

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE COMPUTAÇÃO**

Marcelly Homem Coelho

**MINERAÇÃO DE DADOS E APRENDIZADO DE MÁQUINA
APLICADOS AO PROGNÓSTICO DE FALHAS EM COMPONENTES
AERONÁUTICOS**

Araranguá

2020

Marcelly Homem Coelho

**MINERAÇÃO DE DADOS E APRENDIZADO DE MÁQUINA
APLICADOS AO PROGNÓSTICO DE FALHAS EM COMPONENTES
AERONÁUTICOS**

Trabalho de Conclusão de Curso submetido ao curso de Bacharelado em Engenharia de Computação para a obtenção do grau de Bacharela em Engenharia de Computação.

Orientador: Prof. Anderson Luiz Fernandes Perez, Dr.

Coorientador: Roberto Smidt Hirschmann

Embraer S.A

Araranguá

2020

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Homem Coelho, Marcelly

Mineração de dados e aprendizado de máquina aplicados ao prognóstico de falhas em componentes aeronáuticos / Marcelly Homem Coelho ; orientador, Anderson Luiz Fernandes Perez, coorientador, Roberto Smidt Hirschmann, 2020.

79 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Campus Araranguá, Graduação em Engenharia de Computação, Araranguá, 2020.

Inclui referências.

1. Engenharia de Computação. 2. Prognóstico de falhas Aprendizado de Máquina. 3. Mineração de dados. 4. Aprendizado de máquina. 5. Manutenção preditiva.. I. Fernandes Perez, Anderson Luiz . II. Smidt Hirschmann, Roberto . III. Universidade Federal de Santa Catarina. Graduação em Engenharia de Computação. IV. Título.

Marcelly Homem Coelho

**MINERAÇÃO DE DADOS E APRENDIZADO DE MÁQUINA
APLICADOS AO PROGNÓSTICO DE FALHAS EM COMPONENTES
AERONÁUTICOS**

Este Trabalho de Conclusão de Curso foi julgado aprovado para a obtenção do Título de “Bacharela em Engenharia de Computação”, e aprovado em sua forma final pelo curso de Bacharelado em Engenharia de Computação.

Araranguá, 3 de dezembro 2020.



Documento assinado digitalmente
Fabrício de Oliveira Ourique
Data: 14/12/2020 20:25:19-0300
CPF: 916.167.860-00

Prof. Fabrício Ourique, Dr.
Coordenador do Curso

Banca Examinadora:



Documento assinado digitalmente
Anderson Luiz Fernandes Perez
Data: 14/12/2020 15:04:59-0300
CPF: 020.803.459-58

Prof. Anderson Luiz Fernandes Perez, Dr.
Orientador

DocuSigned by:
Roberto Smidt Hirschmann
AR00RFL3M57R676

Roberto Smidt Hirschmann
Embraer S.A
Coorientador

João Pedro Pinheiro Malere
Embraer S.A



Documento assinado digitalmente
Luciana Bolan Frigo
Data: 14/12/2020 14:48:34-0300
CPF: 910.389.799-00

Prof.(a) Luciana Bolan Frigo, Dr.(a)



Documento assinado digitalmente
Alexandre Leopoldo Goncalves
Data: 14/12/2020 15:44:50-0300
CPF: 786.740.349-34

Prof. Alexandre Leopoldo Gonçaves, Dr.

Este trabalho é dedicado aos meus pais, familiares e todos aqueles que me apoiaram nesta jornada.

AGRADECIMENTOS

Ao professor Anderson Luiz Fernandes Perez, meu orientador, pela educação, incentivo e ensinamentos que levarei em cada passo da minha vida.

Ao Roberto Smidt Hirschmann, meu coorientador, pela amizade, atenção e confiança depositada em mim durante a realização deste trabalho, especialmente no período de estágio na Embraer. Agradeço também pela disponibilidade. Cada reunião foi um enorme aprendizado.

Ao engenheiro João Pedro Pinheiro Malere pelo importante auxílio ao longo da elaboração deste trabalho.

Aos supervisores César Ortolani Marcondes de Castro e Edilson Cardoso pela oportunidade de fazer parte da equipe fantástica de *Innovation & Digital* da área de Serviços e Suporte da Embraer. Grata a toda a equipe pelo apoio e direcionamento. Agradeço também ao supervisor Luiz Augusto Rodrigues Nerosky por suas contribuições.

Ao professor Rafael Santos, do Instituto Nacional de Pesquisas Espaciais (INPE), por ter me oferecido a oportunidade de cursar as disciplinas de Introdução à Ciência de Dados e Princípios e Aplicações de Mineração de Dados.

As professoras Eliane Pozzebon e Luciana Bolan Frigo do Laboratório de Tecnologias Computacionais (LabTeC) por terem me acolhido e compartilhado tanto do seus saberes desde o início da graduação. Muito obrigada por tudo.

Aos professores do curso Técnico em Informática, Jéferson Mendonça de Limas, Cristiane Machado de Vargas e Daniel Fernando Anderle, do Instituto Federal de Educação, Ciência e Tecnologia Catarinense, por terem me incentivado a seguir na área de computação.

A todos os amigos que fiz no decorrer destes anos no LabTeC, pelo companheirismo, ensinamentos e ambiente agradável compartilhado.

A instituição de ensino Universidade Federal de Santa Catarina por me proporcionar formação profissional de qualidade, baseada nos pilares de ensino, pesquisa e extensão.

A minha família que sempre me incentivou a aprender, especialmente o meu avô, Zelindo Homem, que sempre se mostrou muito orgulhoso durante cada etapa da minha vida profissional.

Grata a todas as pessoas que me ajudaram ao longo do percurso.

Por fim, agradeço aos membros da banca examinadora por suas contribuições.

Uma vez que você tenha experimentado voar, você andará pela terra com seus olhos voltados para o céu, pois lá você esteve e para lá você desejará voltar.

Leonardo da Vinci

RESUMO

No setor de transporte aéreo, a manutenção preditiva de sistemas é um importante campo de estudo para reduzir os custos operacionais causados por eventos não programados e aumentar a disponibilidade das aeronaves. Estes fatores motivam pesquisas relacionadas ao monitoramento da condição para promover diagnósticos e prognósticos de falhas. Neste contexto, este trabalho propõe um método para promover prognóstico de falhas em componentes aeronáuticos por meio da abordagem orientada a dados. Para tanto, foram utilizadas técnicas de mineração de dados e aprendizado de máquina em um conjunto de dados históricos referentes ao sistema de indicação de motores e alerta de tripulação, mensagens de manutenção, dados de sensores e reportes de remoções de componentes. Os conjuntos de dados foram obtidos por meio de parâmetros registrados pelo sistema de bordo da aeronave. O trabalho descreve o desenvolvimento de um sistema computacional, cuja finalidade é avaliar o potencial de modelos de aprendizado de máquina na estimativa de vida útil remanescente de componentes do sistema pneumático. A contribuição deste trabalho consiste na comparação de diferentes casos orientados a dados. O modelo de *Gradient Boosting* foi capaz de avaliar a condição de degradação de um modo de falha com uma taxa de acerto média de 64,65% com desvio padrão de 5,89%. Os resultados experimentais obtidos demonstram que o método proposto possui potencial na previsão da vida útil remanescente dos componentes do sistema pneumático, mais especificamente, do subsistema de controle ambiental. A principal observação do estudo foi que a implementação de prognóstico de falhas combinando recursos de mensagens do sistema de bordo e dados de sensores apresentou a melhor probabilidade de detecção de falha e menor taxa de falso alarme entre as situações avaliadas. Por fim, destaca-se que o método pode ser estendido a outros sistemas de aeronaves, desde que os dados de voo e os registros de manutenção sejam disponibilizados.

Palavras-chave: Prognóstico de Falhas. Aprendizado de Máquina. Mineração de Dados. Manutenção Preditiva.

ABSTRACT

In the air transport sector, predictive systems maintenance is an important field of study to decrease the operational costs caused by unforeseen events and increase aircraft availability. These factors motivate studies on condition monitoring in order to promote failure diagnosis and prognosis. In this context, this work proposes a method to promote failure prediction in aeronautical components through a data-oriented approach. For this purpose, data mining and machine learning techniques were used on a set of historical data referring to the engine indicating and crew alerting system, maintenance messages, sensor data and component removal reports. The data set was obtained using parameters recorded by the aircraft's on-board system. The work describes the development of a computational system, which purpose is to evaluate the potential of machine learning models in estimating the remaining functional lifespan of pneumatic system components. The contribution of this work consists in the comparison of different data-oriented cases. The Gradient Boosting model was able to assess the degradation condition of a failure mode with an average success rate of 64.65% and a standard deviation of 5.89%. The obtained experimental results show that the proposed method indeed has the potential to predict the remaining useful lifespan of the pneumatic system components, more specifically, of the environmental control subsystem. The main observation of the study was that the implementation of failure prognosis combining on-board messaging resources and sensor data showed the best probability of failure detection and the lowest false positive rate among the evaluated situations. Finally, it should be noted that the method can be extended to other aircraft systems, as long as flight data and maintenance records are available.

Keywords: Failure Prognostic. Machine Learning. Data Mining. Predictive Maintenance.

LISTA DE FIGURAS

Figura 1	Representações genéricas de sistemas da aeronave.	20
Figura 2	Exemplo genérico do sistema pneumático.	21
Figura 3	Sistema simplificado de sangria de ar e sistemas associados.	22
Figura 4	Válvula PRSOV no sistema de controle ambiental.	23
Figura 5	Arquitetura genérica de comunicação a bordo.	24
Figura 6	Painel principal de instrumentos eletrônicos de uma aeronave.	26
Figura 7	Exemplo de informações no EICAS.	27
Figura 8	Representação dos tipos de manutenção aeronáutica.	29
Figura 9	Representação da curva P-F.	30
Figura 10	Uma taxonomia de abordagens em PHM.	34
Figura 11	Etapas do processos de KDD.	37
Figura 12	Partes do processo de aprendizado de máquina automatizado por TPOT.	40
Figura 13	Representação do método de validação cruzada <i>K-fold</i>	45
Figura 14	Método proposto para aplicação de mineração de dados e aprendizado de máquina no prognóstico de falhas.	47
Figura 15	Representações de perfis de voos.	51
Figura 16	Representações das classes de saída do prognóstico de falhas.	56

LISTA DE TABELAS

Tabela 1	Exemplo de matriz de confusão para duas classes.....	43
Tabela 2	Estrutura do arquivo de mensagens do sistema de indicação do motor e alerta da tripulação.....	48
Tabela 3	Estrutura do arquivo das mensagens de manutenção.....	48
Tabela 4	Estrutura do arquivo de dados de remoções.....	49
Tabela 5	Estrutura do arquivo de dados de sensores.....	49
Tabela 6	Matriz de confusão para o Caso 1(a).....	60
Tabela 7	Métricas de avaliação para o Caso 1(a).....	60
Tabela 8	Matriz de confusão para o Caso 1(b).....	61
Tabela 9	Métricas de avaliação para o Caso 1(b).....	61
Tabela 10	Matriz de confusão para o Caso 2.....	61
Tabela 11	Métricas de avaliação para o Caso 2.....	62
Tabela 12	Matriz de confusão para o Caso 3.....	62
Tabela 13	Métricas de avaliação para o Caso 3.....	63
Tabela 14	Matriz de confusão para o Caso 4.....	63
Tabela 15	Métricas de avaliação para o Caso 4.....	63
Tabela 16	Matriz de confusão para o Caso 5.....	64
Tabela 17	Métricas de avaliação para o Caso 5.....	64
Tabela 18	Matriz de confusão para o Caso 6.....	65
Tabela 19	Métricas de avaliação para o Caso 6.....	65
Tabela 20	Comparativo entre os modelos de aprendizado de máquina.....	77

LISTA DE ABREVIATURAS E SIGLAS

IATA	<i>International Air Transport Association</i>	15
ANAC	Agência Nacional de Aviação Civil.....	15
MRO	<i>Maintenance, Repair and Overhaul</i>	15
ABEAR	Associação Brasileira das Empresas Aéreas	15
MD	Mineração de Dados.....	15
AM	Aprendizado de Máquina.....	15
AutoML	<i>Automated Machine Learning</i>	17
TPOT	<i>Tree Based Pipeline Optimization Tool</i>	17
APU	<i>Auxiliary Power Unit</i>	21
ECS	<i>Environmental Control System</i>	21
PRSOV	<i>Pressure Regulating Shutoff Valve</i>	22
SOV	<i>Shutoff Valve</i>	22
BITE	<i>Built-In Test Equipment</i>	23
QAR	<i>Quick Access Recorder</i>	24
ASCB	<i>Avionics Standard Communication Bus</i>	24
LAN	<i>Local Area Network</i>	24
MAU	<i>Modular Avionic Unit</i>	25
VBPCI	<i>Virtual Backplane Peripherol Component Interconnect</i>	25
AFDAU	<i>Flight Data Acquisition Unit</i>	25
FDR	<i>Flight Data Recorder</i>	25
CVR	<i>Cockpit Voice Recorder</i>	25
EICAS	<i>Engine Indicating and Crew Alerting System</i>	26
CMC	<i>Central Maintenance Computing</i>	27
PHM	<i>Prognostic Health Management</i>	28
RUL	<i>Remaining Useful Life</i>	32
IA	Inteligência Artificial.....	35
KDD	<i>Knowledge Discovery in Databases</i>	37
GBM	<i>Gradient Boosting Machine</i>	40
MSE	<i>Mean Square Error</i>	42
RMSE	<i>Root Mean Square Error</i>	42
VP	Verdadeiro Positivo	43
VN	Verdadeiro Negativo.....	43
FP	Falso Positivo	43
FN	Falso Negativo	43
FDE	<i>Flight Deck Event</i>	48
MM	Mensagem de Manutenção	48
RR	Reporte de Remoção	48

LISTA DE SÍMBOLOS

\bar{x} – Média aritmética

s^2 – Variância

s – Desvio padrão amostral

ω – Oscilação

α – Taxa de falso alarme

β – Probabilidade de detecção

τ – Taxa de aprendizado

i – Índice de contagem

M – Número total de iterações

N – Número total de observações

e – Erro

P_{Q_n} – Posição do quartil n no conjunto de dados

SUMÁRIO

1 INTRODUÇÃO	15
1.1 OBJETIVOS	16
1.1.1 Objetivo Geral	16
1.1.2 Objetivos Específicos	16
1.2 MOTIVAÇÃO E JUSTIFICATIVA	16
1.3 METODOLOGIA DA PESQUISA	17
1.4 HIPÓTESE	18
1.5 ORGANIZAÇÃO DO TRABALHO	18
2 FUNDAMENTOS DE SISTEMAS DE AERONAVES	19
2.1 DESCRIÇÃO DE SISTEMAS DE AERONAVES	19
2.1.1 Sistema Pneumático	20
2.1.2 Sistema de Aquisição, Armazenamento e Transmissão de Dados	24
3 MANUTENÇÃO AERONÁUTICA	28
3.1 TIPOS DE MANUTENÇÃO AERONÁUTICA	28
3.1.1 Manutenção Preventiva	29
3.1.2 Manutenção Corretiva	30
3.1.3 Manutenção Preditiva	31
3.1.3.1 Fundamentos de Aprendizado de Máquina	35
3.1.3.2 Fundamentos de Mineração de Dados	37
3.1.3.3 Aprendizado de Máquina Automatizado	38
3.1.3.4 Algoritmos de Classificação	40
3.1.3.5 Métricas de Avaliação	42
4 DESCRIÇÃO DO MÉTODO PROPOSTO PARA A PREDIÇÃO DE FALHAS EM COMPONENTES AERONÁUTICOS	46
4.1 MÉTODO PROPOSTO	46
4.1.1 Identificação e Compreensão do Conjunto de Dados	48
4.1.2 Pré-processamento de Dados	49
4.1.3 Seleção de Dados	50
4.1.4 Construção de Recursos	51
4.1.4.1 Recursos dos Dados de Sensores	52
4.1.4.2 Recursos dos Dados de Mensagens de Falha	54
4.1.5 Aplicação do Aprendizado de Máquina Automatizado	54
4.1.5.1 Descobrimto do Modelo de Aprendizado de Máquina	54
4.1.5.2 Execução do Modelo de Aprendizado de Máquina	55
4.1.6 Aplicação do Algoritmo de Mineração de Dados	56
4.1.7 Avaliação de Padrões	57
5 DESCRIÇÃO E AVALIAÇÃO DOS RESULTADOS OBTIDOS COM O MÉTODO PROPOSTO PARA A MANUTENÇÃO PREDITIVA DE AERONAVES	59
5.1 METODOLOGIA ADOTADA NA REALIZAÇÃO DOS EXPERIMENTOS ..	59
5.1.1 Análise do Caso 1(a)	59
5.1.2 Análise do Caso 1(b)	60
5.1.3 Análise do Caso 2	61
5.1.4 Análise do Caso 3	62
5.1.5 Análise do Caso 4	63

5.1.6 Análise do Caso 5	64
5.1.7 Análise do Caso 6	64
5.2 DISCUSSÕES DOS RESULTADOS	65
6 CONSIDERAÇÕES FINAIS E PROPOSTAS PARA TRABALHOS FUTUROS	67
6.1 PROPOSTAS PARA TRABALHOS FUTUROS	69
REFERÊNCIAS	70
APÊNDICE A – Algoritmo <i>Gradient Boosting</i>	75
APÊNDICE B – Comparação entre os casos executados e modelos de aprendizado de máquina.	77

1 INTRODUÇÃO

De acordo com dados estatísticos divulgados pela Associação Internacional de Transporte Aéreo (IATA), em 2018, foi registrado um crescimento de 6,8% no tráfego mundial internacional e doméstico. Os maiores contribuintes para esse crescimento foram os operadores do Médio Oriente 10,5%, da Ásia Pacífico 8,9%, as Latino-Americanas 7,8% e companhias Europeias 6,3% (IATA, 2020). No que tange às estatísticas da aviação civil brasileira, segundo o relatório de atividades realizado pela Agência Nacional de Aviação Civil (ANAC) a demanda doméstica do transporte aéreo apresentou, em 2018, crescimento de 7,3% com relação ao ano anterior em termos de passageiros (ANAC, 2020).

Nos diferentes segmentos do setor aéreo, seja na aviação comercial, executiva ou defesa, a manutenção de aeronaves é um importante campo de estudo (VIANNA; MALERE, 2015). Para possibilitar um melhor desempenho na operação é desejável minimizar os custos e aumentar a disponibilidade das aeronaves. Diante desse contexto, os centros de serviços de Manutenção, Reparação e Revisão geral (MRO) devem ser capazes de assegurar tais atividades com uma alta eficiência.

A intervenção na maioria das atividades de manutenção aeronáutica são preventivas. Os equipamentos e sistemas de aeronaves são inspecionados enquanto ainda estão em boas condições de uso e não atingiram o fim de vida útil. A visão clássica da manutenção é o reparo de itens danificados. Por essa perspectiva, as atividades de manutenção estão restritas a tarefas reativas de ações de reparo.

Segundo a Associação Brasileira das Empresas Aéreas (ABEAR), em 2018, defeitos na aeronave foi o motivo operacional que mais ocasionou atrasos e cancelamentos de voos domésticos no Brasil, representando um total de 47,9% das causas atribuíveis à operadora (ABEAR, 2020).

O custo da manutenção contribui significativamente para os custos operacionais gerais de uma companhia aérea (CAI; LI; CHEN, 2017). O desenvolvimento de uma estratégia de manutenção preditiva, adicionada aos demais tipos de manutenção, pode minimizar os custos e aumentar a disponibilidade das aeronaves. Assim, melhorando a operação e, conseqüentemente, o desempenho do setor aéreo (BAPTISTA et al., 2016).

Os avanços tecnológicos possibilitaram aumentar a quantidade de sensores embarcados nas aeronaves, os quais, além de fornecer informações para a tripulação, podem ser utilizados para avaliar a condição de degradação de componentes críticos. Esse aumento foi acompanhado do crescimento da capacidade de armazenamento de dados em voo. Esta realidade possibilitou o aparecimento da manutenção preditiva ou manutenção baseada na condição. Neste tipo de manutenção, monitora-se a evolução da condição ou saúde¹ do equipamento ao longo do tempo e estima-se sua vida residual baseando-se nas séries temporais dos parâmetros medidos (FAN; CHEN; LI, 2014).

De acordo com Luo et al. (2014) e Vianna e Yoneyama (2018), a manutenção baseada em condição favorece a transformação do paradigma da manutenção de aeronaves, pois possibilita reduzir os impactos causados por eventos não previstos, dado o custo elevado que a imobilização de uma aeronave representa para uma companhia aérea.

Este trabalho descreve o desenvolvimento de uma prova de conceito para promover a manutenção preditiva de aeronaves, cujas técnicas são baseadas em princípios de Mineração de Dados (MD) e Aprendizado de Máquina (AM). Para esse fim, foram utilizados

¹Saúde: o termo saúde, no contexto de manutenção, pode significar o estado de degradação de um componente ou sistema.

dados históricos gravados em voos e históricos de manutenção de aeronaves. O objetivo da pesquisa é avaliar os diferentes casos, orientados a dados, na classificação da condição de degradação dos equipamentos aeronáuticos. Em particular, foi executado o modelo de aprendizado de máquina *Gradient Boosting*.

1.1 OBJETIVOS

Esta seção apresenta o objetivo geral e os objetivos específicos do presente trabalho.

1.1.1 Objetivo Geral

Este trabalho tem como principal objetivo propor e desenvolver um método voltado à previsão de vida útil remanescente de componentes do sistema pneumático de aeronaves.

1.1.2 Objetivos Específicos

Os objetivos específicos deste trabalho encontram-se descritos abaixo:

- (a) Realizar a preparação e limpeza dos conjuntos de dados.
- (b) Realizar o estudo e identificação das variáveis pertinentes ao domínio do problema.
- (c) Aplicar uma ferramenta de geração de *pipelines* de aprendizado de máquina que permita realizar uma avaliação do método proposto com a utilização dos dados reais.
- (d) Avaliar o desempenho de diferentes casos, orientados a dados, para promover o prognóstico de falha² de componentes do sistema pneumático de aeronaves.

1.2 MOTIVAÇÃO E JUSTIFICATIVA

Na indústria aeronáutica, existem setores que são caracterizados por margens de lucro menores, concorrência disruptiva, requisitos legais e de segurança bastante rígidos. As companhias aéreas enfrentam ambientes de mercado desafiadores e dinâmicos, a rentabilidade do setor é um grande desafio econômico. Embora haja um crescimento do tráfego aéreo mundial, registrado em 2018, historicamente, as companhias aéreas têm apresentado rentabilidade baixa (IATA, 2020). No geral, os resultados preliminares da IATA mostram que, para suas 290 companhias aéreas membros, o retorno sobre o capital investido é igual ou inferior ao custo total de capital.

Para que uma aeronave possa cumprir seu papel de transportar pessoas ou cargas é fundamental realizar atividades de manutenção e que seus componentes estejam em condições adequadas para o voo. No quadro complexo e competitivo, vivido pelas companhias aéreas, a inovação e a melhoria contínua devem fazer parte do cotidiano destas organizações, inclusive no setor de manutenção.

²Falha: significa um desvio inesperado das propriedades características ou parâmetros aceitáveis e padrões de um equipamento ou sistema.

Esses fatores ressaltam a necessidade de inovação nos negócios. Em virtude desta situação, novos conceitos estão emergindo dentro das MROs. A manutenção preditiva, incorporada às demais formas de manutenção, tem-se revelado uma grande aposta para diminuir interrupções não programadas nas operações e acompanhar as condições de degradação física dos componentes de aeronaves.

A aplicação de técnicas de manutenção preditiva tem um enorme potencial na redução dos impactos causados por eventos não previstos, dado o custo elevado que a imobilização de uma aeronave representa para uma empresa aérea. Os sistemas de manutenção preditiva estão sendo cada vez mais utilizados na redução do tempo de inatividade das aeronaves e consequentes perdas operacionais. Desta maneira, espera-se contribuir com o desenvolvimento de novas tecnologias para auxiliar a tomada de decisão de ações de manutenção, bem como privilegiar a eficiência e a disponibilidade das aeronaves.

1.3 METODOLOGIA DA PESQUISA

Este trabalho consiste em um estudo de caso de um conjunto de dados fictícios baseados em dados reais. Devido à necessidade de confidencialidade, os dados foram descaracterizados. Os conjuntos de dados são referentes a mensagens do sistema de alerta de tripulação, mensagens de manutenção, reportes de remoções³ e dados de sensores do sistema. O sistema em estudo é o pneumático. Os parâmetros foram registrados por um período de tempo.

A abordagem utilizada foi a técnica orientada a dados. Baseia-se no uso de dados passados e técnicas de aprendizado de máquina para avaliar a condição de degradação e determinar a vida útil remanescente dos equipamentos da aeronave, chamado de prognóstico de falhas.

Para determinar a melhor técnica de aprendizado de máquina, para a aplicação específica, foi utilizado o Aprendizado de Máquina Automático (AutoML). Esse método visa tomar decisões de forma automatizada e orientada a dados. Por meio de um conjunto de dados de entrada, o sistema AutoML determina automaticamente a abordagem com melhor desempenho para o conjunto específico. Existem vários softwares e serviços para geração automática de aprendizado de máquina. Neste trabalho, foi utilizado o *framework Tree Based Pipeline Optimization Tool* (TPOT). Esta abordagem utiliza programação genética para explorar diversos canais e encontrar o melhor resultado para o conjunto específico de dados de entrada.

Para promover o prognóstico de falhas foram construídos vários cenários, na tentativa de melhorar o desempenho do classificador. Em particular, foi executado o modelo de aprendizado de máquina *Gradient Boosting*.

Para avaliação dos cenários foi utilizada a validação cruzada *K-fold* com 10 partições. Esta técnica é amplamente empregada em problemas de predição. Por fim, foi gerada a matriz de confusão. Por meio da matriz de confusão foi possível identificar as frequências de classificação para cada classe de saída do modelo e, na sequência, calcular as métricas de avaliação: precisão, revocação e medida F.

³Reportes de remoções: permitem aos responsáveis, pelas atividades de inspeções e reparos de aeronaves, reportar eventuais ações que tenham acontecido durante a manutenção. Estas atividades são fundamentais para a identificação da data de manutenção, componente substituído, dentre outras informações.

1.4 HIPÓTESE

Acredita-se que modelos de prognóstico de falha derivados de dados, gravados em voos e registros de manutenção, são capazes de estimar a vida útil remanescente de componentes do sistema pneumático de aeronaves e, assim, promover a previsibilidade das atividades de manutenção. Considera-se o potencial da utilização de aprendizado automático na construção de modelos preditivos, sob medida, para elaboração de um método de PHM.

1.5 ORGANIZAÇÃO DO TRABALHO

Além desta introdução, este trabalho está estruturado em seis capítulos e dois apêndices que abordam os seguintes conteúdos:

O **Capítulo 2** apresentará os princípios básicos dos principais sistemas de aeronaves. Em especial, serão destacadas as características específicas do sistema pneumático. A justificativa desta ênfase é que o conjunto de dados utilizado neste trabalho refere-se a um modo de falha⁴ do subsistema de controle ambiental. A última seção do capítulo fornecerá uma visão geral dos métodos de aquisição, armazenamento e transmissão de dados de aeronaves.

O **Capítulo 3** apresentará os fundamentos teóricos dos principais tipos de manutenção de aeronaves. O capítulo proporcionará compreensão de PHM e suas abordagens para promover prognósticos de falhas. Em especial, serão destacadas as características de prognóstico de falhas orientado a dados. A justificativa desta ênfase é que a abordagem aplicada neste trabalho refere-se a utilização de conjuntos de dados históricos para determinar a condição de degradação de componentes da aeronave. Por fim, serão apresentados conceitos de mineração de dados e aprendizado de máquina e destacadas as métricas de avaliação para determinar o desempenho da classificação de modelos preditivos.

O **Capítulo 4** apresentará o método proposto para a aplicação de mineração de dados e aprendizado de máquina para promover o prognóstico de falhas de componentes de aeronaves. O capítulo descreverá as etapas realizadas para transformar os conjuntos de dados, referentes às aeronaves e suas operações, em conhecimentos para geração de um modelo preditivo capaz de estimar a vida útil remanescente de componentes do sistema pneumático. O método apresentado abrange desde a aquisição dos dados até a geração de aprendizado de máquina automática.

O **Capítulo 5** apresentará os resultados da aplicação do método proposto, para a avaliação do efeito de diferentes conjuntos de dados de entrada sobre o algoritmo de aprendizado de máquina supervisionado em prognóstico de falhas. Para cada um dos casos, serão discutidos os valores das métricas de desempenho do modelo preditivo.

O **Capítulo 6** apresentará as considerações finais obtidas com base na discussão dos resultados, assim como, contribuições geradas pela pesquisa. Também são apresentadas algumas recomendações e propostas para trabalhos futuros.

O **Apêndice A** apresentará as etapas lógicas do Algoritmo de Friedman para implementação do modelo *Gradient Boosting*.

O **Apêndice B** apresentará uma tabela de resultados obtidos nos experimentos, relacionando os três modelos de aprendizado de máquina aos casos executados.

⁴Modo de falha: é uma causa de falha ou uma forma possível pela qual um sistema pode falhar.

2 FUNDAMENTOS DE SISTEMAS DE AERONAVES

Neste capítulo são apresentados os princípios básicos dos principais sistemas de aeronaves. Em especial, são destacadas as características específicas do sistema pneumático. A justificativa desta ênfase é que o conjunto de dados utilizado neste trabalho refere-se a um modo de falha do subsistema de controle ambiental. A última seção do capítulo fornece uma visão geral dos métodos de aquisição, armazenamento e transmissão de dados de aeronaves.

2.1 DESCRIÇÃO DE SISTEMAS DE AERONAVES

As aeronaves são compostas por estruturas nas quais são instalados vários sistemas como, por exemplo, sistema de controle de voo, sistema elétrico, sistema hidráulico, sistema pneumático, sistema de pressurização e ar condicionado, sistema de proteção contra gelo e chuva, sistema de combustível, sistema de comunicação, dentre outros. De acordo com Moir e Seabridge (2011), existem interações significativas entre os sistemas e métodos automatizados para operar cada um deles, facilitando o trabalho da tripulação e melhorando o desempenho de controle de voo e gerenciamento de motores.

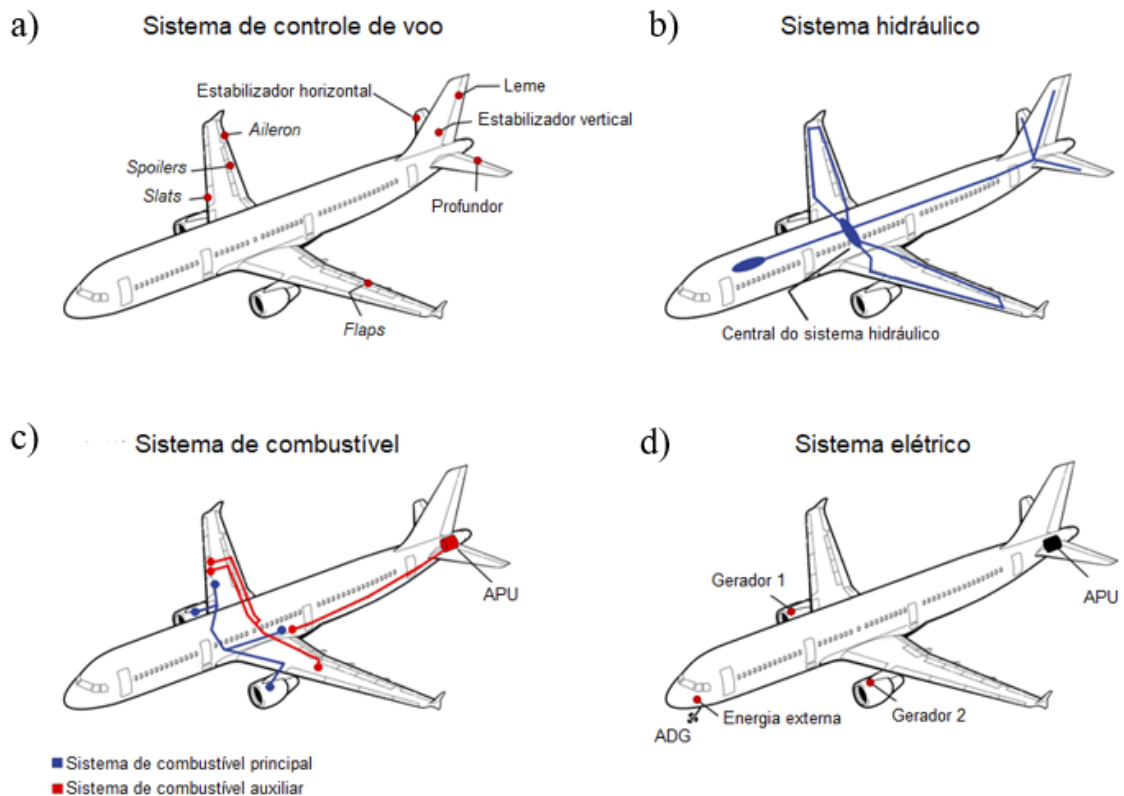
O sistema de controle de voo de uma aeronave consiste em superfícies de controle de voo, seus respectivos controles na cabine de pilotagem, cabos de comando ou atuadores. A finalidade do sistema é prover meios para o controle direcional e de altitude de uma aeronave durante os voos, decolagens e pousos. Incluindo controlar manobras, aumentar a sustentação em pousos e decolagens e aumentar o arrasto em voo ou em solo. Para isso, são utilizadas superfícies de controle de voo. As superfícies, geralmente, são divididas em duas categorias: superfícies primárias e superfícies secundárias. O grupo primário de superfícies de controle de voo consiste de *ailerons*, profundos e lemes. Enquanto as superfícies secundárias incluem compensadores, *flaps*, *spoilers* e *slats* (MCLEAN, 1990). A Figura 1(a) ilustra um exemplo genérico de algumas das superfícies de controle de voo.

Na aviação, denomina-se sistema hidráulico o conjunto das partes destinadas ao acionamento de componentes por meio da pressão transmitida por um fluido. Os sistemas hidráulicos são compostos por depósitos de líquido e bombas. Uma bomba de pressão é alimentada de fluido hidráulico, bombeando-o por meio de todo o sistema e acumuladores, nos quais parte desse líquido é armazenado. Esse fluido acondicionado pode ser utilizado para produzir pressão hidráulica nos sistemas da aeronave. O sistema hidráulico executa diversas funções. As principais funções incluem a operação de trem de pouso e o acionamento de superfícies de controle de voo, como *flaps* e *spoilers* (MOIR; SEABRIDGE, 2011). A Figura 1(b) ilustra um exemplo de sistema hidráulico.

Um sistema de combustível de aeronaves tem a finalidade de armazenar e distribuir o combustível. Para satisfazer a demanda do motor, a distribuição deve conter uma quantidade apropriada de combustível, o combustível deve estar limpo e a pressão deve obedecer um valor específico. O sistema de combustível deve assegurar um fluxo de combustível eficiente em todas as fases do voo, que inclui mudanças de altitude, manobras, acelerações e desacelerações. A cabine de pilotagem possui indicadores de informações do sistema de combustível. Os parâmetros são disponibilizados para a tripulação durante o voo e em operações em terra (LANGTON et al., 2009). A Figura 1(c) ilustra um exemplo genérico do sistema de combustível.

Segundo Lombardo (1999), as principais funções de um sistema elétrico são a geração, controle e distribuição de energia elétrica para a aeronave. Existem várias formas de se obter energia para transferir aos sistemas elétricos. As fontes de energia incluem: geradores acoplados ao motor, gerador movido a ar, unidades de energia auxiliar e fonte de alimentação externa. O sistema elétrico da aeronave é responsável por atender às necessidades dos atuadores, sistemas de iluminação, aquecimento, sistemas de entretenimento de passageiros e para a integração dos computadores do sistema de gerenciamento de voo. A Figura 1(d) ilustra um exemplo genérico do sistema elétrico de aeronaves.

Figura 1 – Representações genéricas de sistemas da aeronave.




Fonte: Elaborado pela autora.

O estudo de caso, abordado neste trabalho, refere-se ao sistema pneumático mais especificamente ao subsistema de sangria de ar. A Subseção 2.1.1 aborda esse sistema em detalhes e a Subseção 2.1.2 descreve a aquisição, armazenamento e transmissão de dados de uma aeronave.

2.1.1 Sistema Pneumático

O sistema pneumático é responsável pelo acionamento de freios, pressurização dos reservatórios hidráulicos, abertura e fechamento de portas, partida de motores, dispersão de chuva do para-brisa, detecção da atmosfera ao redor da fuselagem, controle ambiental, dentre outras atribuições (MOIR; SEABRIDGE, 2011). A Figura 2 ilustra um exemplo genérico do sistema pneumático de aeronaves.

Figura 2 – Exemplo genérico do sistema pneumático.



Fonte: Elaborado pela autora.

O sistema de controle ambiental é responsável por manter um ambiente confortável para a tripulação e para os passageiros. Esse sistema gerencia a temperatura, pressão e fluxo de ar da aeronave, que inclui os compartimentos do *cockpit*¹ e cabine (SANO; MALERE; BERTON, 2020). Embora exista uma grande variedade de modelos de aeronaves, os projetos dos sistemas de controle ambiental são muito semelhantes. Em termos simplificados, nesses sistemas o ar é primeiro comprimido a alta pressão e temperatura e depois condicionado, antes de ser entregue para o interior da aeronave para manter um ambiente confortável, ou seja, para manter temperatura e pressão dentro de limites aceitáveis (COUNCIL et al., 1986) e (BAPTISTA et al., 2016).

Um subsistema importante do sistema de controle ambiental é o de sangria de ar (do Inglês, *Bleed Air*). Esse subsistema é uma fonte de ar de alta pressão para os sistemas a jusante. A sangria de ar fornece o ar exigido pelos consumidores, enquanto regula a pressão e a temperatura do ar dos motores. O ar pode ser fornecido por meio dos motores ou pela Unidade Auxiliar de Energia (do Inglês, *Auxiliary Power Unit*) (APU). A APU é um pequeno motor, projetado com o intuito de geração de energia. Quando a aeronave está em voo o responsável pelo fornecimento de ar são os motores. Já a APU é responsável pelo fornecimento de potência elétrica usualmente quando os motores não estão operando ou quando há indisponibilidade das funções de *Bleed*.


A disponibilidade de ar comprimido de alta pressão e alta temperatura, da seção de compressor do motor, adequa-se à capacidade de fornecer energia pneumática para vários subsistemas de aeronaves, seja por razões de aquecimento, distribuição de energia ou como fonte de ar para o condicionamento da cabine e sistemas de pressurização. De acordo com Moir e Seabridge (2011), o sistema pneumático pode ser representado por três principais subsistemas relacionados ao ar da aeronave:

- Proteção contra gelo: fornecimento de ar quente para o descongelamento das entradas dos motores, das arestas das asas, da cauda ou da superfície da aeronave.
- Sistema de controle ambiental (ECS): suprimento da principal fonte de ar para controle e resfriamento de temperatura ambiente.
- Pressurização: bombeamento de ar para dentro da cabine de uma aeronave. Tem a finalidade de manter uma pressão adequada durante os voos em altitudes mais elevadas.

¹ *Cockpit*: também conhecido como cabine de pilotagem, consiste em uma área usualmente situada na parte dianteira de uma aeronave, de onde os pilotos conduzem a aeronave.

O modelo simplificado de uso de sangria de ar dos motores em sistemas pneumáticos é representado na Figura 3. Como mostrado, o sistema de sangria é uma rede complexa de válvulas e outros componentes que regulam o fluxo de ar entre o motor e aeronave. Este exemplo genérico trata da configuração de aeronaves bimoteres.

Figura 3 – Sistema simplificado de sangria de ar e sistemas associados.




Fonte: Adaptado de Moir e Seabridge (2011).

O ar dos motores passa por uma Válvula de Corte Regulada por Pressão (PRSOV) que serve para controlar e, quando necessário, interromper o fornecimento de ar do motor. Segundo Moir e Seabridge (2011), o ar jusante da válvula PRSOV pode ser usado de várias maneiras:

- Válvula de controle de fluxo cruzado (SOV): por meio desta válvula, o sistema pode fornecer ar para o lado oposto da aeronave. Isto pode ser requisitado durante a partida do motor ou se o motor oposto da aeronave esteja inoperante por algum motivo.
- Válvula SOV da APU: este recurso pode ser utilizado para isolar o fornecimento de ar da APU.
- Válvulas SOVs: fornecem isolamento aos sistemas de ar condicionado e de pressurização.
- Válvulas SOVs adicionais: fornecem os meios para a desativação de recursos adicionais como, por exemplo, desligamento dos sistemas de anticongelamentos dos motores direito e esquerdo.

Uma válvula PRSOV típica é mostrada na Figura 4. Esta válvula é controlada por solenoide e operada pneumáticamente para controlar a temperatura e a pressão. A PRSOV executa as seguintes funções: controle do acionamento do sistema, proteção da temperatura de ar do motor e do fluxo reverso, seleção durante as ações de manutenção para testar a operação do reverso, regulação do ar proveniente do motor por meio de uma válvula borboleta acionada por pressão pneumática.

Figura 4 – Válvula PRSOV no sistema de controle ambiental.



Fonte: Adaptado de Moir e Seabridge (2011).

A válvula PRSOV é controlada por sinais elétricos e operada de forma pneumática. Esta operação ocorre por meio de um controlador de sangria de ar, o qual permite o gerenciamento dos níveis de pressão predeterminados. De acordo com Moir e Seabridge (2011), vários sinais de pressão e fluxo possibilitam que o Módulo de Equipamento e Teste Embutido de sangria de ar (do Inglês, *Built-In Test Equipment*) (BITE) controle a operação correta da combinação das válvulas PRSOV. Além disso, os sistemas de monitoramento embutidos podem ser usados durante a verificação de integridade do sistema pneumático por meio da análise de entradas discretas do sistema.

Uma válvula PRSOV controla a pressão de cada um dos lados do sistema de sangria de ar, isto significa que, o lado direito e esquerdo da aeronave podem oferecer pressões diferentes. A posição da válvula é sinalizada por meio de sinais discretos para o controlador de sangria de ar. As várias pressões, vazões e sinais discretos permitem confirmar a operação correta da combinação das válvulas PRSOV. Deste modo, é garantido que o ar com temperatura e pressão regulada seja entregue ao pré-resfriador e, posteriormente, a jusante ao sistema de distribuição pneumática.

A válvula permite a saída do excesso de ar, por meio de aberturas na carenagem da asa ou do revestimento da fuselagem. Um tipo de válvula de saída de fluxo é uma borboleta. Esta válvula é aberta ou fechada por um motor elétrico, isto é, o motor recebe sinais elétricos para variar a posição da válvula.

Ao longo do tempo, o sistema de controle ambiental pode apresentar problemas de funcionamento. Esses problemas podem estar associados a válvula borboleta ou aos de-

mais componentes que integram o sistema. Em seus estudos Sano, Malere e Berton (2020), destacam modos de falhas relacionados ao ECS que são do tipo isolada ou simultânea e referem-se a deformação da mola, atrito durante o movimento de rotação (abertura e fechamento) e vazamentos. Devido a esse motivo é necessário realizar ações de manutenção. A manutenção do sistema pneumático consiste em reparos, pesquisas de panes, remoções, instalações de componentes e testes operacionais.

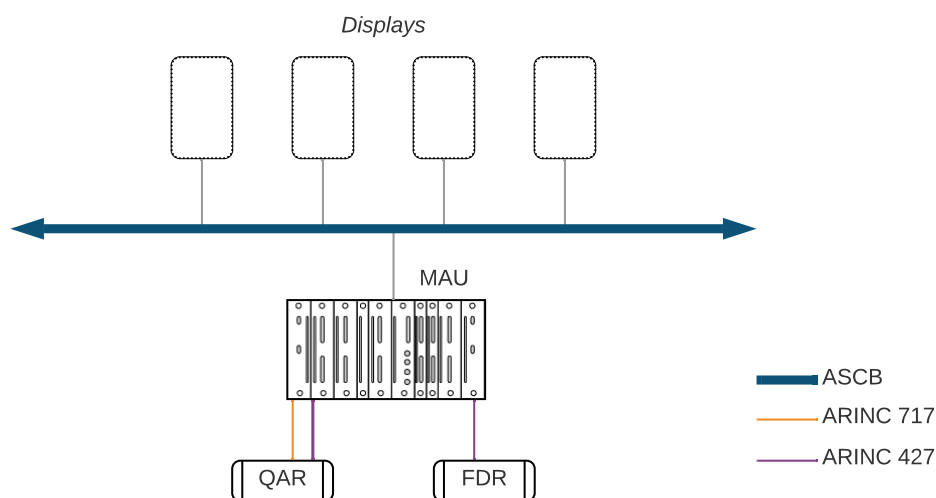
Os dados e status de indicações do sistema de sangria de ar são exibidos durante os voos. Em geral, as informações são mostrados na tela do sistema de alerta de tripulação e armazenadas no Gravador de Acesso Rápido (do Inglês, *Quick Access Recorder*) (QAR). Os dados gravados durante os voos podem ser recuperados e utilizados para promover a manutenção preditiva.

2.1.2 Sistema de Aquisição, Armazenamento e Transmissão de Dados

Os sistemas de aeronaves são monitorados por meio de uma grande quantidade de sensores embarcados, os quais geram imenso volume de dados. Os parâmetros medidos podem ser do tipo analógico ou digital. Um conjunto de parâmetros pode ser processado de forma a extrair informações relevantes para a operação dos sistemas da aeronave. Estas informações são exibidas, para a tripulação, nas unidades de *displays*.

As unidades de exibição recebem informações por meio do barramento de comunicação para o domínio aviônico. O ASCB (do Inglês, *Avionics Standard Communication Bus*) é um dos tipos de barramento principal encontrado em algumas aeronaves. Segundo Paulitsch (2011), o ASCB consiste em um barramento de dados bidirecional para comunicações periódicas em tempo real. As aeronaves também podem conter outras maneiras para realizar comunicações como, por exemplo, a rede local (do Inglês, *Local Area Network*) (LAN). A LAN utiliza o padrão de transmissão de dados Ethernet. É usada para manutenção do sistema e atualização de softwares. A Figura 5 ilustra um exemplo genérico de comunicação de bordo de algumas aeronaves.

Figura 5 – Arquitetura genérica de comunicação a bordo.



Fonte: Adaptado de Moir e Seabridge (2011).

As aeronaves podem possuir Unidades Aviônicas Modulares (do Inglês, *Modular Avionic Unit*) (MAU) que consistem em gabinetes que contém vários módulos de hardware e um barramento de comunicação de dados do tipo VBPCI (do Inglês, *Virtual Backplane Peripheral Component Interconnect*), responsável pela ligação dos módulos. Os módulos mais importantes são duplicados para evitar com essa redundância uma possível perda de recurso. Alguns exemplos de módulos são: módulo computador de manutenção central e módulo de controle de entrada e saída.

O barramento de dados ASCB interliga as MAUs aos circuitos da aeronave. A rede LAN permite a obtenção de dados das MAU por meio de comunicação externa. A MAU fornece um fluxo de dados de saída nos padrões ARINC 429² e ARINC 717³. Os dados são encaminhados para a Unidade de Aquisição de Dados de Voo (do Inglês, *Flight Data Acquisition Unit*) (AFDAU).

A AFDAU é responsável pelo recebimento de vários parâmetros de sensores dos sistemas. Após o recebimento, os dados são encaminhados para o Gravador de Dados de Voo (do Inglês, *Flight Data Recorder*) (FDR) e, se necessário, para um gravador QAR. As informações do AFDAU são enviadas por quadros de dados específicos, que dependem do fabricante da aeronave. O armazenamento FDR é obrigatório pelas autoridades, enquanto o armazenamento de dados QAR é opcional (MOIR; SEABRIDGE, 2011).

As aeronaves possuem um sistema de registro de voz e um sistema de registros de parâmetros, conhecidos popularmente como caixas-pretas. São capazes de suportar altas temperaturas e submersão a fluídos. Em caso de acidentes, a caixa-preta precisa ser rastreada em locais de difícil acesso.

Os áudios entre o piloto, copiloto e torre de comando são gravados pelo CVR (do Inglês, *Cockpit Voice Recorder*), enquanto que os dados de desempenho como velocidade, aceleração vertical, quantidade de combustível, altitude e dentre outros, são gravados pelo FDR. Portanto, os dois são equipamentos distintos e independentes, mas ambos com uma indicação de tempo, que é fundamental para alinhar os eventos de voz aos eventos de desempenho. Desse modo, quando necessário, os órgãos investigadores podem realizar uma auditoria e apurar as causas de um evento acessando os dados das caixas-pretas.

Além dos gravadores FDR e CVR, as aeronaves contém um gravador QAR que é um gravador projetado para fornecer acesso rápido e fácil aos dados brutos de voo, por meios como conexões USB, rede de celular ou o uso de cartões de memória. Basicamente, os dados QAR podem ser agrupados em categorias como, por exemplo, dados inerciais, taxas angulares, dados aerodinâmicos, dados de controle da cabine e dados de controle de superfícies. Os QARs são normalmente usadas pelas companhias aéreas para melhorar a eficiência na operação (HAVERDINGS; CHAN, 2010).

O QAR é capaz de amostrar dados em taxas mais altas que o FDR e, em alguns casos, por períodos mais longos. De acordo com Haverdings e Chan (2010), as taxas de amostragem de dados variam para os diferentes parâmetros. Ao contrário do FDR, o QAR geralmente não é exigido pelas autoridades em voos comerciais e não foi projetado para sobreviver a um acidente aéreo. O QAR foi projetado para coletar e gravar dados de desempenho de aeronaves e seus subsistemas. Segundo Zhang e Zhang (2017), o gravador QAR fornece uma referência científica para promover o prognóstico de falhas. Os dados utilizados deste trabalho são derivados do gravador do tipo QAR.

²ARINC 429: é um padrão de barramento de dados utilizado na aviação. A Série 400 descreve diretrizes para instalação, fiação, barramentos de dados e bancos de dados.

³ARINC 717: é um padrão de barramento de dados utilizado na aviação. A Série 700 descreve a forma, ajuste e função dos equipamentos instalados em aeronaves.

Em aeronaves mais recentes, armazena-se uma quantidade significativa de dados de monitoramento. A facilidade com que as informações de desempenho de componentes são coletadas e transmitidas para o computador central levaram ao surgimento de algoritmos de prognósticos de falhas. O processamento de dados históricos pode mostrar tendências e encontrar componentes em estado de degradação. Este é um aspecto importante da melhoria nas atividades de manutenção de subsistemas de aeronaves (MOIR; SEABRIDGE, 2011).

Os instrumentos essenciais para a operação de uma aeronave estão localizados em painéis, cujo número varia de acordo o modelo da aeronave e seu *layout* da cabine de comando. O painel de instrumentos dianteiro, posicionado na linha de visão normal dos pilotos, contém vários instrumentos que podem ser utilizados em voo. A Figura 6 mostra o painel principal de instrumentos eletrônicos.

Figura 6 – Painel principal de instrumentos eletrônicos de uma aeronave.



Fonte: Adaptado de bizbrazilmagazine.com.

Segundo Tooley (2007), o Sistema de Indicação do Motor e Alerta de Tripulação (do Inglês, *Engine Indicating and Crew Alerting System*) (EICAS) compreende unidades de exibição digitalmente controladas. Este sistema fornece à tripulação informações sobre diversos fatores, como: razão de pressão do motor, RPM, temperatura dos gases de exaustão, pressões dos sistemas hidráulicos, parâmetros dos sistemas elétricos, dentre outros. Existem três modos de exibição de informações, as quais são categorizadas de acordo com seus respectivos modos:

- Modo operacional: é utilizado pela tripulação de voo. É responsável por exibir as informações operacionais do motor e todos os alertas que exigem ação da tripulação.
- Modo de status: é utilizado pela tripulação de voo. É responsável por mostrar as posições das superfícies de controle de voo, parâmetros de subsistemas e mensagens de status dos equipamentos.
- Modo de manutenção: é usado somente quando a aeronave está em solo. Este modo fornece aos técnicos e engenheiros de manutenção informações para ajudá-los a testar os principais subsistemas e encontrar possíveis falhas.

Existem vários tipos de mensagens de falhas para notificar eventos inesperados ou comportamento anormal. O sistema monitora continuamente um grande número de entradas derivadas dos sistemas de bordo da aeronave. Se um mau funcionamento for detectado, uma mensagem de alerta será anunciada no visor. Os registros e alertas são observados no EICAS por meio de uma simbologia padrão de cores para os alertas, dependendo da relevância para o alerta determinando a prioridade do sistema que será acionado na aeronave (DORNEICH; VERVERS; GOOD, 2001). As mensagens são classificadas de acordo com os seguintes níveis:

- Nível A - *Warning*: requer ação imediata dos pilotos. Esta categoria é exibida na cor vermelha e é acompanhada de um alarme aural.
- Nível B - *Caution*: exige consciência da tripulação e possível ação. Esta categoria é exibida na cor amarela, também é ativado um alarme aural.
- Nível C - *Advisory*: exige conhecimento da tripulação. Esta categoria é exibida na cor branca e sem a presença de alarme aural.

A Figura 7 ilustra uma tela com diferentes mensagens de alerta, exibidas no painel primário EICAS.

Figura 7 – Exemplo de informações no EICAS.



Fonte: Adaptado de wikipedia.org.

As aeronaves mais modernas possuem um Computador Central de Manutenção (do Inglês, *Central Maintenance Computing*) (CMC). Este consiste em módulos de hardware conectados à MAU. Desta forma, estão integrados aos demais sistemas da aeronave. De acordo com Osmanbhoy, Runo e Mallasch (2010), a função do CMC é coletar, consolidar e relatar dados de falhas. Os dados de falha podem ser informados para a tripulação durante os voos e, além disso, podem ser armazenados para, posteriormente, serem acessados pelos responsáveis de manutenção. O CMC inclui um sistema de processamento de entradas e saídas, transferência de dados e dispositivos de memória. Durante os voos e operações em solo, o CMC controla a coleta dados de falhas dos sistemas e associa as falhas isoladas às mensagens de manutenção. Estes fatos são armazenados no dispositivo de memória de históricos de falhas. Os dados históricos podem ser acessados em solo, os quais podem fornecer informações importantes para os responsáveis pelas ações de manutenção de aeronaves.

3 MANUTENÇÃO AERONÁUTICA

Neste capítulo são apresentados os fundamentos teóricos dos principais tipos de manutenção de aeronaves. O capítulo proporciona compreensão do Prognóstico e Gerenciamento de Saúde (do Inglês, *Prognostic Health Management*) (PHM) e suas abordagens para promover prognósticos de falhas. Em especial, são destacadas as características de prognóstico de falhas orientado a dados. A justificativa desta ênfase é que a abordagem aplicada neste trabalho refere-se a utilização de conjuntos de dados históricos para determinar a condição de degradação de componentes da aeronave. Por fim, apresentam-se conceitos de mineração de dados e aprendizado de máquina e destacam-se as métricas de avaliação para determinar o desempenho da classificação de modelos preditivos.

3.1 TIPOS DE MANUTENÇÃO AERONÁUTICA


A manutenção é o conjunto das operações destinadas à conservação de equipamentos, subsistemas e componentes (MANZINI et al., 2009). A manutenção aeronáutica consiste em realizar intervenções, limpezas, inspeções e verificações detalhadas das peças e sistemas das aeronaves. A finalidade é corrigir, prevenir, detectar falhas de equipamentos ou deterioração do desempenho de sistemas e controlar o tempo de vida dos componentes. Em resumo, o objetivo é manter a aeronavegabilidade que consta no projeto da aeronave (KNOTTS, 1999) (BERGH; BRUECKER; PEETERS, 2013). Normalmente, cada fabricante define o plano de manutenção, com um programa preventivo, que deve ser aprovado pela autoridades aeronáuticas e seguido pelo operador. No Brasil, cabe à ANAC a responsabilidade de aprovação do plano de manutenção.

A manutenção de aeronaves pode ser dividida em manutenção programada e não programada. Segundo Yabsley e Ibrahim (2008), a manutenção programada consiste em um conjunto de metodologias e atividades que tem como objetivo detectar, prevenir e reduzir falhas de equipamentos antes que resultem em defeitos ou restrições operacionais devido aos sistemas inoperantes. Já a manutenção não programada, também conhecida como não planejada, ocorre quando há um problema inesperado, esse deve ser resolvido imediatamente para permitir a continuidade da operação.

Ainda que as manutenções da aeronave, não programada e programada, sejam realizadas em diferentes cenários, estas estão interligadas. Frequentemente, a necessidade de manutenção não programada é descoberta durante verificações de rotina e manutenção programada. Nesses casos, a manutenção não programada pode ser executada para corrigir um problema antes que ele cause transtornos na operação de uma companhia aérea. As atividades de manutenção não programada também podem surgir de prognósticos de falhas realizados como parte da manutenção preditiva, estas têm implicações significativas para gerenciamento de estoque de peças, planejamento de recursos e execução de manutenção.

De acordo Kumar, Crocker e Knezevic (1999) e Bergh, Bruecker e Peeters (2013), as ações de manutenção que se aplicam a uma aeronave, peça ou subsistema, podem ser classificadas em três categorias: manutenção preventiva, manutenção corretiva e manutenção preditiva. A Figura 8 ilustra os tipos de manutenção aeronáutica.

Figura 8 – Representação dos tipos de manutenção aeronáutica.



Fonte: Elaborado pela autora.

Conforme a Figura 8, no grupo de manutenções programadas estão presentes a manutenção preventiva, a manutenção corretiva programada e a manutenção preditiva. Enquanto que, na manutenção não programada está a manutenção corretiva.

Existem na literatura estudos que agregam outras categorias de manutenção que podem ser aplicadas em sistemas. Em Ansari, Glawar e Nemeth (2019), os autores propõem o termo manutenção baseada em conhecimento, a qual pode ser dividida em quatro instâncias: descritiva, diagnóstica, preditiva e prescritiva. A manutenção descritiva fornece informações sobre as operações anteriores de manutenção. Assim, ele apoia a coleta de informações. A manutenção diagnóstica caracteriza-se pela análise das relações de causa-efeito e fornece mais detalhes técnicos sobre operações de manutenção anteriores. A manutenção preditiva busca prever eventos futuros por meio do aprendizado de ações de manutenção históricas. Por fim, a manutenção prescritiva é responsável por controlar a ocorrência de um evento específico, fornecendo recomendações para a tomada de decisão e otimização da execução das atividades de manutenção.

As próximas subseções abordarão cada uma das categorias da manutenção aeronáutica representadas na Figura 8.

3.1.1 Manutenção Preventiva

Na manutenção preventiva, de forma periódica, devem ser realizadas revisões nas aeronaves, sejam particulares ou de companhias aéreas. Neste modelo de manutenção, a escolha do tipo de pacote de serviço ocorre de acordo com o tempo de utilização da aeronave. Conforme Samaranayake e Kiridena (2012), a manutenção preventiva consiste na prática de substituir componentes ou subsistemas antes que eles falhem. A função é manter um determinado nível de funcionamento e disponibilidade antes da manifestação de uma anomalia. Segundo Andreacchio et al. (2016), esse tipo de manutenção visa reduzir a probabilidade de ocorrência de falha ou degradação de ativos. A periodicidade da manutenção preventiva é definida em função de três parâmetros: horas de voos acumuladas pela aeronave; número de ciclos de voos (corresponde ao número de decolagens e pousos) ou data de calendário.

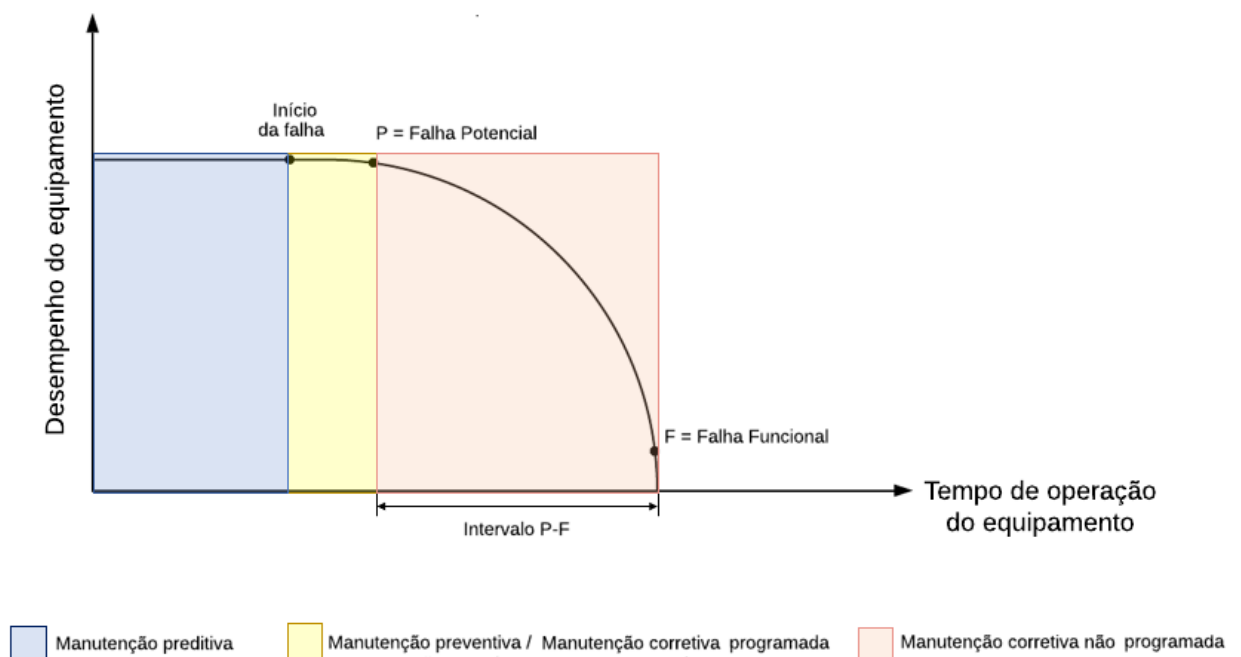
As empresas aeronáuticas, geralmente, são responsáveis pela elaboração do programa de manutenção para cada modelo específico de aeronave. A manutenção preventiva é efetuada de acordo com esse programa. Neste tipo de manutenção, mesmo que o componente esteja operando de modo correto, esse deve ser removido e enviado para uma oficina de reparo. Com o passar dos anos, os planos de manutenção programada estão se tornando cada vez mais sofisticados. Porém, fatos imprevisíveis também fazem parte da manutenção aeronáutica e estes, por sua vez, podem exigir manutenção imediata não programada.

3.1.2 Manutenção Corretiva

De acordo com Knotts (1999), a manutenção corretiva consiste em todas as ações realizadas com o objetivo de restaurar as condições iniciais e ideais de operação de equipamentos, eliminando as fontes de falhas que possam existir. Dependendo do contexto, a manutenção corretiva pode ocorrer em duas situações distintas: devido a uma avaria inesperada e não planejada que tenha ocorrido ou em função de relatos de problemas identificados por meio de um programa de monitoramento das condições do equipamento (MANZINI et al., 2009).

Uma falha potencial é uma falha em estágio inicial, que manifesta a existência de alguma anormalidade, porém o equipamento ainda está desempenhando suas funções. Enquanto que uma falha funcional é caracterizada pela incapacidade do equipamento realizar as suas funções de projeto (LV et al., 2015). As falhas funcionais estão em estágios mais avançados em relação às falhas potenciais. A Figura 9 ilustra a curva P-F, de potencial de falha, representa o desempenho de um equipamento ao longo de seu tempo de operação. Em que P é o potencial de falha do equipamento e F é a falha funcional.

Figura 9 – Representação da curva P-F.



Fonte: Elaborado pela autora.

De acordo com Lv et al. (2015), a curva P-F é a base teórica dos prognósticos de falhas. A curva descreve as mudanças no estado de degradação de sistemas. O intervalo P-F corresponde ao período de tempo entre a falha potencial e falha funcional. Para evitar a falha funcional, o tempo de reparo deve estar antes do ponto F . Enquanto isso, o tempo também deve ser após o ponto P , para aproveitar ao máximo a vida útil remanescente do equipamento.

Na Figura 9, a curva P-F indica que os componentes iniciam o processo de degradação no “Início da falha”. A partir do ponto P pode-se detectar uma anomalia e posteriormente, se não for detectada e corrigida, a deterioração do componente continua, normalmente com taxas mais acelerada, até atingir o ponto da falha funcional F .

A manutenção corretiva planejada é um plano de ação vindo de uma inspeção anterior, geralmente vindo da manutenção preditiva. Após a detecção de um problema, agenda-se uma correção. A manutenção corretiva programada é realizada para eliminar a falha potencial antes que ela evolua para a falha funcional. Dependendo da situação, uma falha potencial pode ser programada para ser resolvida no momento mais conveniente para os centros de serviços de manutenção.

A manutenção corretiva não programada consiste em substituir componentes após uma falha (ANDREACCHIO et al., 2016). O objetivo é restaurar o funcionamento do subsistema depois que ele apresentou anomalias. As atividades de manutenção corretiva não programada são aquelas realizadas após uma falha funcional do equipamento e, por esse motivo, o componente deve ser reparado. Em termos gerais, esse tipo de manutenção não é a estratégia mais eficiente nem a mais econômica. Os gastos são decorrentes, principalmente, das paradas na operação. Segundo Kumar, Crocker e Knezevic (1999), para os operadores comerciais, as interrupções provocam grande transtorno no setor de transporte aéreo. Além dos gastos com ociosidade de colaboradores, as paradas causam atrasos e insatisfações dos clientes.

O desenvolvimento de medidas de monitoramento por condição por meio da aplicação de técnicas inteligentes de gestão de manutenção, pode favorecer a detecção de falhas em um estágio de degradação menos avançado. As técnicas de manutenção preditiva podem ser aplicadas a um subsistema específico com o auxílio da utilização de sensores embarcados nas aeronaves. Desta forma, é possível detectar grandezas relacionadas com a temperatura, vibração, pressão, dentre outras. Quando se aplica técnicas para detectar variações destas grandezas, torna-se possível prognosticar uma falha potencial em estágios prematuros, diminuindo as chances de ocorrência de falhas funcionais. A Subseção 3.1.3 apresenta algumas técnicas de manutenção preditiva, que permitem monitorar as falhas com base na curva P-F.

3.1.3 Manutenção Preditiva

A manutenção preditiva, também chamada de manutenção sob condição, consiste na tentativa de definir o estado futuro de um equipamento, componente ou subsistema, por meio dos dados coletados ao longo do tempo por sensores, verificando e analisando as tendências de ocorrência de falhas. A finalidade é indicar as condições reais de funcionamento dos sistemas com base em dados que informam o processo de degradação. Portanto, trata-se de uma modalidade de manutenção que prediz o tempo de vida útil dos componentes das aeronaves (MOBLEY, 2002).

A manutenção preditiva caracteriza-se pela previsibilidade da deterioração dos equipamentos, prevenindo falhas por meio do monitoramento de parâmetros, com a aeronave em operação. A proposta da manutenção preditiva é fazer o monitoramento regular das condições mecânicas, eletrônicas, pneumáticas, hidráulicas e elétricas dos equipamentos e instalações.

Dentre os principais benefícios da manutenção preditiva, estão: antecipação da necessidade de serviços de manutenção; redução da chance de desmontagem desnecessária; aumento do tempo de disponibilidade das aeronaves e determinação prévia de interrupções na programação de voos de uma companhia aérea. Esses fatores podem contribuir significativamente na redução de custos no setor aéreo.

Um mecanismo para a execução da manutenção preditiva é o prognóstico e gerenciamento de saúde de componentes. Conforme Pecht e Kang (2019), o prognóstico é a previsão do estado futuro da saúde do componente com base nas condições de saúde atuais e históricas. Na indústria aeronáutica, o PHM foi introduzido com a finalidade de utilizar dados reais, de aeronaves, para avaliar a condição de saúde dos componentes. O PHM é considerado uma abordagem que previne falhas e aumenta a disponibilidade de sistemas, reduzindo tempo de inatividade. As informações geradas podem ser utilizadas para planejar ações de manutenção.

Os autores Vianna e Malere (2015) destacam que o PHM é uma tecnologia que pode proporcionar benefícios em diferentes segmentos do setor aeronáutico. Na aviação comercial, a utilização de PHM pode favorecer o aumento de disponibilidade de aeronaves, redução de atrasos e cancelamentos de voos e redução de custos de manutenção. No segmento executivo, pode favorecer a experiência aprimorada do produto, aumento de disponibilidade e redução de custos de manutenção. Já na defesa, pode promover a otimização da prontidão da missão, análise da integridade da missão e melhorias na logística.

O PHM serve para avaliar a degradação do componente. O objetivo é evitar problemas operacionais imprevistos que podem comprometer a programação de uma companhia aérea. Mais especificamente, é o processo de prever a Vida Útil Remanescente (do Inglês, *Remaining Useful Life*) (RUL) de um sistema, estimando a progressão de uma falha, dado o atual grau de degradação, o histórico e as condições operacionais (NIU, 2017). De acordo com Pecht e Kang (2019), juntamente com a detecção de anomalias, o PHM possui como elementos principais o diagnóstico e prognóstico falhas. A seguir são detalhadas cada uma das abordagens:

- Detecção de anomalias: visa identificar um comportamento inesperado do componente. Os resultados da detecção de anomalias podem fornecer avisos de falha, geralmente chamados precursores de falha. As anomalias não indicam necessariamente uma falha, porque alterações nas condições operacionais podem influenciar os dados dos sensores. No entanto, as informações são valiosas para o gerenciamento de integridade do componente, pois podem indicar um comportamento inesperado.
- Diagnóstico: permite a extração de informações relacionadas a falhas, como modos de falha. As informações são importantes, pois alimentam o planejamento de manutenção e logística de peças. O principal objetivo é determinar alguns tipos de falhas incipientes existentes para que a causa raiz da falha possa ser descoberta e localizada.
- Prognóstico: refere-se à previsão da vida útil de um componente dentro de intervalos de confiança, o que geralmente requer informações adicionais que não são

tradicionalmente fornecidas por sensores, como histórico de manutenção e perfis operacionais. Com base nas previsões, o objetivo é informar os tomadores de decisão sobre possíveis atividades necessárias para garantir a continuidade da operação. O prognóstico de falhas deve apoiar a tomada de decisão apropriada, prevenir falhas do sistema, aumentar a disponibilidade da aeronave, informar ações de reparo apropriadas e favorecer o suporte logístico de peças.

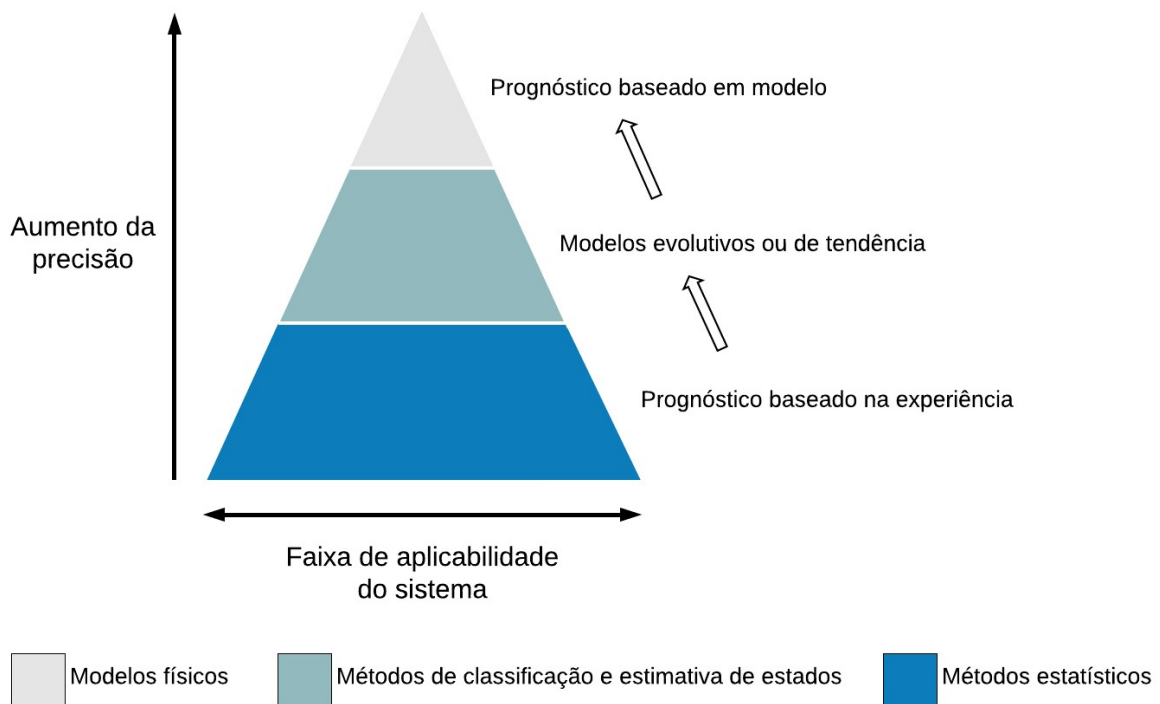
O diagnóstico e prognóstico são integrados na estrutura do PHM. Embora compartilhem princípios similares, a principal diferença é que o diagnóstico se concentra na identificação da natureza ou causa das falhas, enquanto o prognóstico envolve uma previsão sobre como a falha evoluirá. O PHM inclui tecnologias de monitoramento, métodos de coleta de dados e análise estatística avançada de parâmetros ambientais e operacionais.

Segundo Ferreira e Arnaiz (2010), existem basicamente três tipos de abordagens que podem ser utilizadas para promover a base da previsão de RUL em práticas prognósticas: modelos estatísticos, modelos físicos ou matemáticos e, por fim, modelos baseados em monitoramento de condições ou modelos orientados a dados. Os modelos estatísticos são baseados em probabilidades de falha. Os modelos físicos ou matemáticos são baseados em propriedades físicas para representar o comportamento de sistemas. Os modelos de monitoramento de condições ou modelos orientados a dados, normalmente, são elaborados com base em padrões encontrados nos dados obtidos na aeronave, como sensores e mensagens de falha. Este, por sua vez, tem a capacidade de prever a degradação dos sistemas monitorados. Os tópicos a seguir explicam cada uma das abordagens.

- Técnicas baseadas em modelos físicos: este tipo de abordagem pode fornecer um meio para calcular os danos causados por componentes críticos em função das condições de operação. A modelagem física pode ser integrada a técnicas estocásticas. O modelo pode ser usado para avaliar a distribuição da vida útil remanescente em função de incertezas no componente, propriedades físicas e condições da falha. As implementações de modelos baseados em física têm sido usadas para entender a progressão de modos de falhas específicos (JENNIONS, 2013).
- Modelos estatísticos: são utilizados em situações em que os modelos refinados de prognóstico não podem ser utilizados. O motivo, para o impedimento, pode ser o alto investimento em modelos não justificáveis ao negócio. Esta abordagem de prognóstico é menos complexa. Tipicamente, os modelos estatísticos tentam estimar uma distribuição estatística conforme os dados históricos de falhas. Apesar da perda de informações, em comparação com as demais abordagens, os prognósticos estatísticos baseados em distribuições podem ser usados para orientar as atividades de manutenção.
- Técnicas orientadas a dados: são apropriadas quando a compreensão dos princípios de operação do sistema não é abrangente ou quando o sistema é suficientemente complexo de forma que desenvolver um modelo preciso é caro. Portanto, as principais vantagens das técnicas orientada a dados são que, geralmente, podem ser implantadas de forma mais rápida e barata em comparação com outras abordagens e podem fornecer cobertura de todo o sistema, por exemplo, modelos dinâmicos baseados em aspectos físicos, podem ter uma faixa de aplicabilidade menor. A principal desvantagem é que requerem uma quantidade necessária de dados para treinamento do modelo (NIU, 2017).

Na Figura 10, são mostradas as três principais abordagens de PHM. As abordagens são apresentadas em função da faixa de aplicabilidade e a precisão. A base da pirâmide consiste na utilização de estatísticas e experiências para desenvolver modelos de prognósticos de falha. A parte central fundamenta-se em técnicas orientadas a dados que empregam modelos evolutivos ou modelos de tendências. Por fim, o topo é ocupado por modelos físicos ou matemáticos.

Figura 10 – Uma taxonomia de abordagens em PHM.



Fonte: Adaptado de Jennions (2013).

Conforme Jennions (2013), ao escolher uma abordagem de prognóstico deve-se considerar a criticidade do problema e a complexidade em descrever o funcionamento do sistema. De acordo com a Baptista (2018), a válvula de sangria de ar é um componente importante de um sistema complexo da aeronave. Por este motivo, no presente trabalho, foi estudado como a técnica orientada a dados pode promover o prognóstico do subsistema de controle ambiental dos compartimentos de *cockpit* e cabine da aeronave. Os métodos baseados em mineração de dados e métodos de aprendizagem de máquina são usados para desenvolver uma modelagem preditiva diretamente de um conjunto de dados que é representativo do subsistema específico.

As abordagens orientadas por dados são capazes de processar grande volume de dados, transmitidos dos sensores das aeronaves, com o objetivo de extrair informações úteis para o desenvolvimento de métodos de prognóstico de falhas (GAN, 2020). A próxima seção visa fornecer os fundamentos da área de Aprendizado de Máquina.

3.1.3.1 Fundamentos de Aprendizado de Máquina

O aprendizado de máquina é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da Inteligência Artificial (IA) baseado na ideia de que sistemas podem aprender com dados históricos, criar conexões, identificar padrões e tomar decisões de forma inteligente com o mínimo de ajuda humana. Enquanto a IA pode ser definida, de modo amplo, como a ciência que se propõe a desenvolver tecnologias que simulem as habilidades humanas, o AM é um subconjunto da IA que treina máquinas para aprender com dados disponíveis.

Segundo Samuel (1959) e Gan (2020), o AM consiste em um campo de estudo que permite aos computadores a capacidade de aprender sem serem explicitamente programados. É um conjunto de técnicas que possibilitam extrair informações úteis por meio de associações entre diferentes dados. Um aspecto que separa o AM de outros sistemas inteligentes é a sua capacidade de modificar-se quando exposto a mais dados, ou seja, o aprendizado de máquina é dinâmico e não requer intervenção humana para realizar certas mudanças. Em seu estudo Marsland (2015), o autor destaca que a generalização consiste no reconhecimento da semelhança entre diferentes situações, para que possam ser usadas em outras. Esta perspectiva torna o aprendizado útil, pois o conhecimento adquirido pode ser utilizado em diferentes circunstâncias.

Quando se desenvolve um sistema de AM, a estrutura utilizada na programação é diferente da programação de software tradicional. No método tradicional elabora-se um conjunto de regras para gerar uma resposta a partir do processamento dos dados introduzidos. Já os algoritmos de AM são desenvolvidos a partir dos conjuntos de dados históricos. Os dados são analisados e geram resultados. Por fim, o sistema cria as suas próprias regras.

Dependendo da natureza do problema, existem diferentes abordagens com base no tipo e no volume dos dados. De acordo com Marsland (2015), as quatro categorias principais de AM são: aprendizado supervisionado, aprendizado não supervisionado, aprendizado por reforço e aprendizado evolutivo. Na sequência, são abordadas cada uma das quatro categorias citadas.

- **Aprendizado supervisionado:** nos modelos de aprendizado de máquina supervisionado, os dados de treinamento fornecidos aos algoritmos incluem as soluções, chamadas *targets*. O conjunto de dados é rotulado, isto é, a saída é conhecida. Em geral, cada exemplo é descrito por um vetor de valores de características e o rótulo da classe associada. O objetivo do algoritmo é construir um classificador que possa determinar corretamente a classe de novas instâncias. As aplicações de aprendizagem supervisionadas podem ser divididas em problemas de regressão e classificação. Em um problema de regressão, busca-se prever os resultados em uma saída contínua. Em um problema de classificação, espera-se prever os resultados em uma saída discreta, isto é, busca-se mapear variáveis de entrada em categorias distintas. Em seu estudo, Marsland (2015) destaca que o aprendizado supervisionado pode ser amplamente utilizado para classificação e regressão em PHM. Os métodos de regressão buscam encontrar como uma variável evolui em relação a outra. Já os métodos de classificação, buscam explicar uma variável categórica, com duas categorias (variáveis binárias) ou mais (variáveis multiclases). Segundo Gan (2020), os sistemas de diagnóstico e prognóstico de falhas são exemplos de aprendizado supervisionado. Ambas metodologias são treinadas com muitas variáveis e recursos juntamente com

sua classe de saída e devem aprender a classificar novas instâncias. Para o caso de diagnóstico de falhas busca-se identificar se o componente está íntegro ou defeituoso. Já para o caso de prognóstico de falhas, o objetivo é prever a RUL de um componente, dado um conjunto de recursos chamados preditores.

- **Aprendizado não supervisionado:** neste tipo de aprendizado, o conjunto de dados de treinamento não é rotulado, classificados ou categorizados previamente, ou seja, não se conhece os efeitos das variáveis e recursos de entrada. O aprendizado busca descobrir padrões, preliminarmente desconhecidos, entre as variáveis e recursos de entrada para que os dados semelhantes sejam categorizados juntamente (MARS-LAND, 2015). Esta abordagem é usada quando o problema não tem os resultados desejados. A aplicação pode possuir algumas informações, então, o algoritmo gera alguns *insights* sobre a possível solução do problema que se pretende resolver. As técnicas de AM não supervisionadas incluem: análise de agrupamentos, detecção de anomalias e visualização de dados.
- **Aprendizado por reforço:** caracteriza-se pela obtenção de um agente que possa observar o ambiente, selecionar e executar ações e obter recompensas ou punições. O agente aprende por si próprio qual é a melhor estratégia para obter o máximo de recompensas ao longo do tempo (GAN, 2020). A aprendizagem por reforço é o treinamento de modelos de AM para tomar uma sequência de decisões. O agente aprende a atingir uma meta em um ambiente incerto e, potencialmente, complexo. Neste tipo de aprendizado, o sistema de aprendizado de máquina enfrenta uma situação. O computador utiliza tentativas e erros para encontrar uma solução para o problema. Para que a máquina faça o que o programador deseja, o algoritmo recebe recompensas ou penalidades pelas ações que executa. Seu objetivo é maximizar a recompensa total. Embora o cientista de dados defina a política de recompensa, ele não fornece ao modelo nenhuma sugestão de como resolver o problema. Cabe ao método descobrir como executar a tarefa, começando com testes totalmente aleatórios e terminando com táticas sofisticadas.
- **Aprendizado evolutivo:** é uma forma de aprendizado baseado em evolução biológica que, por sua vez, pode ser como um processo de aprendizagem de organismos biológicos. A ideia é utilizar conceitos de evolução genética para se adaptarem. Dessa forma, melhorando suas taxas de sobrevivência e chance de geração de indivíduos mais aptos em um ambiente.

A importância do AM está relacionada ao aumento do volume e variedade de dados disponíveis, ao armazenamento de dados de forma acessível e ao processamento computacional mais barato e poderoso. Esses fatores tornaram possível produzir modelos capazes de analisar grandes quantidades de dados complexos e gerar resultados mais rápidos e precisos. De acordo com Marsland (2015), as pesquisas em AM foram impulsionadas pela utilização de mineração de dados. Os algoritmos de AM utilizam técnicas de mineração de dados para melhoria do modelo de aprendizado e, conseqüentemente, para o aumento do desempenho preditivo (BUCZAK; GUVEN, 2015). A técnica de mineração de dados concentra-se na descoberta de novos conhecimentos sobre os dados que, anteriormente, eram desconhecidos.

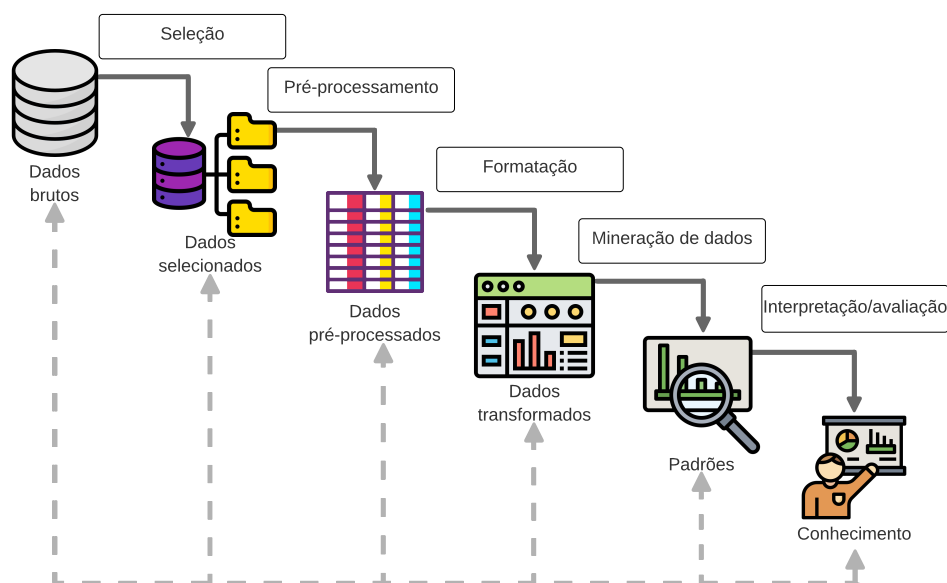
3.1.3.2 Fundamentos de Mineração de Dados

A área de mineração de dados pode ser considerada multidisciplinar. Neste trabalho, são destacados os três principais domínios que estão relacionados com mineração de dados: aprendizado de máquina, banco de dados e estatística. Em seu estudo comparativo, Zhou (2003) analisa as características comuns entre as três perspectivas. O autor destaca que a área de banco de dados está relacionada à eficiência da extração de informações úteis. A ênfase da perspectiva de aprendizado de máquina está na eficácia, porque é fortemente atraída por heurísticas substantivas que apresentam um bom funcionamento na análise de dados. Quanto à estatística, sua ênfase está na validade, uma vez que a ciência preocupa-se com os princípios matemáticos dos métodos de minerar dados.

A mineração de dados pode ser considerada uma etapa dentro de um processo de descoberta de conhecimento que visa descobrir padrões e correlações em grandes volumes de dados para prever tendências futuras. Segundo Fayyad, Shapiro e Smyth (1996), esta ciência consiste na análise de conjuntos de dados históricos. A finalidade é extrair informações, entre as bases de dados, para torná-los compreensíveis e extrair *insights* interessantes. A mineração de dados contribui de forma significativa no processo de descoberta de conhecimento, permitindo aos especialistas concentrarem esforços no entendimento do conjunto de dados.

A Descoberta de Conhecimento em Bancos de Dados (do Inglês, *Knowledge Discovery in Databases*) (KDD) consiste em processo completo que lida com a extração de informações úteis utilizadas para identificação de padrões em grandes bases de dados. O KDD envolve iterações significativas que podem conter *loops* entre as etapas. O processo é dividido em cinco fases: seleção de dados, pré-processamento de dados, transformação de dados, mineração de dados e interpretação e avaliação de resultados (BUCZAK; GUVEN, 2015). Esse processo tem como objetivo descobrir informações relevantes para apoiar a tomada de decisões. A Figura 11 ilustra uma representação do processo de KDD.

Figura 11 – Etapas do processos de KDD.



Fonte: Adaptado de Fayyad, Shapiro e Smyth (1996).

A primeira etapa do KDD é a seleção de dados. Nesta etapa, são decididos quais conjuntos de dados serão relevantes para que sejam obtidos resultados com informações úteis. Para isso, é necessário ter conhecimento e entendimento do domínio do problema que pretende-se resolver. São selecionados conjuntos de dados, subconjuntos de variáveis ou amostras de dados.

Na etapa de pré-processamento de dados são executadas operações básicas como remoção de ruídos, adaptação de frequências de gravação variadas, decisão de estratégias para lidar com campos de dados faltantes e tratamento de *outliers*. As informações ausentes, errôneas e inconsistentes nas bases de dados devem ser corrigidas para não comprometer a qualidade dos modelos de conhecimento a serem extraídos ao final do processo de KDD.

A próxima etapa compreende a formatação, transformação ou dimensionalidade dos dados. O objetivo é analisar os dados, da etapa anterior, de forma a reorganizá-los para que possam ser interpretados na etapa seguinte. Na grande maioria das aplicações, faz-se necessário a redução do número de variáveis para encontrar representações para os dados. Pode-se destacar a descoberta de recursos. Em geral, o conhecimento do domínio é usado para a construção de recursos (PECHT; KANG, 2019).

A etapa de mineração de dados refere-se ao processo de extrair informações de uma grande quantidade de dados. A mineração inclui a seleção de um método e a definição de seus parâmetros para procurar padrões, relacionamentos e correlações dentro da base de dados. Os padrões, uma vez encontrados, precisam passar por um processo de validação para serem considerados informações úteis. Devido à grande quantidade de dados a serem avaliados, a mineração não pode ser feita apenas com ação humana. Por este motivo, é necessário utilizar técnicas para identificar padrões e relações que validam o processo. Existem diversos métodos de mineração, estes devem ser escolhidos de acordo com propósito específico da aplicação. Em problemas aos quais é desejável prever um rótulo, o mais indicado é o método de classificação. A regressão é aplicada nos problemas que se pretende prever uma saída contínua. O agrupamento é indicado nos problemas que pretende-se atribuir rótulos aos conjuntos de dados segundo o seu grau de semelhança de forma independentemente a classes predefinidas.

Na última etapa, interpretação e validação de resultados, as regras indicadas pelo processo anterior serão interpretadas e avaliadas. Após a interpretação poderão surgir padrões e descoberta de novos fatos, que podem ser utilizados para pesquisas e otimizações.

O uso de mineração de dados, combinado com algoritmos de aprendizado de máquina, pode auxiliar especialistas em manutenção aeronáutica nos momentos críticos que demandem decisões rápidas quanto à necessidade de realizar ações de reparos. Por meio de algoritmos de aprendizado de máquina podem ser desenvolvidos modelos de predição para identificação prévia de desgastes a partir de determinados sintomas de uma aeronave.

3.1.3.3 Aprendizado de Máquina Automatizado

O Aprendizado de Máquina Automatizado (do Inglês, *Automated Machine Learning*) (AutoML) visa automatizar tarefas necessárias para construções de modelos preditivos. Os métodos AutoML automatizam uma ou mais etapas na geração de *pipelines*¹ de um modelo de aprendizado de máquina como, por exemplo, a seleção de algoritmos de

¹*Pipeline*: os *pipelines* são sequências de etapas de processamento e análise aplicadas aos dados para uma finalidade específica. A saída de uma etapa consiste na entrada da próxima.

pré-processamento, seleção de algoritmos de aprendizado e otimização de parâmetros.

Devido à grande variedade de modelos e suas respectivas configurações, a tarefa de projetar e ajustar sistemas de aprendizado de máquina é intensiva. O campo do aprendizado automático está focado em automatizar esta tarefa. As ferramentas AutoML permitem aos usuários desenvolver modelos úteis para a aplicação específica de forma ágil.

Existem diversas ferramentas de AutoML como, por exemplo, TPOT, Autokeras, PennAi, H2O, AutoWeka, dentre outras. Neste trabalho, foi utilizado o TPOT. A justificativa desta escolha é que o *framework* TPOT é de código aberto, bem documentado e em desenvolvimento ativo. O *framework* tem a capacidade de avaliar *pipelines* de forma automática e eficiente (OLSON; MOORE, 2019). Este procedimento resulta na seleção de um modelo com os parâmetros otimizados. Permite realizar uma pesquisa minuciosa no espaço do *pipeline* para a aplicação específica. Além disso, possibilita interromper a execução e obter o melhor resultado parcial. A execução pode ser reiniciada do ponto de parada. Em (FEURER et al., 2015), o autor destaca que uma das características mais importante da ferramenta TPOT é a capacidade de exportar um modelo preditivo e inseri-lo diretamente em um código-fonte.

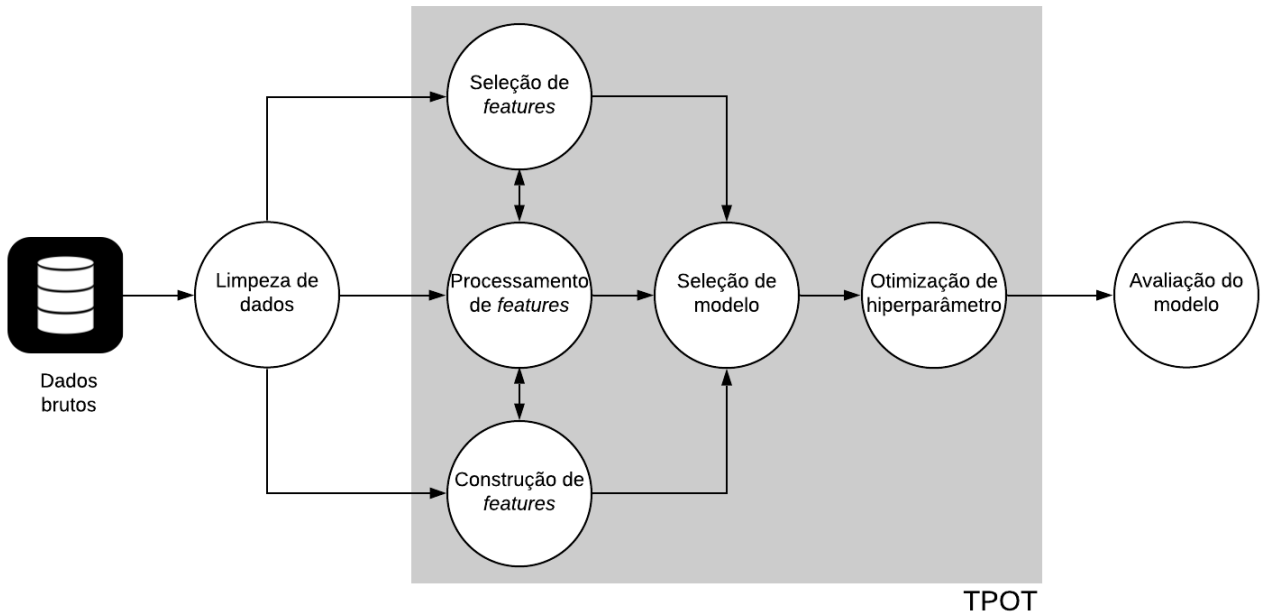
O TPOT é um *framework* de aprendizado de máquina automático, baseado na linguagem de programação Python, que otimiza *pipelines* de AM para produzir modelos de regressão e de classificação. A ferramenta explora vários canais possíveis para encontrar o melhor dentre eles para um conjunto de dados específico. Para tanto, são considerados vários algoritmos de aprendizado de máquina, bem como diversas configurações de parâmetros (OLSON et al., 2016).

Para construir e otimizar *pipelines*, o TPOT utiliza programação genética. A ideia do algoritmo evolutivo é criar, inicialmente, uma população de *pipelines* de AM aleatória e evoluí-la com mutações e cruzamentos de geração em geração (BALAJI; ALLEN, 2018). Os *pipelines* são avaliados e recebem uma pontuação de condicionamento físico, para que o procedimento de seleção possa determinar quais indivíduos estarão na próxima geração. Existem algumas restrições de parada, geralmente, estão relacionadas ao tempo máximo de execução ou tamanho da população.

Na configuração padrão, 100 gerações com 100 indivíduos na população, o TPOT avaliará um total de 10.000 configurações de *pipelines*. Desta forma, a pesquisa de grade inclui 10.000 combinações de parâmetros para um algoritmo de aprendizado de máquina. São 10.000 configurações de modelos a serem avaliadas com validação cruzada de 10 vezes, o que significa que aproximadamente 100.000 modelos são ajustados e avaliados nos dados de treinamento da aplicação específica.

Inicialmente, antes da aplicação do TPOT, é necessário realizar a preparação e limpeza dos dados brutos. Como algoritmos de AM aprendem de diferentes maneiras, em alguns casos é necessário incluir algo além dos dados de entrada pré-processados para generalizar o conteúdo. A construção, o processamento e a seleção de características, conhecidas também como *features*, podem facilitar o entendimento dos dados de entrada, por meio da adição de regras implícitas. Como resultado deste processo iterativo tem-se a seleção de um modelo de AM. Na sequência, é realizada a otimização de parâmetros que consiste em ajustar diferentes restrições, pesos ou taxas de aprendizagem para encontrar operadores que minimizem os erros de predição do modelo selecionado. Por fim, a avaliação do modelo resultante é de responsabilidade do usuário da ferramenta. A Figura 12 ilustra o processo de aprendizado de máquina realizado pelo TPOT.

Figura 12 – Partes do processo de aprendizado de máquina automatizado por TPOT.



Fonte: Adaptado de Olson et al. (2016).

3.1.3.4 Algoritmos de Classificação

O *framework* TPOT disponibiliza vários modelos de aprendizado de máquina como, por exemplo: Regressão Logística, *Gaussian Naive Bayes*, *Decision Tree*, *Extra Trees*, *Gradient Boosting*, *Bernoulli Naive Bayes*, *Multinomial Naive Bayes*, *Random Forest*, *K-Neighbors*, *Support Vector Classifier*, *XGBoost*, dentre outros.

Nesta seção, é apresentado o embasamento teórico do algoritmo *Gradient Boosting*. A justificativa é que esse modelo foi o selecionado, pelo AutoML, para promover o prognóstico de falhas no conjunto de dados do problema específico.

Em Máquinas de Aumento de Gradiente (do Inglês, *Gradient Boosting Machines*) (GBMs), o procedimento de aprendizado se ajusta consecutivamente a novos modelos para fornecer uma estimativa mais precisa da variável resposta. O algoritmo tem a finalidade de construir novos aprendizes para serem maximamente correlacionados com o gradiente negativo da função de perda, associado a todo o conjunto de dados.

A modelagem do algoritmo *Gradient Boosting* consiste na soma de etapas iterativas. Fundamenta-se em um processo de adição de vários termos, mais simples, para formar uma função complexa (FRIEDMAN, 2002). A ideia é que o algoritmo aprenda o modelo tomando uma soma ponderada de um número de bases de aprendizado. O modelo final $F_M(x)$, ao término da execução do algoritmo, será aprendido pela soma ponderada de seus aprendizes $h_m(x)$.

O conjunto de dados consiste em uma variável de resposta y e um conjunto de variáveis de entrada $x = \{x_1, x_2, \dots, x_n\}$. Dada uma amostra de treinamento $\{y_i, x_i\}_1^N$ de valores (y, x) conhecidos, o objetivo é encontrar uma função $F(x)$ que mapeie x para y , de modo que, ao longo da distribuição de todos os valores (y, x) , a função de perda $\psi(y, F(x))$ seja minimizada por meio das M iterações.

Inicialmente, o modelo é ativado com um valor constante. Considerando a notação:

$$F_0(x) = \underset{\gamma}{\operatorname{argmin}} \sum_{i=1}^n \psi(y_i, \gamma) \quad (3.1)$$

a variável argmin representa o valor ótimo do argumento γ que minimiza a função de perda $\psi(y_i, \gamma)$.

Para analisar a adequabilidade de um método, a cada iteração de m , é calculado o resíduo. A função $h_m(x)$ é ajustada pelo Método dos Mínimos Quadrados que é uma técnica de otimização matemática que procura encontrar o melhor ajuste para um conjunto de dados tentando minimizar a soma dos quadrados das diferenças entre o valor estimado e os dados observados, tais diferenças são chamadas resíduos. Logo, o erro residual (e_r) é dado pela diferença entre a variável resposta observada (y_{real}) e a variável resposta estimada ($y_{predito}$), conforme a Equação 3.2.

$$e_r = (y_{real} - y_{predito})^2 \quad (3.2)$$

O erro pode ser calculado tomando a derivada parcial da função de perda em relação a variável $y_{predito}$, enquanto que a variável y_{real} é mantida como constante. A derivada do erro é equivalente à descida do gradiente. A definição matemática é mostrada na Equação 3.3.

$$e_{r_{i,m}} = - \left[\frac{\partial \psi(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{(m-1)}(x)} \quad \text{para } i = 1, 2, \dots, m. \quad (3.3)$$

O próximo passo consiste em ajustar as bases de aprendizado aos resíduos. Assim, um novo conjunto de dados é derivado do conjunto de dados de treinamento combinado à função residual da Equação 3.3. A abordagem estudada por Friedman (2002) é a *Gradient Tree Boosting*. Esta consiste no aumento da árvore de gradiente especializada em que o aprendiz $h_m(x)$ é uma árvore de regressão do nó terminal L . A cada iteração de m , uma árvore de regressão particiona o espaço x em regiões L - disjuntas $\{R_{lm}\}_{l=1}^L$ e prevê um valor constante em cada região. Usando a Equação 3.4, a saída de $h_m(x)$ para a entrada x pode ser escrita como:

$$h_m(x, \{R_{jm}\}_{j=1}^{J_m}) = \sum_{j=1}^{J_m} \bar{e}_{r_{j,m}} \mathbf{1}(x \in R_{jm}) \quad (3.4)$$

em que $\bar{e}_{r_{j,m}}$ é o valor previsto na região R_{jm} .

Os coeficientes $\bar{e}_{r_{j,m}}$ são multiplicados por um γ_m , escolhido usando pesquisa linear para minimizar a função de perda e o modelo é atualizado, conforme a Equação 3.5.

$$F_m(x) = F_{m-1} + \gamma_m h_m(x) \quad (3.5)$$

Para estimar o valor de cada região, do modelo $F_m(x)$ no conjunto de dados original, é calculada a função perda $\psi(y, F(x))$. Destaca-se que a perda é uma função de γ . Para encontrar o γ_m deve ser resolvido o seguinte problema de otimização:

$$\begin{aligned}
\gamma_m &= \operatorname{argmin}_{\gamma} \sum_{i=1}^n \psi(y_i, F_m(x)) \\
&= \operatorname{argmin}_{\gamma} \sum_{i=1}^n \psi(y_i, F_{m-1}(x) + \gamma h_m(x_i))
\end{aligned} \tag{3.6}$$

Em seu estudo, Friedman (2002) propõe modificar o algoritmo para que ele encontre um valor ótimo γ_{jm} em cada uma das regiões da árvore, em vez de apenas um único γ_m para a árvore inteira. Por meio da utilização da árvore, a Equação 3.4 prediz um valor constante de $\bar{e}_{r_{j,m}}$ dentro de cada região R_{jm} , logo as soluções para as Equações 3.5 e 3.6 resumem-se nas Equações 3.7 e 3.8, respectivamente.

$$F_m(x) = F_{m-1} + \sum_{j=1}^{J_m} \gamma_{jm} \mathbf{1}_{R_{jm}}(x) \tag{3.7}$$

e

$$\gamma_{jm} = \operatorname{argmin}_{\gamma} \sum_{x_i \in R_{jm}} \psi(y_i, F_{m-1}(x_i) + \gamma) \tag{3.8}$$

A aproximação atual F_{m-1} é então atualizada separadamente em cada região:

$$F_m(x) = F_{m-1} + \tau \gamma_{jm} \mathbf{1}(x \in R_{jm}) \tag{3.9}$$

em que a taxa de aprendizado é dada por τ .

O modelo $F_m(x)$ é obtido em cada uma das iterações de m , conforme a Equação 3.9. No método *Gradient Boosting*, após cada iteração m , a força de descida do gradiente atualiza o valor de γ_{jm} para um valor cada vez menor da função de perda. Ao término de cada iteração de m , o modelo final $F_M(x)$ é atualizado em função do valor de $F_m(x)$. O processo é repetido até que uma determinada condição de parada seja satisfeita como, por exemplo, ao atingir o número máximo de iterações M . Após realizar as M iterações totais, obtém-se o modelo final $F_M(x)$. O Apêndice A lista o pseudocódigo do modelo *Gradient Boosting*.

3.1.3.5 Métricas de Avaliação

No campo de aprendizado de máquina, existem diversas métricas que podem ser utilizadas para avaliar a qualidade de modelos de regressão e de classificação. De acordo com Buczak e Guven (2015), a escolha das métricas de desempenho depende do contexto do problema específico que se pretende avaliar.

Dentre as medidas mais comumente usadas para avaliar a qualidade de modelos de regressão estão o Erro Médio Quadrático (do Inglês, *Mean Square Error*) (MSE) e a Raiz do Erro Médio Quadrático (do Inglês, *Root Mean Square Error*) (RMSE). Enquanto que, para problemas de classificação, são utilizadas a taxa de acerto média, precisão, revocação, medida F, dentre outras. O presente trabalho se utilizará de métricas de avaliação para problemas de classificação.

As medidas de desempenho de classificadores podem ser calculadas a partir da matriz de confusão. Segundo Marsland (2015), a matriz de confusão consiste em uma matriz

quadrada que indica quantas instâncias foram classificadas corretamente e quantas foram classificadas de forma incorreta para cada uma das classes de saída. A matriz de confusão representa todas as formas fundamentais de comparar o valor previsto com o valor real. A matriz de confusão descreve a quantidade de Falsos Positivos (FP), Falsos Negativos (FN), Verdadeiros Positivos (VP) e Verdadeiros Negativos (VN) oriundos da classificação dos dados. A Tabela 1 exemplifica a matriz de confusão de uma aplicação com duas classes.

Tabela 1 – Exemplo de matriz de confusão para duas classes.

		Valor real	
		Positivo (1)	Negativo (0)
Valor preditivo	Positivo (1)	VP	FP
	Negativo (0)	FN	VN

A diagonal principal da matriz de confusão, representada na Tabela 1 pelos verdadeiros positivos e verdadeiros negativos, representa as previsões corretas do modelo. Enquanto que os números em outras partes da matriz indicam os erros da classificação. A seguir são detalhados cada um dos elementos.

- Verdadeiro Positivo: ocorre quando no conjunto real, a classe que se está buscando foi prevista corretamente. Por exemplo, no contexto de diagnóstico de falhas, um VP seria um componente que realmente tenha uma falha e o modelo de classificação previsse corretamente que ele apresentou um defeito.
- Verdadeiro Negativo: situação em que a previsão do modelo é compatível com a situação real, sendo os dados originalmente falsos e de fato preditos como falsos. Por exemplo, seria um componente que não apresentou anomalia e o modelo previu corretamente que o componente não tem falha.
- Falso Positivo: ocorre quando no conjunto real, a classe que se está buscando prever foi prevista incorretamente. Por exemplo, se um componente não apresentar defeito, mas o modelo de predição pressupõe que tenha. Neste caso, o modelo prediz um falso positivo, porque está predizendo falsamente a presença de uma anomalia.
- Falso Negativo: um falso negativo é representado por um resultado que indica a não existência de sinais de anormalidade quando, na verdade, uma falha está presente. Por exemplo, quando o componente está com defeito e o modelo prediz, incorretamente, que este componente está saudável.

Por meio das informações da matriz de confusão é possível calcular as métricas de desempenho. Neste trabalho, para avaliar as modelagens preditivas foram utilizadas as métricas: taxa de acerto, precisão, revocação ou probabilidade de detecção, medida F e taxa de falso alarme. Estas métricas são utilizadas em tarefas de classificação. As métricas podem ser adaptadas e utilizadas tanto para problemas de classificação binária quanto de múltiplas classes. Nas tarefas de classificação busca-se prever qual é a categoria que uma amostra pertence. No contexto de prognóstico de falhas, significa determinar o intervalo de tempo até a falha de um componente do subsistema em estudo. Os tópicos a seguir explicam os significados de cada uma das métricas avaliadas neste trabalho.

- Taxa de acerto: consiste na razão entre o número de acertos (positivos) pelo número total de exemplos. Esta métrica de desempenho deve ser usada em aplicações em que as classes de saídas são de mesma proporção. A utilização da taxa de acerto em problemas com classes desproporcionais, pode causar uma falsa impressão de bom desempenho. A Equação 3.10 define a taxa de acerto.

$$\begin{aligned} \text{Taxa de acerto} &= \frac{\text{predições corretas}}{\text{todas as predições}} \\ &= \frac{VP + VN}{VP + FP + VN + FN} \end{aligned} \quad (3.10)$$

- Precisão: tem como objetivo identificar a porcentagem das amostras classificadas positivamente, isto é, quantas amostras foram classificadas de forma correta em relação ao número de classificações positivas. Utilizando a Equação 3.11 é possível definir a precisão como sendo o número de verdadeiros positivos dividido pelo número de verdadeiros positivos mais o número de falsos positivos. Esta medida expressa o número de exemplos classificados como pertencentes a uma classe, que realmente são daquela classe, dividido pela soma entre esse número e o número de exemplos classificados nesta classe, mas que pertencem a outras.

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3.11)$$

- Revocação: a medida revocação, também conhecida como probabilidade de detecção (β), consiste na capacidade de detecção de falha quando o componente realmente apresenta defeito. É definida como o número de VP dividido pelo número de VP mais o número de FN, conforme a Equação 3.12. Esta medida define o número de exemplos classificados como pertencentes a uma determinada classe, que realmente são daquela classe, dividido pela quantidade total de exemplos que pertencem a esta classe, mesmo que sejam classificados em outra.

$$\text{Revocação} = \beta = \frac{VP}{VP + FN} \quad (3.12)$$

A partir das métricas de avaliação, precisão e revocação, é possível calcular a medida F. Esta consiste em uma combinação dos valores de precisão e de revocação.

- Medida F: nos casos em que se deseja encontrar uma combinação entre precisão e revocação, pode-se utilizar a medida F. Esta métrica é calculada por meio de uma média harmônica entre os valores de precisão e de revocação. A Equação 3.13 representa esta relação.

$$\text{Medida F} = 2 * \frac{P * R}{P + R} \quad (3.13)$$


A média harmônica, conforme a Equação 3.13, permite punir diferenças extremas entre a precisão e a revocação, gerando uma nova métrica de avaliação que se ajusta a partir da troca entre as outras métricas. A medida F é indicada quando o conjunto de dados possui classes desproporcionais. Em geral, quanto maior for o valor da medida F melhor.

- Falso alarme: a taxa de falso alarme (α), no contexto de falhas, consiste em considerar erroneamente um componente como defeituoso sendo que este não apresenta condição de anomalia. É definido como a somatória de FP pelo total de condição positiva, conforme a Equação 3.14.

$$\alpha = \frac{FP}{FP + VN} \quad (3.14)$$

Para avaliar o desempenho dos algoritmos de classificação podem ser utilizados métodos de validação cruzada. Neste trabalho, utilizou-se a validação cruzada do tipo *K-fold*. De acordo com Marsland (2015), a metodologia de validação cruzada *K-fold* consiste em dividir o conjunto de dados de entrada em k subgrupos distintos, também chamados de *folds*, com tamanhos aproximadamente iguais. O modelo de AM é treinado em todos os subconjuntos, exceto um ($K - 1$). Na sequência, avalia-se o modelo no subconjunto que não foi usado para o treinamento. O processo é repetido K vezes, com um subconjunto diferente reservado para avaliação e excluído do treinamento. Ao término das iterações, calcula-se a média das métricas de avaliação. A Figura 13 exemplifica uma representação do método de validação cruzada *K-fold* para K iterações.

Figura 13 – Representação do método de validação cruzada *K-fold*.



Fonte: Elaborado pela autora.

Segundo Borra e Ciaccio (2010), o viés do método *K-fold* diminui quanto maior o valor de K . Porém, um K muito elevado acaba aumentando o custo computacional da técnica, além de implicar uma amostra de teste pequena, o que aumenta a variância. Na literatura, se discute qual valor de K seria o ideal, sendo como opções mais usuais os valores $K = 2, 5$ e 10 . Em seu estudo, o autor traz essa discussão e afirma que, para sua aplicação, $K = 10$ tem um melhor desempenho. Neste trabalho, adotou-se o número de partições sendo $K = 10$.

4 DESCRIÇÃO DO MÉTODO PROPOSTO PARA A PREDIÇÃO DE FALHAS EM COMPONENTES AERONÁUTICOS

Neste capítulo será apresentado o método proposto para a aplicação de mineração de dados e aprendizado de máquina para promover o prognóstico de falhas de componentes de aeronaves. O capítulo descreve as etapas realizadas para transformar os conjuntos de dados, referentes às aeronaves e suas operações, em conhecimentos para geração de um modelo preditivo capaz de estimar a vida útil remanescente de componentes do sistema pneumático. O método apresentado abrange desde a aquisição dos dados até a geração de aprendizado de máquina automática.

4.1 MÉTODO PROPOSTO

O método proposto neste trabalho é baseado em um conjunto de dados fictícios baseados em dados reais. Devido à necessidade de confidencialidade, os dados foram descharacterizados. Os conjuntos de dados são referentes a mensagens do sistema de indicação de motores e alerta de tripulação, mensagens de manutenção, reportes de remoções e dados de sensores de aeronaves. O objetivo principal é identificar quando os componentes do sistema pneumático estão próximos de apresentar falhas. Para o sistema específico são selecionados um conjunto de dados de sensores e registrados os históricos de remoções. Estas informações podem ser utilizadas como indicativos de desempenho do sistema em estudo.

A abordagem escolhida para promover o prognóstico de falhas foi a técnica orientada a dados. Esta baseia-se no uso de conjuntos de dados históricos e técnicas de mineração de dados e aprendizado de máquina para avaliar a condição de degradação e determinar a vida útil remanescente dos equipamentos da aeronave.

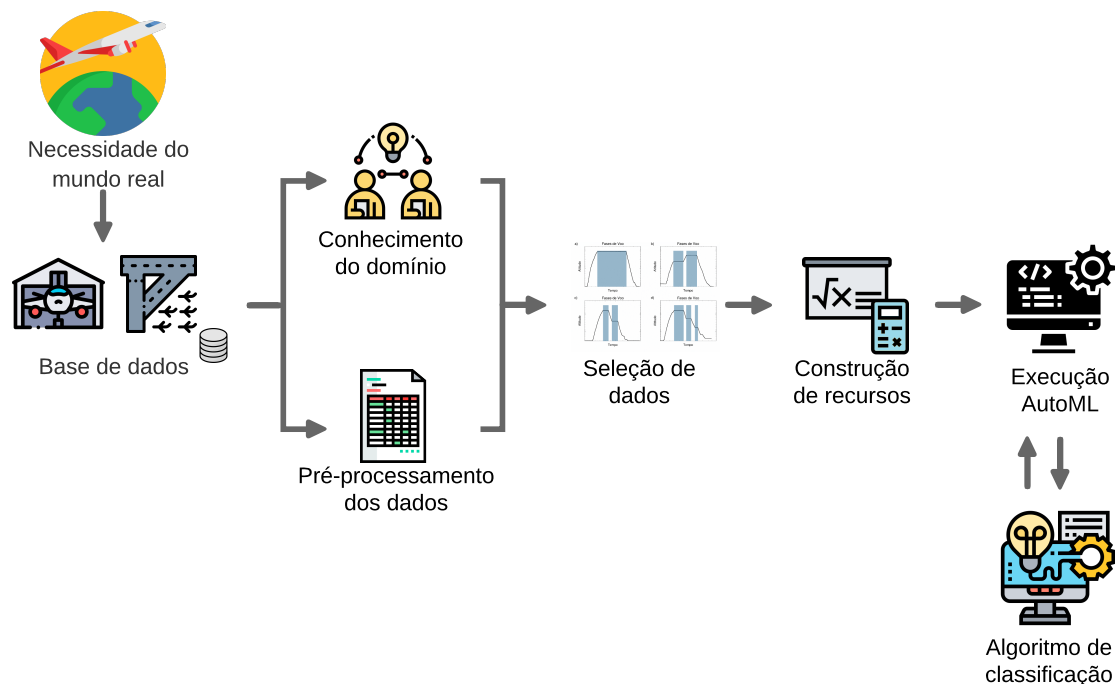
Para determinar o modelo de aprendizado de máquina mais adequado e suas respectivas configurações, para a aplicação específica, foi utilizado o AutoML. Este método visa tomar decisões de forma automatizada e orientada a dados. Por meio de um conjunto de dados de entrada, o sistema AutoML determina automaticamente a abordagem com melhor desempenho para o conjunto específico. Existem vários softwares e serviços para geração automática de aprendizado de máquina. Neste trabalho, foi utilizado o TPOT. Este *framework* utiliza programação genética para explorar diversos canais e encontrar o melhor resultado para o conjunto de dados de entrada.

O algoritmo resultante, do processo de geração AutoML, é aplicado em diferentes cenários construídos a partir de conjuntos de dados distintos. A ideia é avaliar o desempenho dos recursos na geração de prognóstico de falhas. Destaca-se que diferentes conjuntos de dados de entradas podem gerar diferentes modelos de aprendizado de máquina. Para todos os cenários propostos neste trabalho, o modelo de aprendizado de máquina selecionado pelo AutoML foi o *Gradient Boosting*. Os cenários foram executados considerando a validação cruzada *K-fold* com 10 partições. Por fim, foram geradas as matrizes de confusão e calculadas as métricas de avaliação.

De modo geral, o método aplicado neste trabalho abrange as etapas do processo de descoberta de conhecimento. Inicialmente, foram adquiridas as bases de dados históricas. Os conjuntos de dados são referentes a uma frota de aeronaves e seus históricos de inspeções e reparos. A etapa de pré-processamento de dados ocorreu juntamente com o

estudo do domínio. No início do pré-processamento dos dados foram realizadas reuniões com especialistas da área aeronáutica com o objetivo de favorecer o entendimento dos dados e criação de estratégias. As fases seguintes consistem na seleção dos dados e construção de recursos, ambas utilizadas com o intuito de selecionar os atributos interessantes para o problema. A partir deste ponto, considera-se que os dados foram transformados em características e estão prontos para serem aplicados em algoritmos de aprendizagem supervisionada. O próximo passo consistiu na execução do AutoML, cujo objetivo foi descobrir o modelo de AM indicado pelo *framework*. Por fim, foi realizada a aplicação do algoritmo de classificação. A finalidade é gerar um modelo preditivo que a partir de um novo conjunto de dados operacionais seja capaz de evidenciar padrões nestes dados e promover o prognóstico de falhas. A Figura 14 ilustra o método proposto para aplicação de mineração de dados e aprendizado de máquina no desenvolvimento de prognóstico de falhas orientado a dados.

Figura 14 – Método proposto para aplicação de mineração de dados e aprendizado de máquina no prognóstico de falhas.



Fonte: Elaborado pela autora.

A extração do conhecimento é uma área dinâmica e evolutiva, envolvendo integrações com outras ciências como Estatística, Inteligência Artificial e Banco de Dados. Destaca-se que as etapas de descoberta de conhecimentos em conjuntos de dados são processos iterativos e exploratórios. Portanto, algumas etapas podem ser executadas novamente dependendo dos resultados dos passos posteriores. De acordo com Fayyad, Shapiro e Smyth (1996), o processo de KDD é constituído de diversas fases e tem início na análise do entendimento do domínio da aplicação e dos objetivos a serem realizados. As próximas subseções abordarão cada um dos processos realizados para minerar os conjuntos de dados e obter como saída um quadro de dados para geração do AutoML.

4.1.1 Identificação e Compreensão do Conjunto de Dados

Este estudo de caso é baseado em um conjunto de dados gravados em voo e registros de reportes de remoções. Os dados referem-se às mensagens do sistema de indicação do motor e alerta da tripulação, mensagens de manutenção, datas de remoções de componentes e dados de sensores das aeronaves. Para fins de confidencialidade, foi necessário realizar uma descaracterização nos dados.

Os conjuntos de dados referentes à Evento da Cabine de Pilotagem (do Inglês, *Flight Deck Event*) (FDE), Mensagens de Manutenção (MM) e dados de sensores foram adquiridos por meio do gravador QAR, enquanto que os dados de Reporte de Remoções (RR) foram adquiridos por meio de históricos de atividades de manutenção. Os dados de QAR foram disponibilizados no sistema de numeração decimal.

Para analisar o conjunto de dados de FDEs, foram consideradas duas características importantes, quais sejam, uma FDE para um sistema específico pode resultar em falhas ou não falhas e nem todas as FDEs resultam diretamente em ações de manutenção. Como resultado, uma FDE pode ocorrer novamente em vários voos adjacentes. A Tabela 2 representa a estrutura do cabeçalho dos arquivos referentes as FDEs.

Tabela 2 – Estrutura do arquivo de mensagens do sistema de indicação do motor e alerta da tripulação.

ID Aircraft	Fault Text	Flight Phase	Date
-------------	------------	--------------	------

As mensagens de manutenção podem ser acessadas pelos profissionais do centro de serviço de manutenção. Estas possibilitam a visualização de informações históricas relacionadas à saúde e operação de sistemas específicos de aeronaves. As MMs consistem em alertas e avisos mais detalhados que as FDEs. A ocorrência de uma FDE não dispara, necessariamente, uma MM equivalente. A Tabela 3 representa a estrutura do cabeçalho dos arquivos referentes às mensagens de manutenção.

Tabela 3 – Estrutura do arquivo das mensagens de manutenção.

ID Aircraft	Maintenance Message	Flight Phase	Date
-------------	---------------------	--------------	------

As empresas de transporte aéreo podem utilizar sistemas de manutenção para gerenciar itens de manutenção programada e não programada. Esses sistemas podem gerar informações relevantes sobre as substituições de componentes, rastreamento de peças e reportes de remoção. As informações geradas podem ser utilizadas no contexto de prognóstico de falhas.

Os reportes de remoção, disponíveis neste trabalho, são categorizados de acordo com o motivo da remoção. O primeiro motivo é ocasionado pela manutenção programada, significa que o componente atingiu a quantidade de horas de voo ou ciclos de voo. O segundo motivo é a remoção não programada, ou seja, a troca pode ter ocorrido devido a uma falha. Neste trabalho, foram considerados os reportes de remoções de uma provável falha de componentes. A Tabela 4 representa a estrutura do cabeçalho dos arquivos referentes a remoções.

Tabela 4 – Estrutura do arquivo de dados de remoções.

ID Aircraft	S/N Installed	S/N Removed	Reason	Time Hours	Date
-------------	---------------	-------------	--------	------------	------

Por fim, o último conjunto de dados refere-se aos sensores da aeronave. No total, foram analisados dados de seis sensores, nos quais, quatro estão diretamente relacionados com o subsistema em estudo e o restante exerce alguma influência. Este conhecimento do domínio foi observado por um especialista do negócio. A Tabela 5 representa a estrutura do cabeçalho dos arquivos.

Tabela 5 – Estrutura do arquivo de dados de sensores.

ID Aircraft	ID Flight	Altitude	Date	Sensor S_1	Sensor S_2	...	Sensor S_n
-------------	-----------	----------	------	--------------	--------------	-----	--------------

4.1.2 Pré-processamento de Dados

O pré-processamento dos dados consiste em transformar os dados de entrada para um formato mais apropriado para análises posteriores. As etapas envolvidas no processamento incluem a fusão de dados de múltiplas fontes e sua limpeza. A limpeza dos dados abrange a seleção de variáveis, tratamento de dados faltantes, ajuste de dados duplicados e a adaptação de frequências de gravação diferentes. O pré-processamento de dados pode ser feito de diversas formas, a solução depende do conjunto de dados e do problema que se pretende resolver. Uma vez limpos, esses conjuntos podem ser gravados em uma nova estrutura de dados.

Para a tarefa de pré-processamento, o especialista de domínio foi consultado com o propósito de esclarecer dúvidas, indicar caminhos e complementar informações referentes a base de dados.

Inicialmente, foram excluídas colunas dos conjuntos de dados. Essa estratégia foi utilizada devido ao fato de algumas variáveis não exercerem influência sobre o resultado procurado. Nos conjuntos de dados de FDEs e MMs foram excluídas as colunas que indicam as diferentes etapas que uma aeronave deve cumprir em terra e no ar (*Flight Phase*). Quanto aos dados de RR, foram desconsideradas as colunas que informam o total de horas de voo do componente (*Time Hours*) e o número de série, da peça instalada e removida, que é o identificador atribuído a uma peça específica da aeronave (*S/N Installed*) e (*S/N Removed*). Por fim, no conjunto de dados referente aos sensores foram mantidas todas as colunas, visto que, a base de dados de sensores contém informações do subsistema da aeronave em estudo.

A próxima etapa consistiu no tratamento de dados faltantes. Nos conjuntos de dados de FDEs e MMs todas as colunas estavam completas. No que se refere aos dados de sensores registrados em cada um dos voos, esses apresentaram a ausência de poucos registros, os quais foram removidos do quadro de dados. Esta decisão de projeto foi tomada pelo fato dos dados faltantes apresentarem uma representatividade baixa, aproximadamente 0,1%, da quantidade total de registros de sensores gravados.

A partir dos atributos originais é possível criar um novo conjunto de dados que contenha as informações importantes e um número menor de atributos, possibilitando obter

os benefícios de redução de dimensionalidade. Ao término da etapa de pré-processamento obteve-se uma nova versão dos conjuntos de dados.

O conjunto de dados resultante conteve 180.575 mensagens do sistema de indicação dos motores e alerta de tripulação. As FDEs são referentes ao sistema em estudo e possuem 12 tipos de mensagens distintas. Quanto às mensagens de manutenção, foram registradas um total de 75.670 ao longo do tempo. O conjunto de dados possui 78 tipos de MMs diferentes. O total de remoções consideradas foi 65.

4.1.3 Seleção de Dados

A próxima etapa consiste em aplicar técnicas de seleção de atributos a fim de reduzir a dimensionalidade das bases pré-processadas anteriormente. O procedimento foi aplicado no conjunto de dados de sensores. O objetivo deste módulo é selecionar os dados que são mais representativos para o problema que se pretende resolver.

Segundo a ANAC, um voo pode ser segmentado em diferentes fases padrão: táxi¹; decolagem; subida; voo de cruzeiro; descida; aproximação para o pouso; pouso e táxi até o ponto de estacionamento (ANAC, 2020). Os dados de voos, armazenados no QAR, se parecem como grandes sinais temporais multivariados. As observações temporais consistem em sinais estruturados que podem ser decompostos nas diferentes fases de um voo.

Em seus estudos Lacaille et al. (2019), ressaltam que durante cada fase de voo pode haver regimes estabilizados e fases transitórias. Os regimes estabilizados são mais fáceis de entender e de modelar. Em contrapartida, os regimes transitórios são mais complexos, pois dependem dos comandos emitidos pelos pilotos. As transições entre as fases de voo dependem de vários parâmetros como, por exemplo: plano de voo, geografia do solo do aeroporto, horário, estação e meteorologia.

Neste contexto, foi implementado um código para seleção da fase de voo de cruzeiro. Esta fase faz parte do regime estabilizado definido por Lacaille et al. (2019). Segundo o autor, a transformação dos dados permite várias perspectivas como, por exemplo, o reconhecimento de comportamentos semelhantes ou padrões durante a fase de voo específica.

A Figura 15(a) representa a relação entre a altitude e o período de tempo de um perfil de voo genérico. Pode-se observar a presença de uma fase de voo de cruzeiro, compreendida entre o final da subida e o início da descida. Em uma determinada altitude, a aeronave atinge o voo de cruzeiro, parte nivelada central, após um período começa a descida para pouso. A parte destacada, em azul, representa o segmento de regime estacionário do voo que foi selecionado para calcular os recursos estatísticos de dados de sensores das aeronaves.

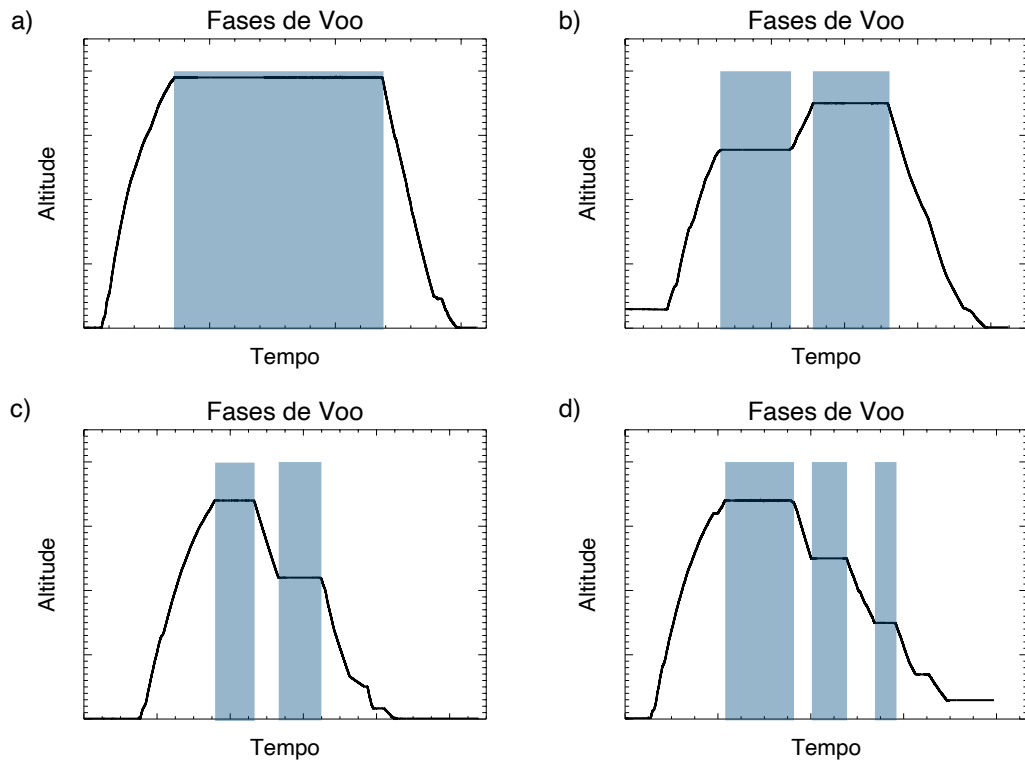
A Figura 15(b) representa a altitude da aeronave ao longo de um voo. Neste caso, observa-se a presença de dois trechos do voo de cruzeiro, estes estão representados pelos seguimentos azuis. A primeira fase de voo de cruzeiro acontece em uma altitude mais baixa, na sequência a aeronave entra em um regime transitório e, logo depois, atinge um pico de altitude representando, pela segunda vez, uma fase de voo de cruzeiro.

A Figura 15(c) representa um perfil de voo com duas fases de voo de cruzeiro. Os dois segmentos, destacados em azul, representam regimes estacionários de voos e serão utilizados para calcular os recursos estatísticos de dados de sensores.

¹Táxi: no contexto aeronáutico, táxi consiste em uma das fases de um voo. Refere-se ao movimento de uma aeronave em um aeródromo. Corresponde a etapa do voo desde o ponto de estacionamento da aeronave até o ponto de decolagem.

A Figura 15(d) representa um voo que dispôs de três fases de cruzeiro. Neste caso, desde a decolagem até a aterrissagem, observa-se a presença de três trechos de voo de cruzeiro, estes estão representados pelos segmentos azuis. Os três segmentos, destacados em azul, representam regimes estacionários de voos e serão utilizados para calcular os recursos estatísticos de dados de sensores.

Figura 15 – Representações de perfis de voos.



Fonte: Elaborado pela autora.

4.1.4 Construção de Recursos

A construção de recursos é o processo de criação de novos atributos a partir dos dados existentes. Essa etapa é de grande importância, porque os algoritmos de aprendizado de máquina aprendem com os dados fornecidos. A descoberta de recursos envolve análise de tempo, análise de frequência e redução de dimensionalidade. A finalidade é extrair recursos para construir representações para classificação do conjunto de dados.

Neste trabalho, foram criados recursos a partir dos dados de sensores e mensagens de falha. As Subseções 4.1.4.1 e 4.1.4.2 explicam os processos desenvolvidos para extrair recursos dos dados de sensores da aeronave e das mensagens de falhas do sistema de bordo, respectivamente.

4.1.4.1 Recursos dos Dados de Sensores

Neste estudo, foi realizada a etapa de construção de recursos utilizando o conjunto de dados de sensores. Foi verificada a necessidade de redução de dimensionalidade devido à grande quantidade de registros da fase de voo de cruzeiro. Para isso, foram calculadas estatísticas de cada um dos voos. O objetivo da construção de recursos estatísticos foi encontrar um bom conjunto de recursos que pode ser usado para promover o prognóstico de falhas de componentes da aeronave. As métricas estatísticas calculadas foram: média (\bar{x}), variância (s^2), desvio padrão (s), quartis (Q_1, Q_2 e Q_3), oscilação (ω) e uma adaptação da medida *zero cross*.

A média aritmética é definida como a soma de todas as observações da variável x , dividida pelo número de elementos N do conjunto de dados. Frequentemente a média aritmética é o valor que melhor representa um conjunto de dados. A expressão genérica para encontrar a média aritmética é demonstrada na Equação 4.1.

$$\bar{x} = \frac{\sum_{i=1}^N x_i}{N} \quad (4.1)$$

em que x_i é o valor na posição i no conjunto de dados.

A variância de uma amostra é a medida da variação em torno da média. Por definição, variância é a média dos quadrados dos desvios em torno da média e pode ser calculada por meio da Equação 4.2.

$$s^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N} \quad (4.2)$$

sendo, x_i o valor na posição i no conjunto de dados, \bar{x} a média aritmética e N representa a quantidade de dados.

O desvio padrão amostral é uma medida que expressa o grau de dispersão de um conjunto de dados. Quanto maior o desvio padrão, maior a dispersão dos dados em torno da média. O desvio padrão pode ser definido como a raiz quadrada positiva da variância. Essa medida corrige o problema de unidade que surge na variância. O desvio padrão amostral é calculado por meio da Equação 4.3.

$$s = \sqrt{s^2} = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}} \quad (4.3)$$

A amplitude do intervalo de classe pode ser descrita por uma oscilação de sequência. Seja a_n uma sequência de números reais, a oscilação $\omega(a_n)$ dessa sequência é definida como a diferença entre o limite superior e o limite inferior de a_n . A estimativa da oscilação entre o limite superior e o limite inferior é obtida por meio da Equação 4.4.

$$\omega(a_n) = \lim_{n \rightarrow \infty} \sup a_n - \lim_{n \rightarrow \infty} \inf a_n \quad (4.4)$$

As próximas estatísticas calculadas foram os quartis. Em estatística descritiva da amostra, quartis são valores dados a partir do conjunto de observações ordenado em ordem crescente, que dividem a distribuição em quatro partes iguais. O primeiro quartil, Q_1 , é o número que deixa 25% das observações abaixo e 75% acima, enquanto que o terceiro quartil, Q_3 , deixa 75% das observações abaixo e 25% acima. Já Q_2 é a mediana, deixa 50% das observações abaixo e 50% das observações acima.

Existem duas abordagens que podem ser utilizadas para calcular os quartis. As abordagens são conhecidas como método inclusivo² e método exclusivo³. Neste trabalho, para calcular os quartis dos dados de sensores foi utilizado o método exclusivo.

O processo de determinação dos quartis inclui duas etapas. Inicialmente, deve-se determinar a posição do quartil no conjunto de dados. Em um segundo momento, deve-se calcular o valor do quartil. Quando o quartil coincide com um elemento do conjunto de dados, a posição é um valor inteiro k e, neste caso, o valor do quartil é imediato. Quando o quartil fica entre dois elementos, a sua posição é um valor não inteiro e, neste caso, é necessário calcular o seu valor fazendo a média dos valores nas posições adjacentes.

A posição dos quartis pode ser calculada matematicamente. Considere-se um conjunto de dados ordenado com n elementos $x_1 \leq x_2 \leq x_3 \leq \dots \leq x_n$. A posição de Q_2 em um conjunto de dados com n elementos é dada pela Equação 4.5.

$$P_{Q_2} = \frac{n+1}{2} \quad (4.5)$$

A determinação das posições de Q_1 e Q_3 no conjunto de dados varia de acordo com a abordagem aplicada. O método utilizado neste trabalho foi o exclusivo. As Equações 4.6 e 4.7 apresentam os cálculos das posições dos primeiro e terceiro quartis, respectivamente.

$$P_{Q_1} = \begin{cases} K = \frac{n+2}{4}, & \text{para } n \text{ par} \\ K = \frac{n+1}{4}, & \text{para } n \text{ ímpar} \end{cases} \quad (4.6)$$

$$P_{Q_3} = \begin{cases} K = \frac{3n+2}{4}, & \text{para } n \text{ par} \\ K = \frac{3n+3}{4}, & \text{para } n \text{ ímpar} \end{cases} \quad (4.7)$$

Uma vez conhecida a posição dos quartis, a próxima etapa consiste em calcular o seu valor. O cálculo do valor dos quartis é equivalente nos métodos inclusivo e exclusivo. A Equação 4.8 apresenta a forma para calcular um quartil Q_p , dada a sua posição k no conjunto de dados.

$$Q_p = \begin{cases} x_k, & \text{para } k \text{ inteiro} \\ \frac{x_i + x_{i+1}}{2}, & \text{para } k \text{ não inteiro} \end{cases} \quad (4.8)$$

sendo $i < k < i + 1$.

Por fim, o último recurso estatístico criado foi o *zero crossing*. Para cada sensor, foi calculada a quantidade de vezes que um registro cruzou o valor da média \bar{x} .

²Método inclusivo: quando o conjunto de dados tem um número ímpar de elementos, o elemento correspondente ao Q_2 é incluído em ambas as metades do conjunto de dados para cálculo dos Q_1 e Q_3 .

³Método exclusivo: quando o conjunto de dados tem um número ímpar de elementos, o elemento correspondente ao Q_2 não é incluído em nenhuma das metades do conjunto de dados para cálculo dos Q_1 e Q_3

4.1.4.2 Recursos dos Dados de Mensagens de Falha

Na maioria dos modelos de prognóstico de falhas orientados a dados, a entrada vem diretamente de sinais de sensores como, por exemplo, temperatura, pressão, corrente elétrica, tensão, dentre outros. Embora estas fontes de dados sejam de grande importância para a geração de prognósticos no contexto de manutenção preditiva, alguns autores, tais como Baptista et al. (2016) e Sano, Malere e Berton (2020) promoveram o uso de fontes alternativas, como dados gerados pelos sistemas de controle a bordo da aeronave e tempos históricos até a ocorrência de falhas.

Os dados derivados dos sistemas de controle a bordo consistem em mensagens do sistema de alerta de tripulação e mensagens de manutenção que visam detectar equipamentos danificados. Em Baptista et al. (2016), os autores destacam que as mensagens são amplamente usadas na definição de procedimentos de manutenção, mas são raramente utilizadas no desenvolvimento de soluções que promovam prognósticos de falhas no setor aéreo.

Para gerar uma notificação, seja para a tripulação ou responsável em manutenção, os sistemas de bordo fazem uso de equações que caracterizam processamentos de falhas de várias fontes. Como resultado, os dados de falha são diferentes dos dados de sensores.

Neste trabalho, além de utilizar os dados estatísticos de sensores da aeronave, também foram construídos recursos por meio da quantidade de mensagens do sistema de alerta de tripulação e mensagens de manutenção adjacentes ao voo. Ambas as mensagens foram contadas ao longo de 1 dia, 2 dias, 3 dias, 5 dias, 7 dias, 10 dias, 15 dias e 20 dias anteriores ao voo. Os procedimentos de fusão entre os diferentes recursos de entrada utilizados na geração do prognóstico de falhas serão detalhados na Subseção 4.1.7.

4.1.5 Aplicação do Aprendizado de Máquina Automatizado

Neste trabalho, foi utilizado o aprendizado de máquina automatizado que consiste automatizar o processo de aplicação do aprendizado de máquina a problemas do mundo real. A finalidade de aplicação do AutoML é a possibilidade de selecionar modelos que apresentem o melhor desempenho nos conjuntos de dados específicos.

Para executar os métodos de aprendizado de máquina automático, foi utilizado o *framework* TPOT. A ferramenta considera vários algoritmos de aprendizado de máquina para tarefas de classificação supervisionada. Neste trabalho, foi aplicado o algoritmo *Gradient Boosting*.

4.1.5.1 Descobrimto do Modelo de Aprendizado de Máquina

Anteriormente à execução do AutoML, a procura de um modelo de classificação ideal para o conjunto de dados específico, é necessário aplicar codificadores de etiquetas nas variáveis dos conjuntos de dados. Os dados de textos categóricos devem ser convertidos em dados numéricos para, posteriormente, serem compreensíveis com modelos de predição. A variável de saída (*target*) é do tipo categórica. Logo, foi transformada para o tipo numérico por meio da utilização da classe *LabelEncoder* da biblioteca *Scikit-learn* da linguagem de programação Python.

Quanto às variáveis de entrada, sendo estas representadas pelos dados de sensores,

quantidades de mensagens de falha e mensagens de manutenção, foi observado que estas variáveis são numéricas, logo, não é necessário aplicar a abordagem anterior. Porém, estas variáveis podem apresentar valores discrepantes umas em relação as outras, isto é, as variáveis de entrada podem estar em escalas distintas. Esse fator pode causar problemas no treinamento do modelo, uma vez que, escalas diferentes podem gerar influência nos resultados. Para solucionar esse problema foi realizada a padronização dos conjuntos de dados por meio da classe *StandardScaler* da biblioteca *Scikit-learn* da linguagem de programação Python.

Na sequência, os dados são divididos em conjuntos de treinamento e teste. A porcentagem do conjunto de dados para treinamento é de 75%, enquanto que a porcentagem do conjunto de dados para teste é de 25%.

A função *fit* inicializa o algoritmo de programação genética para encontrar o *pipeline* com a pontuação mais alta com base na validação cruzada média de dobras *K*. Em seguida, o *pipeline* é treinado em todo o conjunto de amostras fornecidas e a instância TPOT pode ser usada como um modelo adequado. Na sequência, o *pipeline* pode ser avaliado no conjunto de dados de teste por meio da função *score*. A ferramenta retorna a pontuação do *pipeline* otimizado nos dados de teste usando a função de pontuação especificada pelo usuário. A função de pontuação padrão do TPOT, para problemas de classificação, é a precisão.

A saída de um algoritmo de classificação é um classificador, que pode ser usado para prever a classe de novas instâncias sem rótulo. Por fim, o TPOT exporta o código Python correspondente para o *pipeline* otimizado para um arquivo de texto usando a função *export*. Quando esse código terminar a execução, gerará um arquivo em linguagem de programação Python com o modelo de classificação resultante e suas respectivas configurações de parâmetros.

4.1.5.2 Execução do Modelo de Aprendizado de Máquina

Após a descoberta da abordagem de AM mais apropriada para o conjunto de dados, a próxima etapa consiste em executar a aplicação com o modelo selecionado.

O TPOT possui operadores padrão para os modelos de aprendizado de máquina. Além das configurações padrão que acompanham o TPOT, o *framework* permite que os usuários forneçam configurações personalizadas para seus operadores e parâmetros. Neste trabalho, em ambos os casos simulados foram utilizadas as configurações padrão.

Inicialmente, é necessário aplicar codificadores de etiquetas nas variáveis categóricas dos conjuntos de dados. Novamente, a variável de saída (*target*) foi transformada para o tipo numérico. Na sequência, o conjunto de dados de entrada foi particionado em amostra de treinamento e teste. A porcentagem do conjunto de dados para treinamento foi de 75%, enquanto que a porcentagem do conjunto de dados para teste foi de 25%. O *pipeline* foi treinado em todo o conjunto de dados de treinamento. Em seguida, o modelo foi avaliado no conjunto de dados de teste. Por fim, para permitir a análise do classificador, foi gerada a matriz de confusão.

4.1.6 Aplicação do Algoritmo de Mineração de Dados

A mineração de dados consiste no processo de exploração de informações úteis nos conjuntos de dados. A partir dessa fase consideram-se os dados coletados como tratados. A finalidade das técnicas de mineração de dados é identificar padrões, correlações ou relacionamentos entre os diferentes conteúdos dentro da base, os quais por outros tipos de análises poderiam não serem detectados.


A aplicação do algoritmo de mineração é a etapa principal do processo, todas as demais etapas são realizadas em função desta. O algoritmo de mineração recebe como entrada os conjuntos de dados pré-processados e gera saídas padronizadas, a qual reflete o comportamento dos dados de treinamento. A forma como os padrões são gerados e o significado destes apresentam variações para cada algoritmo de mineração de dados. Porém, nem todos os padrões gerados pela mineração são válidos ou úteis. Assim, na etapa de avaliação dos padrões, Subseção 4.1.7, são gerados cenários de interesse para identificar os padrões que apresentam o melhor desempenho na estimativa de vida útil remanescente de componentes da aeronave.

Neste trabalho, a técnica de mineração de dados utilizada foi a classificação. A classificação de dados visa associar objetos a uma determinada classe, ela busca prever uma classe de uma nova instância automaticamente. Por exemplo, por meio de uma base de dados que armazena características de falhas, baseado em históricos de operações de aeronaves, pode-se classificar estas falhas em categorias para descobrir a vida útil remanescente de componentes. Um novo voo poderá ser classificado em uma das categorias definidas, de acordo com suas características.

Uma tarefa de classificação cria um classificador a partir de um conjunto de exemplos rotulados. Este conjunto de exemplo consiste em grupos de instâncias que podem ser marcados por um determinado critério. O classificador é treinado para classificar novos grupos de instâncias.

Inicialmente, para promover o prognóstico de falhas, a data de falha foi definida como a data que o componente foi substituído. A partir da data de remoção, foram traçadas três classes de saída, sendo estas: 05, 10 e 15 dias antes da falha. O classificador multiclasse deve prever o tempo restante de vida útil do componente. As classes de saída representavam o quão próximo da falha o voo está. A Figura 16 representa o método utilizado para definição das classes de saída do classificador.

Figura 16 – Representações das classes de saída do prognóstico de falhas.



Fonte: Elaborado pela autora.

No conjunto de dados, foram detectados 1197 voos pertencentes às classes definidas. No total, a classe 05 obteve 391 voos. A classe 10 teve um total de 404 voos e a classe 15 apresentou 402 voos.

4.1.7 Avaliação de Padrões

Na etapa de avaliação dos padrões, são analisados indicadores de métricas de desempenho para identificar os padrões que apresentam qualidade para classificar a condição de degradação de componentes da aeronave. Destaca-se que a capacidade de um sistema de realizar o reconhecimento de padrões, de forma flexível e adaptável, está intimamente associada à ideia de que um sistema de reconhecimento de padrões deve aprender as características definidas por um determinado cenário do domínio de aplicação e, por conseguinte, ser capaz de aprender como associar um determinado padrão à classe real pertencente.

A análise de prognóstico de falhas representa a área de investigação nos dados que busca inferir resultados a partir dos padrões encontrados. A finalidade é dar suporte ao aprendizado por meio de descrições de situações apresentadas ao sistema (padrões ou casos). Neste contexto, para promover a avaliação de padrões, foram executados experimentos construídos de diferentes casos, os quais diversificam os recursos de entrada utilizados. Em todas as situações, foram realizados os procedimentos descritos nas Subseções 4.1.5.1 e 4.1.5.2 com o objetivo de descobrir o modelo de AM mais adequado para o conjunto de atributos de entrada específico e os resultados de sua execução, respectivamente. Em especial, foram construídos seis casos para avaliar a qualidade do classificador. Os tópicos a seguir apresentam cada um dos casos.

- Caso 1(a): considerando como atributos de entrada os recursos estatísticos dos dados de quatro sensores obtidos na fase de voo de cruzeiro.
- Caso 1(b): considerando como atributos de entrada os recursos estatísticos dos dados de seis sensores obtidos na fase de voo de cruzeiro.
- Caso 2: considerando como atributos de entrada as quantidades de FDEs anteriores aos voos.
- Caso 3: considerando como atributos de entrada os recursos estatísticos dos dados de quatro sensores obtidos na fase de voo de cruzeiro e as quantidades de FDEs anteriores aos voos. Esse caso corresponde a uma junção dos atributos de entrada utilizados no Caso 1(a) e no Caso 2.
- Caso 4: considerando como atributos de entrada as quantidades de MMs anteriores aos voos.
- Caso 5: considerando como atributos de entrada os recursos estatísticos dos dados de quatro sensores obtidos na fase de voo de cruzeiro e as quantidades de MMs anteriores aos voos. Esse caso corresponde a uma junção dos atributos de entrada utilizados no Caso 1(a) e no Caso 4.
- Caso 6: considerando como atributos de entrada os recursos estatísticos dos dados de quatro sensores obtidos na fase de voo de cruzeiro e as quantidades de FDEs e MMs anteriores aos voos.

O conhecimento extraído e os padrões encontrados nos dados podem ser utilizados para a realização de execuções de casos distintos, que podem combinar recursos de entrada de diferentes fontes de origem para indicar condições potenciais de falhas de equipamentos. Estes experimentos poderão contribuir também para verificar o comportamento do classificador e avaliar a taxa de acerto média do modelo preditivo. Neste contexto, a avaliação dos experimentos realizados deve ser capaz de identificar problemas e recomendar soluções e estratégias para melhorar o desempenho do preditor na classificação do nível de degradação de componentes do sistema em estudo.

Pelas razões destacadas acima, a geração de casos distintos visa possibilitar descobertas de padrões relevantes e impactantes para promover o prognóstico de falhas. No Capítulo 5 são apresentados os resultados obtidos em cada um dos seis casos destacados nesta subseção.

5 DESCRIÇÃO E AVALIAÇÃO DOS RESULTADOS OBTIDOS COM O MÉTODO PROPOSTO PARA A MANUTENÇÃO PREDITIVA DE AERONAVES

Este capítulo apresenta os resultados da aplicação do método proposto, para a avaliação do efeito de diferentes conjuntos de dados de entrada sobre o algoritmo de aprendizado de máquina supervisionado em prognóstico de falhas. Para cada um dos casos, são discutidos os valores das métricas de desempenho do modelo preditivo.

5.1 METODOLOGIA ADOTADA NA REALIZAÇÃO DOS EXPERIMENTOS

Neste trabalho é proposta a avaliação da capacidade de predição de algoritmos de aprendizagem de máquina supervisionada sob diferentes conjuntos de dados de entrada. Desse modo, foi executado um método para analisar as abordagens orientadas a dados, o qual foi baseado em observações da matriz de confusão. No total, foram construídos seis conjuntos de dados distintos para avaliação do modelo de predição. Em todos os casos foi aplicada a validação cruzada *K-fold* com 10 partições, na qual 75% dos dados foram usados para treinamento e as observações restante, compreendendo 25% dos dados, foram utilizadas para teste. Ao término das execuções, foram calculadas as métricas de avaliação para cada uma das situações. As métricas calculadas foram: precisão, revocação ou probabilidade de detecção (β), medida F e taxa de falso alarme (α).

O modo de falha avaliado refere-se ao sistema pneumático de aeronaves. No total, ocorreram 1197 instâncias dentro das classes de saídas possíveis. As classes de saída representam a vida útil remanescente, isto é, o quão próximo da falha está o componente. Dentre os 1197 voos, 391 pertencem a classe 05, o que significa que esses voos aconteceram no intervalo de 0 a 5 dias antes da data de remoção. No intervalo de 5 a 10 dias, obteve-se um total de 404 voos. Esses foram marcados como classe 10 e, por fim, no intervalo 10 a 15 dias foram registrados 402 voos, os quais pertencem a classe 15. A distribuição semelhante das classes de saída sugere que a aplicação seja um problema com classes equilibradas.

Os experimentos foram executados em uma mesma máquina com sistema operacional para 64 bits. As configurações técnicas da máquina são: processador Intel® Core™ i7-8565U, memória RAM de 16 GB e disco rígido de 256 GB.

5.1.1 Análise do Caso 1(a)

No primeiro modelo de simulação elaborado neste trabalho, a construção do conjunto de atributos de entrada foi baseada em recursos estatísticos dos dados de sensores das aeronaves, para cada um dos voos. Foram geradas duas situações. A primeira considerando os recursos estatísticos de quatro sensores relacionados diretamente com o sistema em estudo. A segunda, utilizando recursos estatísticos desses quatro sensores mais recursos de dois sensores adicionais. Os sensores adicionais não pertencem diretamente ao sistema, mas estão correlacionados. Nesse contexto, buscou-se avaliar a adequabilidade da utilização dos sensores para cada caso descrito. O experimento realizado consiste fundamentalmente na aplicação da técnica de AM sobre os conjuntos de dados distintos para determinar qual das abordagens será mantida nas etapas futuras.

Na primeira abordagem, considerando quatro sensores, foi executado o otimizador de *pipelines* da biblioteca TPOT. A execução do AutoML resultou no modelo de classificação *Gradient Boosting*. O tempo de execução do *framework* para encontrar esse modelo foi de 5min 5s. A Tabela 6 exemplifica a matriz de confusão. A taxa de acerto média foi de 40,01% com desvio padrão de 4,94%.

Tabela 6 – Matriz de confusão para o Caso 1(a).

		Classe predita		
		Classe 05	Classe 10	Classe 15
Classe real	Classe 05	122	92	82
	Classe 10	90	110	96
	Classe 15	81	97	127

A Tabela 7 mostra os resultados das métricas de avaliação do classificador para a situação descrita acima.

Tabela 7 – Métricas de avaliação para o Caso 1(a).

Classe	Métricas de avaliação		
	Precisão	Revocação	Medida F
Classe 05	0,42	0,41	0,41
Classe 10	0,37	0,37	0,37
Classe 15	0,42	0,42	0,42

Analisando a Tabela 7 é possível destacar que a precisão e a revocação, em ambas as classes, apresentou pequenas diferenças. Esse fato sugere que o preditor não é tendencioso para apenas uma das classes. Porém, a taxa de acerto média igual a 40,01% com desvio padrão de 4,94% é considerada baixa, visto que, a porcentagem de 35,07% está muito próxima do aleatório, que para três classes de saída, corresponde a 33,33%.

5.1.2 Análise do Caso 1(b)

Na segunda abordagem, considerou-se os mesmos atributos de entrada do caso anterior. Porém, desta vez, foram apontados seis sensores. Adicionalmente, foram inseridos recursos estatísticos de mais dois sensores. Estes, por sua vez, não fazem parte diretamente do sistema pneumático, mas estão relacionados. A Tabela 8 representa a matriz de confusão.

A execução do AutoML resultou no modelo de classificação *Gradient Boosting*. O tempo de execução do *framework* para escolher esse modelo foi de 6min 51s. Para este caso, a taxa de acerto média foi de 38,68% com desvio padrão de 4,09%. Pode-se observar que, em geral, as métricas de avaliação para o Caso 1(b) foram inferiores aos resultados obtidos no Caso 1(a).

A Tabela 9 representa as métricas de desempenho do experimento simulado. Uma hipótese para estes resultados é que a inserção dos recursos estatísticos dos dados dos sensores adicionais possa ter prejudicado o desempenho do classificador.

Tabela 8 – Matriz de confusão para o Caso 1(b).

		Classe predita		
		Classe 05	Classe 10	Classe 15
Classe real	Classe 05	115	81	100
	Classe 10	90	110	96
	Classe 15	87	91	127

Tabela 9 – Métricas de avaliação para o Caso 1(b).

Classe	Métricas de avaliação		
	Precisão	Revocação	Medida F
Classe 05	0,39	0,39	0,39
Classe 10	0,39	0,37	0,38
Classe 15	0,39	0,42	0,40

Analisando o comportamento das duas situações, sugere-se que o experimento 1(a) se mostra mais apropriado que o experimento 1(b). Devido a esta observação, nas próximas execuções serão considerados os recursos estatísticos de quatro sensores das aeronaves.

5.1.3 Análise do Caso 2

Para construção do *dataframe*, para o Caso 2, foram contadas quantidades de mensagens FDEs que antecederam cada um dos voos. A execução do AutoML resultou no modelo de classificação *Gradient Boosting*. O tempo de execução do *framework* para encontrar esse modelo foi de 5min 5s. A Tabela 10 ilustra a matriz de confusão para o experimento 2. A taxa de acerto média foi de 61,75% com desvio padrão de 3,99%.

Tabela 10 – Matriz de confusão para o Caso 2.

		Classe predita		
		Classe 05	Classe 10	Classe 15
Classe real	Classe 05	126	5	155
	Classe 10	4	126	169
	Classe 15	5	5	302

Este cenário apresentou um aumento significativo na taxa de acerto média em relação aos casos avaliados anteriormente. A taxa de acerto aumentou de 40,01%, resultado do Caso 1(a), para 61,75%. Porém, destacam-se duas observações na Tabela 10. A primeira é que muitas instâncias com classe real 05 foram classificadas como classe predita 15. A segunda é que muitas instâncias com classe real 10 foram classificadas como classe predita 15. Estas duas observações revelam quantidades elevadas de falsos positivos para a classe 15. O valor de FP interfere diretamente na taxa de falso alarme (α). Por meio da Equação 3.14 é possível calcular a taxa de falso alarme para cada uma das classes de saída. Os resultados das taxas de falso alarme para as classes 05, 10 e 15, foram 2%, 2,2% e 56,2%, respectivamente. Esses valores sugerem que o classificador tem uma alta

probabilidade de classificar um voo como estando longe de uma condição de degradação, quando na verdade, neste voo o componente do sistema está muito próximo de falhar.

Pode-se destacar que este caso acerta muito bem a classe 15. Porém, tem problemas em classificar as instâncias próximas da falha. Por exemplo, para a classe 15 ele consegue acertar 302 voos e erra apenas 10 entre as classes 05 e 10. Porém, se for feita a mesma analogia para a classe 05, é possível observar que o classificador erra a classe de saída de 160 voos. Na Tabela 11 são demonstrados os valores das métricas de avaliação. Pode-se verificar a disparidade das medidas de revocação. Para a classe 15 é muito representativa $\beta = 97\%$. Este resultado sugere que o preditor é muito restritivo, pois apresenta uma alta probabilidade de detecção para a classe 15, mas para as classes 05 e 10, o classificador não possui boas probabilidades de detecção ($\beta = 44\%$ e $\beta = 42\%$).

Tabela 11 – Métricas de avaliação para o Caso 2.

Classe	Métricas de avaliação		
	Precisão	Revocação	Medida F
Classe 05	0,93	0,44	0,60
Classe 10	0,93	0,42	0,58
Classe 15	0,48	0,97	0,64

5.1.4 Análise do Caso 3

Neste experimento foram considerados os recursos estatísticos de quatro sensores relacionados diretamente ao sistema pneumático e a quantidade de mensagens do sistema de alerta de tripulação que antecederam cada um dos voos. A razão pela qual foi construída a junção da coleção de preditores é que muitos preditores diferentes, os quais tentam prever a mesma variável de destino, podem executar um trabalho melhor do que um preditor isolado. A taxa de acerto média foi de 57,86% com desvio padrão de 7,62%. A execução do AutoML resultou no modelo *Gradient Boosting*. O tempo de execução do *framework* para determinar esse modelo foi de 5min 5s. A Tabela 12 representa a matriz de confusão e permite visualizar a dispersão dos valores previstos para as classes reais.

Tabela 12 – Matriz de confusão para o Caso 3.

		Classe predita		
		Classe 05	Classe 10	Classe 15
Classe real	Classe 05	156	68	62
	Classe 10	63	160	76
	Classe 15	39	70	203

A Tabela 13 apresenta os resultados das métricas de avaliação da aplicação do método *Gradient Boosting* para o conjunto de recursos descritos. Pode-se observar uma menor dispersão entre os valores de revocações, isto significa que as probabilidades de detecção, para todas as classes, são mais uniformes do que o Caso 2.

Tabela 13 – Métricas de avaliação para o Caso 3.

Classe	Métricas de avaliação		
	Precisão	Revocação	Medida F
Classe 05	0,60	0,55	0,57
Classe 10	0,54	0,54	0,54
Classe 15	0,60	0,65	0,62

5.1.5 Análise do Caso 4

Em relação ao Caso 4, os resultados produzidos pelo algoritmo *Gradient Boosting* são representados na Tabela 14. O tempo de execução do *framework* para encontrar esse modelo foi de 4min 33s. Neste caso, os atributos de entrada foram construídos a partir de parâmetros de quantidades de mensagens de manutenção anteriores a data dos voos. Observa-se que apesar da taxa de acerto média ter aumentado para 60,08% com desvio padrão de 4,25%, a probabilidade de falso alarme (α) para a classe 15 é muito significativa, cerca de 58%. Esses resultados sugerem que o caso é muito restritivo, pois considera muitas classes reais 05 e 10 como classe predita 15.

Tabela 14 – Matriz de confusão para o Caso 4.

		Classe predita		
		Classe 05	Classe 10	Classe 15
Classe real	Classe 05	124	6	156
	Classe 10	10	117	172
	Classe 15	3	11	298

A Tabela 15 mostra os resultados das métricas de avaliação do classificador para a situação descrita acima.

Tabela 15 – Métricas de avaliação para o Caso 4.

Classe	Métricas de avaliação		
	Precisão	Revocação	Medida F
Classe 05	0,91	0,43	0,59
Classe 10	0,87	0,39	0,54
Classe 15	0,48	0,96	0,64

Na Tabela 15 é possível observar a diferença entre a probabilidade de detecção (revocação), para cada uma das classes de saída. Enquanto que a classe 15 apresenta uma probabilidade de detecção igual a 96% dos casos, as probabilidades β da classe 05 e da classe 10 são 43% e 39%, respectivamente. Essas diferenças sugerem, novamente, que o Caso é limitado, pois apresenta uma taxa de detecção elevada para somente uma das classes de saída.

5.1.6 Análise do Caso 5

Para o desenvolvimento do quinto caso, foi construído um *dataframe* a partir dos recursos estatísticos dos dados de quatro sensores e a quantidade de mensagens de manutenção ao longo dos voos. A execução do AutoML resultou no modelo *Gradient Boosting*. O tempo de execução do *framework* para encontrar esse modelo foi de 5min 5s. A Tabela 16 ilustra a matriz de confusão. Como resultado desse experimento, tem-se uma taxa de acerto média foi de 59,63% com desvio padrão de 3,79%.

Tabela 16 – Matriz de confusão para o Caso 5.

		Classe predita		
		Classe 05	Classe 10	Classe 15
Classe real	Classe 05	176	59	51
	Classe 10	54	165	80
	Classe 15	40	78	194

Os resultados produzidos pelo algoritmo são representados por um conjunto de métricas de avaliação descritas na Tabela 17. É possível observar um melhor equilíbrio na métrica de avaliação revocação. Esse resultado significa que as sensibilidades da classificação, para todas as classes de saída, possuem o valor mais próximos umas das outras.

Tabela 17 – Métricas de avaliação para o Caso 5.

Classe	Métricas de avaliação		
	Precisão	Revocação	Medida F
Classe 05	0,65	0,62	0,63
Classe 10	0,55	0,55	0,55
Classe 15	0,60	0,62	0,61

5.1.7 Análise do Caso 6

Neste caso foi analisada a junção dos recursos estatísticos dos dados de quatro sensores da aeronave, quantidades de mensagens do sistema de indicação de motores e alerta de tripulação e mensagens de manutenção. A execução do AutoML resultou no modelo de classificação *Gradient Boosting*. O tempo de execução do *framework* para encontrar esse modelo foi de 5min 5s. A Tabela 18 mostra a matriz de confusão.

Esta abordagem apresentou os melhores resultados: taxa de acerto média de 64,65% com desvio padrão de 5,89%, comparados aos valores obtidos pelos cenários anteriores. A Tabela 18 apresenta a matriz de confusão correspondente ao Caso 6.

Tabela 18 – Matriz de confusão para o Caso 6.

		Classe predita		
		Classe 05	Classe 10	Classe 15
Classe real	Classe 05	183	53	50
	Classe 10	43	192	65
	Classe 15	36	70	205

Pode-se observar que apesar do classificador apresentar erros na determinação das classes preditas, estes erros acontecem em menores quantidades do que dos demais casos executados.

Tabela 19 – Métricas de avaliação para o Caso 6.

Classe	Métricas de avaliação		
	Precisão	Revocação	Medida F
Classe 05	0,70	0,64	0,67
Classe 10	0,61	0,64	0,62
Classe 15	0,64	0,66	0,65

Por meio dos resultados da coluna revocação, Tabela 19, é possível observar que os valores, para todas as classes, são mais próximos. Esta análise significa que a probabilidade de detecção de classes variadas apresenta um pequeno desvio padrão. Logo, o classificador mantém um equilíbrio entre as classes reais. A métrica de avaliação precisão também apresenta uniformidade para as classes de saída do problema.

5.2 DISCUSSÕES DOS RESULTADOS

Inicialmente, pode-se destacar que os dados de voos para cada uma das classes de saída são equilibrados. Para o aprendizado de máquina, uma distribuição distorcida dos valores-alvo pode causar um viés de precisão nos algoritmos e afetar negativamente o desempenho dos modelos. Neste ponto, observa-se que as classes de saída são equilibradas e que eventuais resultados não satisfatórios não são devido ao desbalanceamento de classes.

Com relação à utilização de AutoML, para determinar o modelo de AM que mais se adequa ao conjunto de dados, em todos os casos o modelo que obteve a maior pontuação foi o *Gradient Boosting*. É importante ressaltar que o *framework* de geração de aprendizado automática poderia resultar em modelos distintos, mas, para todos os conjuntos de dados de entrada, foi selecionado o mesmo modelo.

No Caso 1(a), no qual os recursos estatísticos são construídos a partir de quatro sensores, o segundo modelo de AM mais pontuado pelo *pipeline* foi o *K-Neighbors*, com $K = 9$. Enquanto que, no Caso 6, o segundo melhor pontuador foi o modelo *Random Forest*. Diante destes acontecimentos, foram executados todos os casos com essas duas abordagens. A Tabela 20, disponível no Apêndice A, apresenta uma comparação entre os casos executados e os modelos de aprendizado de máquina. Uma observação que chama a atenção é que o Caso 6 apresentou a taxa de acerto média maior no modelo *Random Forest*, do que no *Gradient Boosting*. Sugere-se que isto pode ter ocorrido de-

vido à próxima pontuação dos *pipelines* de aprendizado de máquina destes dois modelos. Na documentação do TPOT, é destacado que um mesmo conjunto de dados pode gerar modelos AutoML diferentes. Isto está relacionado com a aleatoriedade dos processos de programação genética utilizada no *framework*. Na execução do AutoML, para todos os casos foi utilizada uma “semente” padrão. A finalidade é que o conjunto de dados de treinamento e o conjunto de dados de teste fossem os mesmos para todos os casos e modelos analisados.

Pode-se destacar que o caso de prognóstico de falhas controlado por múltiplas fontes de dados tem um desempenho superior. Conforme foi observado nos estudos de Baptista et al. (2016) e Sano, Malere e Berton (2020). Observa-se que no Caso 6 ambas as métricas de avaliação tendem a apresentar um comportamento similar nas três classes reais. A análise da métrica revocação, também chamada de probabilidade de detecção, evidencia um equilíbrio entre detectar dados multiclass, diferentemente dos cenários simulados com recursos apenas de quantidade de mensagens do sistema de bordo da aeronave (Caso 2 e Caso 4). Portanto, sugere-se que a geração de prognósticos de falhas por meio de uma coleção de preditores, os quais integram dados de mensagens de sistema de alerta de tripulação, dados de mensagens de manutenção e dados de sensores, é capaz de apresentar desempenho significativamente maior do que os modelos baseados apenas nos dados de sensores das aeronaves. Acredita-se que quando os conjuntos de preditores diferentes tentam prever a mesma variável de destino, estes executam um trabalho melhor do que qualquer preditor isolado. Os resultados sugerem que os recursos utilizados têm grande influência no desempenho do classificador.

6 CONSIDERAÇÕES FINAIS E PROPOSTAS PARA TRABALHOS FUTUROS

Os sistemas de prognóstico e gerenciamento de saúde de aeronaves têm a função de fornecer informações relacionadas ao comportamento de componentes nas diversas fases de operação ao longo do tempo. A adição de técnicas de manutenção preditiva tem um enorme potencial na redução dos impactos causados por eventos não previstos, dado o custo elevado que a imobilização de uma aeronave representa para o setor de transporte aéreo. Cada vez mais, as companhias aéreas, fabricantes e MROs estão investindo em abordagens preditivas com o intuito de adicioná-las às suas práticas de manutenção. No contexto econômico, a implantação de manutenção preditiva traz a expectativa de converter manutenção não programada em eventos esperados e, assim, minimizar custos e reduzir o tempo de inatividade das aeronaves. Apesar dos benefícios da manutenção preditiva serem difíceis de quantificar, sugere-se que a inserção deste tipo de manutenção às demais práticas seja vantajosa tanto do ponto de vista da manutenção quanto da perspectiva de logística de peças.

Como pode ser observado, há uma demanda relacionada ao desenvolvimento de ferramentas de prognóstico de falhas destinadas à estimativa das condições de degradação de equipamentos de aeronaves. Para tanto, a partir de históricos de uma série de dados, propôs-se avaliar o desempenho de um classificador como forma de visibilizar o prognóstico de falhas orientado a dados. Em relação ao conjunto de dados históricos, foram utilizados dados referentes ao sistema de alerta de tripulação e indicação de motores, mensagens de manutenção, dados de sensores e reportes de remoções de peças.

Uma série de etapas foram definidas para adequação dos dados, conforme apresentado no Capítulo 4. Inicialmente, foram adquiridos os dados descaracterizados. Em seguida, foi realizado o pré-processamento de dados. Nesta etapa, o entendimento do domínio foi compreendido por meio de orientações de especialistas da área aeronáutica. A seleção de dados ocorreu logo em sequência e, uma vez finalizada, a mesma foi submetida aos procedimentos de construção de recursos. Neste trabalho, foram gerados seis cenários para estimar a vida útil remanescente de componentes da aeronave. Para cada um dos casos, foi executado o AutoML com o objetivo de descobrir qual modelo de AM adequa-se para o conjunto de dados de entrada. Com relação ao modelo resultante do AutoML, em todos os casos a técnica *Gradient Boosting* obteve a maior pontuação.

Analisando o comportamento das situações que consideram apenas recursos estatísticos de dados de sensores, Caso 1(a) e Caso 1(b), sugere-se que a utilização de dados somente dos sensores que estão diretamente ligados ao subsistema se mostra mais apropriada do que a utilização de dados de sensores adicionais que não estejam diretamente relacionados. Uma hipótese para esta conclusão é que a inserção de sensores, que não estejam diretamente relacionados ao subsistema em estudo, pode ter prejudicado o desempenho do classificador. Logo, a adição de características não significa que sempre se obtém uma melhora de desempenho na classificação.

Nas simulações dos casos 2 e 4, representando os prognósticos de falhas por meio de recursos de quantidades de mensagens de falha e quantidades de mensagens de manutenção, respectivamente, ambos parecem apresentar desempenho inferior ao cenário descrito no Caso 6, embora tenham resultado em uma taxa de acerto média elevada, 61,75% e 60,08%, respectivamente. A justificativa da não adequação dos cenários é que a taxa de falso alarme para as classes 15, longe da falha, apresenta um valor muito elevado (56,2%

e 57,6%). Isto significa que o classificador tem uma alta probabilidade de indicar que as falhas estão distantes, quando na verdade, a falha está muito próxima de ocorrer.

Quanto ao Caso 6, observa-se um desempenho positivo. Esse cenário considera como atributos de entrada os recursos estatísticos dos dados de quatro sensores, quantidade de ocorrência de FDEs e quantidade de ocorrência de MMs. O prognóstico de falhas combinando recursos estatísticos de diferentes fontes apresenta métricas de avaliação superiores, comparadas aos demais casos. A probabilidade de detecção e a taxa de falso alarme evidenciam um equilíbrio entre as predições de instâncias multiclases, diferentemente dos casos simulados com recursos apenas de quantidade de mensagens do sistema de bordo da aeronave (Caso 2 e Caso 4). Portanto, sugere-se que a geração de prognósticos de falhas por meio de uma coleção de preditores é capaz de apresentar desempenho significativamente maior do que os métodos baseados apenas nos dados de sensores ou somente quantidades de mensagens de falha. Acredita-se que, quando os conjuntos de preditores diferentes tentam prever a mesma variável de destino, estes executam um trabalho melhor do que qualquer preditor isolado. Em particular, tomando como base a técnica *Gradient Boosting*, destaca-se que no Caso 6 o classificador promove uma taxa de acerto média de 64,65% com desvio padrão de 5,89%.

Considera-se que os resultados obtidos no Caso 6, conforme a Subseção 5.1.6, são satisfatórios para fomentar a discussão de prognóstico de falhas na indústria aeronáutica. Este resultado foi alcançado por meio da identificação das variáveis pertinentes ao domínio do problema, utilizadas como recursos de entrada em um modelo de classificação. Destaca-se que a combinação de recursos de diferentes fontes foi promissora, mostrando um aumento significativo de desempenho na estimativa RUL em relação aos demais casos executados. Essas observações encorajam pesquisas adicionais relacionadas a aplicação de outros algoritmos e adição de novas *features*.

A interpretação do resultado do Caso 6, mediante ao segmento de transporte aéreo, envolve vários fatores operacionais dos aeroportos. Existem muitas questões complexas que afetam o gerenciamento de manutenção de uma companhia aérea, tais como, a programação de voo, o planejamento de materiais e peças, a disponibilidade dos MROs, o gerenciamento do estacionamento, o rearranjo da tripulação, dentre outras. Todos esses fatores devem ser considerados na tomada de decisão de realizar uma ação de manutenção. Acredita-se que o resultado obtido no Caso 6 gere conhecimento para orientar e direcionar os responsáveis de manutenção quanto à antecipação de ações de manutenção e reparo de aeronaves.

Por fim, de acordo com o estudo realizado até o momento, pode-se concluir que a geração de prognóstico de falhas baseada em conjuntos de dados históricos de voos apresenta-se promissora para a concepção de um módulo de manutenção preditiva. A avaliação de cenários distintos mostrou que conjuntos de preditores de diferentes fontes tendem a executar um trabalho melhor do que preditores de fontes isoladas. Em especial, obteve-se resultados superiores considerando estatísticas de dados de sensores e quantidades de mensagens de falha anteriores aos voos. Sendo assim, este trabalho apresenta uma contribuição fundamental para a área de manutenção preditiva de aeronaves, em que detecções antecipadas de níveis elevados de degradações podem favorecer as atividades de inspeção e reparo de componentes.

6.1 PROPOSTAS PARA TRABALHOS FUTUROS

Existe uma grande variedade de possibilidades para analisar as condições de saúde de sistemas de aeronaves. Durante o desenvolvimento deste trabalho foram identificados alguns aspectos importantes que podem ser considerados em trabalhos futuros. O desenvolvimento deste trabalho focou na exploração de um conjunto de dados históricos. Entretanto, é possível utilizar abordagens baseadas em modelos físicos, bem como aplicar outras técnicas. Algumas propostas para trabalhos futuros são listadas a seguir:

- A pesquisa foi realizada para o sistema pneumático, um dentre os muitos sistemas de uma aeronave. Uma sugestão seria estender os estudos para os demais sistemas como, por exemplo, o sistema elétrico, o sistema hidráulico, o sistema de pressurização e ar condicionado, o sistema de proteção contra gelo e chuva, dentre outros.
- Futuras investigações poderão estender o trabalho identificando outros benefícios potenciais fornecidos por um sistema PHM por meio de estudos qualitativos ou quantitativos. Outra oportunidade interessante seria explorar esses benefícios para os diferentes clientes de uma aplicação PHM, dentre eles: fabricantes de equipamentos, serviços de MROs, fornecedores de peças e fabricantes de aeronaves.
- Elaborar um estudo combinando técnicas de PHM. Na literatura, estes tipos de abordagens são chamadas de modelos de prognósticos híbridos. Os modelos baseados em dados podem ser combinados, por exemplo, a modelos físicos para prever a condição de um sistema em algum momento de tempo futuro.
- Desenvolvimento de uma solução para aplicativos móveis, Android e IOS, com o propósito de emitir notificações e alertas específicos, para os responsáveis de manutenção, sobre as condições de degradação da frota.
- Desenvolver prognósticos de falhas de sistemas de aeronaves, usando modelos físicos e comparando os resultados com abordagens orientadas a dados. Uma comparação entre diferentes métodos orientados a dados também é uma recomendação.
- Integrar uma solução de manutenção preditiva orientada a dados às atividades de manutenção corretiva programada e atividades de manutenção preventiva.
- Desenvolver um método eficiente de otimização para o gerenciamento de manutenção, capaz de adaptar-se aos estados de degradação da frota em tempo real e considerar requisitos da companhia aérea como, por exemplo, condições de estoque, requisitos de expedição, custos de equipamentos, atrasos e cancelamentos de voos.
- Desenvolver tecnologias de prognósticos de falhas embarcados a bordo das aeronaves. Uma possibilidade seria explorar visualizações, relacionadas aos índices de desgastes de componentes, com indicações no EICAS.

REFERÊNCIAS

- ABEAR. *Associação Brasileira das Empresas Aéreas*. [S.l.], 2020.
- ANAC. *Agência Nacional de Aviação Civil*. [S.l.], 2020.
- ANDREACCHIO, M. et al. Balancing preventive and corrective maintenance of aircraft assets: A cyber-physical systems approach. In: *14th International Conference on Industrial Informatics*. [S.l.]: IEEE, 2016. p. 500–503.
- ANSARI, F.; GLAWAR, R.; NEMETH, T. PriMa: a prescriptive maintenance model for cyber-physical production systems. *International Journal of Computer Integrated Manufacturing*, Taylor & Francis, v. 32, p. 482–503, 2019.
- BALAJI, A.; ALLEN, A. Benchmarking automatic machine learning frameworks. *ArXiv*, August 2018.
- BAPTISTA, M. et al. A comparison of data-driven techniques for engine bleed valve prognostics using aircraft-derived fault messages. In: *Conference of the prognostics and health management society*. Denver, CO: [s.n.], 2016.
- BAPTISTA, M. L. *Machine learning and deep learning for prognostic and predictive maintenance of aeronautical equipment*. Tese (Doutorado) — Universidade de Lisboa, May 2018.
- BERGH, J. V. D.; BRUECKER, P. D.; PEETERS, J. B. J. *Aircraft maintenance operations: state of the art*. Bruxelas, BE, November 2013.
- BORRA, S.; CIACCIO, A. D. Measuring the prediction error. A comparison of cross-validation, bootstrap and covariance penalty methods. In: COLUBI, A.; KONTOGHIORGHES, E.; PARK, B. (Ed.). *Computational Statistics & Data Analysis*. [S.l.]: Elsevier, 2010. v. 54, n. 12, p. 2976–2989.
- BUCZAK, A. L.; GUVEN, E. A survey of data mining and machine learning methods for cyber security intrusion detection. *IEEE Communications surveys & tutorials*, v. 18, n. 2, p. 1153–1176, 2015.
- CAI, J.; LI, X.; CHEN, X. Joint optimization of maintenance inspection and spare provisioning for aircraft deteriorating parts. *Journal of Systems Engineering and Electronics*, Beijing Institute of Aerospace Information, v. 28, n. 6, p. 1133–1140, December 2017.
- COUNCIL, N. R. et al. *The airliner cabin environment air quality and safety*. Washington, DC: National Academies Press, 1986.
- DORNEICH, M. C.; VERVERS, P. M.; GOOD, M. D. Design and evaluation of an integrated avionics alerting system. In: *20th Digital Avionics Systems Conference*. [S.l.]: IEEE, 2001.
- FAN, H.; CHEN, Y.; LI, X. Research on proactive maintenance strategy based on CBM for the aviation ground support facility. In: WANG, J. (Ed.). *Symposium on Aviation Maintenance and Management*. [S.l.]: Springer, 2014. v. 2, p. 245–253.

- FAYYAD, U.; SHAPIRO, G. P.; SMYTH, P. Knowledge discovery and data mining: towards a unifying framework. In: *International Conference on Knowledge Discovery and Data Mining*. [S.l.]: AAAI Press, 1996. p. 82–88.
- FERREIRO, S.; ARNAIZ, A. Improving aircraft maintenance with innovative prognostics and health management techniques - case of study: brake wear degradation. In: *2nd International Conference on Agents and Artificial Intelligence*. [S.l.]: Springer, 2010. p. 568–575.
- FEURER, M. et al. Efficient and robust automated machine learning. In: CORTES, C. et al. (Ed.). *Advances in Neural Information Processing Systems*. [S.l.]: Neural Information Processing Systems, 2015.
- FRIEDMAN, J. H. Stochastic gradient boosting. In: *Computational Statistics & Data Analysis*. [S.l.]: Elsevier, 2002. v. 38, n. 4, p. 367–378.
- GAN, C. L. Prognostics and health management of electronics: fundamentals, machine learning, and the internet of things. In: *Life Cycle Reliability and Safety Engineering*. [S.l.]: Springer, 2020.
- HAVERDINGS, H.; CHAN, P. W. Quick access recorder data analysis software for windshear and turbulence studies. *Journal of Aircraft*, v. 47, n. 4, p. 1443–1447, August 2010.
- IATA. *International Air Transport Association*. [S.l.], 2020.
- JENNIONS, I. K. Prognostics. In: *Integrated vehicle health management: the technology*. Warrendale, PA: SAE International, 2013. cap. 4, p. 49–69.
- KNOTTS, R. M. H. Civil aircraft maintenance and support fault diagnosis from a business perspective. *Journal of quality in maintenance engineering*, MCB UP Ltd, v. 5, n. 4, p. 335–348, 1999.
- KUMAR, U. D.; CROCKER, J.; KNEZEVIC, J. Evolutionary maintenance for aircraft engines. In: *Annual Reliability and Maintainability Symposium*. [S.l.]: IEEE, 1999. p. 62–68.
- LACAILLE, J. et al. Automatic indexation of turbofan data to identify anomalous behaviors. In: *Proceedings of the Annual Conference of the PHM Society*. [S.l.: s.n.], 2019. v. 11, n. 1.
- LANGTON, R. et al. *Aircraft Fuel Systems*. 1st. ed. Chichester, UK: John Wiley & Sons, 2009.
- LOMBARDO, D. *Aircraft systems*. [S.l.]: McGraw Hill Professional, 1999.
- LUO, B. et al. Research on condition-based maintenance for airborne equipments. In: WANG, J. (Ed.). *Symposium on Aviation Maintenance and Management*. [S.l.]: Springer, 2014. v. 2, p. 175–180.
- LV, Z. et al. Prognostics health management of condition-based maintenance for aircraft engine systems. In: *IEEE Conference on Prognostics and Health Management*. [S.l.]: IEEE, 2015. p. 1–6.

- MANZINI, R. et al. *Maintenance for industrial systems*. [S.l.]: Springer Science & Business Media, 2009.
- MARSLAND, S. *Machine learning: an algorithmic perspective*. 2nd. ed. Boca Raton, FL: CRC Press, 2015.
- MCLEAN, D. *Automatic flight control systems*. [S.l.]: Prentice Hall, 1990.
- MOBLEY, R. K. *An introduction to predictive maintenance*. 2nd. ed. Woburn, MA: Elsevier, 2002.
- MOIR, I.; SEABRIDGE, A. *Aircraft systems: mechanical, electrical, and avionics subsystems integration*. 3rd. ed. Hoboken, NJ: John Wiley & Sons, 2011.
- NIU, G. Overview of data-driven phm. In: *Data-driven technology for engineering systems health management: design approach, feature construction, fault diagnosis, prognosis, fusion and decisions*. Singapore: Springer, 2017. cap. 3, p. 35–48.
- OLSON, R. S.; MOORE, J. H. TPOT: A tree-based pipeline optimization tool for automating machine learning: Methods, systems and challenges. In: HUTTER LARS KOTTHOFF, J. V. F. (Ed.). *Automated Machine Learning*. [S.l.]: Springer, 2019. cap. 8, p. 151–160.
- OLSON, R. S. et al. Automating biomedical data science through tree-based pipeline optimization. In: SQUILLERO, G.; BURELLI, P. (Ed.). *Applications of Evolutionary Computation*. Porto, PT: Springer, 2016. p. 123–137.
- OSMANBHOY, M. Z.; RUNO, S.; MALLASCH, P. Development of fault detection and reporting for non-central maintenance aircraft. In: *IEEE Aerospace Conference*. [S.l.]: IEEE, 2010.
- PAULITSCH, M. ASCB - avionics standard communications bus. In: OBERMAISSER, R. (Ed.). *Time-Triggered Communication*. Boca Raton, FL: CRC Press, 2011. cap. 13, p. 323–330.
- PECHT, M. G.; KANG, M. Machine learning: diagnostics and prognostics. In: *Prognostics and Health Management of Electronics: Fundamentals, Machine Learning, and the Internet of Things*. 1st. ed. Hoboken, NJ: Wiley-IEEE Press, 2019. cap. 8, p. 163–191.
- SAMARANAYAKE, P.; KIRIDENA, S. Aircraft maintenance planning and scheduling: an integrated framework. *Journal of Quality in Maintenance Engineering*, v. 18, n. 4, p. 432–453, October 2012.
- SAMUEL, A. L. Some studies in machine learning using the game of checkers. *Journal of research and development, IBM*, v. 3, n. 3, p. 210–229, July 1959.
- SANO, H. H.; MALERE, J. P. P.; BERTON, L. Single and multiple failures diagnostics of pneumatic valves using machine learning. In: *Proceedings of 16th National Meeting on Artificial and Computational Intelligence*. Porto Alegre, RS, Brasil: Sociedade Brasileira de Computação, 2020.

TOOLEY, M. *Aircraft digital electronic and computer systems: principles, operation and maintenance*. 1st. ed. [S.l.]: Butterworth Heinemann, 2007.

VIANNA, W. O. L.; MALERE, J. P. P. An overview of the prognostics and health monitoring aspects in the aeronautical industry. In: *Health Management of Energy Systems Workshop*. [S.l.: s.n.], 2015. p. 29–31.

VIANNA, W. O. L.; YONEYAMA, T. Predictive maintenance optimization for aircraft redundant systems subjected to multiple wear profiles. *IEEE Systems Journal*, IEEE, v. 12, n. 2, p. 1170–1181, June 2018.

YABSLEY, A.; IBRAHIM, Y. Study on maintenance contribution to life cycle costs: aircraft auxiliary power unit example. In: *IEEE International Conference on Industrial Technology*. [S.l.]: IEEE, 2008. p. 1–6.

ZHANG, J.; ZHANG, P. *Time series analysis methods and applications for flight data*. 1st. ed. Beijing, CN: Springer, 2017.

ZHOU, Z. H. Three perspectives of data mining. In: *Artificial Intelligence*. [S.l.]: Elsevier, 2003. v. 143, n. 1, p. 139–146.

APÊNDICE A - Algoritmo *Gradient Boosting*

O Algoritmo 1 resume o procedimento completo de execução do algoritmo *Gradient Boosting* com árvores de decisão.

Algoritmo 1: Algoritmo de Friedman

1 Entradas:

2 Dados de entrada $(\mathbf{x}_i, \mathbf{y}_i)$

3 Número de iterações M

4 Escolha da função de perda $\psi(\mathbf{y}, \mathbf{F}(\mathbf{x}))$

5 Escolha do modelo do aluno base $\mathbf{h}_m(\mathbf{x})$

6 Taxa de aprendizado τ

7 Processamento:

8 Inicialize o modelo com um valor constante: $\mathbf{F}_0(\mathbf{x}) = \arg \min_{\gamma} \sum_{i=1}^n \psi(\mathbf{y}_i, \gamma)$

9 Para $m = 1$ até M faça

10 Calcular o erro residual: $\mathbf{e}_{r_{i,m}} = - \left[\frac{\partial \psi(\mathbf{y}_i, \mathbf{F}(\mathbf{x}_i))}{\partial \mathbf{F}(\mathbf{x}_i)} \right]_{\mathbf{F}(\mathbf{x}) = \mathbf{F}_{(m-1)}(\mathbf{x})}$

11 Ajustar a função de aprendizado $\mathbf{h}_m(\mathbf{x})$ para $\{\mathbf{R}_{jm}\}_{j=1}^{J_m}$ nó terminal da árvore.

12 Estimar o valor de cada região:

$$\gamma_{jm} = \underset{\gamma}{\operatorname{argmin}} \sum_{\mathbf{x}_i \in \mathbf{R}_{jm}} \psi[\mathbf{y}_i, \mathbf{F}_{m-1}(\mathbf{x}_i) + \gamma]$$

13 Atualizar o modelo: $\mathbf{F}_m(\mathbf{x}) = \mathbf{F}_{m-1} + \tau \gamma_{jm} \mathbf{1}(\mathbf{x} \in \mathbf{R}_{jm})$

14 fim

15 Saída:

16 $\mathbf{F}_x = \mathbf{F}_M(\mathbf{x})$

**APÊNDICE B – Comparação entre os casos executados e modelos de
aprendizado de máquina.**

Na Tabela 20 são apresentados os resultados dos modelos de aprendizado de máquina em relação aos casos executados e seus respectivos valores de taxa de acerto média (\bar{x}) e desvio padrão (s).

Tabela 20 – Comparativo entre os modelos de aprendizado de máquina.

Casos executados	Taxa de acerto	Modelos de aprendizado de máquina		
		<i>Gradient Boosting</i>	<i>K - Neighbors</i>	<i>Random Forest</i>
Caso 1(a)	\bar{x}	40,01%	38,35%	39,69%
	s	4,94%	5,05%	5,23%
Caso 1(b)	\bar{x}	38,68%	36,80%	39,36%
	s	4,09%	4,55%	3,40%
Caso 2	\bar{x}	61,75%	57,75%	58,86%
	σ	3,99%	2,73%	2,48%
Caso 3	\bar{x}	57,86%	40,01%	59,42%
	s	7,62%	3,40%	4,25%
Caso 4	\bar{x}	60,08%	54,51%	58,18%
	s	4,25%	4,53%	4,87%
Caso 5	\bar{x}	59,63%	39,34%	58,41%
	s	3,79%	3,35%	4,97%
Caso 6	\bar{x}	64,65%	39,68%	64,99%
	s	5,89%	3,42%	4,32%