

FILIPE HENRIQUE DA COSTA CRUZ

***Health Monitoring* para Manutenção Preditiva em Sistemas de Ar em Aeronaves**

Guaratinguetá - SP

2021

Filipe Henrique da Costa Cruz

***Health Monitoring* para Manutenção Preditiva em Sistemas de Ar em Aeronaves**

Trabalho de Graduação apresentado ao Conselho de Curso de Graduação em Engenharia Mecânica da Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, como parte dos requisitos para obtenção do diploma de Graduação em Engenharia Mecânica

Orientadora: Prof^a. Dra. Eliana Vieira Canettieri
Coorientador: Alan Ferreirós

Guaratinguetá - SP

2021

C957h	Cruz, Filipe Henrique da Costa “Health Monitoring” para manutenção preditiva em sistemas de ar em aeronaves / Filipe Henrique da Costa Cruz – Guaratinguetá, 2021. 71 f : il. Bibliografia: f. 69-71 Trabalho de Graduação em Engenharia Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2021. Orientadora: Prof^ª. Dr^ª. Eliana Vieira Canettieri Coorientador: Alan Ferreirós 1. Aeronaves - Manutenção. 2. Indústria Aeroespacial. 3. Inteligência artificial. I. Título. CDU 629.733
-------	--

Luciana Máximo

Bibliotecária CRB-8/3595

FILIPPE HENRIQUE DA COSTA CRUZ

ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO
PARTE DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE
“ENGENHARIA MECÂNICA”

APROVADO EM SUA FORMA FINAL PELO CONSELHO DE CURSO DE
GRADUAÇÃO EM ENGENHARIA MECÂNICA



Prof. Dr. CELSO EDUARDO TUNA
Coordenador

BANCA EXAMINADORA:



Prof. Dra. Eliana Vieira Canettieri
Orientador/UNESP-FEG



Prof. Dr. Thiago Averaldo Bimestre
UNESP-FEG



Alan Ferreiros
Membro Externo

Fevereiro 2021

DADOS CURRICULARES

FILIPPE HENRIQUE DA COSTA CRUZ

NASCIMENTO	01.08.1996 – Alfenas/ MG
FILIAÇÃO	Paulo Henrique da Cruz Marilsa Santos da Costa
2015/2020	Curso de graduação Engenharia mecânica – Faculdade de Engenharia do Campus de Guaratinguetá da Universidade Estadual Paulista - UNESP

Aos meus pais, minha irmã, e minha
companheira pelo amor e apoio
incondicionais.

AGRADECIMENTOS

Em primeiro lugar, agradeço a meus pais, Paulo e Marilsa, que sempre me apoiaram, incentivaram e investiram em minha formação;

a minha irmã, Carolina, e minha namorada, Yasmin, por todos os momentos compartilhados, ajuda direta ou indireta e conselhos dados no decorrer da caminhada acadêmica;

aos meus amigos, Marcus, Matheus e Leonardo, sem os quais a sanidade seria difícil de manter, pela companhia e companheirismo nos momentos de estudos e de lazer;

aos amigos da república RSCC, com os quais passei a maior parte do curso;

à professora doutora Eliana Canettieri, por orientar este trabalho, prestando todo o suporte necessário;

ao coorientador deste trabalho e engenheiro atuante no setor aeronáutico, Alan Ferreirós, cujo conhecimento, auxílio e empenho tornaram esse estudo possível;

aos funcionários e professores da Faculdade de Engenharia de Guaratinguetá, pelos serviços prestados com excelência e manutenção da qualidade do ensino superior público do estado de São Paulo e do Brasil.

“Ciência é muito mais uma maneira de pensar do
que um corpo de conhecimentos.”

Carl Sagan

RESUMO

Nas últimas décadas, a indústria da aviação cresceu aceleradamente em âmbito mundial, conectando países, culturas e pessoas. Um grande desafio enfrentado pelo setor é manter-se eficiente e rentável frente aos custos de operação e consequente margem de lucro reduzida. Dentre os custos mais significativos para as linhas aéreas, destacam-se os associados a combustível, manutenção, depreciação e a folha de pagamento da tripulação. O gasto com manutenção é um dos que se pode controlar com a aplicação de estratégias e tecnologias para controle de estoque, logística, agendamento e, mais recentemente, previsão de falhas. Existem três tipos principais de manutenção: corretiva, preventiva e preditiva. A última consiste no monitoramento de um sistema ou componente específico através de parâmetros gravados por sensores, a fim de detectar um padrão de falha, possibilitando a previsão. Esta prática pode reduzir os custos de manutenção pela otimização do controle logístico de peças e maior disponibilidade de informação para tomada de decisão, evitando falhas inesperadas e diminuindo o tempo de AOG (*Aircraft On Ground*). Este trabalho apresenta o monitoramento da válvula de corte e reguladora de pressão do sistema de ar condicionado aeronáutico com dados descaracterizados para aplicação de manutenção preditiva, utilizando técnicas de predição estatística e inteligência artificial. Os dados foram obtidos a partir da descaracterização de dados reais a fim de manter a verossimilhança com o caso real, porém garantindo a confidencialidade da informação original. Os procedimentos computacionais relativos ao tratamento dos dados, *data mining* e *machine learning* foram desenvolvidos com o uso da linguagem Python 3. Os resultados obtidos demonstram a redução de 12,8% no custo por hora de voo a partir da aplicação da manutenção preditiva, com possibilidade de expansão até 63,8% considerando os valores estimados de custo de troca e cancelamento de voos.

PALAVRAS-CHAVE: Manutenção Preditiva. *Machine Learning*. Indústria aeroespacial. Custo de Manutenção. *Data Science*. *Data Mining*.

ABSTRACT

In the last decades, the aviation industry grew rapidly worldwide, connecting different countries, cultures, and peoples. A major challenge faced by this industry is improving its efficiency and profits in spite of the operational costs and the resulting low profit margin. Among the most significant costs for airlines, one can highlight those associated with fuel, maintenance, depreciation and crew payroll. Maintenance expenses are possible to be managed by applying strategies and technologies for inventory control, logistics, scheduling and, more recently, failure prediction. There are three main types of maintenance: corrective, preventive, and predictive. The latter consists in monitoring a system or specific component using the parameters recorded by sensors to detect a failure pattern, thus enabling predictions. This procedure can lower maintenance costs by optimizing parts management, enhancing decision-making, preventing unexpected failures, and reducing AOG time. This paper presents the results of monitoring the recorded data from the pressure regulating and shut off valve of the air conditioning system of multiple aircraft for predictive maintenance, using statistical prediction and artificial intelligence techniques. The data for the study was collected from real aircraft and then anonymized and treated to maintain the real case system behavior while guaranteeing its confidentiality at the same time. The computational procedures related to data treatment, data mining and machine learning were developed using Python 3 programming language. The results of applying predictive maintenance in this study showed a 12,8% reduction of the cost per flight hour, which may increase up to 63,8% considering the estimated costs for valve replacement and flight cancellation.

KEYWORDS: Predictive Maintenance. Machine Learning. Aerospace Industry. Maintenance Cost. Data Science. Data Mining.

LISTA DE ILUSTRAÇÕES

Figura 1 – Perda de receita e aumento de custo devido a falhas não esperadas	13
Figura 2 – Comparação entre os principais tipos de manutenção	14
Quadro 1 – Prós e contras dos tipos de manutenção citados	15
Figura 3 – Displays com indicações diversas no cockpit de um Embraer E195-E2	17
Figura 4 – Crescimento anual do RPK da indústria aeronáutica vs. PIB global	19
Figura 5 – Esquema típico do sistema de sangria de ar quente de motores turbofan	21
Figura 6 – Diagramas T-S e P-V do ciclo termodinâmico ideal de Brayton	22
Figura 7 – Comportamento da pressão da cabine e atmosférica em grandes altitudes	23
Figura 8 – Fluxograma para aplicação eficaz de <i>machine learning</i>	24
Quadro 2 – Lista de parâmetros utilizados	26
Figura 9 – Metodologia aplicada para o desenvolvimento da análise	28
Figura 10 – Exemplo de gráfico boxplot para visualização de dados	30
Figura 11 – Redução dimensional propiciada pela aplicação de PCA.	32
Figura 12 – Exemplo fictício de classificador DTC aplicado a diagnósticos médicos	35
Figura 13 – Formato característico da função sigmoide.....	36
Figura 14 – Aplicação da descida gradiente na função genérica f	38
Figura 15 – Rede neural com cinco entradas, duas camadas de perceptrons e uma saída	39
Quadro 3 – Estrutura de hipóteses e premissas adotadas	41
Quadro 4 – Formato utilizado para identificação e rotulagem dos dados.	42
Figura 16 – Primeiras linhas com alguns parâmetros da ABT	44
Figura 17 – Análise de contiguidade e completude dos dados.....	46
Figura 18 – Histogramas da análise univariada para cada parâmetro	49
Figura 19 – Matriz de correlação das variáveis para análise bivariada	50
Figura 20 – Gráfico <i>boxplot</i> de acordo com o lado, categoria de alvo e parâmetro.....	52
Figura 21 – Resultados do tratamento de outliers na base de dados	54
Figura 22 – Análise de clusters na base de dados com 4 e 5 agrupamentos	55
Figura 23 – Resultados obtidos na análise de custos de manutenção.....	60
Figura 24 – Comportamento dos modelos para a aeronave 10.....	62
Figura 25 – Comportamento dos modelos para a aeronave 4.....	63
Figura 26 – Comportamento dos modelos para a aeronave 6.....	64

LISTA DE TABELAS

Tabela 1 – Avaliação de completude por aeronave	45
Tabela 2 – Distribuição da base original para treino e teste	57
Tabela 3 – Matriz de Confusão para cada modelo.....	57
Tabela 4 – Limites mínimos de probabilidade para previsões.....	59

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ABT	<i>Analytical Base Table</i>
AMS	<i>Air Management System</i>
ANAC	Agência Nacional de Aviação Civil
AOG	<i>Aircraft on ground</i>
CAS	<i>Crew-Alerting System</i>
Csv	<i>Comma-separated values</i> (formato de arquivo)
DTC	Árvore de Decisão (<i>Decision Tree Classifier</i>)
ECS	<i>Environmental Control System</i>
FAA	<i>Federal Aviation Administration</i>
GBC	<i>Gradient Boosting Classifier</i>
GNB	Gaussian Naïve Bayes
ICAO	<i>International Civil Aviation Organization</i>
IoT	<i>Internet of Things</i> (Internet das Coisas)
MLPC	<i>Multi-Layer Perceptron Classifier</i>
MTBUR	<i>Mean Time Between Unscheduled Removal</i>
OEM	<i>Original Equipment Manufacturer</i>
PdM	Manutenção Preditiva (<i>Predictive Maintenance</i>)
QAR	Quick Access Recorder (Gravador de rápido acesso)
RL	Regressão Logística
RPK	<i>Revenue Passengers Kilometers</i>

SUMÁRIO


1	INTRODUÇÃO.....	13
1.1	CONTEXTUALIZAÇÃO HISTÓRICA	13
1.2	ASPECTOS FACILITADORES NO SETOR AERONÁUTICO	16
1.3	OBJETIVOS	18
1.4	JUSTIFICATIVAS	18
1.5	ESTRUTURA DO TRABALHO	20
2	CONCEITOS E FUNDAMENTAÇÃO TEÓRICA	20
2.1	SISTEMA DE ADMINISTRAÇÃO DE AR.....	20
2.2	PROCEDIMENTOS COMPUTACIONAIS	23
3	METODOLOGIA APLICADA.....	25
3.1	OBTENÇÃO DE DADOS.....	25
3.2	FERRAMENTAS UTILIZADAS	27
3.3	TRATAMENTO E ANÁLISE DE DADOS	28
3.3.1	Exploração dos Dados	29
3.3.2	Tratamento de Dados	29
3.3.3	Modelagem	32
3.3.4	Avaliação dos Modelos	40
3.3.5	Avaliação de Custos de Manutenção.....	41
4	RESULTADOS E DISCUSSÃO	42
4.1	OBTENÇÃO E ORGANIZAÇÃO DA INFORMAÇÃO	42
4.2	ANÁLISE EXPLORATÓRIA.....	46
4.2.1	Pre-processamento dos voos	46
4.2.2	Análises Univariada e Bivariada	48
4.3	TRATAMENTO DE DADOS E ANÁLISE DE CLUSTERS	52
4.3.1	Outliers	52
4.3.2	Normalização e Análise de <i>Clusters</i>.....	54
4.4	APLICAÇÃO DE MODELOS E ALGORITMOS	56
4.5	ANÁLISE DO CUSTO DE MANUTENÇÃO.....	58
4.6	AVALIAÇÃO GRÁFICA DOS MODELOS DE PREDIÇÃO.....	61
5	CONCLUSÃO	66
	REFERÊNCIAS.....	67

1. INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO HISTÓRICA

Definida pela ABNT (NBR 5462/1994) como o “conjunto de ações técnicas e administrativas para manter ou realocar um equipamento ou maquinário”, a manutenção exerce papel fundamental na indústria moderna. Os benefícios da gestão eficaz da manutenção vão desde o aumento da vida útil de componentes à maior segurança operacional e redução de custos com remoções e falhas não esperadas, que podem causar perda de receita, como apresentado na Figura 1. A partir do desenvolvimento tecnológico e dos aprimoramentos na gestão de custos e processos industriais, o papel da manutenção na indústria mudou ao longo do tempo. Na época da invenção dos motores a vapor, durante primeira revolução industrial (século XVIII), a manutenção era aplicada principalmente de forma reativa, ou seja, apenas após a ocorrência de falhas (Christiansen, 2020). O equipamento falhado e mesmo a linha de produção poderiam ficar fora de operação para que fossem realizados os reparos necessários. Dessa forma, além do custo de mão de obra na correção da falha, haveria gasto adicional por perda de produtividade.

Figura 1 – Perda de receita e aumento de custos devido a falhas não esperadas.




Fonte: Autor

O século XX, particularmente, foi um período fértil para a inovação de paradigmas relativos à manufatura industrial. Com as grandes guerras veio a noção de que o sucesso e produtividade das fábricas seriam fatores decisivos para estratégias internacionais bem-sucedidas no contexto geopolítico. O toyotismo de Taiichi Ohno, influenciado pelas ideias de Henry Ford, construiu as bases da manufatura enxuta (*lean manufacturing*, em inglês), filosofia presente em larga escala na cultura industrial atual. A metodologia *lean* pode ser resumida como práticas para a eliminação de desperdícios e foco em melhoria contínua (Smith & Hawkins, 2004). Nesse contexto, o emprego apenas da manutenção corretiva torna-se insuficiente para garantir a máxima eficiência, produtividade e redução de custos. A cada revolução industrial, novas formas de manutenção foram introduzidas, evoluindo de uma atividade secundária, na indústria 1.0, para uma fonte direta de aumento da eficiência e lucratividade (Poór *et al.*, 2019).

Além da manutenção corretiva, duas outras estratégias principais de manutenção são aplicadas na indústria: manutenção preventiva e preditiva. A primeira baseia-se na inspeção de equipamentos e execução de tarefas programadas proativamente ou em intervalos definidos para prevenir e detectar a ocorrência de falhas. Caso a condição operacional do equipamento inspecionado esteja dentro da tolerância admitida, apenas a inspeção é realizada, entretanto não haveria real necessidade de parada do equipamento naquele momento e mão de obra seria utilizada antes do necessário. (Smith & Hinchcliffe, 2004).

Figura 2 – Comparação entre os principais tipos de manutenção.



Fonte: Autor

A manutenção preditiva (PdM), em contrapartida, tem como objetivo a predição da falha antes que esta ocorra. As previsões são feitas a partir de modelos estatísticos ou algoritmos de aprendizagem de máquina (*machine learning*) aplicados a bases de dados históricos, prevendo padrões de comportamento e tendências (Hashemian, 2011). A PdM está ligada à estratégia chamada de manutenção baseada na condição (em inglês, *condition-based maintenance* – CBM), que relaciona ações preditivas a menores consequências de falhas e redução de custos ao substituir, quando possível, as operações programadas de manutenção preventiva (Zhu, 2015; Hashemian, 2011). A aplicação da PdM aliada aos métodos tradicionais resulta em aumentos significativos de eficiência, porém necessita da disponibilidade e tratamento criterioso dos dados utilizados e, frequentemente, times multidisciplinares envolvidos para obter a informação correta. (Welte, 2020)

Quadro 1 – Prós e contras dos tipos de manutenção citados

Tipo de Manutenção	Descrição	Prós	Contras
Corretiva	Conserto após ocorrência de falha	Baixo custo de implementação	Pode elevar o custo de reparo e aumenta o tempo de indisponibilidade da máquina
Preventiva	Manutenção em intervalos programados	Pode prevenir a ocorrência de falhas sem necessitar de pessoal altamente especializado	Pode levar a paradas desnecessárias
Preditiva	Baseada na condição do equipamento a partir de dados	Menor indisponibilidade de equipamentos, melhor determinação de causa da falha, melhor controle logístico de peças	Requer profissionais treinados e recursos para realizar o monitoramento

Fonte: Autor

As ferramentas necessárias para o desenvolvimento da análise e tratamento de dados na PdM têm sido desenvolvidas e aprimoradas nos últimos anos, motivo pelo qual diferentes setores buscam

aplicar esta tecnologia (Dalzochio, 2020). Desde soluções de mobilidade urbana, como veículos autônomos e controle de tráfego aéreo, até o desenvolvimento de modelos descritivos e preditivos para pandemias mundiais, a tecnologia na indústria 4.0 tem transformado paradigmas para a resolução de problemas. Com a introdução de ferramentas inovadoras em processos industriais e a criação de áreas de pesquisa na engenharia, como a ciência dos materiais, computação e ciência de dados, o papel da manutenção foi estendido.

A aplicação de acelerômetros, sensores de pressão e temperatura, complexas malhas de controle em projetos e a conectividade introduzida pelo conceito IoT (*Internet of Things*) viabilizou a maior disponibilidade de dados sobre as condições de funcionamento das máquinas.

1.2 ASPECTOS FACILITADORES NO SETOR AERONÁUTICO

Dispositivos como sensores e computadores integrados são utilizados em larga escala na indústria aeroespacial moderna. A partir da década de 1960, a introdução dessa tecnologia no setor se tornou requisito para certificação na aviação civil (ATSB, 2014). Dentre os regulamentos oficiais da FAA (*Federal Aviation Administration*), órgão regulador para certificação e operação aérea nos Estados Unidos, encontra-se o seguinte trecho no regulamento para aeronaves com vinte ou mais passageiros, publicado em 1988:

“Após o dia 11 de outubro de 1991, nenhuma pessoa está permitida a operar aeronave de grande porte certificada antes do dia primeiro de outubro de 1969, para operações acima de 25 mil pés de altitude, nem avião movido a mais de um motor com turbina certificado antes do dia primeiro de outubro de 1969, a menos que a aeronave esteja equipada com um ou mais gravadores de voo aprovados, que utilize método digital de gravação e armazenamento de dados com método rápido para recuperação de dados do meio de armazenamento.” (Tradução nossa - FAA, 1988)

No setor aeronáutico, a disponibilidade de dados está diretamente ligada à segurança operacional. O requisito da FAA localizado na seção 121.344 dos regulamentos federais de aviação descreve quais são os parâmetros mínimos a serem gravados para que uma aeronave tenha

permissão para operar. A lista, que inclui desde a posição geográfica e hora exata da gravação até informações de altitude e atitude do avião, totaliza ao menos 91 parâmetros na versão consultada (FAA, 2009). O Regulamento Brasileiro de Aviação Civil cita requisitos similares para gravadores de voo (ANAC, 2014). Os parâmetros requeridos são definidos tendo em vista a informação mínima necessária para se entender o comportamento da aeronave em eventos com perda total, o que ajuda a evitar reincidências desses eventos.

Com relação ao funcionamento de aeronaves, as informações coletadas por sensores são utilizadas pelas leis de controle, indicação de atitude e altitude, lógica de mensagens CAS (*Crew Alerting System*), determinação de fase de voo, controle do envelope de performance em todos os graus de liberdade da aeronave, entre outros. Com relação ao controle do envelope de voo, por exemplo, informações de velocidade relativa do ar e ângulo de ataque, que diz respeito à rotação da aeronave em torno do eixo que passa pelas asas (ângulo de *pitch*), são utilizadas para evitar situações de estol (perda de sustentação aerodinâmica). Dado que os parâmetros gravados contêm informações como temperatura, pressão e vibração de sistemas da aeronave, podem ser utilizados também para monitorar o comportamento e desempenho de componentes.

Figura 3 – Displays com indicações diversas no cockpit de um Embraer E195-E2



Fonte: AERO MAGAZINE (2019).

1.3 OBJETIVOS

O foco deste trabalho é a avaliação qualitativa e financeira dos resultados de aplicação da PdM em um estudo de caso do setor aeronáutico, especificamente focado na válvula reguladora de pressão e de corte do sistema de controle do ambiente (Environmental Control System - ECS) em aeronaves equipadas com motores do tipo *turbofan* para a predição de falhas. A análise qualitativa aborda o comportamento da válvula reguladora de pressão até o momento da falha para determinação de padrões de comportamento do sistema, avaliados através de ferramentas estatísticas computacionais, possibilitando predição com maior confiabilidade. A partir dos resultados de cada algoritmo utilizado, a análise de custo é desenvolvida como forma de avaliação dos ganhos obtidos pela aplicação dos modelos frente à situação original (*baseline*).

1.4 JUSTIFICATIVAS


Entre 2018 e 2019, o setor aeronáutico transportou, em média, 12,2 milhões de pessoas diariamente movimentando bilhões de dólares e conectando empresas, países e continentes através de viagens internacionais e viabilizando a mobilidade nacional aérea por meio de voos domésticos (ICAO, 2019). Dentre as diversas modalidades de transporte disponíveis atualmente, o setor conquistou seu espaço como o mais seguro, o que se deve aos esforços para o controle rigoroso da qualidade de componentes e peças, investimento em tecnologia e redundância de sistemas aeronáuticos, treinamento de pessoal, certificação e fiscalização por parte de autoridades internacionais e investigação de acidentes (Stoop & Kahan, 2005). O alto padrão de segurança e qualidade necessário resulta em aumento de gastos, pois componentes e peças têm de atender a elevados requisitos, o que pode tornar, em última instância, a operação das aeronaves mais cara (Farooq et al., 2017 ; Koivu,2013)

A análise e o monitoramento de componentes individuais em sistemas integrados aumenta o entendimento que se tem dos modos de falhas e suas prováveis soluções ou formas de mitigação. A informação gravada por meio de sensores pode ser utilizada no contexto da manutenção para monitorar a saúde de peças e sistemas, possibilitando a previsão de falhas e redução de custo operacional (Yan et al., 2017). A conversão de dados brutos em informação útil aumenta a eficiência e reduz o tempo de resposta para tomada de decisão. Para a indústria aeroespacial, em

particular, sujeita ao mesmo tempo a baixas margens de lucro e às flutuações de preços internacionais de combustível e outros insumos, a redução de custo proporcionada pela gestão inteligente da manutenção aumenta a competitividade internacional (Gonzales et. al. 2016).

A métrica comumente utilizada no setor para medir a demanda é o RPK (*Revenue Passenger-Kilometers* – passageiros-quilômetros pagos transportados, em português), que é calculada a partir da multiplicação do número de passageiros pagantes pela distância percorrida. Verifica-se pela Figura 4 a relação entre o comportamento do indicador RPK na indústria aeronáutica com o crescimento do PIB mundial. Eventos que afetaram a economia mundial como a recessão europeia no início da década de 90, os atentados de 2001, a pandemia de SARS em 2003 e a crise de 2008 são claramente identificados na figura, evidenciando a influência direta na demanda do setor aeroespacial.

Figura 4 – Crescimento anual do RPK da indústria aeronáutica vs. PIB global



Fonte: IATA (2018).

O levantamento preliminar sobre os efeitos da pandemia causada pelo vírus COVID-19 em 2020 feito pela ICAO (*International Civil Aviation Organization*) apontou a redução de aproximadamente 52% da quantidade total de assentos oferecidos pelas linhas aéreas, o que corresponde à redução de aproximadamente 3 bilhões de passageiros e resultantes perdas potenciais

brutas de até USD 400 bilhões (ICAO, 2020). A queda abrupta de receita aumenta a relevância de aplicações para reduções de custo como a manutenção preditiva. Um levantamento realizado em 2019 pela Delta Airlines sobre a implementação de manutenção preditiva verificou a redução de 98% dos cancelamentos das operações entre 2010 e 2018 (DELTA AIRLINES, 2019). Uma estimativa conservadora da ICF International feita em 2018 concluiu que a aplicação de *health monitoring* e PdM poderia resultar na poupança de USD 3 bilhões anualmente para as linhas aéreas (ICF, 2018).

1.5 ESTRUTURA DO TRABALHO

Este trabalho está estruturado quatro outros capítulos além desta introdução. No Capítulo 2, a seguir, são apresentados os conceitos utilizados, bem como a fundamentação teórica que motivou o início deste estudo. Este capítulo também apresenta maiores detalhes do funcionamento do sistema analisado, bem como de seus sistemas de interface. Além disso, alguns dos conceitos da análise computacional empregada são apresentados.

No Capítulo 3, é delineada a metodologia aplicada na obtenção e tratamento de dados para aplicação dos algoritmos de aprendizagem de máquina. Este processo é necessário e importante para garantir o funcionamento dos modelos e algoritmos computacionais, que requerem a padronização dos dados analisados.

O Capítulo 4 é dedicado a apresentar textual e visualmente os resultados obtidos a partir da aplicação da base teórica e metodologia propostas nos capítulos anteriores. Por fim, o Capítulo 5 aborda as conclusões obtidas no decorrer e finalização do presente trabalho.


2 CONCEITOS E FUNDAMENTAÇÃO TEÓRICA

2.1 SISTEMA DE ADMINISTRAÇÃO DE AR

O ECS recebe ar quente e pressurizado (ar de sangria, também chamado de *bleed*) sangrado do compressor instalado nos motores da aeronave. O ar segue tipicamente para a máquina de ciclo de ar para trocar calor com o ar ambiente e, em seguida, para a ventilação e pressurização da cabine. A pressurização da aeronave é necessária principalmente devido às condições do ambiente na

altitude máxima padrão para operação de voos comerciais, que varia entre 30 e 41 mil pés (9-12 km), onde o ar é rarefeito e a pressão parcial de oxigênio impossibilita a respiração. Outro requisito aborda a carga mínima de ventilação, correspondente a 250g de ar fresco a ser disponibilizada para cada passageiro por minuto (FAA, 1996; ANAC, 2014). A vazão de ar deve também garantir o conforto térmico e a ventilação das baias eletrônicas da aeronave. Um esquema genérico do sistema de sangria dos motores é mostrado na Figura 5.

Figura 5 – Esquema típico do sistema de sangria de ar quente de motores *turbofan*.




Fonte: ASHRAE (2019).

Os motores da aeronave são o principal componente do sistema de propulsão, construídos com base no ciclo termodinâmico de Brayton aberto, descrito na Figura 6. O ar é ejetado a altas velocidades, fornecendo a tração para que o avião atinja a velocidade necessária para decolar e sustentar voo. O motor do tipo turbofan tem seu funcionamento baseado na propulsão gerada principalmente pelo “fan” (corresponde a 80% da tração), cujo eixo rotaciona devido à potência gerada pela turbina após a queima de combustível na câmara de combustão (Sforza, 2014).

O trabalho gerado pela turbina na expansão dos gases de exaustão também aciona o compressor, que aumenta a massa específica e a temperatura do ar aspirado para o núcleo do motor antes da combustão em um processo isentrópico (Cantwell, 2019). Como mostrado na Figura 5,

parte do ar quente comprimido é extraída de estágios diferentes do compressor e direcionada para a utilização do ECS e sistema anti-gelo. O estágio para tomada de ar geralmente varia de acordo com a fase de voo para se adequar à demanda do sistema e minimizar a extração de potência em fases críticas como a decolagem caso os motores sejam a única fonte pneumática utilizada.


Figura 6 – Diagramas T-S e P-V do ciclo termodinâmico ideal de Brayton



Fonte: Adaptado de Spakovszky (2002).

Na altitude de cruzeiro (41.000 ft), aeronaves conseguem atingir maiores velocidades com menor consumo de combustível, o que reduz o custo de operação. Segundo determinado por requisito, a pressão das zonas habitadas na aeronave deve ser, no máximo, equivalente à altitude de 8 mil pés quando a aeronave estiver na maior altitude de operação sob condições normais (ASHRAE, 2019; ANAC, 2014), para garantir as condições de sobrevivência de passageiros e tripulantes, como mostrado na Figura 7a. Em caso de depressurização em altas altitudes, máscaras de oxigênio são disponibilizadas aos passageiros através dos painéis acima dos assentos, enquanto o procedimento padrão realizado pelos pilotos nesta situação é a redução imediata para menores altitudes. O gráfico na Figura 7b ilustra como a pressão atmosférica diminui de acordo com o aumento da altitude.

Figura 7 – Comportamento da pressão da cabine e atmosférica em grandes altitudes



(a) Altitude de cabine se mantém a 2400m (8 mil pés) devido à pressurização

(b) Redução da pressão atmosférica em grandes altitudes

Fonte: Autor

Através do controle de abertura ou modulação das válvulas do sistema, realiza-se o controle de pressão e temperatura nos dutos. Este processo consequentemente altera a vazão mássica da tomada de ar dos motores, que é definida pela demanda das packs de ar condicionado e pelo sistema anti-gelo, consumidores do sistema. Como a malha de controle envolvendo desde a extração de ar do motor até a pressurização da cabine precisa atender ao mesmo tempo a tolerância de pressão máxima dos dutos, vencer a perda de carga das packs de ar e atender às demandas dos consumidores, a válvula reguladora de pressão trabalha constantemente modulando sua abertura para garantir as condições necessárias no duto. No entanto, este esforço repetitivo pode resultar no desgaste de anéis de vedação e outros componentes da válvula e consequente redução da vida útil e degradação de performance do componente.

2.2 PROCEDIMENTOS COMPUTACIONAIS

Com base em dados históricos descaracterizados de gravações reais, busca-se determinar padrões e tendências de comportamento do sistema com a aplicação de ferramentas estatísticas e computacionais de *Data Science*, como *machine learning* (ML) e *data mining*. O método utilizado para a avaliação financeira consiste na análise do custo de manutenção estimado para as predições resultantes de cada algoritmo testado. Os algoritmos de ML, bem como o tratamento de dados, são desenvolvidos através da linguagem de programação Python 3 e bibliotecas como Pandas, Numpy e Scikit-Learn.

A aprendizagem de máquina, ou *machine learning*, pode ser entendida como algoritmos descritivos e/ou preditivos baseados em modelos matemáticos e estatísticos para reconhecimento ou classificação de padrões a partir de dados históricos (Alpayadin, 2010). Algoritmos de ML são utilizados em diversas áreas, como mercado financeiro, diagnósticos médicos, reconhecimento facial e vocal, classificação de e-mails contendo arquivos maliciosos, entre outros. A mineração de dados, ou *data mining*, é a aplicação de ML em grandes bancos de dados para geração de novas informações úteis, como associações, classificações e categorizações (*clustering*). Aplicações práticas comuns de algoritmos de ML e mineração de dados na indústria geral estão frequentemente ligados à estimativa do tempo de vida útil de máquinas e diagnóstico de falhas. (Chukwuekwe, 2016; Adhikari, 2018)

Figura 8 – Fluxograma para aplicação de *machine learning*



Fonte: Adaptado de Welte (2020).

3 METODOLOGIA APLICADA

3.1 OBTENÇÃO DE DADOS

Aviões comerciais modernos são equipados com módulos para gravação em altas taxas de amostragem de dados conhecidos como QAR (*Quick Access Recorder*, gravadores de rápido acesso, em português). Assim como as conhecidas caixas-pretas, as informações gravadas do QAR são provenientes de sensores de diversos sistemas da aeronave. Como o nome sugere, os dados gravados nesse módulo devem ser de fácil acesso, podendo ser obtidos por meio de conexões USB ou cartões de memória e são utilizados para a realização de investigações de falhas e análises de comportamento da aeronave e seus sistemas.

A obtenção da informação utilizada foi possível devido ao acesso a uma base restrita e anônima de dados reais com arquivos QAR contendo 64.106 voos e diversos parâmetros gravados de diferentes sistemas aeronáuticos. Dentre os parâmetros disponíveis, foram selecionados aqueles que têm relação direta ou indireta com o sistema de controle de ar, mais especificamente parâmetros ligados aos componentes mostrados na Figura 5. A seleção de parâmetros foi necessária principalmente devido à otimização dos processos computacionais realizados. A base completa compactada ocupa aproximadamente 260GB de memória de disco, porém pode ser reduzida através do procedimento de seleção, aumentando também a velocidade de processamento dos dados.

Alguns parâmetros indiretamente relacionados ao sistema foram selecionados para possibilitar o entendimento mínimo necessário sobre as condições operacionais, como a fase de voo. Como mostrado na Figura 7, existe variação das condições do ambiente de acordo com a altitude da aeronave, característica que pode influenciar no comportamento do sistema de gerenciamento do ar. Além disso, a demanda dos consumidores do sistema podem variar de acordo com as condições de operação. Baixas temperaturas em determinadas altitudes, por exemplo, podem fazer com que o sistema anti-gelo demande mais ar quente. Os parâmetros selecionados para análise são descritos no Quadro 2.

Quadro 2 – Lista de parâmetros utilizados

Parâmetro	Unidade/Formato Original
Altitude	ft
Data/Hora	mm/dd/aaaa hh:MM:ss
Pressão em linha	psig
Posição Booleana da válvula de alta pressão	0 – Fechada 1 – Aberta
Posição Booleana da válvula reguladora de pressão	0 – Fechada 1 – Aberta
Posição da manete de potência	Graus
Pressão de descarga do compressor	psia
Peso no trem de pouso	0 – Em voo 1 – Em solo
Utilização do sistema Anti-gelo	0 – Desligado 1 – Ligado

Fonte: Autor

Outros parâmetros disponíveis como a velocidade de rotação dos eixos do motor da aeronave, temperatura e vazão de ar para os consumidores foram desconsiderados para esta análise. O motivo para esta escolha foi evitar redundância ou colinearidade de parâmetros no modelo criado para o sistema. Outros parâmetros, como as correntes utilizadas pelos controladores das válvulas estavam indisponíveis. Este dado poderia fornecer informações relevantes sobre o esforço realizado sobre as válvulas.

A seleção de parâmetros mais relevantes visa manter a generalidade do modelo e evitar a colinearidade entre variáveis, minimizando este efeito que provavelmente enviesaria os modelos. Dentre os diversos componentes do sistema ECS, este estudo foca na falha da válvula reguladora de pressão, que pode apresentar diferentes modos de falha. Como a principal informação numérica diretamente ligada ao sistema considerado é a pressão da linha, espera-se que seja um parâmetro relevante para os algoritmos.

3.2 FERRAMENTAS UTILIZADAS


A linguagem de programação utilizada foi Python 3, escolhida devido às bibliotecas disponíveis para aplicações de *machine learning* e *data mining*, bem como à vasta documentação e bibliografia disponível online para consulta e aprendizado. Além de ter a sintaxe simples, a linguagem Python é comumente utilizada para este tipo de aplicação de acordo com a observação da literatura disponível. A biblioteca utilizada para *machine learning* é conhecida como *scikit-learn* e é equipada com módulos e algoritmos para aprendizado de máquina, além de funções úteis para classificação, agrupamento e regressão. Dentre as demais bibliotecas utilizadas, Pandas foi utilizada para manipulação de dados e aplicação de filtros; Matplotlib, Seaborn e Plotly para visualização de dados; Numpy e Scipy para manipulação matemática.

A plataforma de desenvolvimento escolhida foi o Jupyter Notebook, que é uma aplicação *open-source* gratuita, robusta e de fácil personalização. A ferramenta funciona como uma interface gráfica facilitadora e suporta mais de 40 linguagens de programação, além de possuir *plug-ins* úteis que auxiliam na customização e organização da análise de dados. Os scripts são dispostos em formato de células, o que facilita a realização de testes e correções individuais antes da execução final. A linguagem Python e a interface proporcionada pelo Jupyter demonstraram bom desempenho na execução dos scripts criados para a análise e alta estabilidade, considerando que algumas células levam tempo para concluir a execução.

3.3 TRATAMENTO E ANÁLISE DE DADOS

A aplicação de *machine learning* neste trabalho envolve um problema de classificação supervisionada e a metodologia empregada desde a aquisição dos dados até a etapa de avaliação do modelo final foi desenvolvida com base na literatura consultada e adaptada para esta aplicação em particular, conforme previamente esboçado na Figura 8 e melhor descrito na Figura 9. Na etapa de aquisição de dados, após a obtenção dos arquivos, foi aplicada a correlação entre os eventos disponíveis e as falhas da válvula reguladora de pressão que realmente ocorreram. Este processo visa criar um alvo – “*target*” – de predição para o modelo a ser construído. Dessa forma, será possível treiná-lo.

Figura 9 – Metodologia aplicada para o desenvolvimento da análise.



Fonte: Baseado em Adhikari (2018) e Welte (2020)

O tratamento preliminar dos dados brutos obtidos foi necessário para garantir a integridade da informação. Arquivos corrompidos e com informações inconsistentes ou incoerentes, como aqueles que apresentaram valores fora da faixa da ordem de grandeza esperada ou de tipos diferentes dos esperados (e.g. informações numéricas gravadas erroneamente como caracteres, por exemplo), foram descartados para evitar contaminação da base e enviesamento dos algoritmos. A informação de data e hora foi retificada em alguns casos em que a rotação dos motores apresentava variação excessiva, o que poderia prejudicar a análise.

3.3.1 Exploração dos dados

A etapa que segue a aquisição dos arquivos é a análise exploratória, em que se realiza o pré-processamento e as avaliações estatísticas necessárias para o processo seguinte. Os voos que apresentaram condições diferentes do esperado para uma operação padrão foram eliminados. Como exemplo, todos os arquivos contendo voos com altitude máxima inferior a 10 mil pés foram eliminados para evitar que quaisquer gravações anômalas sejam consideradas. A análise univariada é utilizada para descrever e resumir as dispersões e características de cada variável, enquanto a bivariada mostra a correlação de todos os parâmetros dois a dois. Ambas são procedimentos necessários e relevantes para garantir que não haja alta colinearidade entre os parâmetros. A primeira consiste na aplicação de histogramas e outros gráficos estatísticos e a segunda de uma matriz de correlação. Considerando três variáveis, por exemplo, P_1, P_2 e P_3 , a matriz de correlação de Pearson é ilustrada pelas expressões seguintes.

$$M_{\text{corr}} = \begin{bmatrix} r_{(P_1, P_1)} & r_{(P_1, P_2)} & r_{(P_1, P_3)} \\ r_{(P_2, P_1)} & r_{(P_2, P_2)} & r_{(P_2, P_3)} \\ r_{(P_3, P_1)} & r_{(P_3, P_2)} & r_{(P_3, P_3)} \end{bmatrix},$$

em que

$$r_{(p_j, p_k)} = \frac{\sum_{i=1}^n (p_{ji} - \bar{p}_j)(p_{ki} - \bar{p}_k)}{(n-1)s_{p_j}s_{p_k}} \quad (1)$$


As variáveis s_{p_j} e s_{p_k} na equação 1 são os desvios-padrões amostrais de P_j e P_k , respectivamente e a diagonal principal da matriz de correlação deve ser unitária, visto que cada variável é completamente correlacionada consigo mesma. Os demais valores da matriz mostram a correlação de cada variável com a outra. Entre dois parâmetros com alta colinearidade, um deve ser eliminado antes da aplicação do modelo para evitar que haja viés preditivo relacionado às mesmas.

3.3.2 Tratamento de dados

Com a informação colhida na análise exploratória, os dados podem ser tratados de forma mais específica e aprofundada através da análise de *outliers*. Os valores denominados de *outliers* são

aqueles discrepantes em uma série de valores e podem ser facilmente identificados através da aplicação de gráficos do tipo *boxplot*. Como mostrado na Figura 10, o gráfico *boxplot* permite a visualização da posição, dispersão, simetria e valores discrepantes de uma sequência de dados. Dependendo da característica do parâmetro, o tratamento de outliers pode incluir sua eliminação da série ou o ajuste para os limites inferior ou superior. A análise de valores nulos também é feita para caso alguma variável contenha valores com erros de gravação ou indisponíveis. Estes valores devem ser tratados, pois muitos modelos de predição têm seu funcionamento prejudicado quando estão presentes na série de dados.

Figura 10 – Exemplo de gráfico *boxplot* para visualização de dados




Fonte: Autor

A informação fornecida pelo gráfico de *boxplot* se assemelha àquela da curva normal. Entre o primeiro e terceiro quartis estão 50% dos dados e os limites inferior e superior são definidos a partir do valor entre quartis. Os pontos que ficam fora destes limites são identificados de forma diferente e chamados de *outliers*.

Outro processo destacado na etapa de tratamento da informação é o balanceamento da base de dados, que neste caso consiste em duplicar os eventos em que houve falha real da válvula reguladora de pressão até que a base esteja igualmente dividida entre os eventos comuns e os de falha. Caso esse processo não seja realizado, os algoritmos de aprendizagem de máquina entenderão que o sistema raramente falha, causando resultados falsos-negativos. Isso ocorre porque os eventos de falhas durante a operação ocorrem com baixa frequência. Existem outros métodos de balanceamento, como sortear valores aleatórios da categoria dominante, entretanto os dados utilizados seriam reduzidos drasticamente por este procedimento.

Alguns dos modelos de *machine learning* também requerem que os dados de entrada estejam normalizados, isto é, centrados no centro do eixo de coordenadas e desvio-padrão igual a 1. A partir desse procedimento, todos os parâmetros passam a compartilhar a mesma ordem de grandeza, independentemente dos valores anteriores. Entretanto a proporcionalidade interna dos dados é mantida. A normalização permite a aplicação dos métodos descritos a seguir, como *Kmeans* e a análise de componentes principais. Também facilita a interpretação dos coeficientes gerados pelos algoritmos, como a regressão logística.

A análise de agrupamentos (*clusters*) é feita através de um algoritmo chamado *Kmeans*, que agrupa os dados de acordo com a distância entre pontos. A visualização dos agrupamentos foi feita por meio do método PCA (*Principal Component Analysis* – Análise de Componentes Principais, em português), que permite entender a variância dos dados a partir da redução da dimensionalidade do conjunto de dados, algo semelhante à projeção dos pontos em duas ou três dimensões de modo a fornecer mais informações, como mostrado na Figura 11. Com a aplicação do PCA e do algoritmo de “*clusterização*”, a variabilidade dentro de cada grupo é reduzida, enquanto a variabilidade de elementos entre grupos é potencializada. Este procedimento também requer a normalização dos dados.



Fonte: Scholz (2006).

3.3.3 Modelagem

A etapa realizada a seguir é a preparação para a modelagem e a aplicação dos modelos de aprendizagem. A base de dados é, então, separada em duas, numa proporção que geralmente é definida como 60% e 40% ou 70% e 30% para treino e teste, respectivamente. A base de treino é utilizada para treinar os algoritmos e a base de testes é utilizada para verificar a eficácia e precisão dos modelos. Durante o treinamento, os algoritmos receberão os parâmetros selecionados (X) e um alvo (Y) para ser atingido. O alvo, como descrito anteriormente, é criado a partir de falhas reais.

Entretanto é necessário propagar esta informação para algum tempo antes do momento do evento real, a fim de que os modelos possam aprender a prever a falha antes que aconteça de fato. Os modelos de aprendizagem utilizados são *Gaussian Naïve Bayes* (GNB), *Árvore de Decisão* (DTC), *Regressão Logística* (RL), *Gradient Boosting Classifier* (GBC) e *Multi-Layer Perceptron Classifier* (MLPC). Foram escolhidos com base em critérios de desempenho, opções de configuração de hiperparâmetros e por serem modelos confiáveis e utilizados em larga escala para aplicações em *machine learning*.

3.3.3.1 Gaussian Naïve Bayes

O modelo GNB é um classificador probabilístico baseado no teorema de Thomas Bayes que desconsidera a correlação entre as variáveis, motivo pelo qual é chamado *naïve* (ingênuo). A consideração de que os parâmetros selecionados são independentes é inverossímil, principalmente em um sistema tão interligado como o analisado, contudo esta aproximação é aceitável na maioria das aplicações após a realização da análise bivariada (Steele *et al.*, 2016). O teorema de Bayes é mostrado abaixo na equação 2.

$$P(h|d) = \frac{P(d|h)*P(h)}{P(d)} \quad (2)$$

Em que $P(h|d)$ é a probabilidade do evento h considerando que o evento d ocorreu, e é chamada de probabilidade a posteriori;

$P(d|h)$ é a probabilidade dos dados, d , considerando que a hipótese h foi verdadeira;

$P(h)$ é a probabilidade da hipótese h ser verdadeira, independentemente dos dados e é chamada de probabilidade a priori;

$P(d)$ é a probabilidade dos dados, constante e independentemente da hipótese.

O modelo GNB constrói as hipóteses com base nos parâmetros fornecidos e é treinado a partir da categoria alvo, que informa se a falha ocorreu. Como $P(d)$ é um fator de normalização constante e $P(h)$ é igual para eventos normais e com falha após o balanceamento da base de dados, a maximização da probabilidade $P(h|d)$ depende de $P(d|h)$. Após testar a probabilidade a posteriori para diferentes hipóteses, é possível selecionar a hipótese com probabilidade máxima. Dessa forma, o algoritmo ajusta os valores de probabilidade de falha durante o aprendizado considerando a base de treino e a categoria alvo (Alpayadin, 2010). Uma grande vantagem do algoritmo GNB comparado com outros modelos é a velocidade de processamento e desempenho computacional (Adhikari, 2018). Este modelo é utilizado em diferentes setores e aplicações, como classificações de *emails* e diagnósticos médicos (Ortega et al., 2017; Griffis, 2016).

3.3.3.2 Árvore de Decisão (*Decision Tree Classifier*)


Modelos desenvolvidos a partir do algoritmo DTC constroem estruturas hierárquicas que consistem de um nó raiz, nós de decisão, nós “folhas” e arestas direcionadas para os níveis da hierarquia. A cada nível da árvore, o conjunto de dados de entrada é avaliado e dividido para os próximos níveis a partir de uma verificação feita pelo algoritmo. Para um conjunto de variáveis de entrada, a decisão é baseada em operações lógicas aplicadas a determinadas variáveis. Algoritmos DTC são utilizados para classificação de sinais de radar, reconhecimento facial e de fala, diagnósticos médicos, entre outros (LANDGREBE; SAFAVIAN, 1991). Um exemplo comum é a aplicação da árvore de decisão em diagnósticos médicos, em que as variáveis de entrada podem incluir a idade, peso, altura e pressão arterial de um grupo de pessoas, como mostrado na Figura 12.

A árvore de decisão pode ser utilizada para problemas de regressão ou classificação e funciona a partir da regra que produzir o máximo decréscimo da impureza do respectivo nó. Em problemas de classificação, uma das formas de medida para esta impureza é o índice Gini, descrita na equação 3.

$$G(t) = 1 - \sum_{i=1}^c p_i^2 \quad (3)$$

Onde $G(t)$ é a medida de impureza Gini do nó t , e p_i é a proporção de observações da classe c nesse mesmo nó (Albon, 2018).

Figura 12 – Exemplo fictício de classificador DTC aplicado a diagnósticos médicos.



Fonte: Autor

O algoritmo aprenderá com a base de treino e construirá a árvore hierárquica com base em operações com estes parâmetros informados. Em grupos com idades maiores do que cinquenta anos, índice de massa corporal acima da referência e a pressão arterial alta, por exemplo, a árvore poderá classificar o conjunto de características como um diagnóstico específico. Por outro lado, grupos com idades menores de 50 anos, porém com IMC maior do que a referência são classificados como grupos de risco para o diagnóstico positivo. Para os parâmetros considerados neste trabalho, o algoritmo deve considerar informações ligadas à pressão em linha, altitude e verificar se a posição de alguma válvula específica se relaciona com a probabilidade de falha.

O caminho da raiz da árvore até uma folha qualquer pode ser reescrito em termos das regras e condições definidas pelos nós de decisão. Usando o mesmo princípio para a estrutura como um todo, a árvore completa conforme mostrada na Figura 12 pode ser facilmente descrita na forma de regras condicionais usando lógicas do tipo “Se(condição), então (resultado do diagnóstico)”. Quanto maior a estrutura da árvore, mais trabalhosa se torna esta forma de descrição, entretanto a simplicidade se mantém. Dessa forma, o modelo é de fácil compreensão uma vez que o resultado seja obtido e pode ser replicado a outras bases de dados similares (Albon, 2018).

3.3.3.3 Regressão Logística


A função logística, também chamada de sigmoide devido a seu formato característico, é aplicada quando se deseja estimar a probabilidade de ocorrência de uma variável binária tendo em vista um conjunto de parâmetros independentes. Os valores da função logística variam de zero a um, fazendo com que a verificação da probabilidade seja feita diretamente. Possui alto grau de confiabilidade e requer número reduzido de hipóteses ou suposições sobre a base de dados. Este modelo de regressão utiliza o método da máxima verossimilhança, que ajuda na determinação de coeficientes de um modelo estatístico.

O conjunto de n variáveis independentes X_i , que são os parâmetros selecionados e tratados, compõe a expressão que será a entrada da função logística. A função logística e a expressão de entrada são descritas nas equações 4 e 5, respectivamente.

$$P(Y) = \frac{1}{1+e^{-g(x)}} \quad (4)$$

$$g(x) = C_0 + C_1X_1 + \dots + C_nX_n \quad (5)$$

Onde os termos C_i são os coeficientes que maximizam a probabilidade da amostra ter sido observada e são definidos pelo algoritmo através do método da máxima verossimilhança. O formato da curva gerada por $P(Y)$ é apresentado na Figura 13.



Fonte: Autor

Observa-se pela equação 3 e pela Figura 13 que quando $g(x) \rightarrow +\infty$, $P(Y) \rightarrow 1$ e quando $g(x) \rightarrow -\infty$, $P(Y) \rightarrow 0$, correspondente ao esperado para probabilidades. A função sigmoide também pode receber polinômios de ordens superiores, o que garante maiores graus de liberdade. Apesar do fato de que a variabilidade do grau de liberdade pode ser um ponto forte, caso utilizada de forma incorreta, esta característica pode fazer com que o aprendizado de máquina fique extremamente adaptado para a base de dados de treino, cenário chamado de *overfitting* e que prejudica a acurácia generalista do modelo (Alpayadin, 2010). Para evitar que isto ocorra, a validação do modelo criado a partir do treinamento com a base de teste é fundamental.

O modelo define os coeficientes para cada parâmetro a partir da minimização do erro de predição na base de treino. Avaliando estes coeficientes, os positivos contribuem para aumentar a probabilidade, enquanto os negativos a diminuem. O valor de cada coeficiente tem relação com o impacto gerado pela respectiva variável independente, o que significa que parâmetros fortemente correlacionados com as falhas apresentarão maiores valores absolutos dos coeficientes.


3.3.3.4 *Gradient Boosting Classifier (GBC)*

Modelos de *machine learning* supervisionados que aplicam *boosting* são utilizados massivamente para aplicações de ciência de dados e pesquisa e são considerados dos mais efetivos algoritmos de aprendizagem com métodos não lineares para resolução de diversos problemas. O termo *boosting* se refere à técnica iterativa aplicada a um conjunto de diferentes hipóteses, que são fracas a princípio, chamadas de *learners* (Sigrist, 2020). É comum a utilização de árvores de decisão com poucos nós e folhas para a construção das hipóteses, que são testadas a cada iteração com parte dos dados originais de treino e adaptadas para minimização do erro na próxima iteração.

Problemas de otimização frequentemente estão ligados com a busca pelo máximo ou mínimo de determinada função. Para se avaliar o comportamento e variações de determinadas funções, derivadas são a ferramenta matemática aplicada em cálculo diferencial. Derivadas indicam a sensibilidade de mudança do valor de saída de determinada função com relação ao valor do argumento de entrada e auxiliam na indicação de pontos máximos e mínimos. O método que

geralmente auxilia na otimização dos algoritmos minimizando funções de custo (ou erro) para cada iteração no GBC é o da descida gradiente, cujo princípio é esboçado na Figura 14.

Figura 14 – Aplicação da descida gradiente na função genérica f .




O vetor gradiente (definido pelo operador nabla $-\nabla$) é baseado no conceito de derivadas parciais e, de forma simplificada, indica o sentido em que uma função tem o maior acréscimo. No caso da descida gradiente, a intenção é seguir no sentido oposto ao do vetor gradiente, de modo a minimizar o valor da função. Como se pode notar pela linha pontilhada vermelha na Figura 14, algumas funções apresentam pontos mínimos locais. Para evitar que o algoritmo apresente convergência para regiões com estas características, existem métodos estocásticos para avaliação da descida gradiente. A aleatoriedade na determinação de pontos para avaliação da função permite o aumento da performance, visto que não é necessário percorrer todos os pontos.

3.3.3.5 *Multi-Layer Perceptron Classifier (MLPC)*

Quando se trata de aprendizagem de máquina e inteligência artificial, é comum haver comparações entre os mecanismos e processos realizados por computadores com o funcionamento da mente humana. Dentre os algoritmos computacionais de aprendizagem existentes, o *Multi-Layer Perceptron* (MLP) é um dos que apresenta estrutura de funcionamento análoga ao que se entende comumente de nossa central de processamento, o cérebro. MLP diz respeito a múltiplas camadas de *perceptrons*, que são os blocos de construção da rede neural artificial, equivalentes a neurônios. Um modelo ilustrativo de rede neural é mostrado na Figura 15.

Figura 15 – Rede neural com cinco entradas, duas camadas de perceptrons e uma saída.



Fonte: Autor

O modelo *Perceptron* foi desenvolvido nas décadas de 1950 e 1960 por Frank Rosenblatt. Estes componentes fundamentais foram apresentados com valores de entrada, pesos (w) e vieses ($bias$) e apenas um valor de saída. A Figura 15 parece sugerir que o número de saídas de cada neurônio artificial é igual ao número de neurônios na camada seguinte, entretanto o que ocorre é um único valor de saída sendo transmitido para todos os elementos da próxima camada. Os pesos são números reais que expressam a importância de cada valor de entrada para o resultado da saída e o viés pode ser visto como um fator que facilita ou dificulta a “ativação” desse neurônio. Por exemplo, se o valor do viés é muito negativo, se torna mais difícil que o produto entrada-peso seja suficiente para ativar o *perceptron*. A regra para resultados binários é mostrada na expressão seguinte.

$$saída = \begin{cases} 0, & \text{se } w.x + b \leq 0 \\ 1, & \text{se } w.x + b > 0 \end{cases}$$

onde x é o valor da entrada, w é o peso e b o viés.

3.3.4 Avaliação dos modelos

Após a modelagem, os algoritmos utilizados devem ser submetidos à validação através da aplicação do aprendizado obtido (coeficientes característicos) na base de teste. Uma métrica simples para esta avaliação é a medida de acurácia de cada modelo, ou seja, a comparação de entre falsos-positivos, falsos-negativos e acertos através de uma matriz de confusão. Dessa forma, a acurácia pode ser medida a partir da razão entre os acertos e o total de dados, sendo que os acertos compreendem verdadeiros-positivos e verdadeiros-negativos. Também são analisadas especificidade e sensibilidade de cada modelo.

Além da validação qualitativa, é necessário verificar a viabilidade de cada modelo através da análise de custo de manutenção: modelos distintos podem apresentar diferentes previsões ao longo do tempo. Além disso, um mesmo modelo pode indicar alta probabilidade de falha nos próximos voos e, no voo seguinte, indicar novamente baixa probabilidade. Dessa forma, é preciso definir quais fatores devem ser analisados para que se considere uma previsão, visto que o resultado numérico de cada algoritmo é dado em termos de probabilidades. Sendo assim, de forma a amenizar o efeito de previsões espúrias, o critério para que se considere uma previsão será quando o valor da média móvel da probabilidade descrita por um algoritmo nos últimos 20 voos for maior que um valor limite. Como cada modelo tem suas particularidades e pode se comportar de forma diferente, é necessário personalizar este valor limite para cada algoritmo. Esta personalização deve ser feita de forma a minimizar o custo de manutenção, pois as diferenças entre as previsões afetam o custo final de implementação de cada modelo.

Se um algoritmo realiza a previsão do evento um mês antes da falha, enquanto o outro prediz uma semana antes, o primeiro acusará a remoção do componente enquanto ainda havia

tempo maior de vida útil, o que consequentemente aumenta o custo final. Em situações práticas, outras variáveis de decisão, como o tempo hábil para troca de componentes da linha aérea, disponibilidade de agenda de manutenção e logística de peças são características que devem ser levadas em consideração, pois existem casos em que o algoritmo que prevê com um mês de antecedência pode ser mais econômico do que aquele que prevê com uma semana de antecedência. Sendo assim, as conclusões da análise de custo serão definidas pelas premissas adotadas, podendo ser alteradas de acordo com as características operacionais do caso real.

3.3.5 Avaliação de custos de manutenção

Custos de manutenção envolvem variáveis como preços de equipamento, mão de obra, tempo fora de serviço e lucro cessante, depreciação, cancelamentos e atrasos, entre outros. Neste estudo, são avaliados para comparação apenas o preço da válvula reguladora de pressão e o custo do cancelamento do voo, ambos estimados e fixos. Para o caso real, o valor da peça pode variar a partir de acordos comerciais com os fornecedores usando como parâmetro o tempo desde a última revisão ou o MTBUR (“*mean time between unscheduled removal*”, ou “tempo médio entre remoções não programadas”, em português), por exemplo.

Considerando-se o custo de cancelamento do voo e o preço da válvula, a análise de custo permite definir parâmetros importantes deste estudo. Como mencionado no tópico anterior, os valores dos limites para cada algoritmo devem ser definidos a partir da minimização do custo. Algumas premissas básicas são desenvolvidas para que se obtenha as conclusões necessárias na minimização do custo de manutenção. A primeira delas é a de que toda previsão de falha de determinado algoritmo resulta em remoção da válvula reguladora de pressão. Também se considera que toda falha que ocorre, ou seja, quando um algoritmo não foi capaz de prevê-la, resulta em cancelamento do voo e posterior troca da válvula. Caso o modelo indique a falha antes que esta ocorra, apenas a troca da válvula acontecerá e um cancelamento será evitado, diminuindo o custo de manutenção. Um resumo da estrutura de hipóteses adotadas é mostrado no Quadro 3.

Quadro 3 – Estrutura de hipóteses e premissas adotadas

- Uma previsão ocorre quando a média móvel da probabilidade de falha dos últimos 20 voos for superior ao valor limite mínimo para determinado algoritmo;
- Toda previsão de falha resulta em remoção de válvula;
 - Previsões feitas antes da falha não resultam em cancelamento de voo;
 - Previsões feitas sem falha real (falso-positivos) resultam em remoção desnecessária.
- Toda falha não prevista resulta em cancelamento do voo e remoção da válvula;

Fonte: Autor

4 RESULTADOS E DISCUSSÃO

4.1 OBTENÇÃO E ORGANIZAÇÃO DA INFORMAÇÃO

Após a obtenção dos dados em formato de arquivos “csv” (*comma-separated values* – valores separados por vírgula, em português), que é um formato comum para armazenamento de dados e pode ser visualizado utilizando o software Microsoft Excel, foi realizado o processamento de cada arquivo a partir da criação de nomes (*labels*) para as aeronaves e rótulos para cada voo. O formato utilizado para a identificação da informação é descrito abaixo no Quadro 4. Este processo é realizado para garantir a individualidade dos eventos e evitar a mescla indevida de informações entre aeronaves caso arquivos tenham sido gravados no mesmo dia e horário.

Quadro 4 – Formato utilizado para identificação e rotulagem dos dados.

Lista de Aeronaves	Nome do Voo
Aeronave 1	Aeronave_1_ano_mês_dia_Hora_Minuto_Segundo
	Aeronave_1_ano_mês_dia_Hora_Minuto_Segundo
Aeronave 2	Aeronave_2_ano_mês_dia_Hora_Minuto_Segundo
	Aeronave_2_ano_mês_dia_Hora_Minuto_Segundo
.....	
Aeronave 30	Aeronave_30_ano_mês_dia_Hora_Minuto_Segundo Aeronave_30_ano_mês_dia_Hora_Minuto_Segundo

Fonte: Autor

O rótulo do voo e a identificação do avião foram inseridos nos arquivos como uma coluna adicional para facilitar a pesquisa por eventos individuais no decorrer da análise. Dado que o formato ‘csv’ deve ser compactado para viabilizar seu armazenamento, outro procedimento foi realizado nos dados originais, convertendo todos os arquivos desse formato em uma base de dados concatenada para cada aeronave no formato “Parquet”. Este formato é baseado no armazenamento de dados em colunas de forma altamente eficiente e compacta, motivo pelo qual foi escolhido.

Sendo assim, os dados foram organizados em arquivos no formato “parquet” e separados por avião. Com a organização dos arquivos, torna-se mais rápida e fácil a manipulação de voos individuais. Para agilizar o tratamento dos dados através da ferramenta Jupyter Notebook, foi criada uma tabela contendo um resumo dos voos, em que cada linha representa um voo e cada coluna representa um parâmetro. Na literatura consultada sobre a gestão de bases de dados, esta tabela é chamada de *Analytical Base Table* (ABT – Tabela-Base Analítica, em português) e é mostrada na tabela da Figura 16.

Figura 16 – Primeiras linhas com alguns parâmetros da ABT

	Aeronave	Altitude_Cruzeiro	press_desca_1	press_desca_2
Nome do Voo				
Aeronave_1_2016-05-07_00:07:06	Aeronave_1	31012.0	215.235794	553.466110
Aeronave_1_2016-05-07_09:37:18	Aeronave_1	24025.5	487.882684	632.298622
Aeronave_1_2016-05-07_11:33:36	Aeronave_1	39002.0	170.704988	654.356939
Aeronave_1_2016-05-07_13:48:09	Aeronave_1	38015.0	297.223719	535.501017
Aeronave_1_2016-05-07_15:24:43	Aeronave_1	37013.5	264.361855	604.641430
Aeronave_1_2016-05-07_17:32:08	Aeronave_1	40003.0	374.893678	565.653969
Aeronave_1_2016-05-07_19:28:38	Aeronave_1	29031.0	308.363514	616.366496
Aeronave_1_2016-05-07_21:12:50	Aeronave_1	24019.5	231.199888	604.854687
Aeronave_1_2016-05-08_00:43:22	Aeronave_1	36010.0	487.424465	688.826473
Aeronave_1_2016-05-08_10:47:29	Aeronave_1	39014.5	208.250365	442.948540
Aeronave_1_2016-05-08_14:20:58	Aeronave_1	39017.5	271.478083	530.422962
Aeronave_1_2016-05-08_17:06:28	Aeronave_1	38012.0	288.831485	497.801434
Aeronave_1_2016-05-08_19:47:54	Aeronave_1	28029.0	420.453787	737.748623
Aeronave_1_2016-05-08_21:27:08	Aeronave_1	29042.0	420.736705	730.789542

Fonte: Autor

Como mostrado anteriormente, através do Quadro 4, os dados analisados compõem uma frota de trinta aeronaves com voos gravados no ano de 2016, entretanto apenas algumas linhas da “aeronave_1” são mostradas na Figura 16. Conforme explicado, cada linha da ABT corresponde ao resumo de um voo, com cada parâmetro sendo expresso em colunas. O parâmetro “Altitude_Cruzeiro” corresponde à altitude máxima em pés que cada aeronave obteve para determinado “Nome de Voo”. A coluna “alvo” (não mostrada na Figura 16), conforme mencionado na descrição da metodologia, é criada a partir de eventos reais de falha para que os algoritmos possam identificar o comportamento dos parâmetros antes do evento.

Os parâmetros “press_desca_X” foram construídos a partir dos valores médios da pressão em linha, porém descaracterizados por motivos de confidencialidade dos dados. Apesar do fato de que o valor original destas variáveis foi alterado, a proporcionalidade dos dados se mantém, motivo pelo qual as conclusões dos algoritmos não são afetadas. As variáveis com índices numéricos “1” e “2” dizem respeito respectivamente ao lado direito e esquerdo do sistema. O rótulo criado a partir

do nome da aeronave e da data de gravação funciona como o índice para a tabela e mostra também que os dados estão contínuos para o período mostrado.

Para a aplicação desejada, a continuidade dos dados é fundamental a fim de garantir que o comportamento do sistema seja caracterizado com maior precisão descritiva. Caso houvesse meses de interrupção da informação em grande parte dos dados, se tornaria mais difícil de interpretar a evolução dos parâmetros gravados. Para garantir a completude e contiguidade dos dados, pode-se avaliar a porcentagem de dias do ano em que cada avião apresenta ao menos uma gravação. O resultado desta avaliação é mostrado na Tabela 1.

Tabela 1 – Avaliação de completude por aeronave

Aeronave	%complet	Aeronave	%complet	Aeronave	%complet
Aeronave_9	98,90	Aeronave_24	95,34	Aeronave_6	89,86
Aeronave_18	98,63	Aeronave_14	95,07	Aeronave_27	88,49
Aeronave_23	98,63	Aeronave_8	94,52	Aeronave_10	88,22
Aeronave_16	98,08	Aeronave_25	94,25	Aeronave_2	88,22
Aeronave_17	97,81	Aeronave_7	93,97	Aeronave_5	87,67
Aeronave_21	97,26	Aeronave_28	93,69	Aeronave_20	87,39
Aeronave_30	96,98	Aeronave_1	92,60	Aeronave_11	87,12
Aeronave_15	96,71	Aeronave_26	90,96	Aeronave_12	86,85
Aeronave_3	96,16	Aeronave_4	90,68	Aeronave_22	83,56
Aeronave_29	96,16	Aeronave_13	90,14	Aeronave_19	82,47


Fonte: Autor

4.2 ANÁLISE EXPLORATÓRIA

4.2.1 Pre-processamento dos voos

Considerando o ano de 2016, a mínima completude obtida foi de 82.5%, que corresponde à ausência de aproximadamente dois meses de dados no caso da aeronave 19. Entretanto este tipo de verificação não distingue o caso de quando há lacunas internas dos casos em que apenas há menor quantidade de dados em geral. Caso um evento de falha real contido na coluna “alvo” esteja próximo a uma região com indisponibilidade de dados, este evento poderá prejudicar tanto a aprendizagem dos algoritmos quanto a medição de acurácia a partir dos resultados obtidos. Estas informações são mostradas na Figura 17.

Figura 17 – Análise de contiguidade e completude dos dados



Fonte: Autor

Muitas informações úteis podem ser obtidas a partir da Figura 17 para a análise dos dados, entretanto é preciso primeiramente explicá-la. Como pode ser observado, cada linha do eixo ordenado diz respeito a uma aeronave, enquanto o eixo das abscissas contém datas do ano de 2016 com período de cinco dias entre cada rótulo. Linhas horizontais na cor cinza foram colocadas para facilitar a identificação de cada aeronave. As regiões em rosa claro correspondem aos dados de voos comuns, enquanto regiões em cor preta identificam ausência de dados. As regiões pintadas na coloração vinho dizem respeito aos voos ocorridos logo antes de eventos de falha da válvula reguladora de pressão, informação que foi obtida a partir da coluna “alvo”. Observa-se também que os dados, considerando “eventos alvo” e voos comuns, estão desbalanceados, visto que o número de voos comuns é muito maior.

No contexto da análise de contiguidade e completude dos dados, a informação contida na Figura 15 pode permitir melhores estratégias para tratar os dados. Pode-se observar que alguns aviões não apresentaram falhas no período descrito, como a aeronave 1, 3 e 8, por exemplo. Também é visível que a aeronave 19, que apresenta a menor completude de acordo com a Tabela 1, possui dados apenas a partir do meio de fevereiro de 2016, o que explica o resultado na tabela. Algo importante de se notar é que o primeiro evento dessa mesma aeronave não é precedido por um histórico significativo de dados. Outro exemplo dessa mesma situação é a primeira região em cor vinho da aeronave 12. Para evitar que eventos dessa natureza tenham qualquer influência durante o treino dos modelos e medição de acurácia, serão desconsiderados neste estudo.

Antes da execução das análises univariada e bivariada, foram criados parâmetros a partir das variáveis existentes. Com base no funcionamento do sistema ECS, descrito no Capítulo 2, foi constatado que é necessário levar em consideração o fato de que o computador controlador que administra o fornecimento de ar ajusta o sistema para atingir determinadas pressões dependendo da altitude. Dessa forma, é possível fazer a comparação da pressão alvo para cada nível de altitude com a pressão real observada e obter um novo parâmetro. Este parâmetro é chamado de “press_erro”, e é obtido a partir da diferença entre a pressão alvo e a pressão real. A nova variável permite entender se o sistema está conseguindo atingir a pressão alvo ou se há algum comportamento anômalo.


Com base nessa característica do sistema, foram construídos filtros na base de dados brutos para verificar grandes variações de altitude e ângulo da manete de potência, a fim de considerar apenas períodos de estabilidade do sistema. Este procedimento foi realizado porque nas fases de decolagem, subida, descida e aterrissagem existem grandes variações de altitude, potência dos motores ou vibrações características devido ao pouso e turbulência. Estes fatores podem influenciar negativamente o parâmetro “press_erro” e por este motivo tais perturbações foram eliminadas.

Um sintoma de falha conhecido da válvula reguladora de pressão está ligado à oscilação da pressão. Para podermos capturar o comportamento oscilatório, outro parâmetro criado foi “press_osc”, que possibilita verificar o nível médio de oscilação em cada voo. Um parâmetro análogo ao “press_osc” foi feito para avaliar a oscilação da pressão de descarga do compressor do motor, chamado “press_comp_osc”. Com o filtro de estabilidade criado, foi desenvolvido um novo parâmetro chamado “temp_estab”, que mede a duração da estabilidade para cada voo. Outro tratamento inicial realizado, foi a eliminação de voos com altitude máxima inferior a 10 mil pés, como descrito no Capítulo 3. Um novo resumo dos principais parâmetros utilizados é mostrado no próximo tópico.

4.2.2 Análises univariada e bivariada

Para a análise univariada, cada parâmetro é avaliado individualmente através de diagramas, como os gráficos de histograma e dispersão, bem como da utilização de ferramentas estatísticas como aplicações de médias, medianas e desvios-padrões. Este tipo de avaliação dos dados pode levar a novas ideias e estratégias para criação de outros novos parâmetros a partir da informação bruta. Caso novas variáveis sejam criadas, a análise bivariada poderá mostrar se apresentam alta colinearidade com os parâmetros antigos e, então, ocorre a seleção de variáveis. Os resultados da análise univariada são mostrados na Figura 18.

Figura 18 – Histogramas da análise univariada para cada parâmetro.




Fonte: Autor

A Figura 18 apresenta a distribuição de cada um dos principais parâmetros utilizados até então. Os valores de altitude foram descaracterizados, porém sem alteração da proporcionalidade. O limite horizontal dos gráficos foi definido em três vezes o desvio-padrão de cada variável para facilitar a visualização onde os dados estão mais concentrados. Apenas para os gráficos de “press_osc” o limite horizontal foi definido como seis vezes o desvio-padrão, devido à maior dispersão. Observa-se que, para o gráfico do parâmetro “press_osc”, parte dos dados apresenta maior dispersão para a direita, como mostrado em destaque. Isso sugere que ao menos em parte dos voos (possivelmente com presença de falhas) houve maior tendência para oscilação.

Observa-se também que a maioria da informação contida nos parâmetros relativos a oscilação está centrada em zero. Como a base de dados é desbalanceada (mais voos comuns do que voos com falhas), apenas a análise univariada é insuficiente para fazer constatações definitivas. Valores discrepantes mais à direita do parâmetro “press_osc” podem indicar degradação do sistema. Essa tendência de oscilação pode existir, ainda que em menor percentual, em voos comuns (sem falhas). No entanto, como há concentração de dados mais próximo de zero, a visualização desse efeito seria dificultada. Por este motivo, foi apresentada a vista aproximada em escala aumentada para o gráfico deste parâmetro.

Com a criação de novos parâmetros a partir daqueles contidos nos dados brutos, é necessário verificar de que forma cada um está relacionado com o outro. Como explicado no Capítulo 3, a análise bivariada dos dados pode ser aplicada para este fim utilizando uma matriz de correlação. A partir da matriz de correlação, pode-se verificar visualmente o grau de correlação entre as variáveis comparando duas a duas. O resultado deste procedimento é mostrado na Figura 19.

Figura 19 – Matriz de correlação das variáveis para análise bivariada.



Fonte: Autor

Além da indicação numérica variando de -1 a 1 para a correlação entre cada parâmetro, diferentes tons de cor ajudam a identificar quão correlacionados estão dois parâmetros quaisquer. Quanto mais negativo o valor de correlação – ou escuro – maior a correlação inversa entre as duas variáveis; quanto mais positivo – ou claro – maior a correlação direta. Como esperado, a diagonal principal da matriz de correlação mostra o valor unitário, visto que correlaciona o mesmo parâmetro. A altitude média de cruzeiro, por exemplo, é inversamente correlacionada com as pressões de descarga do compressor. Este comportamento pode ser explicado pela informação contida na Figura 7. Como o aumento de altitude está relacionado à redução da pressão atmosférica, a Figura 19 mostra que altitudes maiores geralmente resultam em menores pressões do compressor.

Verifica-se também que os valores de pressão advindas de ambos os motores, bem como seus parâmetros de oscilação, são correlacionados positivamente, enquanto as oscilações de pressão de linha não são fortemente correlacionados. Este resultado pode indicar que possíveis falhas da válvula reguladora de pressão devido à oscilação não devem ter relação com a oscilação da pressão que vem dos motores. Novamente, como a ABT lida com resumos de voos completos, quaisquer constatações finais necessitarão de maior investigação.


A altitude média de cruzeiro também está correlacionada com a duração da estabilidade (“temp_stab”). Considerando-se um limite de correlação em 60%, conclui-se que a remoção do parâmetro de altitude média resulta que todos os valores restantes sejam inferiores ao limite. Dessa forma, a variável “Altitude_Cruzeiro” é retirada da análise e os valores de correlação dos parâmetros remanescentes são considerados dentro do tolerável. Para estas variáveis restantes, aquelas que são divididas em lado 1 e 2 foram concatenadas em apenas uma coluna homônima ao radical, visto que algumas possuíam alta correlação. Por exemplo, os parâmetros “press_osc_comp_1” e “press_osc_comp_2” foram concatenadas em apenas uma coluna chamada “press_osc_comp”. Para possibilitar a diferenciação dos lados, foi criada outra coluna chamada “lado”, contendo o valor 1 e 2 para os respectivos sistemas.

4.3 TRATAMENTO DE DADOS E ANÁLISE DE CLUSTERS

4.3.1 Outliers

A etapa que se segue após as análises de dispersão e correlação dos dados é o tratamento da informação. A avaliação univariada permitiu a obtenção de algumas hipóteses sobre o comportamento do sistema, como a de que o parâmetro de oscilação da pressão de linha apresentava leve acréscimo em voos com falha quando comparado com voos sem eventos. Como comentado anteriormente, este efeito pode ocorrer devido ao desbalanceamento da base de dados, ainda que os dados sem falha apresentem a mesma tendência de acréscimo para alguns voos. Para que seja possível tratar os dados, aplica-se o gráfico do tipo *boxplot*, explicado na Figura 10. O resultado do gráfico é mostrado na Figura 20.

Figura 20 – Gráfico *boxplot* de acordo com o lado, categoria de alvo e parâmetro.



Fonte: Autor

O gráfico é construído com base nos parâmetros concatenados para ambos os lados do sistema e a informação é dividida entre voos alvo e voos comuns. O parâmetro de altitude ainda é mantido nesta análise para a verificação de *outliers* e, como se observa novamente os limite definido para altitude é acima de 10 mil pés. Considerando a hipótese mencionada no parágrafo anterior, verifica-se que os valores *outliers* do parâmetro “press_osc” são mais dispersos para vôos comuns.


Entretanto, a dispersão da maior parte dos dados alvo pode ser visualizada pela posição do terceiro quartil e limite superior desse parâmetro, ambos acima dos valores para voos sem falhas, apesar de também centrados próximos de zero.

Com relação às demais variáveis, o gráfico permite observar que existem voos com tempos de estabilidade próximos a zero e outros com valores suspeitosamente altos. Os parâmetros de oscilação de pressão estão centrados em zero, entretanto a dispersão e quantidade de *outliers* se destacam principalmente para “press_comp_osc”. Estas características devem ser avaliadas antes que os dados sejam submetidos aos modelos de predição. Dentre as estratégias mais comuns para o tratamento de *outliers* estão a remoção dos dados, o reajuste para os limites inferior e superior e, quando a presença desses dados for não prejudicial para a modelagem, os dados são mantidos.

Quando a informação e o comportamento esperado são bem conhecidos, o tratamento de valores discrepantes se torna mais fácil. Caso os dados fossem consistissem em idades de pessoas, quaisquer concentrações de valores acima de 120, por exemplo, chamariam atenção pelo gráfico de *outliers*. Para o parâmetro “temp_estab”, a duração da estabilidade deve ser menor do que a duração do voo. Considerando os critérios utilizados durante a criação desta variável, valores acima do limite superior serão eliminados da análise, bem como aqueles inferiores a 5 minutos.

Para os parâmetros de pressão e oscilação, os valores discrepantes podem indicar comportamentos que não devem ser eliminados, entretanto a maioria dos *outliers* estão em voos marcados como comuns. Dessa forma, estes valores serão reajustados para os limites superiores e inferiores dos respectivos gráficos *boxplot*. Apenas para o parâmetro “press_osc” os valores serão mantidos inalterados. Durante a primeira execução desta análise, foi verificado que o tratamento de valores discrepantes deste parâmetro enviesou o aprendizado dos modelos. Este efeito é apresentado no tópico sobre a avaliação dos modelos. Os resultados finais para o tratamento de *outliers* são mostrados na Figura 21.

Figura 21 – Resultados do tratamento de outliers na base de dados.



Fonte: Autor


Ambos os gráficos inferiores fazem referência ao mesmo parâmetro, “press_osc”, entretanto observa-se à direita os valores originais e, do outro lado, os valores que foram tratados com o mesmo critério que os demais parâmetros. Como mencionado, os dados utilizados serão aqueles retratados pelo gráfico à direita, entretanto pode-se observar que a discrepância entre dados “alvo *True*” e “alvo *False*” é visualmente facilitada pela representação à esquerda. Visto que o tratamento de valores nulos foi concluído anteriormente, a próxima etapa será a verificação de agrupamentos nos dados.

4.3.2 Normalização e análise de *clusters*

Como descrito no Capítulo 3 e explorado através da Figura 11, a base de dados pode ser entendida como uma distribuição n-dimensional, sendo “n” o número de parâmetros. Caso esta

distribuição possua quatro agrupamentos com características marcadamente distintas, pode ser dito que existem quatro *clusters* de dados presentes na base, assim como ilustrado na Figura 11. Para a redução dimensional adequada e que possibilite capturar o plano que melhor descreva os possíveis agrupamentos, a técnica de PCA é aplicada na base de dados já tratada. Como discutido no Capítulo 3, o PCA, bem como a maioria dos algoritmos de aprendizagem, requer a normalização dos dados, ou seja, que os parâmetros tenham médias nulas e variância unitária. Os resultados da análise de componentes principais são mostrados na Figura 22.

Figura 22 – Análise de *clusters* na base de dados com 2 a 5 agrupamentos.



Fonte: Autor

Após a normalização, a avaliação de componentes principais foi realizada em tentativas de agrupamentos de 2 a 5 *clusters*, respectivamente, como mostra a parte superior da Figura 22. Em ambas as tentativas, o plano escolhido pelo algoritmo de PCA não parece indicar grandes diferenças de dispersão na base de dados. A parte inferior da Figura 20 é a vista em três dimensões da imagem à direita, relativa a cinco agrupamentos, que também mostra os diferentes *clusters*. Observa-se que, ainda que exista uma leve dispersão de dados no sentido do eixo vertical, a quantidade dispersa não é suficiente para formar um novo cluster. Contudo, uma nova avaliação será feita com os dados balanceados. Sendo assim, apenas um modelo será construído para os dados a partir de cada um dos algoritmos utilizados e a próxima etapa é o balanceamento dos dados.

O balanceamento da base de dados é feito de forma a equilibrar a informação em voos alvo e voos comuns. O procedimento consiste em selecionar aleatoriamente amostras da categoria que estiver em menor número e duplica-las até que a base de dados seja composta por ambas as categorias em iguais proporções. Antes do balanceamento, existem doze eventos em cada mil voos da base de dados.

4.4 APLICAÇÃO DE MODELOS E ALGORITMOS

Toda a preparação e tratamento dos dados feitos até então visa garantir que os algoritmos sejam executados adequadamente e retornem resultados otimizados. Os modelos utilizam parte da informação disponível para aprendizado e a outra para que realizem testes com o resultado da aprendizagem. Por este motivo, a base de dados deve ser segregada em duas bases separadas. Este procedimento foi descrito no Capítulo 3 e a proporção escolhida para o presente estudo é de 70% das aeronaves direcionadas para o treino dos algoritmos e o restante para testes. Como a quantidade de voos é aproximadamente constante para cada avião, esta segregação corresponde à mesma porcentagem em número de dados. A distribuição obtida aleatoriamente para treino e teste é mostrada na Tabela 2.

Tabela 2 – Distribuição da base original para treino e teste.

	Número da Aeronave
Treino (20)	1,2,3,5,7,9,11,13,14,15,16,18,20, 21,22,26,27,28,29,30
Teste (10)	4,6,8,10,12,17,19,23,24,25.

Fonte: Autor

Com as bases segregadas para treino e teste, cada modelo de predição foi treinado com os dados de 20 aeronaves. Em seguida, cada modelo foi exposto à base de testes, contendo apenas os parâmetros selecionados, sem a coluna alvo. O resultado deste procedimento é a previsão dos modelos, que pode ser vista em forma binária ou probabilística. Ainda que a coluna alvo original seja composta por dados booleanos, o formato escolhido para avaliação das previsões é a forma probabilística, pois permite a aplicação de limites personalizados. Uma forma de avaliação preliminar dos resultados é a visualização da matriz de confusão para cada um dos algoritmos, mostrada na Tabela 3.

Tabela 3 – Matriz de Confusão para cada modelo

	Alvo	FALSO	VERDADEIRO (base balanceada)	Acurá- cia	Especificidade	Sensibilidade
GNB	Falso	35956	189 (33374)	0,973	0,978	0,244
	Verdadeir o	812	61 (8965)			
RL	Falso	35566	183 (31229)	0,963	0,967	0,268
	Verdadeir o	1202	67 (11110)			
DTC	Falso	34775	157 (26537)	0,942	0,946	0,372
	Verdadeir o	1993	93 (15802)			
GBC	Falso	33785	161 (29761)	0,915	0,919	0,356
	Verdadeir o	2983	89 (12578)			
MLP C	Falso	35170	166 (26999)	0,952	0,957	0,336
	Verdadeir o	1598	84 (15340)			

Fonte: Autor

Observa-se pela Tabela 3 que a acurácia está acima de 90% para todos os algoritmos, entretanto é preciso analisar criteriosamente cada um dos indicadores de performance pra atingir conclusões mais representativas dos resultados. A especificidade mostra a taxa de verdadeiros-negativos e, considerando o desbalanceamento dos dados, é o principal fator para o aumento da acurácia. A sensibilidade, que mostra a taxa de acertos considerando eventos marcados como falhas, indica que apenas parte dos eventos foi prevista. Entretanto, é necessário relembrar que os alvos foram construídos com a meta de cinco voos antes das falhas e previsões feitas antes desse intervalo estão sendo consideradas, na métrica atual, como falsos-positivos. Sendo assim, para a avaliação significativa dos dados, será necessária a exploração gráfica dos resultados obtidos.

Os valores mostrados na Tabela 3 são relativos à base de testes desbalanceada e considerando um limite de probabilidade customizada para cada modelo. Ou seja, quando a média móvel da probabilidade de falha indicada nos últimos 20 voos pelo modelo é maior ou igual a este limite considera-se como previsão positiva de falha. A definição dos limites para cada algoritmo foi feita a partir da análise do custo de manutenção, de forma que o valor resultante correspondesse ao menor custo possível para cada modelo.

4.5 ANÁLISE DO CUSTO DE MANUTENÇÃO

Como descrito na seção 3.3.5 e no tópico anterior, os limites, a partir dos quais as previsões ocorrerão, devem ser definidos de forma a resultar no menor custo de manutenção possível. A fim de obter este resultado para cada algoritmo, os valores da média móvel da probabilidade foram submetidos à iteração dos possíveis limites, de 0,1 a 1 em intervalos de 0,01 e considerando-se as premissas adotadas na descrição da metodologia.

Para limites de probabilidade mais baixos, como o intervalo de 0.1 a 0.4, um grande número de previsões espúrias será feito e a válvula reguladora de pressão será trocada com maior frequência. Em valores de 0,5 a 0,8, as previsões ocorrerão quando os modelos apresentarem maior grau de certeza sobre eventos próximos de falha. Por fim, de 0,9 a 1, haverá menos previsões e remoções, entretanto, as falhas devem ocorrer com cancelamentos de voos, como ocorreria se não houvesse programa de manutenção preditiva. Considerando os intervalos extremos, espera-se que

ambos apresentem os maiores custos: o primeiro, por número elevado de remoções; o último, por custo adicional causado pelo cancelamento dos voos.

Espera-se que a maioria dos valores limite estejam na faixa intermediária, entretanto os valores estimados para o custo de remoção da válvula e de cancelamento do voo também interferem na definição dos valores limite. Por exemplo, se o custo de remoção for alto demais em comparação com o custo de cancelamento, a função de minimização de custos aumentará o limite mínimo, visto que as remoções espúrias (características de limites menores de probabilidade) se tornariam mais caras. De forma análoga, o inverso ocorreria caso o custo do cancelamento fosse muito superior que o de remoção, o que levaria a função de custo a evitar cancelamentos através da redução do limite. Os valores estimados para o cancelamento e remoção da válvula reguladora de pressão foram 30 mil e 6 mil dólares, respectivamente. Os resultados dos valores mínimos do limite de probabilidade são mostrados a seguir na Tabela 4.

Tabela 4 – Limites mínimos de probabilidade para previsões


Limite mínimo da média móvel	
GNB	0,55
RL	0,66
DTC	0,68
GBC	0,57
MLPC	0,69

Fonte: Autor

Os resultados mostrados na Tabela 4 foram obtidos a partir da aplicação dos dados da base de treino na função de iteração de valores e minimização do custo, considerando-se as premissas adotadas, os custos estimados para troca da válvula e cancelamento do voo e o tempo total de utilização da válvula no período antes da troca. Este último parâmetro possibilita a atribuição de maior peso a remoções frequentes e espúrias, bem como a diferenciação entre remoções prematuras e aquelas que ocorrem logo antes da falha.

Com a definição dos limites de probabilidade, pode-se determinar e comparar a performance e o custo resultante de cada um dos algoritmos quando aplicados à base de teste. Os resultados

comparativos referentes ao custo de aplicação de cada modelo na base de treino e de teste são mostrados na Figura 23.



O gráfico de barras da Figura 23 mostra o resultado da análise de custo para cada algoritmo e para um sexto caso, chamado de “*baseline*”, que corresponde ao custo por hora voada sem implementação dos modelos. Observa-se que a média dos custos por hora de voo para a base de treino são menores em comparação com os custos mostrados para a base de teste. Este efeito é reflexo do fato de que o valor do limite foi otimizado em função da minimização do custo para a base de treino. Em termos de custo por hora de voo, os algoritmos foram, como esperado, melhor do que o caso “*baseline*”. Entretanto ainda é necessário quantificar a redução percentual de custo considerando o valor de *baseline*. Esta informação é mostrada na Tabela 8.

Tabela 8 - Redução percentual de custo por hora de voo

	Base de Treino (%)	Base de Teste (%)
<i>Baseline</i>	Referência	Referência
GBC	2,65	12,76
GNB	20,95	12,81
MLPC	23,16	12,73
DTC	23,35	12,73
RL	25,57	12,81

Fonte: Autor

Considerando os resultados para a base de teste, todos os algoritmos tiveram performances similares. Esta característica pode ser explorada e verificada novamente a partir de análise gráfica e comparativa dos modelos em uma linha do tempo. O melhor resultado obtido para a base de teste foi a redução de 12,81% do custo de manutenção em comparação com o caso sem aplicação de modelos de predição. Existe um valor máximo de redução para o custo de manutenção, chamado de redução teórica máxima. Para atingir este limite, um modelo deveria prever todos os eventos de falha em um tempo ótimo para a troca da válvula reguladora de pressão.

Na prática, a máxima redução de custo é como uma assíntota, visto que todo modelo de predição tem suas limitações. Como a previsão de falhas resultará em troca de equipamento, sempre haverá pelo menos o custo da troca associado à manutenção. Com os valores estimados para o preço do cancelamento de um voo e o custo de troca da válvula reguladora de pressão, é possível calcular a redução máxima do custo por hora voada. Para os valores estimados e considerando que todas as falhas na base de treino foram previstas, a redução máxima de custo seria de 63,80%, o que alteraria o custo de \$ 1,52/h para \$ 0,55/h.

4.6 AVALIAÇÃO GRÁFICA DOS MODELOS DE PREDIÇÃO


Como mencionado no tópico 4.4, a coluna “alvo” foi criada considerando-se cinco voos antes do evento de falha. Sendo assim, as métricas de performance contidas na Tabela 3 não contêm toda a informação, visto que a matriz de confusão mostra os acertos e erros de cada algoritmo considerando a coluna alvo. Podem haver casos, no entanto, em que o modelo previu a falha, porém antes do período dos cinco voos da coluna “alvo”. Sendo assim, a visualização gráfica em linha do tempo de como os modelos estão se comportando pode prover mais informações úteis de performance.

Nos gráficos, foram colocadas as informações de probabilidade atribuída por cada modelo (pontos azuis) e destaques para quando houve eventos de falha (linhas verticais vermelhas). A curva preta corresponde à média móvel de um intervalo equivalente aos últimos 20 pontos azuis. A curva da média móvel é a considerada para comparação com o valor limite de probabilidade customizado para cada modelo. Quando o valor da média é superior ao limite definido, considera-

se que houve uma previsão. Os tópicos a seguir mostram resultados de três aeronaves da base de testes em que os modelos apresentaram comportamentos distintos.

4.6.1 Aeronave 10 – Predição antes da falha


Figura 24 – Comportamento dos modelos para a aeronave 10



Fonte: Autor

4.6.2 Aeronave 4 – Aumento de probabilidade após primeira falha


Figura 25 – Comportamento dos modelos para a aeronave 4



Fonte: Autor

4.6.3 Aeronave 6 – Ocorrência de Falha sem previsão

Figura 26 – Comportamento dos modelos para a aeronave 6



Fonte: Autor

4.6.4 Análise dos gráficos de probabilidade

Os exemplos escolhidos através das aeronaves 4, 6 e 10 representam os resultados gerais observados da aplicação de cada algoritmo na base de testes. No primeiro caso, para a aeronave 10, todos os algoritmos foram capazes de prever a falha antes que esta ocorresse. Observa-se também a importância de se utilizar a média móvel como critério para predição, visto que, principalmente no caso dos três algoritmos inferiores, existem pontos azuis (que representam a

probabilidade de falha) acima do valor limite de cada modelo meses antes da falha acontecer. Dessa forma, a média móvel atua como um amortecedor do efeito de dispersão dos pontos azuis.

No caso da aeronave 4, nenhum dos algoritmos foi capaz de prever a primeira falha, entretanto, nota-se o aumento da média móvel à medida que a segunda falha se aproxima em todos os modelos. Apenas os algoritmos GBC e MLPC foram capazes de prever o segundo evento, enquanto os demais modelos ficaram próximos ao valor limite, porém sem atingi-lo. A previsão do segundo evento, entretanto, não foi considerada na função de custo, visto que quando a primeira falha ocorreu sem previsão houve remoção da válvula e cancelamento do voo, conforme as premissas adotadas na análise. Se for considerado que houve remoção da válvula logo após o primeiro evento, os dados gravados a seguir deixam de ser representativos, pois seriam gravados com uma nova válvula instalada. Ainda assim, observa-se que os dois modelos que previram o segundo evento de falha obtiveram melhor performance analisando graficamente.

Para o terceiro cenário mostrado, relativo aos dados da aeronave 6, nota-se que nenhum dos modelos obteve êxito na predição da falha. A média móvel da probabilidade de falha apresentou um leve aumento no período próximo à falha da válvula reguladora de pressão em alguns modelos, mas essa alteração não foi expressiva o suficiente para chegar próximo ao valor limite. Visto que os modelos demonstraram maior grau de certeza em eventos como da aeronave 10 (e outras aeronaves com previsões bem-sucedidas) e parcial indiferença em eventos como da aeronave 6 (e outras aeronaves com falhas sem previsões), infere-se que possa haver algum outro modo de falha da válvula reguladora de pressão que não foi representado pelas variáveis escolhidas no presente estudo. Para as previsões exitosas, se entende que os parâmetros considerados foram representativos para a obtenção dos resultados.

5 CONCLUSÃO

Considerando os objetivos iniciais do presente estudo, verifica-se que foram cumpridos através da aplicação dos algoritmos propostos na base de dados e da avaliação de custos de manutenção, performance e ganhos resultantes dos modelos obtidos. O modelo que obteve o melhor desempenho geral, considerando todas as métricas avaliadas foi o *Multi-Layer Perceptron Classifier*, que obteve resultados comparativamente satisfatórios na análise de redução do custo de manutenção e a melhor performance na análise gráfica em linha do tempo.

O modelo de regressão logística, no entanto, obteve resultados levemente superiores na análise de custos e tem a vantagem de ser mais simples para configuração de parâmetros do algoritmo. É necessário ressaltar que os hiperparâmetros do modelo MLPC (DTC e GNB) podem ser definidos em um processo semelhante ao utilizado para os valores limites de predição em função do custo resultante. Este processo, no entanto, não foi feito neste estudo e poderia melhorar o desempenho deste algoritmo ao custo de maior demanda de processamento computacional.

Com relação ao desempenho geral dos algoritmos, foi obtida redução do custo de manutenção, mas foi observado que os modelos nem sempre são capazes de prever eventos de falha. Como mencionado durante a avaliação gráfica em linha do tempo, é possível que haja outros modos de falha da válvula reguladora de pressão que não foram representados pelas variáveis analisadas. Nesse caso, seria necessário o estudo minucioso dos voos em que houve falhas sem previsão para viabilizar um levantamento de quais parâmetros do sistema de controle ambiental (ECS) estão se comportando de forma inesperada. Dessa forma, novos parâmetros poderiam ser criados e adicionados na base de dados para aplicação nos modelos.

Ressalta-se também que os arquivos analisados são provenientes de aeronaves de uma única região do mundo. Para análises comparativas de efeitos ambientais e criação de novas variáveis potencialmente significativas, novos comportamentos do sistema podem ser obtidos com a inserção de dados de outras regiões, sujeitas a diferentes tipos de condições ambientais.

REFERÊNCIAS

- ADHIKARI, Partha *et al.* Machine learning based data driven diagnostics & prognostics framework for aircraft predictive maintenance. *In: INTERNATIONAL SYMPOSIUM ON NDT IN AEROSPACE*, 10., 2018, Dresden. **Proceedings** [...]. Dresden, 2018.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **Regulamento brasileiro de aviação civil**: de 05 de fevereiro de 2014: requisitos de aeronavegabilidade: aviões categoria transporte. Seção 1. §25.1459. Flight data recorders. Brasília, fev. 2014. p. 366.
- ALBON, Chris. **Python machine learning cookbook**: practical solutions from preprocessing to deep learning. Sebastopol: O'Reilly Media, 2018.
- ALPAYADIN, Ethem. **Introduction to machine learning**. 2. ed. Cambridge: MIT Press, 2010. p. 581.
- ASHRAE. **ASHRAE Handbook**: HVAC applications. Ashrae Standard, 2019. cap.13.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 5462**: confiabilidade e manutenibilidade. Rio de Janeiro: ABNT, 1994.
- AUSTRALIAN TRANSPORT SAFETY BUREAU (ATSB). Australian Government (org.). Black box flight recorders. **Safety Publications**, 1 abr. 2014. Disponível em: <https://www.atsb.gov.au/publications/2014/black-box-flight-recorders/>. Acesso em: 4 nov. 2020.
- BROWN, Richard. **The MRO market & key trends**. London: Aviation Week Ap&M Europe, 2018.
- CANTWELL, Brian. **Aircraft and rocket propulsion**. Stanford: Department of Aeronautics and Astronautics, 2019. p. 337.
- CHRISTIANSEN, Brian. The past and the future of industrial maintenance management. **International Society of Automation**, c2020. Disponível em: <https://blog.isa.org/past-and-future-industrial-maintenance-management>. Acesso em: 25 out. 2020.
- CHUKWUEKWE, Douglas. **Condition monitoring for predictive maintenance**: a tool for systems prognosis within the industrial internet applications. 2016. Dissertação (Mestrado em Engenharia de Produção) – Norwegian University of Science and Technology, Trondheim, 2016.
- DALZUCHIO, Jovani *et al.* Machine learning and reasoning for predictive maintenance in industry 4.0: current status and challenges. **Computers in Industry**, v. 123, 2020.
- DELTA AIRLINES. **Delta TechOps expanding predictive maintenance capabilities with new Airbus partnership**. 2019. Disponível em: <https://news.delta.com/delta-techops-expanding-predictive-maintenance-capabilities-new-airbus-partnership>. Acesso em: 22 out. 2020.

DUARTE, Rodrigo. Voo a bordo do E195-E2. **Aero Magazine**, v. 306, n. 312, p. 56-60, nov. 2019.

FAROOQ, Muhammad *et al.* Cost of quality: evaluating cost-quality trade-offs for inspection strategies of manufacturing processes. **International Journal of Production Economics**, p. 156-166. jun. 2017.

FEDERAL AVIATION ADMINISTRATION. **Code of federal regulations**: part 25: airworthiness standards: transport category airplanes. Washington, DC, 1996.

FEDERAL AVIATION ADMINISTRATION. **Federal aviation regulations**: part 125: certification and operations: airplanes having a seating capacity of 20 or more passengers or a maximum payload capacity of 6,000 pounds or more. Seção 125.225. Washington, DC, 1988.

FEDERAL AVIATION ADMINISTRATION. **Federal aviation regulations**: part 121: operating requirements: domestic, flag, and supplemental operations: digital flight data recorders for transport category airplanes. Washington, DC, Seção 121.344, 2009.

GONZALES, Diego *et al.* Assessing the influence of the scale of operations on maintenance costs in the airline industry. **Journal of Transport Literature**, v. 10, n. 3, set. 2016.

GRIFFIS, Joseph *et al.* Voxel-based Gaussian naïve Bayes classification of ischemic stroke lesions in individual T1-weighted MRI scans. **Journal of Neuroscience Methods**, p. 97-108, 2016.

HASHEMIAN, H.M. **State-of-the-art predictive maintenance techniques**, v. 60, n. 10, p. 3480-3492, 2011.

INTERNATIONAL AIR TRANSPORT ASSOCIATION (IATA). **Air passenger market analysis**. IATA Economics Report, p. 4, 2018.

INTERNATIONAL CIVIL AVIATION ORGANIZATION (ICAO). **Effects of novel coronavirus (COVID-19) on civil aviation**: economic impact analysis. Montreal: Air Transport Bureau, 2020.

INTERNATIONAL CIVIL AVIATION ORGANIZATION. **Annual Global Statistics 2019**: presentation of 2019 air transport statistical results. Montreal: ICAO, 2019.

YAN, J. *et al.* Industrial big data in an industry 4.0 environment: challenges, schemes, and applications for predictive maintenance. **IEEE Access**, v. 5, p. 23484-23491, 2017.

KOIVU, Heli. Safety versus cost: the rush hour years of aviation. **Hindsight17**, European Organisation For Safety of Air Navigation, p. 60-64, jul. 2013

LANDGREBE, David; SAFAVIAN, Rasoul. A survey of decision tree classifier methodology. **School of Electrical Engineering**. West Lafayette, p. 660-674, 1991.

ORTEGA, Marlis *et al.* Fast gaussian naïve bayes for searchlight classification analysis. **Neuroimage**, p. 471-479, 2017.

POÓR, Peter *et al.* **Historical overview of maintenance management strategies:** development from breakdown maintenance to predictive maintenance in accordance with four industrial revolutions. *Industrial Engineering and Operations Management*, 2019. p. 495-504.

ZHU, Q. *et al.* A condition-based maintenance policy for multi-component systems with a high maintenance setup cost. **OR Spectrum**, v. 37, no. 4, p. 1007-1035, 2015.

SCHOLZ, Matthias. **Approaches to analyse and interpret biological profile data.** 2006. Tese (Doutorado em bioinformática) – Max Planck Institute of Molecular Plant Physiology, University of Potsdam, Potsdam, 2006.

SFORZA, Pasquale. Engine selection. *In*: SFORZA, Pasquale. **Commercial airplane design principles.** Oxford: Butterworth-Heinemann, 2014. p. 81-118.

SMITH, Anthony; HINCHCLIFFE, Glenn. Preventive maintenance: definition and structure. *In*: SMITH, Anthony; HINCHCLIFFE, Glenn. **Reliability-Centered Maintenance (RCM):** gateway to world class maintenance. Oxford: Butterworth-Heinemann, 2004. p. 19-37.

SMITH, Ricky; HAWKINS, Bruce. Common ground. *In*: SMITH, Ricky; HAWKINS, Bruce. **Lean maintenance.** Oxford: Butterworth-Heinemann, 2004. p. 1-19.

SPAKOVSKY, Zoltán. **Unified:** thermodynamics and propulsion. Massachusetts: Massachusetts Institute of Technology, 2002.

STEELE, Brian *et al.* **Algorithms for data science.** Switzerland: Springer, p. 438, 2016.

STOOP, John; KAHAN, James. Flying is the safest way to travel: how aviation was a pioneer in independent accident investigation. **European Journal of Transport and Infrastructure Research.** Netherlands, p. 116-128, jul. 2005.

WELTE, Rebecca *et al.* A method for implementation of machine learning solutions for predictive maintenance in small and medium sized enterprises. **Procedia CIRP**, v. 93, p. 909-914, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2212827120306223>. Acesso em: 20 out. 2020.