64%	0,38	0,31
7	98,41%	97,90%	0,74	0,64
8	97,43%	96,97%	0,46	0,35

Fonte: O Autor, 2020.

Após experimentos com diferentes configurações, obteve-se o melhor resultado para o modelo gerado pelo XGboost-AS, com os hiperparâmetros em lambda igual a zero (0) e profundidade igual a vinte (20).

É possível observar, como já era esperado, que os resultados encontrados na fase de testes não foram melhores que os resultados encontrados nas etapas de validação. Ao analisar as acurácias na fase de testes percebe-se que nenhuma delas obteve resultado superior as obtidas na validação, sendo a maior delas a da configuração 7, de 97,90%. Quanto ao recall percebe-se resultados mais satisfatórios, com os hiperparâmetros em lambda igual a zero (0) e profundidade igual a vinte (20).

Os resultados da configuração 7 apresentaram valores mais satisfatórios de acurácia e recall, 97,90% e 0,64 respectivamente, sendo ainda uma acurácia acima de 90%, confirmando a capacidade da Árvore XGBoost-AS de se generalizar para predizer falhas nos caminhões fora de estrada com base nos sinais vitais e os registros de ocorrências de manutenção.

Comparando todos os experimentos realizados, os três modelos que alcançaram melhor qualidade de predição, considerando a condição do problema em questão e a saúde do negócio, foram RNA, CHAID e XGBoost-AS. Estes modelos, então, foram comparados em relação às métricas de desempenho.

As matrizes de confusão estão apresentadas abaixo, para cada um dos modelos (Tabela 5.6). A partir delas é possível calcular a Taxa de Positivos Verdadeiros, dentre outras métricas de avaliação. Esta taxa se mostra importante para

o problema em questão. Como já analisado, para este problema é inaceitável e pode ser trágico para o negócio uma classificação de casos positivos como negativos (FN). A manutenção não pode ser surpreendida por caminhões fora de estrada falhando sem previsão.

Tabela 5.6: Matrizes de Confusão dos modelos RNA, CHAID e XGBoost-AS.

		RNA	
		Classe predita	
		+	-
Classe verdadeira	+	695	466
	-	8859	28233

		CHAID	
		Classe predita	
		+	-
Classe verdadeira	+	590	571
	-	4630	32462

		XGBoost-AS	
		Classe predita	
		+	-
Classe verdadeira	+	745	416
	-	386	36706

Fonte: O Autor, 2020.

Aprofundando-se mais na análise dos modelos, foram comparadas a acurácia (ACC) e recall (também denominada revocação ou sensibilidade) desses classificadores. Os valores apurados estão consolidados na Tabela 5.7.

Tabela 5.7: Métricas consolidadas após validação dos modelos de CHAID, RNA e XGBoost-AS.

	Acurácia (ACC)	Recall
XGBoost-AS	97,90%	64,17%
RNA	75,62%	59,86%
CHAID	86,40%	50,82%

Fonte: O Autor, 2020.

Como apurado, três modelos apresentaram melhores resultados. O XGBoost-AS apresentou a maior acurácia, enquanto o RNA a menor. O CHAID assumiu um valor de acurácia mais alto que o RNA (86,40%), mais próximo do XGBoost-AS. Por

outro lado, obteve um menor recall de 50,82%, se aproximando do RNA nessa métrica.

Em relação a recall, métrica determinante para a escolha e para a qualificação do modelo para uso no problema em questão, o classificador CHAID comportou-se como um modelo de baixo recall. Por outro lado, o RNA obteve um valor de recall igual a 59,86%. Neste requisito, o modelo XGBoost-AS, suplantou os outros alcançando na etapa de teste recall de 64,17% e na etapa de validação 74,45%.

Para a avaliação dos modelos, a lógica de avaliação recall é a métrica que garantirá um modelo mais conservador, pois para o problema em estudo, o classificador deve, de qualquer maneira, encontrar todos os caminhões que necessitam de manutenção, mesmo que classifique assim alguns que, na verdade, não precisem (situação de FP). Ou seja, o modelo deve ter alto recall, pois classificar caminhões que precisam de manutenção como “não precisam” é péssimo para o processo.

Olhar a métrica precisão pode levar a indicação de manutenção para um caminhão que, na verdade, não precise e a uma não indicação de manutenção para um caminhão que, na verdade, precise, possibilitando uma inaceitável falha sem previsibilidade. Assim, o modelo de classificador para o problema em análise não precisará ser tão preciso, uma vez que a situação do equipamento falhar sem planejamento e programação de manutenção é extremamente prejudicial ao processo, mas sim deve ser um modelo sensível a detecção de equipamentos a falhar.

CAPÍTULO 6 : CONCLUSÃO

O objetivo desta dissertação foi encontrar os modelos de classificação, entre modelos gerados por diferentes algoritmos de aprendizado de máquina (como XGBoost, CHAID, C5.0, RNA, e CRT), que fossem mais efetivos na predição de falhas em caminhões fora de estrada, para apoiar a decisão da parada de caminhões fora de estrada visando reduzir as paradas de manutenção corretiva.

Os dados foram adquiridos numa grande empresa do setor de Mineração e passaram por tratamento como normalização, análise de correlação e balanceamento sobre-amostragem. Na implementação, foi experimentado o modelador Auto Machine Learning do Sistema SPSS Modeler. Este modelador indicou como melhor resultado o algoritmo XG Boost. A árvore XG Boost foi testada em diferentes calibrações de profundidade máxima (10 e 20), lambda (0 e 1) e outros 6 parâmetros fixados, sendo 4 deles para controle de super ajustes. Além dos experimentos de modo individual com os outros modeladores que apresentaram melhores resultados no Auto ML.

A metodologia se mostrou eficaz para prever se o caminhão irá falhar ou não com base nos dados de sinais vitais destes, correlacionadas as falhas ocorridas dentro do mesmo período. Para os melhores algoritmos, a Taxa de Positivos Verdadeiros variou entre cerca de 51% a 64%, resultados satisfatórios para esse tipo de problema de classificação. Isso indica que o método de seleção de variáveis se mostrou eficiente para reduzir o número de atributos de entrada e a complexidade do problema.

Por meio dos resultados e análises realizadas nas diferentes configurações testadas, com o objetivo de se prever falhas em caminhões fora de estrada com base em seus sinais vitais, pode-se afirmar que os algoritmos poderão ser utilizados como uma ferramenta de auxílio na realização dos planos de manutenção dos caminhões fora de estrada.

Comparando os diferentes modeladores, a Árvore XGBoost apresentou os melhores desempenhos, conclui-se que a acurácia da Árvore XGBoost foi superior a acurácia da RNA em 22,28%. O recall da Árvore XGBoost foi superior ao do modelador CRT em 37,98%, sendo estes o de melhor e pior recall, respectivamente.

Levando em consideração a utilização do método de predição na prática dos planos de manutenção dos caminhões fora de estrada, entende-se que a Árvore XGBoost poderá auxiliar melhor as decisões de manutenção. Deste modo, os experimentos executados em ambientes computacionais (simulados) comprovam a validade do aprendizado de máquina para a criação de modelos de predição de falhas em caminhões fora de estrada utilizados no processo industrial de mineração. Ou seja, os resultados são aplicáveis na prática e poderão contribuir ao modelo atual em operação nas unidades da VALE de modo a torná-lo mais robusto.

Desta pesquisa, foi produzido o *paper* ***Machine Learning Applied to Fault Prediction in Off-Road Trucks*** aceito no congresso internacional Automining 2020 e que será apresentado em dezembro de 2020, fruto de todo o aprendizado sobre metodologia, técnicas e ferramentas de análise preditiva com aprendizado supervisionado e sobre o processo de manutenção de caminhões fora de estrada.

6.1. Trabalhos Futuros

Como trabalhos futuros propõem-se realizar a predição da falha, sendo realizados testes envolvendo validação cruzada, não somente apontando que o caminhão irá falhar, mas também qual componente ocorrerá a falha predita é capaz de reduzir em escala os custos da manutenção deste tipo de equipamento. Conhecer antecipadamente o exato componente a ser substituído em determinando prazo possibilita tomadas de decisão estratégicas com desenvolvimento de boas práticas de gestão orçamentária mais efetivas. Afinal, o duro desafio da gestão de manutenção é o de lidar com não apenas um, mas com frotas numerosas de caminhões fora de estrada.

Nesta intenção, um passo essencial é correlacionar as bases de dados dos sinais vitais com as bases de análises de óleo e os históricos de trocas de componentes. Em seguida, propõem-se também a comparação dos resultados dos modelos obtidos pelos métodos de aprendizagem de máquina RNA e XG Boost Tree com outros métodos, como o *One-Class SVM*, *k-NN* e algum Método de Regressão.

Para avaliação dos resultados, sugere-se para a condução de uma linha de análise a utilização da ROC de acurácia e das métricas de AUC, de Recall e de ACC,

segundo o tipo de componente em busca de se predizer, assim como a aplicação de algoritmos para ajuste de hiper parâmetros para calibrar o treinamento e melhorar a capacidade de generalização do classificador modelado.

Referências

- ABNT. (1994). NBR 5462: Confiabilidade e Manutenibilidade. Rio de Janeiro: ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS.
- ALPAYDIN, E. (2004). *Introduction to Machine Learning (Adaptive Computation and Machine Learning Series)*. Cambridge: MIT.
- BALDISSARELLI, L., & FABRO, E. (2019). Manutenção Preditiva na indústria 4.0. *Scientia cum Industria*, v. 7, n. 2, pp. 12-22.
- BECK, J. W., & JOHNSON, J. H. (1984). The application of analytical ferrography and spectroscopy to detect normal and abnormal diesel engine wear. *SAE transactions*, pp. 1093-1106.
- BELL, J. (2020). *Machine learning: hands-on for developers and technical professionals*. John Wiley & Sons.
- BORGES, F. A. (2013). Extração de características combinadas com árvore de decisão para detecção e classificação dos distúrbios de qualidade da energia elétrica. *Tese de Doutorado*. Universidade de São Paulo.
- BRITTO, R. d., & PEREIRA, M. A. (2003). Manutenção autônoma: estudo de caso em empresa de porte médio do setor de bebidas. *VII SEMEAD, Seminário de Estudos de Administração da USP*. Universidade de São Paulo.
- CATERPILLAR. (2019). *SISCAT*. Fonte: CATERPILLAR: <https://login.cat.com/cgi-bin/login>
- CHAPELLE, O., SCHOLKOPF, B., & ZIEN, A. (2006). *Semi-supervised learning*. MIT Press.
- CHAWLA, N. V. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321-357.
- CHEN, T., & GUESTRIN, C. (2016). Xgboost: A scalable tree boosting system. *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, (pp. 785-794).
- CHO, Y., KIM, Y.-C., & SHIN, Y. (2017). Prediction model of construction safety accidents using decision tree technique. *Journal of the Korea Institute of Building Construction*, 17(3), 295-303.

- DE PISÓN, F., URRACA, R., QUINTIÁN, H., & CORCHADO, E. (2017). Hybrid Artificial Intelligent Systems: 12th International Conference. *HAIS*, 10334. La Rioja.
- DIAS, A. O. (2010). *ENGENHARIA DE CONFIABILIDADE: UM ESTUDO DE CASO DE ANÁLISE DE FALHA DE COMPONENTE CRÍTICO DO TREM DE FORÇA DO CAMINHÃO ELETRODIESEL 830E-AC E PROPOSIÇÕES DE MELHORIAS PARA AUMENTO DE DESEMPENHO*. UFOP, DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO – DEPRO, Ouro Preto.
- DIETZ, W. E., KIECH, E. L., & ALI, M. (1988). Pattern-based fault diagnosis using neural networks. *Proceedings of the 1st international conference on Industrial and engineering applications of artificial intelligence and expert systems*, 1, pp. 13-23.
- EL-GHAMRY, M. H., REUBEN, R. L., & STEEL, J. A. (2003). The development of automated pattern recognition and statistical feature isolation techniques for the diagnosis of reciprocating machinery faults using acoustic emission. *Mechanical Systems and Signal Processing*, 17(4), 805-823.
- FACELI, K., LORENA, A. C., GAMA, J., & CARVALHO, A. C. (2019). *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. Rio de Janeiro: LTC.
- FOG, T., BROWN, E. H., MADSEN, L., SORENSEN, P., HANSEN, E., STEEL, J., . . . PEDERSEN, P. (1988). Exhaust Valve Leakage Detection in Large Marine Diesel Engines. *COMADEM 98*, (pp. 269-278). Launceston.
- FRIEDMAN, J. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, (pp. 1189-1232).
- FURTADO, F. M. (2009). *Redes Neurais na Manutenção Preditiva de Caminhões Fora de Estrada. Tese de Doutorado*. PUC-Rio.
- GAMA, A. L. (2017). *O uso de machine learning na implementação de manutenção preditiva em usinas termelétricas*. Universidade Federal do Rio de Janeiro.
- GEORGANOS, S. (2018). Very high resolution object-based land use–land cover urban classification using extreme gradient boosting. *IEEE geoscience and remote sensing letters*, 15(4), pp. 607-611.

- GRIMMELIUS, H., MEILER, P., MAAS, H., BONNIER, B., GREVINK, J., & KUILENBURG, R. (1999). Three State-of-the-Art Methods for Condition Monitoring. *IEEE Transactions on Industrial Electronics*, 46(2), pp. 407-416.
- HALMENSCHLAGER, C. (2002). *Um algoritmo para indução de árvores e regras de decisão*.
- HERMANN, M., PENTEK, T., & OTTO, B. (2016). Design Principles for Industrie 4.0 Scenarios: A Literature Review. *49th Hawaii international conference on system sciences (HICSS)* (pp. 3928-3937). IEEE.
- HIPKIN, I. B., & DE COCK, C. (2000). TQM and BPR: Lessons for Maintenance Management. *Omega*, pp. 277-292.
- IBM. (2019). IBM SPSS MODELER CRISP-DM GUIDE. 18(1), 1-2. Armonk, NY, USA.
- JAMES, G. (2018). Tree-based methods. *An introduction to statistical learning*, (pp. 303-335). New York.
- KARDEC, A., & NASCIF, J. (2001). *Manutenção: função estratégica* (2 ed.). Rio de Janeiro: Qualitymark.
- LEME, M. O. (2017). *Metodologia de manutenção preditiva para motores elétricos baseada em monitoramento de variáveis físicas e análise multicritério*. Projeto de Doutorado, UTF/PR, Engenharia de Produção, Ponta Grossa.
- LEVITT, J. (1997). *The Handbook of maintenance management*. NY: Industrial Press Inc.
- LIU, Y., LIU, Z., XIE, Y., & YAO, Z. (2000). Research on an on-line wear condition monitoring system for marine diesel engine. *Tribology International*, 33(12), pp. 829-835.
- LOUZADA NETO, F., & DINIZ, C. (2000). *Data mining: uma introdução*. São Paulo: Associação Brasileira de Estatística.
- MANNILA, H. (1996). Data mining: machine learning, statistics, and databases. *Proceedings of 8th International Conference on Scientific and Statistical Data Base Management* (pp. 2-9). IEEE.
- MARÇAL, R. F. (2004). *Gestão da Manutenção*. Notas de aula, Programa de Pós-Graduação em Engenharia da Produção, Ponta Grossa.
- MITCHELL, T. M. (1997). *Machine Learning*. New York: McGraw-Hill Higher Education.

- MOLINARO, F., & CASTANIE, F. (Janeiro de 1995). Signal Processing Pattern Classification Techniques to Improve Knock Detection in Spark Ignition Engines. *Mechanical Systems and Signal Processing*, 9(1), pp. 51-62.
- MONARD, M. C., & BARANAUSKAS, J. A. (2003). Conceitos sobre aprendizado de máquina. Em S. O. Rezende (Ed.), *Sistemas Inteligentes: Fundamentos e Aplicações* (pp. 89–114). MANOLE LTDA.
- MONCHY, F. (1989). *A função manutenção: formação para a gerência da manutenção industrial*. São Paulo: Durban.
- NOGARE, D. (2020). *Performance de Machine Learning – Matriz de Confusão*. Acesso em 24 de 08 de 2020, disponível em Diego Nogare - Inteligência Artificial & Machine Learning: <http://diegonogare.net/2020/04/performance-de-machine-learning-matriz-de-confusao/>
- NUNES, E. L. (2015). *Saberes da Manutenção: uma visão sistêmica*. Paraná: UFPR.
- PESTANA-VIANA, D., ZAMBRANO-LÓPEZ, R., DE LIMA, A. A., PREGO, T. D., NETTO, S. L., & DA SILVA, E. A. (2016). The influence of feature vector on the classification of mechanical faults using neural networks. *IEEE 7th Latin American Symposium on Circuits & Systems (LASCAS)* (pp. 115-118). IEEE.
- PRATA, J. A. (2020). *Predição de falha em motor diesel de locomotiva baseada na análise do óleo lubrificante por meio de técnicas de aprendizado de máquina*. Dissertação de Mestrado, Universidade Federal do Espírito Santo, Centro Tecnológico, Vitória.
- ROCHA, D. S. (2018). *Aprendizado de máquina aplicado ao reconhecimento automático de falhas em máquinas rotativas*. Dissertação de Mestrado, UFMG, Escola de Engenharia, Belo Horizonte.
- RODRIGUES, V. (2019). *Métricas de Avaliação: acurácia, precisão, recall... quais as diferenças?* Acesso em 24 de 08 de 2020, disponível em Medium: <https://medium.com/@vitorborbarodrigues/m%C3%A9tricas-de-avalia%C3%A7%C3%A3o-acur%C3%A1cia-precis%C3%A3o-recall-quais-as-diferen%C3%A7as-c8f05e0a513c>
- SIQUEIRA, I. P. (2005). *Manutenção Centrada na Confiabilidade: Manual de Implementação* (1 ed.). Rio de Janeiro: Qualitymark.

- TAN, P. N., STEINBACH, M., & KUMAR, V. (2005). *Introduction to Data Mining* (1 ed.). Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc.
- TAVARES, L. A. (1999). *Administração moderna da manutenção*. Rio de Janeiro: Novo Polo.
- THE MATHWORKS. (2020). *Designing Algorithms for Condition Monitoring and Predictive Maintenance*. Acesso em 25 de 07 de 2020, disponível em Mathworks: <https://www.mathworks.com/help/predmaint/gs/designing-algorithms-for-condition-monitoring-and-predictive-maintenance.html>
- THOMAS, J., DUBUISSON, B., AGENS, M., & PELTIER, D. (1997). Engine Knock Detection from Vibration Signals Using Pattern Recognition. *International Journal of Mechanical*, 32(5), 431-439.
- TING, K. M. (2017). Confusion Matrix. *Encyclopedia of Machine Learning and Data Mining*, 260.
- XENOS, H. G. (1998). *Gerenciando a manutenção produtiva*. Belo Horizonte: DG.
- ZHENG, Z., XINYU, S., & DAOYUAN, Y. (2006). Fault Diagnosis of a wheel Loader by Artificial Neural Networks and Fuzzy Logic. *IEEE Conference on Robotics, Automation and Mechatronics* (pp. 1-5). IEEE.