



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2024/04.10.17.25-TDI

**ABORDAGEM HÍBRIDA DE APRENDIZADO DE
MÁQUINA PARA AVALIAÇÃO DE ESTADO DE
DEGRADAÇÃO DE UMA VÁLVULA PNEUMÁTICA
AERONÁUTICA**

Henrique Mendes Castilho

Tese de Doutorado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Rafael Duarte Coelho dos Santos, e Wallace Hessler Leal Turcio, aprovada em 01 de abril de 2024.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4B4ST48>>

INPE
São José dos Campos
2024

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2024/04.10.17.25-TDI

**ABORDAGEM HÍBRIDA DE APRENDIZADO DE
MÁQUINA PARA AVALIAÇÃO DE ESTADO DE
DEGRADAÇÃO DE UMA VÁLVULA PNEUMÁTICA
AERONÁUTICA**

Henrique Mendes Castilho

Tese de Doutorado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Rafael Duarte Coelho dos Santos, e Wallace Hessler Leal Turcio, aprovada em 01 de abril de 2024.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4B4ST48>>

INPE
São José dos Campos
2024

Dados Internacionais de Catalogação na Publicação (CIP)

Castilho, Henrique Mendes.

C278a Abordagem híbrida de aprendizado de máquina para avaliação de estado de degradação de uma válvula pneumática aeronáutica / Henrique Mendes Castilho. – São José dos Campos : INPE, 2024.

xxii + 130 p. ; (sid.inpe.br/mtc-m21d/2024/04.10.17.25-TDI)

Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2024.

Orientadores : Drs. Rafael Duarte Coelho dos Santos, e Wallace Hessler Leal Turcio.

1. Prognóstico. 2. Análise de falhas. 3. Aprendizado de máquina. 4. Modelo computacional. I.Título.

CDU 004.85



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÃO



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

DEFESA FINAL DE TESE DE HENRIQUE MENDES CASTILHO BANCA Nº 059/2024, REGISTRO 141755/2019

No dia 01 de abril de 2024, por videoconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Doutor em Computação Aplicada, com a exigência de que o trabalho final a ser publicado deverá incorporar as correções sugeridas pela Banca Examinadora, com revisão pelo(s) orientador(es).

Novo Título: “ABORDAGEM HÍBRIDA DE APRENDIZADO DE MÁQUINA PARA AVALIAÇÃO DE ESTADO DE DEGRADAÇÃO DE UMA VÁLVULA PNEUMÁTICA AERONÁUTICA”.

Membros da Banca:

Dr. Stephan Stephany – Presidente – INPE
Dr. Rafael Duarte Coelho dos Santos – Orientador – INPE
Dr. Wallace Hessler Leal Turcio – Orientador – EMBRAER
Dr. Wlamir Olivares Loesch Vianna – Membro Externo – EMBRAER
Dr. Luis Carlos de Castro Santos – Membro Externo – IME/USP



Documento assinado eletronicamente por **Rafael Duarte Coelho dos Santos, Pesquisadora**, em 03/04/2024, às 07:55 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Stephan Stephany, Pesquisador Titular**, em 03/04/2024, às 09:20 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luis carlos de castro santos (E), Usuário Externo**, em 04/04/2024, às 18:51 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Wallace Hessler Leal turcio (E), Usuário Externo**, em 05/04/2024, às 07:28 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Wlamir Olivares Loesch Vianna (E), Usuário Externo**, em 09/04/2024, às 18:48 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **11825728** e o código CRC **F605DD00**.

Referência: Processo nº 01340.002623/2024-12

SEI nº 11825728

“Ninguém caminha sem aprender a caminhar, sem aprender a fazer o caminho caminhando, refazendo e retocando o sonho pelo qual se pôs a caminhar.”

PAULO FREIRE em *“Pedagogia da Esperança”*, 1992

*À minha esposa **Danielle**, ao meu pai **Walmir** e à
minha mãe **Sandra***

AGRADECIMENTOS

Agradeço à minha esposa Danielle, pelo apoio nas horas difíceis e pela força em vencer os obstáculos. Agradeço aos meu orientador Rafael Santos, meu co-orientador Wallace Turcio e meus colegas Alan Ferreirós e Luis Carlos Santos pelo apoio e retorno, que permitiram a realização deste trabalho.

RESUMO

Na aviação comercial, os eventos de manutenção não-planejados representam uma elevação dos custos de manutenção, além de exigir maior tempo de aeronave em solo, impactando os custos operacionais e a imagem da empresa. Estes impactos podem ser agravados caso uma falha que impeça a decolagem ocorra em um aeroporto despreparado para receber ações de manutenção de determinada aeronave ou linha aérea. No entanto, caso se possua uma estimativa do estado de degradação para alguns equipamentos chaves, que possuem grandes cargas de trabalho podem estar sujeitos a maiores taxas de falha, é possível planejar ações de manutenção essenciais que sejam acomodadas no cronograma de operação da aeronave, evitando assim ações corretivas inesperadas. Para tanto, é possível utilizar algoritmos de aprendizado de máquina em conjunto com análise de modelos, dados de sensores e técnicas de filtragem para estimar de forma mais precisa o estado de degradação de um equipamento. Este trabalho utilizou dados de campo de uma frota de aeronaves, coletando informações de sensores e de registros de manutenção para a criação de uma base de dados de índices de degradação, que passaram por diversas técnicas de filtragem, desde as clássicas, como a média móvel, até mais complexas, como o filtro de Kalman. Com os dados de frota, diversos algoritmos de aprendizado de máquina de complexidades diferentes foram treinados e seu desempenhos registrados frente à resposta esperada. O trabalho então utilizou um modelo matemático computacional do equipamento, que após a validação com dados de campo, foi utilizado para prover uma base de voos sintéticos com evolução de degradação conhecida. Estes voos então foram utilizados para enriquecer a base de dados de voos de campo, permitindo que os algoritmos de aprendizado de máquina gerassem resultados mais precisos após um novo treinamento. Esta análise híbrida, que alia dados de campo a dados de modelo computacional, se mostrou efetiva no aumento de desempenho da solução proposta.

Palavras-chave: Prognóstico. Análise de Falhas. Aprendizado de Máquina. Modelo computacional.

HYBRID MACHINE LEARNING APPROACH FOR ASSESSMENT OF THE DEGRADATION STATE OF AN AIRCRAFT PNEUMATIC VALVE

ABSTRACT

In commercial aviation, unplanned maintenance events represent an increase in maintenance costs, as well as requiring a longer aircraft downtime, impacting operating costs and the company's image. These impacts can be more noticeable if a failure that causes a non-dispatch situation occurs at an airport that is unprepared to receive maintenance actions for a particular aircraft or airline. However, if there is an estimate of the state of degradation for some key equipment, which have high workloads and may be subject to higher failure rates, it is possible to plan essential maintenance actions that are accommodated in the aircraft's operating schedule, thus avoiding unexpected corrective actions. To this end, it is possible to use machine learning algorithms in conjunction with model analysis, sensor data and filtering techniques to more accurately estimate the state of degradation of a piece of equipment. This work used field data from a fleet of aircraft, collecting information from sensors and maintenance records to create a database of degradation indices, which were subjected to various filtering techniques, from classic ones such as the moving average, to more complex ones, such as the Kalman filter. With the fleet data, various machine learning algorithms of varying complexity were trained and their performance recorded against the expected response. The work then used a computational mathematical model of the equipment, which after validation with field data, was used to construct a database of synthetic flights with known degradation evolution. These flights were then used to enrich the field flight database, allowing the machine learning algorithms to generate more accurate results after further training. This hybrid analysis, which combines field data with computer model data, proved to be effective in increasing the performance of the proposed solution.

Keywords: Prognostic. Failure Analysis. Machine Learning. Computational model.

LISTA DE FIGURAS

	<u>Pág.</u>
3.1 Estrutura de um neurônio artificial.	25
3.2 Rede neural multi-camadas.	26
3.3 Funções de transferência.	26
3.4 Árvore de Decisão - Ideal.	31
3.5 Árvore de Decisão - Não Ideal.	32
3.6 Hiperplano ótimo.	33
3.7 Hiperplano ótimo generalizado.	35
3.8 Transformação dos dados pelo <i>kernel</i>	39
3.9 Matriz de Confusão.	43
4.1 Sistema de sangria de ar.	46
4.2 Sistema de sangria de ar.	47
4.3 Diagrama esquemático do modelo da válvula e seus parâmetros.	48
4.4 Diagrama esquemático dos parâmetros.	50
4.5 Validação do modelo - pressão.	54
4.6 Validação do modelo - corrente.	54
4.7 Fluxograma geral para análise dos dados de frota.	56
4.8 Dados de voo longe da troca.	59
4.9 Dados de voo próximo à troca.	60
4.10 Comparação de dados de voo.	62
4.11 Índice construído.	63
4.12 Construção do grau de degradação.	65
4.13 Grau de degradação - único evento.	66
4.14 Grau de degradação - múltiplos eventos.	67
4.15 Grau de degradação - filtro de Kalman.	67
4.16 Construção do nível de degradação - aplicação de filtro.	68
4.17 Nível de degradação.	68
4.18 Índice para uma única aeronave por data.	70
4.19 Índice para uma única aeronave.	71
4.20 Boxplot dos dados puros.	72
4.21 Mapa de calor dos índices.	72
4.22 Efeito de cada filtro nos dados puros.	75
4.23 Boxplot dos dados filtrados.	76
4.24 Poda de complexidade de custo mínimo.	78
4.25 Exemplo de dados de campo para a geração de dados sintéticos.	79
4.26 Entrada de pressão para a geração de dados sintéticos.	81

4.27	Dados sintéticos perfeitos.	81
4.28	Dados sintéticos não perfeitos.	82
4.29	Degradação nos dados de frota (a) Gradual e (b) Súbita.	83
4.30	Boxplot dos dados puros sintéticos.	84
4.31	Degradação não-ideal / Degradação ideal.	86
4.32	Exemplo de degradação não contínua ao longo do tempo.	86
4.33	Boxplot para o mesmo índice com proporções diferentes.	88
5.1	Árvore de classificação.	94
5.2	Objetivo do aprendizado de máquina (a), probabilidade de pertencimento (b) e probabilidade de pertencimento filtrada (c).	95
5.3	Influência da quantidade de dados sintéticos no treinamento, árvore de classificação, taxa de verdadeiros positivos.	100
5.4	Influência da quantidade de dados sintéticos no treinamento, árvore de classificação, taxa de verdadeiros negativos.	101
5.5	Influência da quantidade de dados sintéticos no treinamento, SVM, taxa de verdadeiros positivos.	103

LISTA DE TABELAS

	<u>Pág.</u>
3.1 Matriz de Custo.	30
4.1 Base de Dados de Voos.	55
4.2 Base de dados de voos.	64
4.3 Base de dados de voos sintéticos.	84
5.1 Desempenho da árvore de classificação para dados de frota.	93
5.2 Desempenho da rede neural para dados de frota.	96
5.3 Desempenho dos algoritmos de classificação para dados de frota sem filtragem.	97
5.4 Desempenho dos algoritmos de classificação para dados de frota com filtro média móvel.	98
5.5 Desempenho da árvore de classificação para dados de modelo.	99
5.6 Desempenho da árvore de classificação para dados híbridos, proporção 0%.	102
5.7 Desempenho da árvore de classificação para dados híbridos, proporção 30%.	102
5.8 Desempenho do SVM para dados híbridos, proporção 0%.	104
5.9 Desempenho do SVM para dados híbridos, proporção 30%.	104
5.10 Tempo de treinamento.	105
6.1 Desempenho da árvore de classificação para dados de frota.	107
6.2 Desempenho das Redes Neurais para dados de frota.	108
6.3 Desempenho da árvore de classificação para dados híbridos, proporção 30%.	108
6.4 Desempenho das Redes Neurais para dados híbridos, proporção 30%.	108
A.1 Desempenho da árvore de classificação para dados de frota.	127
A.2 Desempenho da floresta para dados de frota.	127
A.3 Desempenho do gradiente para dados de frota.	127
A.4 Desempenho do KNN para dados de frota.	128
A.5 Desempenho do SVM para dados de frota.	128
A.6 Desempenho das Redes Neurais para dados de frota.	128
B.1 Desempenho da árvore de classificação para dados híbridos, proporção 30%.	129
B.2 Desempenho da floresta para dados híbridos, proporção 30%.	129

B.3	Desempenho do gradiente para dados híbridos, proporção 30%. . . .	130
B.4	Desempenho do KNN para dados híbridos, proporção 30%.	130
B.5	Desempenho do SVM para dados híbridos, proporção 30%.	130
B.6	Desempenho das Redes Neurais para dados híbridos, proporção 30%. .	130

LISTA DE ABREVIATURAS E SIGLAS

CART	–	Classification And Regression Tree
EMBRAER	–	Empresa Brasileira de Aeronáutica
GB	–	Gradient Boost
INPE	–	Instituto Nacional de Pesquisas Espaciais
KNN	–	K-Nearest Neighbors
PHM	–	Prognostics and Health Management
PRSOV	–	Pressure Relief and Shut-Off Valve
RNA	–	Rede Neural Artificial
SVM	–	Support Vector Machine

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Motivação	3
1.2 Pergunta científica	4
1.3 Objetivo	6
2 REVISÃO BIBLIOGRÁFICA	9
2.1 <i>Prognostics and Health Management</i>	9
2.2 Aprendizado de máquina	13
2.3 Métricas de desempenho	15
2.4 Dificuldades de implementação	17
2.5 Modelos computacionais baseados na física	18
2.6 Modelos baseados em dados de campo	19
2.7 Modelos híbridos	20
2.8 Filtragem	21
3 TEORIA	25
3.1 Redes Neurais Artificiais	25
3.2 Árvores de classificação e regressão	27
3.3 Support Vector Machines	32
3.3.1 <i>Kernel</i>	37
3.4 Filtro de Kalman	39
3.4.1 O filtro de Kalman estendido	41
3.5 Desempenho de algoritmos de aprendizado de máquina	42
4 METODOLOGIA	45
4.1 Equipamento estudado	45
4.2 Modelo	47
4.2.1 Validação	52
4.3 Estrutura da análise de dados	56
4.4 Dados de frota	57
4.4.1 Dados de sensores	57
4.4.2 Dados de manutenção	58
4.5 Análise de dados de sensores	58

4.6	Construção de índices	60
4.6.1	Base de dados	64
4.7	Nível de degradação	64
4.8	Análise Exploratória de Dados	68
4.8.1	Seleção de índices	71
4.9	Filtragem dos índices	73
4.10	Aprendizado de máquina	77
4.11	Geração de dados sintéticos	78
4.12	Análise exploratória de dados sintéticos	83
4.13	Análise híbrida	84
4.14	Resultados esperados	88
5	RESULTADOS E DISCUSSÃO	91
5.1	Aprendizado de máquina direcionado por dados de frota	92
5.2	Aprendizado de máquina direcionado por modelo	98
5.3	Aprendizado de máquina híbrido	99
6	CONCLUSÕES	107
	REFERÊNCIAS BIBLIOGRÁFICAS	115
	APÊNDICE A - RESULTADOS APRENDIZADO DE MÁQUINA DADOS DE FROTA	127
	APÊNDICE B - RESULTADOS APRENDIZADO DE MÁQUINA DADOS HÍBRIDOS	129

1 INTRODUÇÃO

Os custos de manutenção de uma aeronave representam uma parcela significativa dos custos operacionais diretos, DOC (*Direct Operational Cost*) (GOLDBERG et al., 2018), e representam uma parte significativa do orçamento de uma linha aérea (PARK; O'KELLY, 2018). Os custos operacionais diretos incluem capital, tripulação, combustível, manutenção e taxas. Os custos de manutenção são ainda mais significativos na presença de eventos não planejados, mas análises de saúde podem identificar falhas latentes e acelerar o processo de identificação de falhas e manutenção (CUSATI et al., 2022). Além dos custos normais, somam-se os impactos e custos associados ao fato de se manter a aeronave parada, evento também chamado de AOG (*Aircraft On Ground*), muito crítico, uma vez que as margens operacionais das empresas aéreas não são grandes.

Os custos operacionais diretos podem ser classificados como custos de voo e de manutenção, além de depreciação dos equipamentos, tanto da aeronave em si quanto seus sistemas. Para compreender os benefícios da interação entre o estágio de projeto e engenharia e o suporte de serviço de campo, é possível utilizar um modelo que estima os custos do ciclo de vida de um produto. Uma das vantagens é a inclusão de dados de falhas de campo na tomada de decisões nos estágios iniciais do desenvolvimento (HEGDE, 1994), além de suporte a pós-venda, sendo no caso da indústria aeronáutica o suporte às frotas dos clientes.

Os custos de manutenção durante a vida útil da aeronave geralmente consideram dois fatores: a mão de obra e os materiais necessários. Uma das preocupações do cronograma de manutenção para linhas aéreas é maximizar o tempo disponível para operação da aeronave (CHAIKA, 2023). O alto custo de manutenção também não afeta apenas linhas aéreas comerciais, mas também escolas de aviação para treinamento de pilotos, que podem dar mais valor aos custos de partes e pessoal do que para o custo indireto de uma aeronave parada (YU et al., 2020). Para aliviar o impacto dos custos operacionais diretos, é possível considerá-los durante o processo de desenvolvimento da aeronave, com o objetivo de criar um produto competitivo, pois estes custos são considerados pelos clientes (VALERI, 2015) e incorporar sua redução durante o projeto da aeronave é benéfico para a empresa.

Um dos possíveis caminhos para auxiliar as tarefas de manutenção é a estimativa do tempo restante para a falha ou a estimativa de saúde de equipamentos. Para tanto, podem ser utilizadas técnicas de aprendizado de máquina aliadas às análises estatísticas tradicionais de relatórios de manutenção e histórico de

sensores. Para certos sistemas, a abordagem por dados de sensores é mais indicada pois o modelo pode ser complexo demais e para grandes volumes de dados, técnicas clássicas tendem a ser computacionalmente intensas. Novas técnicas permitem a possibilidade de trabalhar em tempo real, com o algoritmo de previsão embarcado na aeronave (LU et al., 2019). A abordagem por dados pode utilizar o método de classificação, utilizado neste trabalho, para classificar estados de degradação, métodos de regressão para estimar ciclos de falha ou prever a data da falha até métodos não supervisionados para detectar operação anormal (ABDURAKIPOV; BUTAKOV, 2020).

Previsões de falha ou inferência do estado de degradação são alcançadas ao analisar tendências históricas e padrões que se repetem ao longo de um período (KELLEHER et al., 2020). No caso de sistemas aeronáuticos, tais tendências podem ser inferidas através da análise de diversos dados, que incluem:

- Sensores: as medições realizadas pelos sensores da aeronave são gravadas e podem ser acessadas posteriormente. Dados de sensores podem indicar comportamento anormal quando comparados com o comportamento esperado.
- Mensagens: gravadas no computador da aeronave, indicam comportamentos anormais e são mostradas à tripulação.
- Relatórios de manutenção: registram ações de manutenção realizadas, que variam desde intervenções planejadas ou emergenciais.

Este trabalho visa melhorar os resultados obtidos somente com dados de campo para a classificação do estado de degradação de um equipamento, através da utilização de dados provenientes de um modelo matemático computacional do mesmo, com a pretensão de tornar a estimação do estado de degradação do equipamento mais precisa. Para tanto, é necessário obter um modelo de tendência de degradação, que foi obtido através da análise exploratória dos dados de campo. O modelo matemático computacional foi utilizado para fornecer dados que irão complementar a base de dados de campo. Dessa forma, adotou-se uma abordagem híbrida entre dados de campo e modelo matemático computacional.

Os dados de entrada, tanto de campo como de modelo, serão processados por diversas técnicas de aprendizado de máquina, com a finalidade de encontrar padrões nos dados que viabilizem a classificação do estado de degradação do equipamento, baseado em índices calculados a partir dos dados de entrada. Estes algoritmos serão supervisionados (KOTSIANTIS, 2007), com a saída dese-

jada sendo construída a partir da análise dos dados de sensores e de relatórios de manutenção da frota. Além do desempenho absoluto, uma comparação foi conduzida entre diferentes tipos de algoritmos de aprendizado de máquina para determinar se existe algum que seja superior aos outros para o tipo de aplicação estudado neste trabalho.

Como um dos objetos de estudo deste trabalho é a saúde do equipamento, apresenta-se PHM (*Prognostics and Health Management*) como o nome dado ao campo de estudo da saúde de equipamentos e sistemas, aliado a técnicas de prognóstico, que visam prever o estado de saúde de um equipamento ou sistema, para auxiliar no planejamento de possíveis intervenções. Um dos objetivos do PHM é auxiliar a reduzir o número de falhas inesperadas, através do monitoramento contínuo dos componentes de interesse e prever falhas com antecedência o suficiente para permitir um planejamento adequado da manutenção do sistema. O componente principal do PHM é o prognóstico, que se trata de uma técnica que propõe prever uma falha antes de ocorrerem (CASTILHO, 2016).

Um dos desafios do prognóstico por dados de campo é a falta de dados até o momento da falha. É possível utilizar modelos computacionais para simulação de falhas, o que é especialmente útil quando ao analisar casos cujos dados de sensores estão gravados até o momento no qual o equipamento se torna incapaz de continuar seu funcionamento (SAXENA et al., 2008). Algumas falhas, especialmente as de motor, tendem a se propagar pelo equipamento, comprometendo-o por completo caso a incipiência da degradação não seja detectada. Para o sistema analisado neste trabalho, o sistema ambiental, o diagnóstico de falhas é uma das partes mais complexas de ensaios tanto em solo como em voo, com mensagens de falha sendo refletidas para a tripulação. Porém, a causa raiz das falhas pode ser difícil de ser encontrada. Através da simulação das lógicas que ativam mensagens de falha, a causa raiz pode ser encontrada mais facilmente (HAIYAN, 2019). Outra dificuldade enfrentada é o desequilíbrio dos dados de classificação de saúde, pois a degradação dos equipamentos pode apresentar relações temporais complexas e, nesta condição, os relatórios de manutenção são bastantes úteis no aumento de desempenho do aprendizado através da utilização de técnicas de processamento de linguagem natural (DANGUT et al., 2021).

1.1 Motivação

Existem três principais casos que motivam este trabalho.

O primeiro caso é para aeronaves que já fazem parte do mercado há anos. For-

necer uma estimativa do tempo restante para uma falha é uma ação de mitigação dos impactos negativos causados pelas paradas inesperadas, além de auxiliar o trabalho da área de suporte ao cliente. Um sistema de prognóstico e análise de falhas bem implementado em uma aeronave já presente no mercado pode mitigar a necessidade de se realizar modificações de grande custo, com o objetivo de atingir metas de custo de manutenção que não estavam tão bem estabelecidas na fase de projeto, porém são necessárias para manter o produto competitivo no mercado.

O segundo caso considera modelos de aeronaves novas, para as quais um sistema de prognóstico pode ser vendido como serviço adicional. Este caso é semelhante ao anterior, porém com viés de negócio diferente. A diferença seria vender o serviço de manutenção programada, baseada no prognóstico de falhas do sistema, além da venda da aeronave. A estimativa do estado de degradação de um componente pode auxiliar no planejamento da manutenção da aeronave.

No campo de atuação do INPE, o resultado dessa pesquisa pode trazer benefícios para as áreas de Engenharia e Tecnologia Espacial, especialmente as linhas de pesquisa de Combustão e Propulsão. Outra área potencialmente beneficiada seria a de Computação Aplicada, com ambas as linhas de pesquisa: Modelagem Computacional e Tecnologia da Informação e Extrato de Informações. Entende-se que essa pesquisa está alinhada com os objetivos estratégicos um e dois do Plano Diretor 2016 a 2019 do INPE, que consideram dotar o país de capacidade própria no desenvolvimento de ciclo de vida de sistemas espaciais e também realizar atividades de pesquisa e desenvolvimento para o domínio de tecnologias críticas e geração de produtos e processos inovadores necessários ao Programa Espacial Brasileiro, com ênfase na transferência de conhecimento ao setor produtivo (INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2016).

1.2 Pergunta científica

A pergunta científica que se deseja responder é “Como o uso combinado de dados de campo e modelos pode aumentar a assertividade de prognóstico de falhas?”. Para tanto, pretende-se adotar uma solução híbrida de aprendizagem de máquina utilizando dados de campo e modelos computacionais. A utilização de dados de campo é valiosa pois observa o fenômeno analisado, neste caso a degradação de um equipamento aeronáutico, quando sujeito às condições de operação de campo, que submetem o equipamento a variações e estresses ambientais que podem não estar presentes em laboratórios.

Soluções focadas em dados de campo (ou modelos físicos) se valem de modelos

de tendência, utilizando técnicas estatísticas e de aprendizado de máquina, buscando correlacionar características de observações com eventos. As soluções baseadas em modelos matemáticos computacionais consideram os efeitos físicos de uma falha de um componente no comportamento do sistema através da modelagem de ambos em alta fidelidade. Ambas as soluções podem se beneficiar de dados de sensores, seja para obter uma massa de dados para análises estatísticas ou para validar e suportar o modelo matemático do sistema. Técnicas de aprendizado de máquina podem ser utilizadas em ambas as soluções, para auxiliar na busca de um padrão que represente uma falha, ou na previsão da vida útil remanescente, baseada em dados históricos reais aliados a dados de modelo teórico.

A principal contribuição científica deste trabalho é um método para melhorar a detecção de estados elevados de degradação de um sistema submetido a grandes distúrbios com o sistema de controle compensando em parte a degradação. A ideia principal é utilizar um modelo matemático computacional do sistema analisado, que após a validação frente a dados de campo, pode ser utilizado para reproduzir voos com estados de degradação conhecidos, enriquecendo a base de dados de campo. Com uma base de dados mais completa, o desempenho de algoritmos de aprendizado de máquina pode ser melhorado pois haverá mais exemplos para o treinamento. Além disso, existe o efeito do controlador: o sistema analisado opera em malha fechada, o que pode dificultar (ou no mínimo atrasar) a identificação da falha e a previsão da vida útil remanescente, visto que as degradações podem ser compensadas pelo controlador.

Outras considerações incluem o fato de que parte da literatura ou analisa estatisticamente os dados de sensores ou analisa modelos de alta fidelidade separadamente, apresentando lacunas científicas para métodos que utilizam ambos dados de campo e modelo juntamente. Outra possibilidade de contribuição está no fato dos fenômenos e sistemas estudados na literatura apresentarem menos aplicações reais, como questões humanas e de operação da linha aérea que podem trazer desafios adicionais para o tratamento de dados. Com a utilização de modelos computacionais fiéis, é possível obter exemplos livres de influências externas e focar na degradação dos equipamentos e na operação do sistema.

O modelo computacional pode permitir complementar o conjunto de dados na região do envelope que apresente poucos dados de campo. Dada a alta fidelidade, é possível inserir diferentes níveis de degradação no modelo com a certeza de que uma dada falha ocorreu no momento desejado, o que auxilia a completar a

massa de dados a ser observada por técnicas direcionadas por modelo. O modelo também pode ser utilizado para compreender as condições de falha de voos onde há dúvidas sobre o que a ocasionou.

1.3 Objetivo

O objetivo deste estudo é estimar o estado de degradação de um componente aeronáutico através da análise de dados reais de campo aliados ao modelo matemático computacional do sistema. Os dados reais incluem sensores, relatórios de manutenção e mensagens geradas pelo sistema de monitoramento da aeronave.

O sistema a ser analisado foi o sistema pneumático, responsável pela sangria de ar de estágios de alta pressão do compressor do motor, pelo seu condicionamento e alimentação dos sistemas de ar condicionado, de proteção contra gelo e de pressurização de cabine. O ar sangrado do motor é denominado *bleed* e possui temperatura e pressão elevadas. Um trocador de calor, uma válvula moduladora de vazão de ar, um sensor de temperatura e um controlador são utilizados em um sistema de controle de temperatura para reduzi-la. A sua pressão é controlada por um sistema de controle de pressão composto por uma válvula reguladora de pressão conhecida como PRSOV (*Pressure Regulating Shut-Off Valve*), por um sensor de pressão e um controlador. Esta válvula em particular é o objeto de estudo deste trabalho. Tipicamente essas válvulas são instaladas na *nacelle* do motor, que coloquialmente é o capô do motor. Estando instaladas nessa região, a PRSOV é exposta a níveis elevados de vibração e de temperatura ambiente, bem como tanto por sua instalação como por sua função, essa válvula opera com pressões e temperaturas elevadas em sua entrada. Além disso, os constantes distúrbios exigem que essa válvula seja modulada constantemente durante o voo, contribuindo para seu desgaste.

O principal resultado esperado é uma estimativa precisa e robusta do estado do estado de degradação, suportada por dados de campo de frotas aéreas e pelo conhecimento da física do sistema para dar significado para a análise estatística e de aprendizado de máquina. A principal dificuldade esperada é em relação aos dados, que podem conter informações incompletas ou fora do envelope de operação normal.

Adicionalmente, uma comparação entre os métodos mais clássicos de aprendizado de máquina poderá trazer informações valiosas sobre suas aplicabilidades no campo de PHM, como Redes Neurais e Árvores de Classificação, por exemplo. Caso uma árvore apresente desempenho semelhante a uma rede neural

para o caso estudado, a preferência se dará por técnicas mais simples, pois são mais fáceis de projetar e compreender, além de apresentarem menor tempo de processamento. Outra característica considerada é a facilidade de acesso às regras de aprendizado. Por exemplo, obter o raciocínio usado por uma árvore é mais fácil do que para um SVM, que se trata de uma técnica que não permite acesso trivial às suas regras de classificação.

2 REVISÃO BIBLIOGRÁFICA

O objetivo deste capítulo é apresentar o estado da arte em relação ao escopo do trabalho. É importante ter conhecimento das tecnologias estudadas, a fim de contribuir de forma efetiva para o desenvolvimento tecnológico da área. Neste capítulo são apresentados tópicos como PHM, técnicas de Aprendizado de Máquina, métricas de desempenho, análises com dados de frota, modelagem computacional, além de questões éticas e negociais dos tópicos estudados. O detalhamento teórico das técnicas utilizadas será visto no Capítulo 3.

2.1 *Prognostics and Health Management*

Um dos objetivos das técnicas do *Prognostics and Health Management* (PHM) é descobrir se um determinado componente está degradado, avaliando seu grau de saúde. É possível, através de técnicas de aprendizado de máquina, determinar se um componente está degradado ou não a partir de dados de voo e registros de manutenção (MOREIRA, 2012). O uso de dados de voo e registros de manutenção é especialmente útil, pois estes dados podem revelar alterações no comportamento de um equipamento com poucos equívocos.

Um dos conceitos da área de PHM é a *Remaining Useful Life* (RUL). De forma simples, a RUL é uma previsão do tempo remanescente que um equipamento tem antes de que possa exigir reparo ou troca. Ao levar tal conceito em consideração, as equipes de manutenção podem otimizar o cronograma de manutenção com o objetivo de reduzir o tempo em que a aeronave se encontra indisponível. Existem diversas técnicas para a previsão da RUL (OKOH et al., 2014), com a possibilidade de combiná-las em uma única solução. Além disso, seria possível aliar dados de campo e falha ao conhecimento do sistema por um especialista. No entanto, são necessários dados que vão até o momento da falha, visto que o cálculo da RUL é baseado em regressão.

Um dos desafios do PHM é a grande quantidade de dados. Além do desafio do tempo computacional para processar grandes quantidades de dados, nem toda a coleção de dados é útil para analisar um determinado problema. Uma estimativa da vida útil restante de um componente pode ser obtida apenas analisando dados de frota aliados a técnicas de aprendizado de máquina, como Redes Neurais Artificiais (RIBEIRO, 2015). O especialista do sistema pode analisar as respostas de um sistema saudável e a de um com falha e definir quais são os índices que mais influenciam na resposta do sistema a um determinado estímulo. Em particular, sistemas que possuem modelos matemáticos se aproveitam de análises de sensibilidade para determinar a influência da mudança de parâmetros em sua

resposta.

Porém, pode ser desejável estimar os parâmetros de falhas utilizando certos algoritmos, desde os simples como a regressão linear até os mais complexos como as Redes Neurais Artificiais (PASCOAL, 2013). Dessa forma, é possível obter resultados mesmo que o analista não seja especialista no sistema, embora seja altamente desejável que este faça parte das análises. No entanto, na prática nem sempre isso é possível, devido à restrições de tempo e orçamentárias.

Em certos casos, o analista não precisa ter conhecimento da procedência dos dados nem de seu significado físico para se capaz de estimar o tempo restante para um certo evento (BAPTISTA, 2018). Apenas de posse de dados de sensores censurados e relatórios de manutenção, é possível realizar uma análise preditiva da falha de um determinado componente se valendo de técnicas de aprendizado de máquina. Contudo, esta análise é puramente estatística. Em conjunto com o conhecimento do sistema, uma estimativa mais precisa pode ser obtida. Além da estimativa de vida útil restante, é possível também, de posse do modelo matemático do sistema, identificar o tipo de falha, direcionando de forma mais precisa as eventuais ações de manutenção (CASTILHO, 2016).

Um dos passos mais importantes da análise é a mineração de dados. O volume de dados gerado pelos sistemas de gravação de dados da aeronave é enorme e novos dados são gerados a todo momento, e algumas técnicas podem auxiliar os analistas em selecionar os dados mais significativos. Uma das mais efetivas é a análise de *clusters*. Tais técnicas de mineração de dados quando utilizadas nos dados de leituras de sensores registrados na aeronave são capazes de identificar indicadores precursores de falhas (LIMA, 2017).

É possível se valer da utilização conjunta de modelo computacional e dados de voo em tempo real sem utilizar aprendizado de máquina (WANG, 2012). Ao comparar a saída esperada de um modelo computacional com o dado lido de sensores em tempo real, é possível prever certos eventos em um futuro próximo e tomar ações corretivas no mesmo voo. Contudo, é desejável sempre prever a falha com mais tempo de antecedência, para que as ações corretivas sejam tomadas em solo antes do voo.

Certos sistemas permitem que o PHM seja utilizado de forma ativa, formando o conceito de *Life Extending Control* (LEC) (RAY, 2001). Utilizando um controlador clássico (como PID, Proporcional Integral Derivativo) em conjunto com técnicas de aprendizado de máquina, é possível obter um balanço entre desempenho e vida útil, especialmente de componentes vitais que trabalham sob grande es-

três, como é o caso de foguetes e estruturas de aeronaves de asa rotativa.

A vida útil de um equipamento é geralmente estimada durante seu desenvolvimento (GUO, 2001). Certos componentes são mais importantes em análises de fadiga, principalmente os rotativos localizados em regiões de alto estresse térmico. Por razões de segurança, o limite de troca de certas partes é conservativo, mesmo que não sejam apresentados sinais de degradação no momento da troca. Um prognóstico mais preciso pode evitar trocas desnecessárias e aumentar o limite de vida do equipamento. Utilizando modelos matemáticos e computacionais de um sistema, aliados a controles ativos e análises de sensores e relatórios de manutenção, é possível então estender o limite de vida e detectar falhas de forma preditiva.

No entanto, os resultados destes tipos de análises geralmente produzem curvas unidimensionais de saúde de um componente, que podem ser utilizadas para quantificar a degradação. O uso de Redes Neurais Recorrentes torna possível a extração de mais informações (SHAHID; GHOSH, 2014), que podem fornecer uma maior introspecção na dinâmica das falhas de sistemas complexos.

Os maiores desafios na detecção de anomalias e falhas na área da aviação se devem ao fato de que os dados apresentam alto volume e dimensionalidade, são heterogêneos, multi-modais e temporais (BASORA et al., 2019). Técnicas clássicas como vizinho mais próximo e *clustering* não apresentam bons resultados para dados com alta dimensionalidade, a não ser que alguma técnica de pré-processamento seja utilizada (VIANNA et al., 2015).

Outro grande desafio da área de PHM é definir um indicador de degradação de um sistema complexo, como o de controle de fornecimento de ar condicionado. Como existem diversos parâmetros de desempenho, é necessário uma técnica que os combine em um único indicativo de saúde, em vez de possuir um indicador para cada componente do sistema. Uma possível solução seria uma estimativa de estados multi-variável (SUN et al., 2019a). A vantagem deste método é que diversos parâmetros que caracterizam falhas do sistema podem ser combinados em um único indicador, além de ser uma técnica baseada em dados de campo e não em modelos computacionais.

Um dos problemas que podem atingir a área da aeronáutica são as ações de manutenção imperfeitas (HU et al., 2018), pois é geralmente assumido que ações de manutenção reiniciam os níveis de taxas de degradação, o que nem sempre é verdade. Para contornar este problema, uma modelagem estocástica pode ser utilizada, estimando uma degradação residual pós-manutenção através da

estimação da verossimilhança máxima. Parâmetros de degradação podem ser estimados por meio da análise de dados sem conhecimento do sistema através da função de densidade de probabilidade, que por sua vez são utilizados para estimar a vida útil remanescente.

Além de trabalhar com dados puros, o PHM também pode ser utilizado em conjunto com modelos computacionais de componentes, onde a física destes é representada em alta fidelidade, permitindo a análise de falhas via modelo computacional apenas (TAN et al., 2013). Ao desenvolver os modelos dos componentes, é possível incluir em seu projeto a representação matemática da evolução da falha. Tal representação pode auxiliar o algoritmo de PHM ao fornecer dados preciso sobre falhas desconhecidas em campo, para que ações de manutenção possam ser tomadas antes que existam dados reais sobre uma falha específica, além de fornecer informações sobre a evolução da falha de equipamentos e sistemas inseridos em produtos novos.

As etapas do processo de prognóstico de saúde geralmente podem ser divididas em aquisição de dados, construção de um indicador de saúde, divisão dos estágios de degradação e cálculo da vida útil remanescente (LEI et al., 2018). Aquisição de dados captura os dados de sensores instalados no sistema. Alguns problemas afetam este estágio, como falta de dados de degradação de longo prazo, interferência externa, dados proprietários não disponíveis ao desenvolvedor do sistema de PHM e o fato de que tais sistemas raramente são permitidos que rodem até a falha sem antes passar por uma ação de manutenção. Geralmente, é difícil inferir o grau de dano de um sistema. Para equipamentos industriais, paradas frequentes para inspeção não são permitidas, e mesmo em paradas programadas, a inspeção pode não atingir um nível profundo o suficiente para detectar certas falhas e alguns componentes podem apresentar modos de falha complicados.

Os sinais capturados pelos sensores podem ser utilizados para construir um indicador de saúde do sistema capaz de fornecer informações sobre a condição do sistema, simplificando o processo de PHM e produzindo resultados precisos. Duas questões partem deste problema: como construir um indicador e como avaliá-lo. (HU et al., 2012) propõe utilizar dois indicadores, o PHI (*Physics Health Indicator*) e o VHI (*Virtual Health Indicator*). O PHI utiliza primariamente uma variável física, obtida através de um sensor, para inferir a saúde do componente ou sistema, tipicamente utilizando métricas como RMS. A limitação é que tais sinais devem estar diretamente relacionados à física da falha que se pretende captu-

rar. Já os VHIs são obtidos através da aplicação de diversas operações sob os PHIs. Tais operações podem ser desde simples transformações lineares até a aplicação de PCA (*Principal Component Analysis*) (WIDODO; YANG, 2011).

Algumas características dos indicadores de saúde podem auxiliar no desempenho do sistema de PHM. Uma destas características é a monotonicidade (JAVED et al., 2015). Dado que a degradação dos equipamentos é irreversível sem ações externas, um indicador deve, idealmente, ser monotônico. Outras características incluem robustez, visto que as medidas dos sensores devem estar livre de ruídos e flutuações aleatórias antes de serem fornecidas para o sistema de PHM. A capacidade do indicador de capturar a tendência de degradação ao longo do tempo também é importante, bem como a capacidade do indicador de identificar uma falha específica. Algumas métricas podem ser baseadas em mais de um indicador de saúde (MOSALLAM et al., 2016), sendo desejável que haja algum tipo de correlação entre tais indicadores.

A degradação dos equipamentos e sistemas pode ser dividida em diversos estágios de saúde (PELLEGRINO et al., 2016). Alguns tipos de equipamentos apresentam degradação linear ao longo do tempo. Para estes tipos, não é necessária nenhuma divisão. Porém, alguns tipos de equipamentos apresentam tendências de degradação diferentes, sendo difícil inferir o estado de degradação durante o estágio saudável, pois o sistema funciona dentro do esperado. Quando a degradação atinge um nível crítico, o desempenho do sistema pode cair abruptamente, exigindo ações de manutenção o mais rápido possível. Outros equipamentos/sistemas apresentam estágios discretos de degradação. Até certo ponto, a degradação é estável, mas esta tende a aumentar bruscamente e então se manter estável até certo ponto, quando aumenta novamente e então se mantém estável.

2.2 Aprendizado de máquina

Alguns métodos para a estimação do estado de degradação de um equipamento incluem técnicas de aprendizado de máquina, capazes de compreender relações complexas que talvez sejam difíceis de se expressar através dos métodos anteriores. Algoritmos de aprendizado de máquina mais comuns que foram explorados neste trabalho incluem Árvores de Decisão, Redes Neurais Artificiais e SVM (*Support Vector Machines*)

Uma das técnicas de aprendizado de máquina mais populares no campo de estudo do PHM são as Redes Neurais Artificiais, mais especificamente as redes profundas. Estas últimas são particularmente efetivas para extrair informações

de dados de alta dimensionalidade, mas o fato de que as regras de classificação ou regressão não podem ser acessadas pode tornar os resultados da técnica difíceis de serem interpretados com sucesso (BAPTISTA, 2018).

As chamadas máquinas de aprendizado extremas (HUANG et al., 2004) são um tipo de Rede Neural Artificial com uma única camada escondida capaz de tornar a etapa de aprendizado mais rápida do que redes neurais convencionais. A vantagem deste tipo é que a camada escondida pode conter funções de ativação não-diferenciáveis e não é propensa a cair em mínimos locais. Tais redes podem ser utilizadas em conjunto com filtros de partículas para atingir previsões de vida útil remanescente de certos equipamentos eletrônicos (SUN et al., 2019b). Os filtros são utilizados para definir o conjunto dos pesos de entrada da rede extrema. Para a previsão da vida útil remanescente de baterias aeronáuticas, este método se mostrou acurado, no entanto para outras aplicações o desempenho das máquinas de aprendizado extremas ainda deve ser verificado.

Outro tipo de Rede Neural Artificial que possui aplicações na área de PHM são as redes LSTM (*Long Short Term Memory*), propostas por (HOCHREITER; SCHMIDHUBER, 1997). LSTM são um tipo de rede neural recorrente que permite que o gradiente retro-propagado permaneça sem modificação ao longo das iterações do processo de treinamento, eliminando o problema do mesmo tender a zero. Uma possível aplicação é a estimativa de vida útil remanescente de baterias de íon de lítio utilizadas em satélites (WANG et al., 2018). Aqui também é demonstrada a importância do conhecimento do especialista para a área de PHM, pois os dados de treinamento do algoritmo de aprendizado de máquina provém de um ajuste polinomial de uma variável que dita a saúde do equipamento. Sem o especialista, fica difícil identificar quais variáveis devem ser monitoradas para inferir a saúde do equipamento ou sistema.

Support Vector Machine (SVM) é uma técnica de aprendizado de máquina baseada em dados estatísticos (CORTES; VAPNIK, 1995). É possível analisar as trajetórias entre hiperplanos para estimar o estado de degradação e a velocidade de degradação de sistemas complexos (GALAR et al., 2013), obtendo diversas estimativas de estado de degradação para diferentes componentes e combinando-as em uma única estimativa global de um sistema. O trabalho de (WIDODO; YANG, 2011) apresenta uma forma modificada de SVM denominada *Relevance Vector Machine* (RVM), que provê uma interpretação probabilística de suas saídas. Tal técnica se mostra capaz de prever o estado de degradação, mas por se tratar de uma técnica primariamente estatística, pode ser propensa a *overfitting* em está-

gios de degradação inexistente ou baixa. O SVM é geralmente utilizado aliado à outras técnicas, como o caso da *Auto-Regressive Integrated Moving Average* (ARIMA) (LASHERAS et al., 2015), que se trata de uma generalização da média móvel auto-regressiva. É possível utilizar o ARIMA para prever valores de entrada de um algoritmo de aprendizado de máquina SVM (ORDÓÑEZ et al., 2019), obtendo resultados mais acurados do que se apenas utilizando tais técnicas separadamente.

2.3 Métricas de desempenho

Uma etapa importante da análise do estado de degradação é o estabelecimento de métricas para o desempenho da estimação. É possível identificar três tipos de métricas: aquelas baseadas em verdades fundamentais; as que dependem de dados de falha e troca; e as que dependem de apenas de dados de campo.

As verdades fundamentais são medidas estatísticas clássicas, utilizadas para medir erros não apenas de previsões, mas de modelos em geral. O *Root Mean Square Error* RMSE e o intervalo de confiança podem ser utilizados para medir indicar os erros da previsão de modelos de estimação de vida útil remanescente e estado de degradação (YANG et al., 2016). O horizonte de previsão é definido como o tempo entre o instante no qual os resultados da previsão satisfazem um determinado critério de desempenho e o fim da vida do componente (SAXENA et al., 2010). Para tal métrica, quanto maior o horizonte de previsão, maior é a credibilidade da estimativa. É desejável medir a acurácia da previsão em tempos futuros, para tanto pode ser utilizada uma métrica que representa a qualidade da previsão (SAXENA et al., 2010), que representa quanto de uma previsão cai em um determinado limite de precisão da verdade fundamental a um determinado período. A acurácia relativa é baseada no erro relativo da previsão do estado de degradação em um determinado tempo. As métricas anteriores medem o desempenho em um único ponto no tempo. Para fornecer uma métrica mais compreensiva, é possível atribuir pesos e criar uma acurácia relativa acumulada.

As métricas dependentes de dados de falha utilizam uma base de dados de componentes similares ou que apresentam comportamento similar. Estes métodos capturam perfis de degradação e os comparam com dados medidos do sistema para determinar qual perfil de degradação mais se assemelha. É possível analisar a trajetória da degradação e a transição entre diferentes perfis de degradação para inferir informações sobre o comportamento do sistema analisado (CHAO et al., 2021). Contudo, nem sempre é possível obter dados em quantidade e qualidade suficientes para se conduzir tais análises. A técnica *Step-Stress Accelera-*

ted Degradation Analysis (SSADL) reduz o custo experimental e fornece resultados bons mesmo quando há falta de dados (TSENG; WEN, 2000). Contudo, é desejável ter em mente outras considerações, como variabilidade da degradação ao longo do tempo, variabilidade dos índices de degradação em diferentes unidades do sistema e erros de medições. Uma possível solução seria baseada no conceito de FHT *First Hitting Time* em conjunto com algoritmos genéticos (HAO et al., 2018).

O trabalho de (WANG et al., 2019) traz a ideia de que a vida de um equipamento pode ser definida pelo FHT do momento em que o processo de degradação cruza um certo limite de falha. Tal método leva em consideração as incertezas dos processos operacionais e pode trazer resultados mais precisos do que apenas a previsão de alguns passos futuros na vida do componente ou sistema.

É possível mapear dados gravados de eventos do sistema utilizando um sistema SCADA (*Supervisory Control And Data Acquisition*) em um vetor binário, permitindo a avaliação de dependência entre diferentes eventos (HERP et al., 2018). A partir destes dados, um algoritmo de transição de estados pode ser utilizado para estimar estados futuros com base em estados atuais, o que proporciona uma ideia da degradação de um sistema em um determinado ponto futuro, a partir do qual é possível estimar o estado de degradação utilizando inferência bayesiana.

As métricas mencionadas dependem de dados passados já existentes, sendo consideradas portanto como métricas *offline*. Existem métricas baseadas em medições disponíveis em tempo real, sendo assim consideradas métricas *online*. Os modelos de degradação recentes em sua maioria possuem perfil de degradação de dimensão única e é analisado apenas um equipamento ou sistema. Na realidade, muitas vezes é desejável obter métricas multi-variáveis de desempenho do sistema, como modelos de degradação marginal para diferentes deteriorações, uma estrutura para modelagem de dependências de falhas e consideração de erros de medição (PENG et al., 2019). Tal modelo de trabalho pode ser capaz de prever o estado de degradação com maior precisão, devido ao maior número de informações disponíveis tratadas adequadamente.

Um possível método para a estimação do estado de degradação de sistemas complexos de forma *online* é utilizar variações do método de Monte Carlo, como combinações com cadeia de Markov e Monte Carlo sequencial, em conjunto com modelos de espaço de estados e inferência bayesiana (HU et al., 2018). Tal ideia parte da premissa que o processo de degradação é estocástico, contínuo e não

reversível. O estado de degradação é então estimada com base na degradação dos estados comparados com um limite estabelecido pelo especialista. Contudo, tal método pode ser suscetível a erros de medição.

Ao aliar modelos matemáticos, modelos empíricos e conhecimento teórico dos mecanismos de falha, é possível obter uma previsão do estado de degradação e da vida útil remanescente de um sistema sem dados de falha prévios (AL-MOHAMAD et al., 2020). Tal abordagem se vale de uma variação do filtro de Kalman chamada de *Adaptive Joint Extended Kalman Filter* (AJEKF) para estimar os estados e parâmetros a partir de um modelo global, se se trata de uma junção de um modelo teórico com um modelo empírico. O fim da vida de um sistema pode ser estabelecido teoricamente por um humano, seja por desempenho do sistema ou por requisito de autoridades reguladoras. Mesmo não sendo vital, a utilização de dados de campo que incluam falhas pode ajudar a atingir previsões mais precisas.

Quando analisando o estado de degradação de sistemas, um problema que vem à tona são as dependências entre as degradações dos diversos equipamentos que compõe o sistema. Tal fato é agravado pois geralmente algumas degradações podem ser mascaradas por outras, tornando o estudo das relações entre tais degradações uma parte importante da previsão do estado de degradação. Uma possível solução mapeia essas relações em uma matriz de difusão de coeficientes (XI et al., 2018) em conjunto com o filtro de Kalman sequencial.

2.4 Dificuldades de implementação

Algumas dificuldades práticas da implementação de sistemas de PHM foram estudadas por (MARTIN et al., 2019). Uma primeira análise deve definir quais modos de falhas um sistema pode encontrar e se os sinais que os detectam estão disponíveis e quais sensores podem ser adicionados ao sistema. Um dos maiores problemas práticos seriam os casos de sinais não disponíveis, porém instrumentais para o monitoramento do PHM. Outra parte importante de um sistema de PHM são os modelos de alta fidelidade, capazes de representar a operação normal de um componente, bem como seus modos de falha. Um ponto de atenção seria a validação de tais modelos, mesmo que sejam realísticos. Tal validação pode ser feita via teste em voo, mas estes tendem a ser caros e demorados. Uma alternativa são os testes em bancada, ou na indústria aeronáutica, é possível utilizar o *iron bird*, uma estrutura onde os principais componentes de diversos sistemas da aeronave são instalados em localizações no espaço relativas à própria aeronave. Tal estrutura é utilizada para obter dados de ensaio durante o

projeto de uma aeronave, e pode ser utilizada para validar os modelos de alta fidelidade que fazem parte do sistema completo de PHM.

A tarefa fundamental do PHM é o prognóstico, que se trata de prever com confiança a falha de um determinado sistema ou componente. Caso a previsão do estado de degradação seja confiável e precisa, as ações de manutenção podem ser planejadas em tempo real, evitando perdas econômicas relacionadas à parada de equipamentos. Existem diversas abordagens possíveis para este fim, mas elas podem ser divididas em três tipos: baseadas em modelos computacionais, baseadas em dados de campo e híbridas (XIA et al., 2018).

2.5 Modelos computacionais baseados na física

Modelos computacionais baseados na física se valem de modelos matemáticos que descrevem o comportamento de equipamentos e sistemas. Para utilizar tais modelos em análises de previsão do estado de degradação, é necessário ter conhecimento da física da falha, que envolve a determinação do dano cumulativo baseado em observações de sensores e parâmetros do modelo. Ao se valer de modelagem de física da falha, é preciso manter em mente alguns requisitos: monitoramento de parâmetros críticos, simplificação de dados e determinação de ciclos antes que a falha ocorra (RAMAKRISHNAN; PECHT, 2003). O uso de modelos baseados na física pode ser útil em situações onde precisão teórica é necessária, como a introdução de falhas e a consideração de diferentes condições operacionais. Além disso, devido à incorporação do entendimento físico do sistema ou equipamento, a mudança de características de treinamento de algoritmos de aprendizado de máquina é relativa à mudança de parâmetros do modelo (AHMADZADEH; LUNDBERG, 2013).

Modelos computacionais podem ser aliados à modelos de degradação como filtros de partículas para prever o estado de degradação, sendo um dos tipos possíveis um filtro de Bayes baseado em simulações de Monte Carlo (SUN et al., 2019). O filtro de partículas tem como base o modelo de estados e realiza a previsão baseado em dados históricos de medição a priori e em conjunto com o modelo computacional baseado na físico da degradação do equipamento, atualiza a previsão *a posteriori* para atingir maior confiabilidade. A vantagem é que dispensa dados de falhas e por utilizar modelos físicos e filtros, não há problemas de *overfitting* de dados de treinamento.

Outro uso de modelos computacionais é a habilidade de projetar indicadores de saúde, que devem ter significado físico claro. Utilizando técnicas como Redundância Analítica (VERDIÈRE et al., 2015), constroem-se indicadores de saúde

cuja taxa de desvio da norma demonstra a degradação. De posse dos indicadores, a tendência da degradação pode ser modelada via processos de Markov em conjunto com filtro de Kalman para a estimação do parâmetro de desvio (DJEZIRI et al., 2020).

Modelos matemáticos de sistemas físicos podem ser validados caso existam modelos experimentais, mesmo que simplificados. A parametrização do modelo matemático é em parte características físicas do sistema, como comprimentos, massas e ângulos. Outras técnicas são conhecimento de especialistas e observação do modelos experimental (CUSUMANO et al., 2002). Com o modelo validado, degradações podem ser introduzidas e simuladas.

Modelos matemáticos validados com dados experimentais podem ser utilizados também em casos onde um experimento de escala é impossível de um ponto de vista de segurança ou financeiro (SONG et al., 2015), como em análises de desastres como incêndios. No entanto, novamente um conhecimento matemático detalhado do sistema físico é necessário, bem como a representação fiel do experimento na fase de validação.

Entretanto, estes trabalhos utilizam modelos experimentais simples e em ambientes controlados. Para dados de operação real, especialmente na área aeronáutica, a literatura carece de contribuições. Dados são propriedade das empresas que detém a posse das aeronaves, sejam protótipos dos fabricantes ou aeronaves de série das linhas aéreas. Dados dos gravadores das aeronaves das linhas aéreas salvam dados em frequências baixas para evitar tamanhos excessivos de arquivos. Esta escolha pode afetar a validação de modelos, especialmente quando existe um controlador, pois certas dinâmicas de fenômenos físicos podem apresentar respostas em frequência elevada.

2.6 Modelos baseados em dados de campo

Enquanto as abordagens de modelos computacionais baseados na física provém bons resultados, existe a necessidade de uma compreensão profunda do comportamento físico. Abordagens baseadas em dados tendem a possuir maior flexibilidade de aplicação. Uma das abordagens possíveis é o modelo Weiner, aplicado a sistemas que apresentam degradação contínua. Modelos de previsão de vida útil remanescente podem ser baseados na degradação do componente ou sistema, como é o caso do processo Weiner, caracterizado pelo movimento Browniano. Diversos fatores que afetam a degradação de um equipamento ou sistema podem ser descritos pelo processo Weiner, como não-linearidade, variabilidade, covariação e multi-variação (ZHANG et al., 2018). Adicionalmente, o

processo Wiener é capaz de modelar degradações lineares e não-lineares, visto que alguns sistemas apresentam degradação acelerada em seus estágios finais de vida.

O movimento Browniano pode ser utilizado para estimar o processo de degradação de equipamentos, sendo o estado de degradação dependente de certos parâmetros como desvio e escala, que podem ser estimados em conjunto com um filtro de partículas (DONG et al., 2018), estimando de forma *online* os parâmetros do modelo baseado no movimento Browniano. A previsão do estado de saúde e do estado de degradação se mostram satisfatórias com esta técnica.

Sistemas de prognóstico de falha podem ser utilizados com dados de pós-processamento, quando a leitura de dados *online* não é possível, como em alguns casos da indústria automotiva (GROSSO et al., 2020). Ao analisar dados operacionais, identificando ciclos de funcionamento, é possível construir uma relação entre os diferentes modos de falha e as respectivas severidades ao consultar um especialista. Aliado a um modelo capaz de descrever o processo físico, lacunas onde faltam dados podem ser preenchidas e um modelo baseado em dados apresenta uma maior efetividade.

Um dos desafios de modelos baseados em dados é a qualidade e quantidade dos dados, que frequentemente apresentam ruído, falta de dados para todas as condições, *outliers*, etc. (LIU; ZIO, 2018). Para lidar com este problema, algumas técnicas de aprendizado de máquina podem ser combinadas, como k-NN e lógica difusa. A aplicação de tais técnicas juntas permite escolher os pontos mais relevantes do conjunto de treinamento, separando aqueles que seriam realmente úteis no processo de identificação de falhas e estimação do estado de degradação.

2.7 Modelos híbridos

Para melhorar a estimação do estado de degradação, algumas abordagens combinam modelos físicos com modelo de dados, criando uma abordagem híbrida. É possível utilizar o modelo computacional baseado na física para prever o estado de degradação e o modelo de dados para monitorar a degradação (SUN et al., 2018). Em conjunto com sinais provenientes de sensores, o modelo de dados pode ser capaz de relacionar o estado atual do equipamento com o nível de degradação estimado pelo modelo computacional. O estado de degradação pode ser estimado por um processo Wiener que lê os dados do modelo híbrido.

Um dos pontos importantes da estimação do estado de degradação é a maneira

de quantificar sua confiabilidade. Diferentes abordagens de previsão podem ser: filtros de partículas aplicados a modelos físicos, modelos empíricos treinados com observações de degradação de sistemas similares e modelos empíricos treinados com dados de degradação do sistema exato de interesse. Um dos problemas levantados por modelos físicos seriam as imprecisões e simplificações do modelo matemático, que se propagam ao longo da análise, principalmente em casos de interação entre degradações. Uma possível solução seriam filtros de partículas para estimar estados desconhecidos e a adição de ruído para considerar fenômenos não representados pelo modelo que afetam sua resposta, como ruídos presentes em equipamentos reais. Na abordagem baseada em observações diretas da degradação, é importante a diversidade de dados para que o algoritmo de aprendizado de máquina seja capaz de inferir o comportamento correto. Sem uma quantidade adequada de dados, talvez exista a necessidade da construção de um modelo empírico para cobrir as áreas onde não há dados (BARALDI et al., 2013).

Dados medidos de degradação também podem ser utilizados para validar modelos físicos, principalmente em processos onde a ação de reparo também é uma degradação em si, como na previsão de desgaste de rodas de veículos ferroviários (ZENG et al., 2020). Modelos de degradação e de reparo podem produzir uma quantidade de dados suficiente para uma análise de Monte Carlo, com seu resultado validado por observações da degradação real, em uma abordagem híbrida indireta, onde a contribuição da parte direcionada por dados de sensores é um suporte para a parte baseada em modelos.

Informações sobre o processo de degradação podem ser obtidas através de inspeções periódicas (NGUYEN et al., 2018), porém a frequência de tais inspeções pode incorrer em um alto custo monetário e poucas inspeções podem implicar em falta de informações sobre o processo de degradação.

2.8 Filtragem

Técnicas de filtragem podem ser utilizadas em conjunto com algoritmos de aprendizado de máquina para melhorar a previsão. Técnicas simples como a média móvel podem ser utilizadas em conjunto com aprendizado incremental para inferir o estado de carga de baterias de íon de lítio (WANG et al., 2023), com a média móvel operando na remoção do ruído da medição. A média móvel ainda é utilizada em aplicações médicas de estudos epidemiológicos, com modelos de séries temporais ARIMA e SARIMA (ARUNKUMAR et al., 2021) para prever a dinâmica de modelos estatísticos de aprendizado de máquina. Filtros

convolucionais podem ser utilizados juntamente com técnicas de aprendizado de máquina extremo, reduzindo drasticamente o tempo de treinamento de redes neurais profundas (SANTOS et al., 2019).

Média móvel ponderada foi utilizada para suavizar índices extraídos de dados de processamento de minerais, em conjunto com aprendizado não-supervisionado para prever a dureza de minerais a partir de sua composição geoquímica (HOUSHMAND et al., 2023). A média móvel pode ser utilizada em conjunto do critério de máxima diferença de coordenada para detectar e classificar falhas em linhas de transmissão de alta tensão. O máximo ainda foi utilizado para extrair índices para o aprendizado (FARSHAD; KARIMI, 2021).

A média móvel ponderada exponencialmente traz melhorias para classificadores que lidam com quantidades grandes de dados em tempo real, ajudando na tarefa de monitoramento de taxa de erros de classificação (ROSS et al., 2012). Esta técnica também pode ser utilizada em conjunto com Redes Neurais Artificiais para controle de processos atômicos de semicondutores mais eficientes, provendo caracterização e controle para métricas de produção (TOM et al., 2022).

Filtros baseados na mediana móvel podem ser preferidos em relação aos baseados na média móvel quando os dados apresentam uma alta frequência de ruídos de impulso (REIBENSPIES, 1998). Ambas média e mediana móveis foram utilizadas em conjunto com um algoritmo de aprendizado de máquina, o SVM, para determinar o nível de combustível em tanques veiculares sob condições dinâmicas, provando que o pré-processamento dos dados com os filtros antes da aplicação do SVM realmente traz um resultado melhor do que sem a utilização de filtros ou com apenas os filtros (TERZIC et al., 2010).

O filtro baseado no desvio padrão possui aplicações para monitoramento de precisão analítica, detectando aumento para medidas de alto risco com baixa variação na área médica (KALITA; LYAKHOV, 2022). Outras aplicações incluem o processamento de sinais acústicos para atenuação de ruído e eventual localização de fontes sonoras (PENHALE; BARNARD, 2020), sendo o papel do desvio padrão móvel prover uma estimativa da direção do sinal.

Filtro de Kalman em conjunto com aprendizado de máquina pode ser utilizado para resolver de forma mais eficiente o problema de falta de dados em problemas de regressão e previsão de séries temporais, reduzindo o efeito de colinearidades múltiplas (NOBREGA; OLIVEIRA, 2019). O filtro de Kalman pode ser utilizado em conjunto com outros filtros, como a mediana móvel, para projetar algoritmos de determinação de distâncias para robôs industriais, aumentando o desempenho

em relação às técnicas convencionais (KALITA; LYAKHOV, 2022).

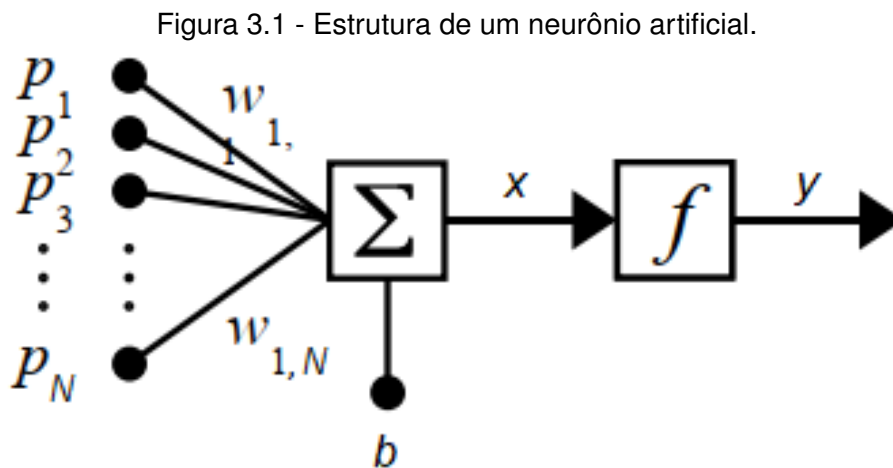
3 TEORIA

Ao longo das próximas seções, serão apresentados os fundamentos matemáticos necessários, bem como suas referências, para o desenvolvimento do trabalho.

3.1 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são redes computacionais inspiradas em sistemas nervosos biológicos, compostas de elementos simples que operam em paralelo (HAYKIN, 1998). Uma RNA é capaz de armazenar informações através de um processo denominado treinamento, um processo de ajuste dos pesos das conexões entre os neurônios. Tipicamente, no treinamento supervisionado há um mapeamento de entradas de um processo por saídas desejadas. Também existe a possibilidade de um treinamento não supervisionado, que usualmente é utilizado para identificar grupos de dados.

A estrutura geral de um único neurônio é ilustrada na Figura 3.1. Um conjunto de entradas é multiplicado por um conjunto de pesos e pode ser adicionado um viés escalar, também chamado de *bias*. Esta soma, por sua vez, passa por uma função de transferência e a saída desta é a saída do neurônio.

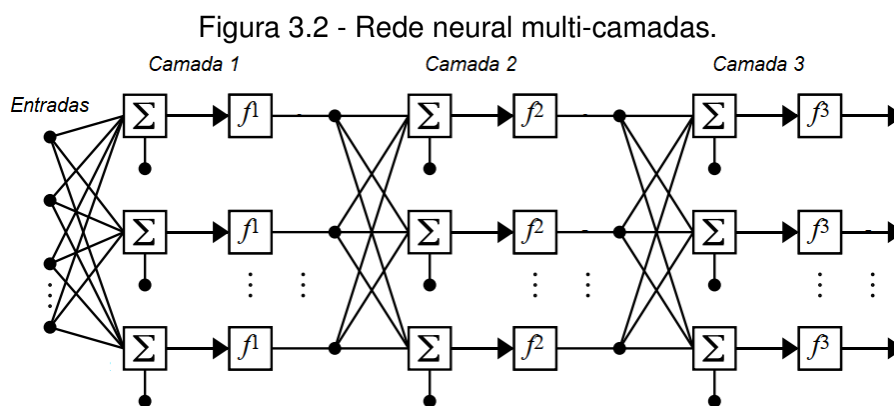


Fonte: Demuth e Beale (2000).

Sendo assim, a Equação 3.1 é a saída de um neurônio sozinho.


$$y = f(\sum w \cdot p + b) \quad (3.1)$$

Uma rede é formada de diversas camadas de neurônios. Cada camada tem a sua própria matriz de pesos, um vetor de *bias* e um vetor de saídas. Tal conceito pode ser observado na Figura 3.2. Um neurônio sozinho é denominado *perceptron*. Uma rede de diversas camadas de diversos *perceptrons* é denominada *Multi Layer Perceptron*, ou MLP.



Fonte: Demuth e Beale (2000).

É notável que as saídas de uma camada são as entradas da camada seguinte. As camadas de uma rede têm diferentes funções. A primeira é denominada camada de entrada. A última é a camada de saída. As intermediárias são denominadas camadas escondidas. As funções de transferência contidas em cada neurônio podem ser de diversos tipos, sendo as mais comuns ilustradas na Figura 3.3.



Fonte: Demuth e Beale (2000).

Neurônios com função de transferência do tipo degrau são geralmente utilizados

em redes de classificação, a função linear é usualmente utilizada para tratar problemas de filtragem de sinais ruidosos e a função sigmoideal é usada comumente em algoritmos de retro-propagação, por ser derivável.

Uma das propriedades mais importantes de uma RNA é a capacidade de aprender e melhorar seu desempenho quando confrontada com um problema. O aprendizado é um processo iterativo de ajuste dos pesos das sinapses com o objetivo de obter o menor erro possível. O treinamento é possivelmente concluído quando a RNA atinge um desempenho aceitável para uma entrada generalizada, pois existem outros critérios de parada. No aprendizado supervisionado, a rede conhece as saídas desejadas e aplica o fator de correção com o objetivo de diminuir o erro entre saída real e saída desejada.

Para redes de múltiplas camadas, um dos algoritmos mais comuns para o treinamento é o de retro-propagação (*backpropagation*), que se trata de um algoritmo de descida de gradiente onde os pesos da rede são alterados na direção negativa do gradiente da função de desempenho. O nome retro-propagação é devido ao fato de que os pesos são corrigidos da última camada para a primeira.

Um algoritmo simples de retro-propagação do erro pode ser descrito pela Equação 3.2.

$$w_{i+1} = w_i - L_i \nabla_i \quad (3.2)$$

Onde w é a matriz de pesos e *bias*, L é a taxa de aprendizado e ∇ é o gradiente da uma função de perda. O gradiente pode ser calculado principalmente de duas formas: incremental, onde os pesos são atualizados a cada exemplo entrada-saída apresentado ou por batelada (*batch*), onde os pesos são atualizados depois que todos os exemplos de entrada são apresentados à rede.

3.2 Árvores de classificação e regressão

Existem muitos tipos de algoritmos de árvores, mas este trabalho irá utilizar o CART (*Classification And Regression Trees*): Árvores de Classificação e Regressão. CART são métodos que utilizam dados de exemplo (treinamento) para construir árvores de decisão - que por sua vez classificam dados novos (TIMOFEEV, 2004).

CART respondem a perguntas binárias, por exemplo “a pressão é maior do que 30 psi?” ou “a válvula está fechada?”. Pode também ser robusto a valores atípicos, isolando-os em ramos individuais. O algoritmo CART consiste em construir

a árvore, podar ramos inúteis (*pruning*) e classificar dados desconhecidos.

Para construir a árvore inicial, a seguinte formulação matemática é utilizada (CASTILHO, 2016):

Seja t_p um nó-pai e t_r e t_l os nós-filhos. Que o conjunto de treinamento X com M variáveis e N amostras e o conjunto de classificação Y com N amostras e K classes. CART divide o conjunto de treinamento em partes menores, e divide os dados com o máximo de homogeneidade para os nós-filhos, definido pela função de impureza (3.3).

$$\Delta i(t) = i(t_p) - E[i(t_c)] \quad (3.3)$$

Sendo t_c os nós-filho. Denominando as probabilidades dos nós-filho de P_r e P_l , temos a Equação (3.4).

$$\Delta i(t) = i(t_p) - P_l i(t_l) - P_r i(t_r) \quad (3.4)$$

A cada nó o CART resolve o problema de maximização da Equação (3.5).

$$\operatorname{argmax}_{x_j \leq x_j^R, j=1, \dots, M} [i(t_p) - P_l i(t_l) - P_r i(t_r)] \quad (3.5)$$

A função de impureza mais comum é o índice de impureza de Gini, representado na Equação (3.6).

$$i(t) = \sum_{k \neq l} p(k|t)p(l|t) \quad (3.6)$$

onde k e l são os índices da classes e $p(k|t)$ é a probabilidade condicional da classe k considerando que estamos no nó t .

Ao aplicar o índice Gini na Equação 3.5, obtemos a medida da mudança de impureza na Equação 3.7.

$$i(t) = - \sum_{k=1}^K p^2(k|t_p) + P_l \sum_{k=1}^K p^2(k|t_l) + P_r \sum_{k=1}^K p^2(k|t_r) \quad (3.7)$$

O algoritmo Gini tenta localizar o máximo (ou mínimo) de acordo com a Equação (3.8):

$$\operatorname{argmax}_{x_j \leq x_j^R, j=1, \dots, M} \left[- \sum_{k=1}^K p^2(k|t_p) + P_l \sum_{k=1}^K p^2(k|t_l) + P_r \sum_{k=1}^K p^2(k|t_r) \right] \quad (3.8)$$

Esse algoritmo procura a maior classe na amostra de treinamento e a isola do resto dos dados.

A árvore produzida inicialmente em geral é muito complexa, possuindo centenas de nós em muitos casos. Para ser útil para um problema de classificação, a árvore precisa passar por um processo de poda de nós e ramos inúteis, chamado de *pruning*.

Existem muitos algoritmos para este fim, mas o utilizado foi o de validação cruzada, que procura uma proporção ótima entre a complexidade da árvore e o erro de classificação. Quanto maior e mais complexa a árvore, menor é o erro de classificação. Contudo, árvores muito grandes apresentam baixo desempenho para dados que fazem parte do conjunto de treinamento. A proporção ótima é encontrada através da função de custo-complexidade (3.9).

$$R_\alpha(T) = R(T) + \alpha(\tilde{T}) \rightarrow \min_T \quad (3.9)$$

onde $R(T)$ é o erro de classificação da árvore T . $\alpha(\tilde{T})$ é a medida da complexidade que depende da soma dos nós terminais \tilde{T} . α é o parâmetro da validação cruzada, em que uma parte dos dados é usada para treinar e outra para testar. O procedimento então se repete para sub-amostras aleatórias de mesmo tamanho dentro do conjunto de treinamento e validação. A complexidade da árvore é determinada pelo número de nós terminais \tilde{T} . É um processo que demora mais do que outros métodos, já que uma série de árvores é construída. Para classificar dados novos, a árvore final posta perguntas a cada nó, atribuindo uma resposta ou uma classe para a entrada.

Depois de construída, uma árvore pode fazer dois tipos de predição: pontual e distributiva. A primeira faz uma única suposição sobre a classe, dizendo “a classe é A” ou “a classe é B”. A segunda atribui uma probabilidade para cada classe. Para a predição pontual, a função perda, que mede os erros de classificação da árvore, pode ser a estratégia de validação mais adequada. Existem algumas maneiras comuns de se medir erros de classificação, porém a utilizada pelo algoritmo empregado neste trabalho é a perda média.

A noção principal é que alguns erros são mais custosos do que outros. Por exem-

plo, ao tentar classificar a válvula entre “saudável” e “falha”, se o algoritmo prever que uma válvula saudável possui falha, a aeronave pode sofrer paradas para manutenção desnecessária, custando tempo e dinheiro. Contudo, esta opção é muito melhor do que a alternativa - se uma válvula com falha for classificada como saudável, as consequências podem ser desastrosas. Haverá um custo para cada combinação de classe real e classe predita. Seja L_{ij} a perda (custo) de classificar uma observação como j quando na verdade é i . Para uma observação x , a árvore fornece probabilidades de classe $Pr(Y = i|X = x)$. O custo esperado de classificar j é apresentado na Equação (3.10):

$$L(Y = i|X = x) = \sum_i L_{ij} Pr(Y = i|X = x) \quad (3.10)$$

Uma matriz de custo possui o seguinte formato:

Tabela 3.1 - Matriz de Custo.

Verdade	Predição	
	Falha	Saudável
Falha	0	10
Saudável	1	0

Se os custos forem simétricos (matriz quadrada, com diagonal zero e outros elementos um), a função perda é o erro de classificação, que é apenas a fração dos casos atribuídos à classe errada. Assim, a árvore sempre irá prever a classe mais provável.

As vantagens do CART são:


- Dispensa pré-seleção de variáveis
- Os resultados são transformadas monotônicas e invariantes
- Lida bem com valores espúrios
- Computacionalmente rápido e sem premissas

As desvantagens são:

- Pode produzir árvores instáveis,
- Apenas produz divisões perpendiculares aos eixos.


As Figuras 3.4 e 3.5 ilustram árvores de decisão em diferentes conjuntos de dados, sem considerar técnicas de pré-processamento. Aqui, o problema não é das árvores em si, mas sim dos dados, que não são ortogonalmente separáveis no segundo caso.

Figura 3.4 - Árvore de Decisão - Ideal.



Fonte: Castilho (2016)

Figura 3.5 - Árvore de Decisão - Não Ideal.




Fonte: Castilho (2016).

3.3 Support Vector Machines

Support Vector Machine (SVM) é uma técnica de classificação estatística que visa separar duas ou mais classes através de um hiperplano. Geralmente, tal problema é restrito a trabalhar com duas classes por vez. O classificador deve ser capaz de classificar corretamente exemplos não apresentados durante o treinamento, isto é, deve possuir alta capacidade de generalização. A Figura 3.6 ilustra o hiperplano de separação ótima, isto é, aquele que maximiza a distância entre o classificador e o ponto mais próximo de cada classe, também denominado *margem* (CASTILHO, 2016).

Figura 3.6 - Hiperplano ótimo.



Fonte: Adaptado de Gunn (1998).

O problema é separar o conjunto \mathcal{D} de vetores de treinamento x e y que pertencem a duas classes diferentes. Conforme (GUNN, 1998):

$$\mathcal{D} = \{(x^1, y^1), \dots, (x^l, y^l)\}, \quad x \in \mathbb{R}^n, \quad y \in \{-1, 1\} \quad (3.11)$$

através de um hiperplano, representado pela Equação (3.12):

$$\langle w, x \rangle + b = 0 \quad (3.12)$$

onde w é um vetor de pesos, x as entradas e b um viés.

O conjunto de vetores é dado como otimamente separado quando as classes são separadas sem erro. Um hiperplano deve satisfazer as seguintes restrições:

$$y^i(\langle w, x_i \rangle + b) \geq 1, \quad i = 1, \dots, l \quad (3.13)$$

Que diz que a norma do vetor de pesos deve ser igual ao inverso da distância do ponto mais próximo do conjunto ao hiperplano. Tal distância de um ponto x ao hiperplano (w, b) é expressa pela Equação (3.14).

$$d(w, b; x) = \frac{|\langle w, x_i \rangle + b|}{\|w\|} \quad (3.14)$$

O hiperplano ótimo é encontrado ao se maximizar a margem ρ , respeitando as restrições da Equação (3.13). A margem é dada por:

$$\rho(w, b) = \frac{2}{\|w\|} \quad (3.15)$$

O hiperplano separa o conjunto de vetores de maneira ótima se os dados são separados sem erro e se a distância ao vetor mais próximo do hiperplano é maximizada. Tal hiperplano ótimo é definido se encontrarmos w e b que minimizem a norma de w ($\|w\|$) de forma que para todos os pontos (x_i, y_i) a Equação (3.13) seja verdade.

O hiperplano ótimo de separação é encontrado ao se minimizar a Equação (3.16).

$$\Phi(w) = \frac{1}{2}\|w\|^2 \quad (3.16)$$

Não é dependente de b se a Equação (3.13) for satisfeita (GUNN, 1998). Mudar b move o hiperplano na direção normal a ele mesmo. Dessa maneira, a margem não muda, mas o hiperplano não é mais ótimo, pois estará mais perto de uma classe do que da outra.

A solução da otimização é dada pelo ponto de inflexão do Lagrangiano representado pela Equação (3.17) (MINOUX, 1986):

$$\Phi(w, b, \alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^n \alpha_i (y_i [\langle w, x_i \rangle + b] - 1) \quad (3.17)$$

onde α são os multiplicadores de Lagrange. O Lagrangiano deve ser minimizado com respeito a w e b e maximizado com respeito a $\alpha \geq 0$. As Equações (3.18) e (3.19) representam o ponto de inflexão, que é mínimo do Lagrangiano Φ em relação à w e b .

$$\frac{\partial \Phi}{\partial b} = 0 \implies \sum_{i=1}^n \alpha_i y_i = 0 \quad (3.18)$$

$$\frac{\partial \Phi}{\partial w} = 0 \implies w = \sum_{i=1}^n \alpha_i y_i x_i \quad (3.19)$$

A solução do problema é dada por (GUNN, 1998)

$$\alpha^* = \arg \min_{\alpha} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle - \sum_{k=1}^n \alpha_k \quad (3.20)$$

sendo que as restrições devem ser satisfeitas:

$$\sum_{j=1}^n \alpha_j y_j = 0 \quad (3.21)$$

A solução da Equação (3.20) com restrições (3.21) fornece o hiperplano ótimo, dado pelas Equações (3.22) e (3.23):


$$\sum_{i=1}^n \alpha_i y_i x_i = 0 \quad (3.22)$$

$$b^* = -\frac{1}{2} \langle w^*, x_r + x_s \rangle \quad (3.23)$$

onde x_r e x_s são os vetores de suporte de cada classe.

Essa solução é válida quando os dados de treinamento são linearmente separáveis. No entanto, geralmente isto não é verdade, conforme ilustrado na Figura 3.7.

Figura 3.7 - Hiperplano ótimo generalizado.



Fonte: Adaptado de Gunn (1998).

Com o intuito de tornar o problema generalizado, são apresentadas variáveis positivas $\xi_i \geq 0$ que são uma medida dos erros de classificação e uma função penalidade (CORTES; VAPNIK, 1995):

$$F_\sigma(\xi) = \sum_i \xi_i^\sigma \quad (3.24)$$

Onde ξ representa uma medida do erro de classificação. Agora o problema é minimizar o erro de classificação e a distância ao hiperplano, e as restrições agora se tornam:

$$y_i[\langle w, x_i \rangle + b] \geq 1 - \xi_i \quad (3.25)$$

O hiperplano ótimo generalizado é determinado pelo vetor w que minimiza o funcional da Equação 3.26:

$$\Phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i \quad (3.26)$$

onde C é um valor conhecido. Assim como no caso onde os dados eram linearmente separáveis, utiliza-se o Lagrangiano para resolver o problema, desta vez modificado na Equação (3.27) (MINOUX, 1986):

$$\Phi(w, b, \alpha, \xi, \beta) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_{i=1}^n \alpha_i (y_i [\langle w, x_i \rangle + b] - 1 + \xi_i) - \sum_{j=1}^n \beta_j \xi_j \quad (3.27)$$

Onde α e β são os multiplicadores de Lagrange, que deve ser minimizado em relação à w , b e x e maximizado em relação à α e β . O ponto de inflexão é dado por:

$$\frac{\partial \Phi}{\partial b} = 0 \implies \sum_{i=1}^n \alpha_i y_i = 0 \quad (3.28)$$

$$\frac{\partial \Phi}{\partial w} = 0 \implies w = \sum_{i=1}^n \alpha_i y_i x_i \quad (3.29)$$

$$\frac{\partial \Phi}{\partial \xi} = 0 \implies \alpha_i + \beta_i = C \quad (3.30)$$

A solução do problema é dada por:

$$\alpha^* = \arg \min_{\alpha} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle - \sum_{k=1}^n \alpha_k \quad (3.31)$$

sendo que as restrições devem ser satisfeitas:

$$\sum_{j=1}^n \alpha_j y_j = 0 \quad (3.32)$$

A diferença ao caso separável é o parâmetro C , que limita os multiplicadores de Lagrange e deve ser escolhido para quantificar o conhecimento do ruído nos dados.

3.3.1 Kernel

Segundo (CASTILHO, 2016), certos problemas de classificação binária podem não possuir um hiperplano de separação ótimo, que isola completamente as classes sem nenhum erro. Para casos onde a separação não é possível no espaço original dos dados, uma possível solução é aplicar um *kernel*, o que permite elevar o conjunto de dados para um espaço implícito de dimensão maior, sem computar as coordenadas dos pontos do conjunto, mas sim o produto interno entre as imagens de todos os pares de dados.

O kernel recorda o i -ésimo par do conjunto de treinamento (x_i, y_i) e atribui um peso correspondente w_i . As predições para dados fora do conjunto de treinamento são tratadas por uma função de similaridade k , que é o próprio kernel. Tal função considera os dados de teste x' e os dados de treinamento x . Um classificador binário transformado pelo kernel está na Equação 3.33 (JORDAN, 2004):

$$\hat{y} = \text{sign} \sum_{i=1}^n w_i y_i k(x_i, x') \quad (3.33)$$

onde:

$\hat{y} \in -1, 1$ - resposta do classificador binário transformada pelo kernel

y - saída verdadeira

k - função kernel que mede a similaridade do o par $x, x' \in \chi$

n - número de pares no conjunto de treinamento, com $y_i \in -1, 1$

w_i - pesos dos pares de treinamento, determinados pelo aprendizado

A função *sign* determina positivo ou negativo para a saída prevista.

Algoritmos de aprendizagem linear necessitam de mapeamento explícito do espaço, para que sejam capazes de aprender uma função não-linear ou fronteira não-linearmente separável. Ao elevar o espaço onde os pares existem, pode ser possível separá-los. O kernel irá elevar o espaço até encontrar uma fronteira separável.

Seja uma classe de funções $G(x, y)$ no espaço linear S e uma funções ϕ que mapeia x para S de forma que:

$$G(x, y) = \langle \phi(x), \phi(y) \rangle \quad (3.34)$$

Esse produto escalar ocorre no espaço S . Esta classe de funções inclui os kernels dos tipos:

Polinomial/Linear (para qualquer $d \in N$):

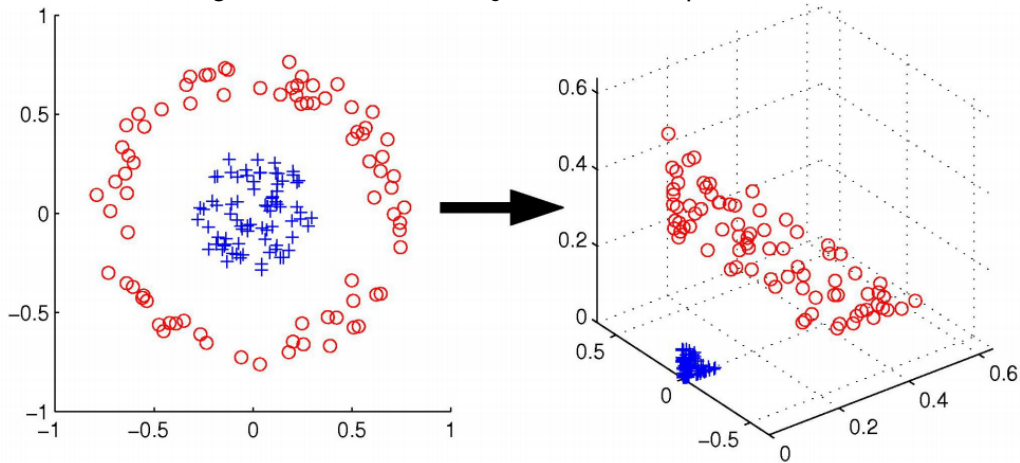
$$G(x, y) = (1 + x'y)^d \quad (3.35)$$

Gaussiano (RBF - para qualquer $\sigma \geq 0$):

$$G(x, y) = e^{-\frac{(x-y)'(x-y)}{2\sigma^2}} \quad (3.36)$$

A utilização do *kernel* torna possível o tratamento de conjuntos não-linearmente separáveis. A Figura 3.8 ilustra um exemplo da operação que eleva um espaço \mathbb{R}_2 para \mathbb{R}_3 . Contudo, pode ser que exista a necessidade de elevar ainda mais a dimensão para separar os dados, a ponto que uma representação visual se torna complexa para interpretar.

Figura 3.8 - Transformação dos dados pelo *kernel*.



Fonte: Jordan (2004).

3.4 Filtro de Kalman

O filtro de Kalman foi proposto por (KALMAN, 1960) como uma solução para o problema de estimação de tempo discreta bayesiana. É um processo recursivo que utiliza medidas, mesmo que incompletas ou ruidosas, para estimar os estados de um sistema linear no domínio do tempo. O filtro é aplicado ao sistema discretizado e iterativamente estima novos estados a cada passo de tempo discreto. O filtro de Kalman considera dois tipos de ruídos independentes. O ruído da medição, que é uma perturbação na informação que o sistema recebe das medidas novas e como estas se comparam ao modelo. O ruído do processo quantifica a incerteza da medida verdadeira em relação ao modelo escolhido.

Considere o modelo discreto linear da Equação 3.37.

$$\begin{cases} x_k = Ax_{k-1} + Bu_{k-1} + w_{k-1} \\ z_k = Hx_k + v_k \end{cases} \quad (3.37)$$

Onde w_k é o ruído do processo e v_k o ruído da medição, que são independentes um do outro, brancos e possuem distribuição normal. A matriz A traz a relação entre o passo de tempo anterior $k - 1$ ao passo atual k . A matriz B relaciona a entrada opcional de controle ao estado x . A matriz H relaciona o estado à medida z_k . (WELCH; BISHOP, 2006) explora as origens computacionais e probabilísticas do filtro de Kalman.

O algoritmo para o filtro de Kalman discreto realiza a estimação do processo utilizando uma abordagem recursiva em dois grupos. A atualização do tempo projeta o estado atual e a covariância do erro no tempo para obter estimativas *a priori* para o próximo passo de tempo. A atualização da medição é realizada pela retroalimentação das novas medidas na estimativa *a priori* com a finalidade de obter uma estimativa *a posteriori* melhorada. Tal abordagem também pode ser chamada de preditor-corretor (VIANNA, 2017).

As equações que governam a parte preditora, também chamada de atualização do tempo, são as seguintes.

Passo 1: projeção do estado para o passo posterior.

$$\hat{x}_k^- = A\hat{x}_{k-1} + Bu_{k-1} \quad (3.38)$$

Passo 2: projeção da covariância do erro para o passo posterior.

$$P_k^- = AP_{k-1}A^T + Q \quad (3.39)$$

Onde Q é a covariância do ruído do processo.

Para a parte corretora, também chamada de atualização da medição, as equações são as seguintes.

Passo 3: cálculo do ganho de Kalman.

$$K_k = P_k^- H^T (HP_k^- H^T + R)^{-1} \quad (3.40)$$

Onde R é a covariância do ruído da medição. O ganho Kalman K_k é determinado de forma que os erros entre as estimativas *a priori* e *a posteriori* seja minimizados.

Passo 4: atualização da estimativa através da medição.

$$\hat{x}_k = \hat{x}_k^- + K_k(z^k - H\hat{x}_k^-) \quad (3.41)$$

Passo 5: atualização da covariância do erro

$$P_k = (I - K_k H)P_k^- \quad (3.42)$$

O filtro então assume sua natureza recursiva ao repetir as equações a cada passo de tempo. Para implementar o filtro, é necessário conhecer as covariâncias R e Q , que podem ser obtidos por um processo de ajuste iterativo. O algoritmo do filtro de Kalman linear itera os passos apresentados, Equações 3.38 a 3.40. Existem diversos critérios de parada das iterações, como minimizar a covariância do erro *a posteriori*, o erro entre a medida e sua estimativa ou até um simples número máximo de iterações.

3.4.1 O filtro de Kalman estendido

Um dos problemas do filtro de Kalman advém do fato de que este estima os estados de um processo que pode ser descrito por uma equação diferencial estocástica *linear*. Para processo não-lineares, uma das soluções é o filtro de Kalman estendido, introduzido por (JAZWINSKI, 1970). O processo do filtro de Kalman estendido se inicia com uma modificação do sistema descrito pelas Equações 3.37.

$$\tilde{x}_k = f(\hat{x}_{k-1}, u_{k-1}) \quad (3.43)$$

Onde f é uma função não-linear que relaciona o estado anterior ao atual.

$$\tilde{z}_k = h(\tilde{x}_k) \quad (3.44)$$

Onde h é uma função não-linear que relaciona o estado à medição.

As novas equações que linearizam uma estimativa em torno das Equações 3.43 e 3.44 se tornam as seguintes.

Atualização do tempo:

$$\hat{x}_k^- = f(\hat{x}_{k-1}, u_{k-1}) \quad (3.45)$$

$$P_k^- = A_k P_{k-1} A_k^T + Q_{k-1} \quad (3.46)$$

Onde A é o jacobiano de derivadas parciais de f em relação à x .

$$A = \frac{\partial f}{\partial x}(\hat{x}_{k-1}, u_{k-1}) \quad (3.47)$$

Atualização da medição:

$$K_k = P_k^- H_k^T (H_k P_k^- H^T + R)^{-1} \quad (3.48)$$

$$\hat{x}_k = \hat{x}_k^- + K_k (z^k - h(\hat{x}_k^-)) \quad (3.49)$$

$$P_k = (I - K_k H_k) P_k^- \quad (3.50)$$

Onde H é o jacobiano de derivadas parciais de h em relação à x .

$$A = \frac{\partial h}{\partial x}(\tilde{x}) \quad (3.51)$$

O processo iterativo do filtro é o mesmo do filtro linear, mas com as novas equações.

3.5 Desempenho de algoritmos de aprendizado de máquina

Para analisar os resultados, serão utilizadas algumas métricas estatísticas comuns na análise de dados resultantes de classificadores.

Algumas definições importantes são necessárias para a avaliação do desempenho de um algoritmo de classificação. Uma matriz de confusão (STEHRMAN, 1997) é uma tabela que exhibe o desempenho de um algoritmo, geralmente supervisionado, como é o caso deste trabalho. A matriz representa como a saída do algoritmo de aprendizado de máquina se sai em relação à classificação verdadeira, resultando em duas dimensões: real e prevista, ilustrada pela Figura 3.9.

Os números na matriz de confusão representam o número de observações reais e previstas. A diagonal principal representa os verdadeiros positivos e negativos. A diagonal oposta representa os falsos positivos (erro tipo I) e os falsos negativos (erro tipo II) (DEKING, 2005). Os resultados são avaliados em termos de alguns indicadores derivados da matriz de confusão, pois os cálculos podem ser feitos para extrair uma melhor compreensão do desempenho do preditor. Os principais indicadores utilizados foram (METZ, 1978):

- Taxa de Verdadeiros Positivos: probabilidade condicional de um resultado de teste ser positivo se a observação for realmente positiva.

$$T_{VP} = \frac{VP}{VP + FN} \quad (3.52)$$

Figura 3.9 - Matriz de Confusão.

		Classe Real	
		Positivo	Negativo
Classe Prevista	Positivo	VP	FP
	Negativo	FN	VN

- Taxa de Verdadeiros Negativos: probabilidade condicional de um resultado de teste ser negativo se a observação for realmente negativa.

$$T_{VN} = \frac{VN}{VN + FP} \quad (3.53)$$

- Taxa de Falsos Positivos: probabilidade de falsamente rejeitar a hipótese nula.

$$T_{FP} = \frac{FP}{FP + VN} \quad (3.54)$$

- Taxa de Falsos Negativos: probabilidade de aceitar a hipótese nula que na verdade é falsa.

$$T_{FN} = \frac{FN}{FN + VP} \quad (3.55)$$

- Precisão: proporção de resultados positivos que são realmente positivos.

$$P_{re} = \frac{VP}{VP + FP} \quad (3.56)$$

- Acurácia: proporção de previsões corretas (positivas ou negativas) entre o número total de casos.

$$A_{CC} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.57)$$

- Fator de Correlação de Matthews: mede a qualidade de classificações

binárias (MATTHEWS, 1975):

$$\text{MCC} = \frac{\text{TP} \times \text{TN} - \text{FP} \times \text{FN}}{\sqrt{(\text{TP} + \text{FP})(\text{TP} + \text{FN})(\text{TN} + \text{FP})(\text{TN} + \text{FN})}} \quad (3.58)$$

4 METODOLOGIA

Este capítulo apresenta a metodologia utilizada no trabalho, desde a apresentação do sistema, as fontes de dados utilizadas, análise exploratória de dados, modelos matemáticos e técnicas de aprendizado de máquina.

4.1 Equipamento estudado

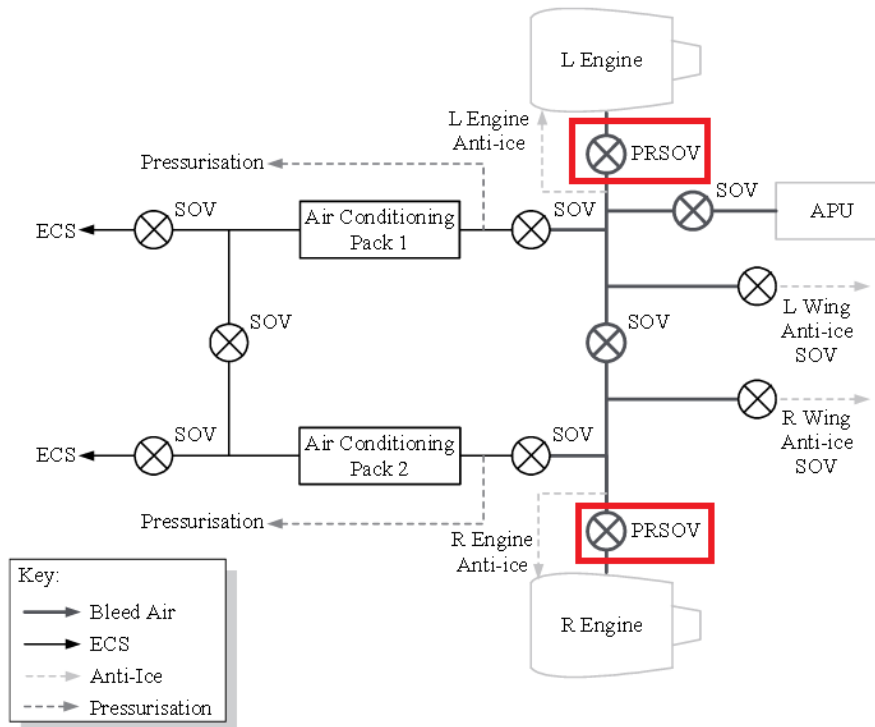
O sistema considerado nesse estudo foi o sistema pneumático, responsável pela sangria de ar do compressor do motor e pelo seu pré-condicionamento, controle de pressão e de temperatura, antes de disponibilizá-lo para outros sistemas, como o sistema de ar condicionado e o sistema de proteção contra gelo. Aspectos gerais deste sistema foram apresentados em (MOIR; SEABRIGDE, 2008). O ar é sangrado dos estágios de alta e de baixa pressão do compressor do motor e possui pressão e temperatura elevadas e também é denominado *bleed*. O controle da pressão é realizado utilizando-se um controlador, um sensor de pressão e uma válvula reguladora. O controle de temperatura é realizado utilizando-se um controlador, um sensor de temperatura, uma válvula para controle de temperatura e um trocador de calor.

A válvula reguladora utilizada no controle de pressão é denominada PRSOV (*Pressure Regulating Shut-Off Valve*) e é o objeto de estudo deste trabalho.

Existem dois sistemas como o descrito na aeronave, um para cada motor, e são vitais para sua operação. Enquanto a operação de apenas um permite que um voo seja realizado em segurança, a falha (ou falta) de uma das válvulas limita consideravelmente o envelope de operação como, por exemplo, a altitude de cruzeiro, tipicamente 31000 *ft*. A falha simultânea de ambos exige que a aeronave desça para 10000 *ft*, pois não será possível pressurizar a cabine, e/ou siga para o destino nessa altitude caso o combustível permita ou pouse no aeroporto mais próximo, geralmente o que ocorre, para não expor os passageiros a limitações de conforto térmico e de pressão.

A válvula reguladora é utilizada como atuador no controle da pressão na entrada do tubo de distribuição para outros sub-sistemas, além de possuir a capacidade de interromper o fluxo de ar caso a pressão ou a temperatura atinjam valores acima de limites seguros. O diagrama simplificado da Figura 4.1 ilustra sua localização no sistema ambiental de uma aeronave.

Figura 4.1 - Sistema de sangria de ar.




Fonte: Adaptado de Moir e Seabridge (2008).

Uma característica desafiadora do sistema é que a válvula tipicamente está localizada na *nacelle* do motor da aeronave, sob o capô do motor. Assim, a PRSOV fica exposta a um ambiente com temperaturas e níveis de vibração elevados, fatores que impactam a degradação. Ela tem uma função importante e é controlada por um sistema de controle de circuito fechado, que tenta manter a pressão no ponto de referência durante todo o voo. À medida que o componente envelhece, é necessária uma ação mais intensa do controlador, até o ponto em que a pressão não consegue mais ser regulada em níveis aceitáveis.

A PRSOV é uma válvula eletropneumática, comandada eletricamente e atuada pneumaticamente. A Figura 4.2 ilustra seu diagrama.

Figura 4.2 - Sistema de sangria de ar.



Fonte: Turcio (2014).

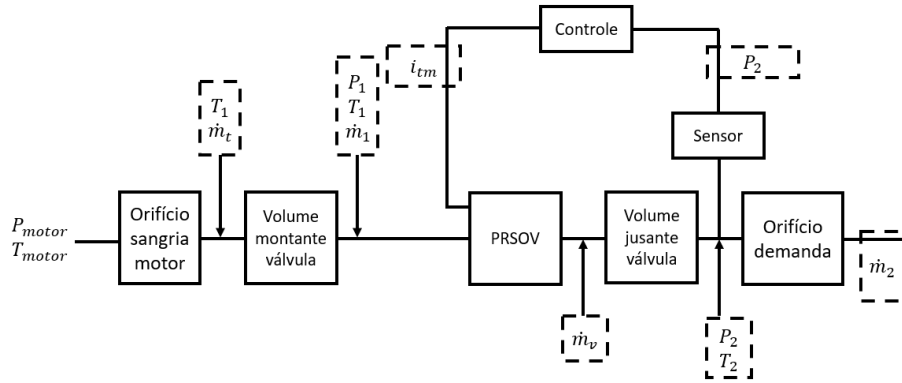
O ar de *bleed* proveniente do motor tem sua temperatura reduzida ao passar por um trocador de calor. Parte do ar adentra a câmara de fechamento e parte a câmara de abertura, sendo a última regulada por uma palheta controlada por um motor de torque, cujos movimentos alteram pequenas áreas de passagem e o ajuste dessas áreas leva à variação da pressão na câmara da válvula, promovendo sua movimentação. Quando o bocal de descarga do motor de torque é bloqueado, a câmara de abertura é pressurizada e a válvula inicia o movimento de abertura. Quando este bocal é aberto, a pressão na câmara diminui e a válvula começa a fechar. O ângulo da borboleta possui uma relação com a pressão regulada. O controle da válvula comanda a corrente do motor para controlar a pressão (TURCIO, 2014).

4.2 Modelo

O modelo do equipamento estudado foi construído em *Simulink*, desenvolvido pelo time de Simulação de Sistemas Ambientais da Embraer e emula o comportamento físico da válvula. Contém as equações matemáticas que descrevem o funcionamento físico da válvula, como pressurização da câmara, acoplamento com o motor elétrico de torque e abertura da borboleta. Os principais componentes do modelo matemático da válvula são:

- Orifício que representa a sangria de ar do motor, simplificando a mode-

Figura 4.3 - Diagrama esquemático do modelo da válvula e seus parâmetros.



lagem da linha pneumática completa.

- Volumes antes e depois da válvula, também chamados respectivamente de montante e jusante.
- Válvula reguladora de pressão.
- Orifício que representa as demandas dos clientes do sistema.
- Válvula de controle de vazão.

A Figura 4.3 ilustra a conexão entre orifícios, volumes e válvulas do modelo, bem como os parâmetros modelados nas equações que descrevem seu funcionamento.

O modelo é parametrizado com características físicas como volumes, comprimentos, massas e coeficientes de atrito, entre outros. Os volumes são representados por equações de balanço de massa e energia (WYLEN et al., 1994), considerando a conservação de ambas, além de equações de gases perfeitos. Para os orifícios, tanto os de entrada e saída, bem como os presentes no interior da válvula reguladora de pressão consideram fundamentos de escoamento compressível isentrópico (FOX et al., 2010).

As equações que descrevem a perda de pressão nos volumes a montante e jusante da válvula são:

$$\frac{dP_1}{dt} = \frac{dm_1}{dt} \frac{RT_1}{V_1} + \frac{m_1 R}{V_1} \frac{dT_1}{dt} \quad (4.1)$$

$$\frac{dT_1}{dt} = \frac{\dot{m}_1 c_p}{m_1 c_v} T_{motor} - \frac{\dot{m}_v c_p}{m_1 c_v} T_1 - \frac{1}{m_1} \frac{dm_1}{dt} T_1 \quad (4.2)$$

As Equações 4.1 e 4.2 são alcançadas através da manipulação de equações básicas de conservação de massa, estado para gases perfeitos e a Primeira Lei da Termodinâmica (WYLEN et al., 1994). As vazões são obtidas através do equacionamento dos modelos dos orifícios de sangria e de demanda, além da PRSOV em si, cuja borboleta age como um orifício, restringindo a passagem do ar e regulando a pressão à jusante. Estes orifícios são considerados bocais convergentes ideais, trabalhando com escoamento compressível em regime subsônico (FOX et al., 2010). A vazão mássica através de um bocal cuja pressão e temperatura de entrada é a total do escoamento e a pressão de saída é estática é (ANDERSEN, 1967):

$$\dot{m} = \frac{KAN}{\sqrt{T_{in}}} P_{in} \quad (4.3)$$

Onde A é a área equivalente do bocal (TURCIO, 2014). O coeficiente K é:

$$K = \sqrt{\left(\frac{\gamma}{R} \left(\frac{2}{k+1} \right)^{\frac{\gamma+1}{\gamma-1}} \right)} \quad (4.4)$$

O coeficiente N é:

$$N = \sqrt{\left(\frac{\left(\frac{P_{out}}{P_{in}} \right)^{\frac{2}{\gamma}} - \left(\frac{P_{out}}{P_{in}} \right)^{\frac{\gamma+1}{\gamma}}}{\left(\frac{\gamma-1}{2} \right) \left(\frac{2}{\gamma+1} \right)^{\frac{\gamma+1}{\gamma-1}}} \right)} \quad (4.5)$$

onde R é a constante dos gases perfeitos ($287 J/kgK$ para o ar) e γ é coeficiente de expansão adiabática (1.4 para o ar).

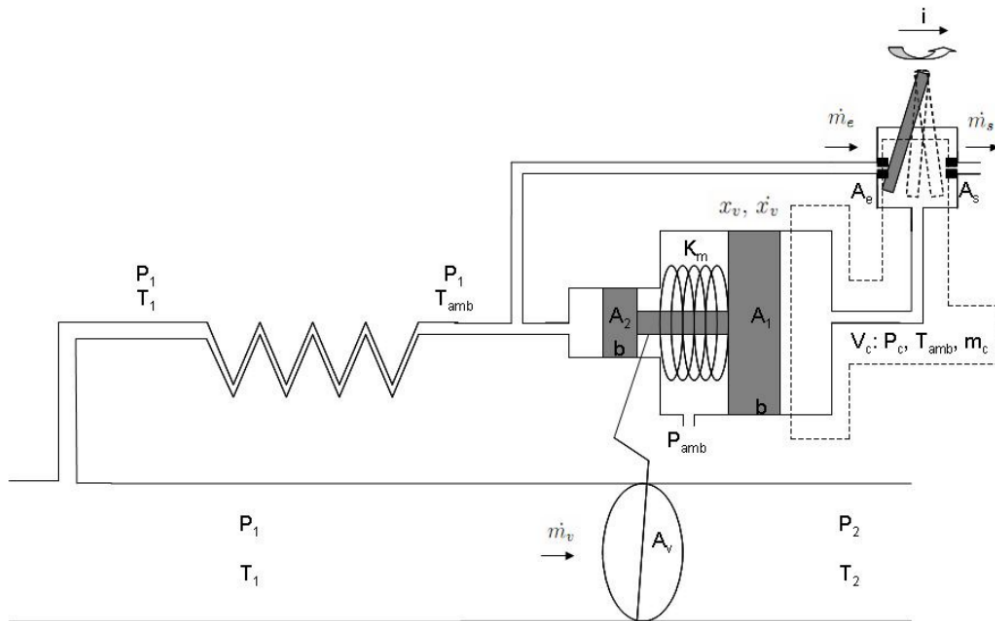
O modelo matemático completo da PRSOV foi descrito por (TURCIO, 2014). A equação final, que descreve a dinâmica do pistão, que por sua vez afeta a pressão regulada é:

$$\ddot{x}_v = \frac{A_1}{m_p} (P_c - P_{amb}) - \frac{A_2}{m_p} (P_1 - P_{amb}) - \frac{K_m}{m_p} \dot{x}_v - \frac{f_{at}(x_v, \dot{x}_v, \Delta P)}{m_p} \quad (4.6)$$

Estes parâmetros e representação de sua localizações na válvula estão ilustrados na Figura 4.4.

Além de características físicas, o modelo também contém o controle que está implementado na válvula real, cujo objetivo é garantir que a pressão na saída da

Figura 4.4 - Diagrama esquemático dos parâmetros.



Fonte: Turcio (2014).

válvula siga a pressão de referência imposta pela programação de pressão do computador da aeronave.

Trabalhar em malha fechada impõe um desafio extra em trabalhar com o modelo, uma vez que a malha de controle compensa os efeitos da degradação. Para os casos reais analisados, tanto o modelo como o sistema real são capazes de lidar com grandes variações na entrada, sendo o controle robusto o suficiente para corrigir tais perturbações. Ou seja, para o caso de pressão de entrada com amplitude e frequência de oscilação baixas e outro caso com pressão de entrada com as mesmas variáveis altas, o controle irá garantir uma pressão de saída em níveis similares.

O modelo computacional possui características físicas em suas equações que impactam sua resposta (FELÍCIO, 2007), como constante de mola, área de vazamento e coeficiente de atrito do pistão dentro da câmara. É possível alterá-las para simular degradação do equipamento. Por exemplo, em casos de alto atrito, o pistão tende a precisar de maior pressão na câmara para se mover, pois a força necessária para movê-lo será maior do que em casos de baixo atrito. Esta característica é importante, pois o movimento do pistão dita o ângulo de abertura da válvula, que por sua vez controla a pressão na saída. O alto atrito pode ser ali-

viado com o aumento da corrente de controle, advinda de uma ação mais rígida do controlador, pois a pressão no interior da câmara de abertura irá aumentar, causando um maior força para mover o pistão no sentido de abertura. No entanto, este aumento de degradação pode ser maior que o controlador é capaz de lidar sem introduzir instabilidades na malha, e os efeitos nocivos da degradação serão percebidos na pressão controlada. Neste ponto a troca da válvula pode ser necessária.

É importante deixar claro que o modelo não replica perfeitamente a realidade e uma margem de erro é esperada. Neste caso, podemos tolerar um erro maior e focar na amplitude e frequência da resposta em relação aos dados reais para inferir a capacidade do modelo em representar o correto funcionamento da válvula. Uma ferramenta possível de ser utilizada é a limitação da faixa operacional do modelo (SLOTA et al., 2011), onde não é simulado um evento completo, com transientes e mudanças de comportamento. No caso do modelo utilizado neste trabalho, o modelo está configurado para trabalhar na fase de cruzeiro de um voo em vez de um voo inteiro. Tal limitação não traz nenhum problema, pois é na fase de cruzeiro em que a variação da pressão de entrada é menor, o que retira esta influência da análise e permite focar na degradação.

O modelo de degradação utilizado considera o aumento do atrito e do vazamento pelo selo do pistão. Na Figura 4.4, o pistão corre dentro de um elemento chamado de camisa. Entre esses existe um selo em formato de anel, que veda e isola as câmaras. O movimento do pistão ocorre em micro movimentos "pare-segue" (*stick-slip*), estimulados pelo atrito. Durante esses movimentos, além do vazamento médio pelos selos, dependendo do nível de envelhecimento, pode ocorrer uma variação momentânea da qualidade do assentamento e vedação do selo, aumentando o vazamento equivalente.

Como impacto, maiores erros da pressão controlada levam a uma ação da malha de controle no sentido de aumentar a abertura do orifício de carregamento, aumentando a pressão na câmara de abertura e causando o movimento da válvula na direção que minimiza o erro entre a pressão lida e a de referência. Com o passar do tempo, o selo tende a degradar, aumentando o efeito deste vazamento além do aumento do atrito, até um ponto que ocorre seu rompimento e válvula se torna incapaz de operar.

O modelo validado sem degradação foi utilizado na criação de casos hipotéticos de degradação, observando a degradação natural nos dados reais de campo. A utilização de um modelo é uma grande vantagem operacional e econômica, pois

alivia a necessidade de testes de campo, que apresentam alto custo de pessoas, maquinário e consumíveis (CASOLI et al., 2016).

4.2.1 Validação

A validação é definida como o processo de determinar se modelo é uma representação precisa do mundo real a partir da perspectiva de seus usuários, estabelecendo confiança em sua robustez (SORNETTE et al., 2007). É importante dizer que o modelo é desenvolvido para um uso específico e sua validação deve ser realizada em relação à finalidade desejada (SARGENT, 2007).

Para (LAW; KELTON, 1982), não há uma abordagem padrão para validação de modelos. O uso de ferramentas estatísticas como chi-quadrado (RINGUEST, 1986) e Kolmogorov-Smirnov (CHAKRAVARTI et al., 1967) na comparação dos resultados do modelo com medidas do sistema de campo representado é complexa e tais técnicas não podem ser diretamente aplicadas devido à natureza não-estacionária de parte dos sistemas e pela correlação entre entradas e saídas. O uso de outras técnicas, como Monte Carlo pode apresentar bons resultados mas seu sucesso é baseado nas incertezas definidas no objetivo do projeto (WEATHERS et al., 2009).

Um aspecto importante discutido por (LAW; KELTON, 1982) é validação qualitativa, na qual a comparação entre simulação e ensaio é avaliada por uma equipe de especialistas e caso não exista um consenso entre o que é modelo e o que é ensaio, o modelo é considerado válido. O trabalho de (BARLAS, 1989) traz um conceito interessante onde a validação pode ser feita pela estrutura matemática do modelo em vez de estatisticamente ponto a ponto. Também discute a validação do comportamento, que observa amplitude, frequência, fase, tendência, etc. Isto torna o processo de validação informal, onde técnicas formais fornecem apenas um ponto de entrada para iniciar as discussões sobre a validade do modelo.

Neste trabalho as entradas do modelo são provenientes de voos de campo, que possuem ruídos e características operacionais que podem estar fora das considerações das equações matemáticas que descrevem o modelo. Outro desafio é que os voos disponíveis são advindos de operação comercial e exploram o envelope de operação por completo, o que traz uma maior excitação dos modos de oscilação do sistema (HIYAMA et al., 2000). A utilização de dados de voos reais significa que não existe garantia que os comandos da válvulas possuam amplitude e frequência desejadas para essa validação mais formal, visto que o sistema possui um controle em malha fechada.

O modelo utilizado nesse trabalho já foi validado formalmente com base em testes em bancada, conforme apresentado em (TURCIO, 2014). Neste trabalho complementou-se a sua validação considerando dados de voo. O processo de validação consistiu em considerar as seguintes grandezas medidas em voo: pressão e temperatura de entrada, vazão pelo sistema, pressão controlada e corrente de comando, forçando as pressões controladas (simulada e medida em voo) a se igualarem, complementando a corrente de comando da simulação com uma diferença calculada a partir do erro entre a pressão controlada da simulação e a medida. Quando essas pressões são igualadas, comparam-se as correntes de comando do voo e da simulação. Sendo iguais e tendo a mesma assinatura, pode-se considerar que o modelo da válvula e sistema é suficientemente representativo para esse estudo.

O conjunto PRSOV e volume à jusante pode ser interpretado como a planta do modelo, na qual existe uma realimentação via um sensor de pressão e o controlador. Se a resposta do controlador, no caso a corrente, for a mesma para o modelo e para o voo real quando submetidos à mesma entrada, o modelo pode ser considerado validado.

Na validação também entra a consideração da região de validação do modelo. O modelo foi validado na região de interesse do modelo, pois este não foi utilizado fora da mesma. No caso deste trabalho, essa região é a fase de cruzeiro do voo. Outros momentos do voo apresentam transientes relacionados a mudanças de operação, como chaveamento de válvulas e demandas de clientes do sistema pneumático, como o sistema de anti-gelo durante a subida. Estes transientes podem levar a pressão para fora da referência do controlador, mas não são indicativos de degradação.

A Figura 4.5 representa as leituras do modelo e do ensaio para a pressão na saída da PRSOV. O ajuste parece ótimo, mas é preciso lembrar que a referência do controlador foi alterada para seguir a pressão lida no mesmo sensor do voo, então é natural que sejam similares.

A validação vem da comparação da corrente de controle, ilustrada na Figura 4.6. A similaridade entre as correntes significa que a planta do modelo, implementada através de equações matemáticas, responde da mesma maneira que a planta real, representada pela válvula. Este método de validação força a saída a ser a mesma e verifica a entrada necessária para alcançar este estado. Como neste caso ambas as correntes são próximas, o modelo da válvula é considerado validado.

Figura 4.5 - Validação do modelo - pressão.

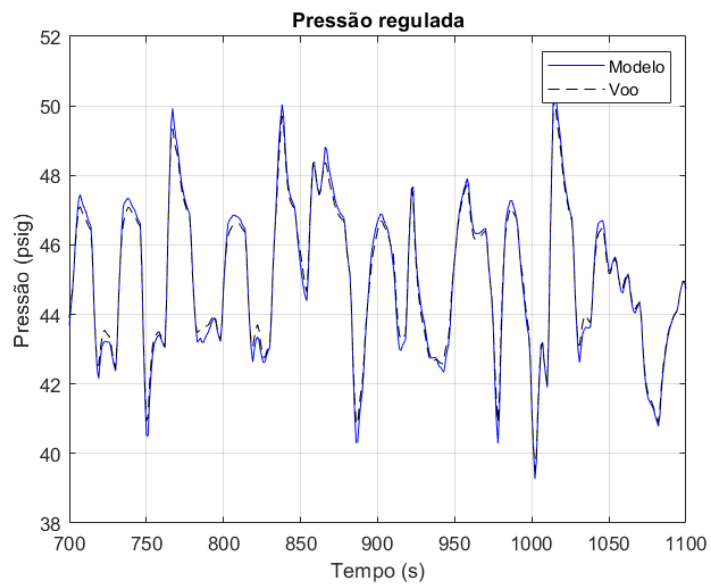


Figura 4.6 - Validação do modelo - corrente.

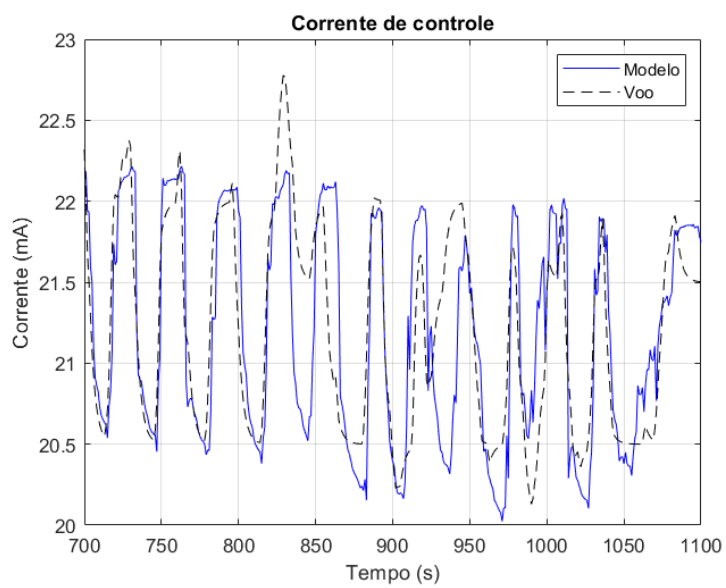


Tabela 4.1 - Base de Dados de Voos.

	\bar{x}_{sim}	\bar{x}_{voo}	S_{sim}	S_{voo}	$REQM$
Pressão	45.0421	45.0425	2.2100	2.0522	3.94E-04
Corrente	21.1810	21.1977	0.6769	0.6343	0.0167

Considerando a abordagem quantitativa, a aderência do modelo à realidade se mostrou satisfatória. Pela abordagem qualitativa, é observado que sem a legenda da Figura 4.6, não seria possível identificar qual curva é modelo e qual é o voo, indicando a adequação do modelo por outra abordagem. Expandindo as métricas quantitativas, seleciona-se a média e o desvio padrão para a comparação numérica das respostas do modelo e do voo, representadas respectivamente pelas Equações 4.7 e 4.8 (MORETTIN; BUSSAB, 2010).

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (4.7)$$

$$S = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}} \quad (4.8)$$

A Tabela 4.1 apresenta as métricas quantitativas da validação do modelo. Os subscritos *sim* e *voo* definem simulação e voo, respectivamente. *REQM* é a raiz do erro quadrático médio.

Os valores das médias e desvios padrão estão próximos, o que indica adequação do modelo. A raiz do erro quadrático médio também mostrou valores pequenos, reforçando a decisão de considerar o modelo como validado para o objetivo do trabalho. É preciso manter em mente que o critério de considerar estes valores como pequenos é subjetivo e a combinação das métricas quantitativas com as considerações qualitativas é de responsabilidade do profissional que está no controle do processo de validação.

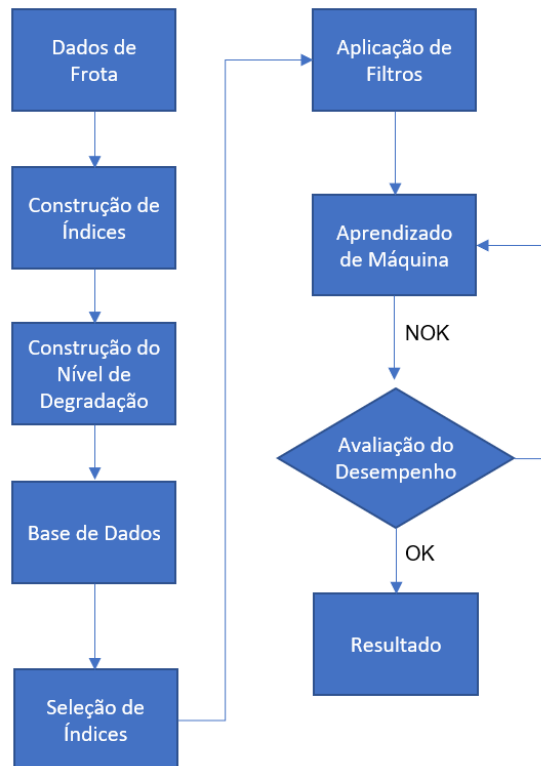
Segundo uma abordagem mais formal de construção de modelos (BARLAS, 1996), se a construção do mesmo segue as equações que descrevem o sistema físico, existe a garantia que a estrutura do modelo e do sistema real é a mesma. A formulação matemática foi descrita na Seção 4.2. A dinâmica do sistema foi validada observando a resposta do controlador ao seguir a mesma saída do modelo, concluindo que a planta do equipamento se comporta de maneira similar tanto para o modelo quanto para o voo. Assim, o modelo foi validado para voos com baixa degradação.

Os fatores representados no modelo impactados pela degradação são três: fator de atrito, fator de vazamento e fator de entupimento. O fator de atrito altera o atrito calculado pelas equações matemáticas de descrição do modelo. O envelhecimento da válvula pode causar o aumento do atrito entre o pistão e a câmara, sendo a representação matemática o aumento do coeficiente de atrito. O fator de vazamento modifica a área de vazamento entre as câmaras da válvula. Com o passar do tempo, o selo que isola as câmaras da válvula sofre desgaste, permitindo que mais ar vaze entre as câmaras. Um pouco de vazamento é esperado e aceito, mas a degradação tende a aumentá-lo acima de níveis toleráveis. Outro fator é o entupimento dos bocais de carga e descarga, que impõe uma perda de pressão adicional, de forma que a pressurização das câmaras é prejudicada.

4.3 Estrutura da análise de dados

As próximas seções irão apresentar a metodologia da análise dos dados de frota, desde sua obtenção, seu tratamento, construção e seleção de índices, até o aprendizado de máquina e a avaliação de seu desempenho. Antes de prosseguir, a Figura 4.7 ilustra o processo geral a ser seguido, que será detalhado ao longo das seções seguintes.

Figura 4.7 - Fluxograma geral para análise dos dados de frota.



O primeiro passo é a obtenção dos dados de campo, que são provenientes de uma frota de aeronaves do mesmo modelo mas de diferentes operadores. O passo seguinte é a construção dos índices que caracterizam os voos, que representam as entradas dos algoritmos de aprendizado de máquina, seguido do passo de definição do nível de degradação, que representa a saída desejada. Os índices compõem a base de dados, que foi utilizada em uma análise exploratória, que irá revelar quais índices são mais úteis e serão mantidos para os processos de filtragem e treinamento dos algoritmos de aprendizado de máquina. Após a avaliação dos dados de teste, os resultados são avaliados por diversos critérios de desempenho de classificação. Parte deste processo foi reutilizado pelas análises com apenas dados de modelo e finalmente na análise híbrida.

4.4 Dados de frota

Esta seção foca na análise utilizando apenas os dados de frota aliados ao conhecimento da física do processo e da operação. Estes dados contém não apenas informações sobre características físicas do sistema como também registros de manutenção.

Os dados de frota contém informações de propriedade intelectual dos operadores das aeronaves. Portanto, serão tratados antes de sua apresentação em figuras, gráficos e diagramas para preservar a propriedade da empresa e de seus clientes. Porém, este tratamento não dificulta a compreensão nem diminui a contribuição acadêmica deste trabalho.

Os dados de entrada para a análise provém de diversas fontes, cuja combinação permite criar uma base de dados robusta e completa antes de iniciar a análise exploratória. As principais fontes de dados são sensores instalados na aeronave e relatórios de manutenção. Estas fontes de dados serão detalhadas nas próximas sub-seções.

4.4.1 Dados de sensores

As aeronaves cujos dados foram utilizados neste trabalho são equipadas com um QAR (*Quick Access Recorder*) (FEDERAL AVIATION ADMINISTRATION, 2004), um gravador que armazena dados de voo, projetado para permitir fácil acesso os dados gravados. Porém, nem todos os parâmetros são gravados no QAR e é possível ignorar certos sensores na gravação, seja por limitações de memória disponível para gravar novos voos ou por decisões administrativas e de negócio. Dessa forma, existem lacunas nos dados, como parâmetros não gravados ou em falta por um intervalo de tempo.

Para este trabalho, apenas os sensores relativos ao componente estudado serão utilizados. Como se tratam de dados puros provenientes de operação real de uma frota de aeronaves, não estão livres de problemas como falha de sensores, operação fora do envelope, seja por limitação técnica ou operacional.

4.4.2 Dados de manutenção

Além dos dados de sensores, outra informação que compõe a base de dados completa foram relatórios de manutenção, que registram ações realizadas na aeronave, sejam planejadas ou emergenciais. Dentre as ações possíveis, existe a troca do componente por um novo. Esta ação impacta na análise, pois a saúde do componente volta a níveis altos e sua tendência de degradação é reiniciada.

Trocas também podem ser classificadas como programadas ou não-programadas. O segundo tipo foi o foco deste trabalho, pois estas ações não esperadas podem causar atrasos na operação, ou em casos mais graves, apresentar falhas em voo. Muitas informações são gravadas manualmente pelo mecânico responsável pela manutenção e as utilizadas foram datas, número de identificação da aeronave, categoria e descrição.


As datas e o número de identificação são utilizados para cruzar as informações corretamente entre as diferentes bases. A categoria é um filtro para manter apenas ações não programadas. A descrição é uma informação manual onde o mecânico descreve o problema e as ações tomadas, que resultam sempre em manutenção. Porém, a descrição ajuda a filtrar remoções que não foram causadas pelo componente de interesse. Por exemplo, em casos de troca de motor a válvula também é removida, pois faz parte de um conjunto.

As ações de troca são registradas manualmente pelo mecânico responsável pela manutenção, uma característica agravante, pois não há padrão estabelecido na indústria, visto que cada linha aérea trabalha de forma distinta. Adicionalmente, a PRSOV faz parte do conjunto do motor, o quando ocorre a troca do mesmo, a válvula é trocada também. Tais fatos exigem a sanitização manual dos dados de troca, para evitar a consideração de trocas espúrias ou que não estejam associadas ao envelhecimento ou falha do equipamento considerado.

4.5 Análise de dados de sensores

A análise dos dados de voo gravados por sensores pode trazer informações valiosas sobre a degradação do componente estudado. Tal análise deve ser acompanhada do conhecimento de especialistas. Existem inúmeros parâmetros monitorados e gravados na aeronave, fato que torna um guia indispensável. Um dos

Figura 4.8 - Dados de voo longe da troca.



principais parâmetros a serem analisados é a pressão controlada utilizando-se a válvula.

A Figura 4.8 ilustra os dados registrados durante um voo para a altitude da aeronave e para a pressão controlada pela PRSOV de um dos lados da aeronave. Pode-se observar que a variável controlada apresenta um comportamento mais oscilatório em algumas fases do voo. As oscilações durante a operação em solo, decolagem, subida, descida, pouso e taxi são funções dos distúrbios causados pelas acelerações e desacelerações do motor e chaveamento de fontes de pressão.


Os índices de degradação podem levar isso em consideração, como valores de transientes durante determinadas ações do sistema, como mudanças na demanda de ar. O mais notável é o anti-gelo, que consome uma boa parte do ar que flui pela PRSOV, mas não é uma demanda contínua. Portanto, ele causa um transiente na variável controlada somente quando é ligado.

A Figura 4.9 apresenta dados de voo para a mesma aeronave, porém para um período futuro em relação à Figura 4.8. Note que a degradação da válvula se manifestou, com a pressão agora apresentando um perfil com maior frequência e amplitude de oscilação. Tal comportamento indica um possível índice de degradação do componente.

As figuras apresentam as assinaturas de uma válvula nova e de uma envelhecida. Já no cruzeiro as variações do motor são bem menos intensas, ocorrendo somente em voos turbulentos em função da resposta do sistema de controle automático de tração.

Após a troca do componente, o comportamento desta variável retorna ao estado anterior, quando a troca está longe e a degradação é baixa, pois o equipamento

Figura 4.9 - Dados de voo próximo à troca.



instalado é novo. A análise dos dados de diferentes sensores em diferentes condições de voo, aliadas ao conhecimento de especialistas, traz a informação de quais variáveis afetam a operação da válvula e os momentos do voo mais propícios para a análise.

Algumas mensagens de falha geradas podem ser ignoradas pela tripulação e certas ações podem ser tomadas, por exemplo, certos sistemas possuem a capacidade de ser reiniciados, o que faz com que seu comportamento possivelmente volte a ser o esperado. Algumas mensagens de falha, por estarem associadas a eventos de baixa criticidade e por contarem com a existências de redundâncias, podem ter como uma primeira ação reiniciar o sistema, caso isso seja devidamente discutido e aprovado por especialistas. No entanto, o equipamento continua degradado e as mensagens de falha vão se tornando mais frequentes. Tais situações aumentam o desafio da natureza não-linear da degradação, pois ainda há fatores humanos na operação.

4.6 Construção de índices

Os dados dos sensores das aeronaves são contínuos e medidos durante todo o voo, desde o momento em que os motores são ligados até o momento em que são desligados. Dessa forma, contém seções do voo que podem não ser de interesse para a inferência da degradação. Esses dados também são ruidosos e estão sujeitos a particularidades e restrições de operação, que incluem altitude de cruzeiro, disponibilidade restrita de equipamentos, ocorrência de gelo, entre outros.

Os dados de sensores gravados no sistema de aquisição de dados da aeronave estão dispostos temporalmente: pressões, temperaturas, estados de ativação, etc. Dependendo da frequência de leitura e gravação, estes dados podem alcançar um grande volume. Para utilizá-los diretamente em algoritmos de aprendi-

zado de máquina, uma das opções disponíveis é o aprendizado profundo (DENG; YU, 2014). Contudo, tais técnicas são custosas computacionalmente (YOU et al., 2017) e as regras de classificação de uma rede neural profunda são difíceis de serem acessadas.


Para aliviar este problema e tornar o trabalho mais compreensível, é interessante definir índices que auxiliam a identificar degradações do equipamento. Isso torna possível o uso de uma gama maior de algoritmos de aprendizado de máquina. Neste trabalho, serão utilizados algoritmos de aprendizado de máquina sem aprendizado profundo. Desta forma, serão necessários índices (também conhecidos como *features*) que resumem certas variáveis a um conjunto de valores unidimensionais.

É aconselhável reduzir os dados do sensor a um único ponto que represente o voo para cada característica específica escolhida. É importante notar que podem existir diversos sensores e diversas maneiras de reduzir um voo a um número. Tais ações criam um conjunto de índices que descrevem a saúde da PRSOV de uma determinada aeronave.

A redução do voo a um conjunto de valores que podem ajudar a descrever a degradação do componente vem da análise de um momento específico do voo, em que a operação é estável e a aeronave não está sujeita a nenhuma mudança de altitude ou qualquer outro subsistema esteja exigindo ar da válvula. A Figura 4.10 ilustra um dos sensores da válvula para ambos os voos mostrados anteriormente no mesmo gráfico, na mesma escala para um momento selecionado. Pode-se observar que o voo próximo ao evento de substituição, pouco tempo antes, tem a leitura do sensor de pressão mais oscilatória, indicando um possível alto nível de degradação. Uma observação importante é que o controlador ainda está tentando corrigir a pressão para aproximá-la do ponto de ajuste, e esse é o motivo pelo qual a pressão média dos dois exemplos é praticamente a mesma. Portanto, um índice pode ser construído aqui calculando o desvio padrão em vez da média. Como o desvio aumenta temporalmente em diferentes voos, a degradação também pode estar aumentando.

Ao calcular este índice em específico para diversos voos do mesmo avião, a Figura 4.11 revela como o comportamento deste índice fica com o passar do tempo e com o aumento da degradação da válvula. Na figura, cada voo é representado um dos pontos. O intervalo selecionado para ilustrar demonstra dois eventos de troca do equipamento. O primeiro, à esquerda, é responsável pelo baixo nível do índice no início do intervalo, pois uma válvula nova sem defeitos de fábrica

Figura 4.10 - Comparação de dados de voo.



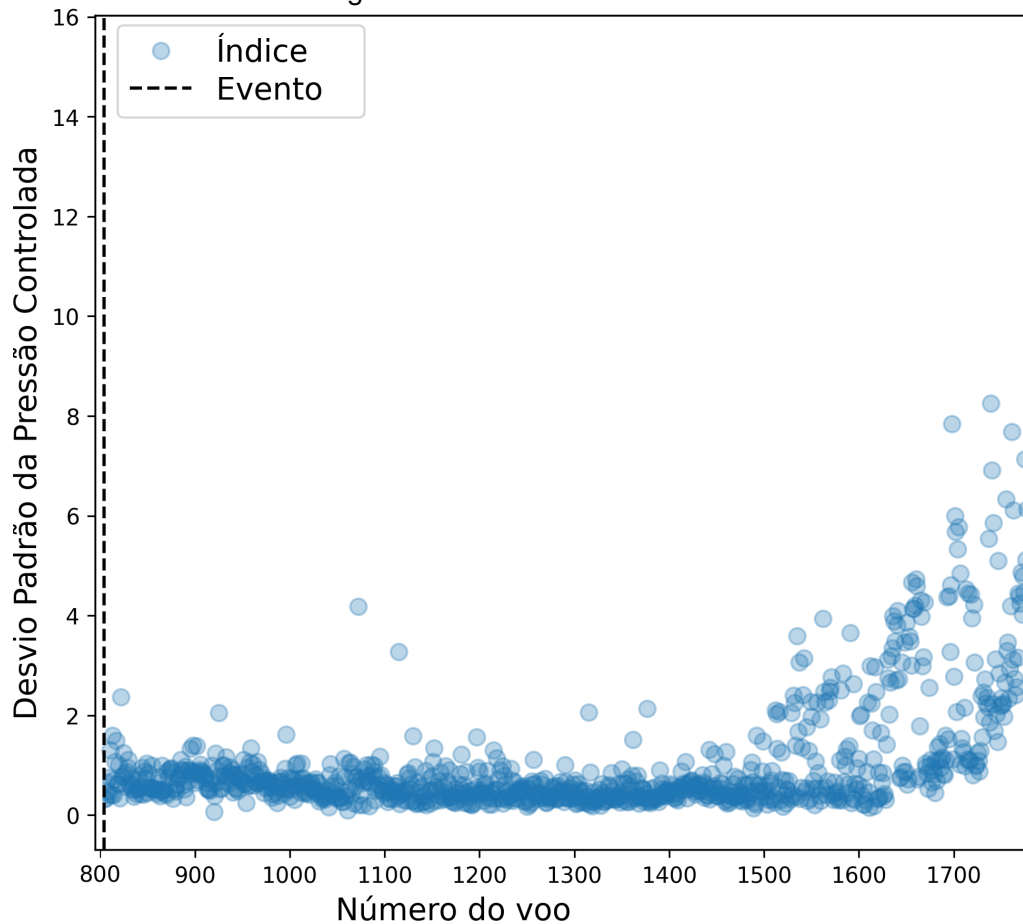
possui uma degradação baixa. No lado oposto, à direita, outra troca. Porém, esta ocorre depois que a degradação da válvula atinge um nível inaceitável e começa a afetar a operação da aeronave, até possivelmente com o sistema alertando a tripulação sobre falhas do componente.

Serão analisados casos reais de baixa degradação (voos logo após uma troca) a casos de alta degradação (logo antes de uma troca). Além da componente temporal, os índices descritos nas seções anteriores auxiliam na determinação do estado de saúde do equipamento. A Figura 4.11 ilustra o índice que observa a variabilidade da pressão controlada, que é particularmente fácil de correlacionar visualmente com a degradação. A análise dos dados que compõem esta figura ajudou na definição dos voos a serem utilizados como entrada no modelo. Na figura, cada ponto representa o desvio padrão da pressão controlada para um voo diferente.

Utilizando o mesmo processo básico, outros índices foram construídos para considerar diferentes sensores e fases de voo. Assim, um voo pode ser descrito por um conjunto de índices, compondo a base de dados que foi utilizada para treinar e testar diferentes algoritmos de aprendizado de máquina. Este processo foi aplicado individualmente nos voos, reduzindo-os a um conjunto de índices para cada voo.

Os índices escolhidos para os dados de frota provém de diversas agregações de grandezas que são afetadas pelo aumento da degradação do equipamento. Para melhor observar mudanças, o foco ficou na fase de voo de cruzeiro, pois o comportamento é mais estável e o aumento da degradação causa um efeito mais perceptível. Em muitos momentos do voo ocorrem transientes que causam mudanças abruptas, que podem não ser indicativas de degradação, mas apenas de uma mudança de ponto de operação. Os índices incluem médias e desvios

Figura 4.11 - Índice construído.



padrões de variáveis como pressão e vazão, média da derivada e índices de estabilidade e número de cruzamentos. Além da fase de cruzeiro, há um índice advindo de um transiente que ocorre durante a subida, um evento de rotina.

Os índices são então construídos com a ajuda de uma equipe de especialistas, com conhecimento não apenas do sistema, mas também da operação em campo, que pode ser muito diferente da operação teórica. Um exemplo de decisão tomada pelo especialista pode ser a redução dos dados de uma determinada variável à sua média durante uma certa fase de voo ou a medição da oscilação da leitura do sensor durante um intervalo de tempo específico. Os índices foram renomeados com nomes genéricos para proteger a propriedade intelectual da empresa e de seus clientes, porém sua essência foi preservada para manter a compreensão acadêmica do trabalho.

Tabela 4.2 - Base de dados de voos.

Aeronave e Voo	Índice 1	Índice 2	[...]	Índice 9	Índice 10
Aeronave 1 Voo 1	37.875	34.099	[...]	1.181	5.170
Aeronave 1 Voo 2	35.375	33.956	[...]	1.645	6.274
[...]	[...]	[...]	[...]	[...]	[...]
Aeronave 98 Voo 1999	40.750	34.492	[...]	6.715	7.168
Aeronave 98 Voo 2000	38.125	41.614	[...]	4.716	11.583

4.6.1 Base de dados

O procedimento de criação dos índices resulta em um banco de dados em que cada voo é uma observação com vários índices que descrevem o estado de saúde do equipamento temporalmente. O banco de dados puros consiste em uma série de aeronaves, cada uma com diversos voos, dispostos ao longo do tempo. Em seguida, os índices são compilados em um banco de dados, sendo cada linha uma observação com dez índices. A base de dados pode ser parcialmente visualizada na Tabela 4.2.

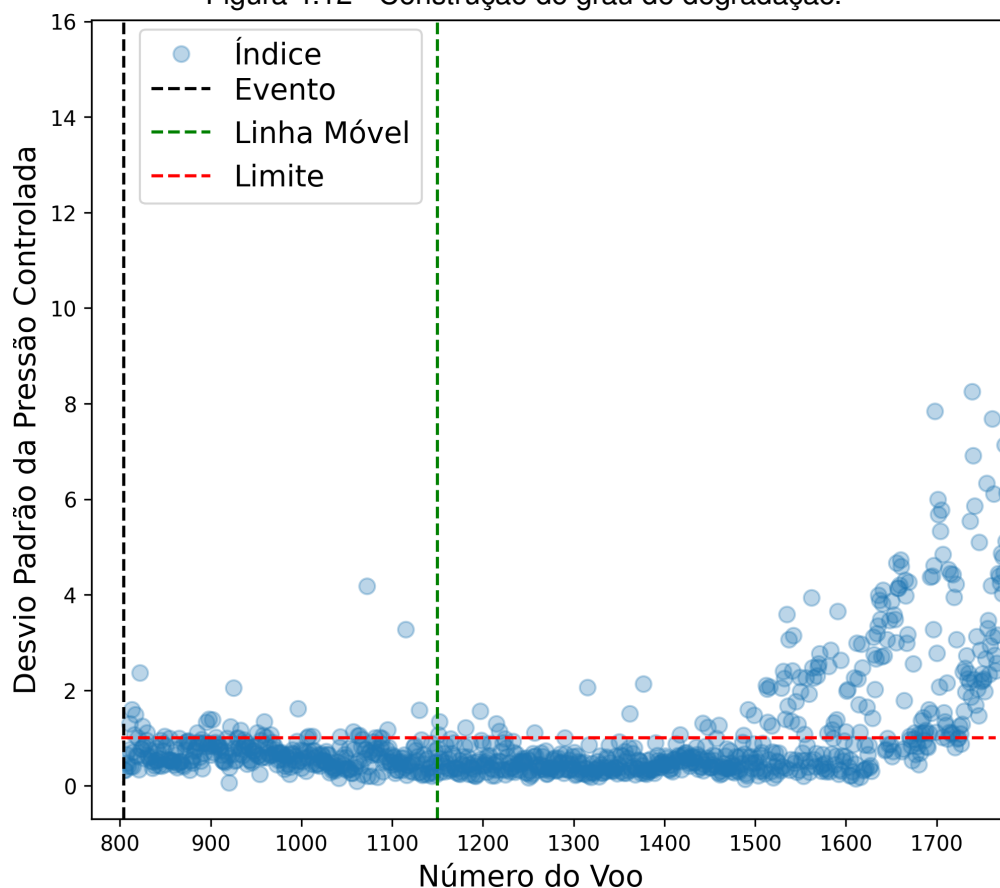
Cada linha do banco de dados representa um voo diferente sendo que cada aeronave possui um certo número de voos, diferente para cada uma. Para definir os índices, é necessário conhecimento detalhado do sistema, onde a participação de especialistas é vital. Inferir a degradação de um equipamento baseado apenas em dados, sem conhecimento da física envolvida pode trazer resultados cuja interpretação não traz ações conclusivas. Além da física do sistema, é necessário compreender que dados de campo trazem desafios extras pelo fato de não se ter o controle das condições de contorno como se tem em laboratório. Índices bons capturam de forma mais precisa as mudanças do fenômeno ao se aproximar das remoções, pois o comportamento do componente ou sistema é alterado conforme a degradação aumenta.

4.7 Nível de degradação

O objetivo desta seção é descrever a construção do alvo, ou seja, a variável a ser prevista pelos algoritmos de aprendizado de máquina. Também pode ser entendido como a saída desejada.

O alvo é denominado nível de degradação e visa a vincular os dados à degradação do componente. A Figura 4.12 ilustra o processo por trás da construção do índice de degradação. Primeiro, a figura representa um único evento para uma única aeronave. Cada ponto é um voo, ou seja, uma observação de um índice específico. O limite foi definido por inspeção visual do mesmo gráfico para todas as

Figura 4.12 - Construção do grau de degradação.

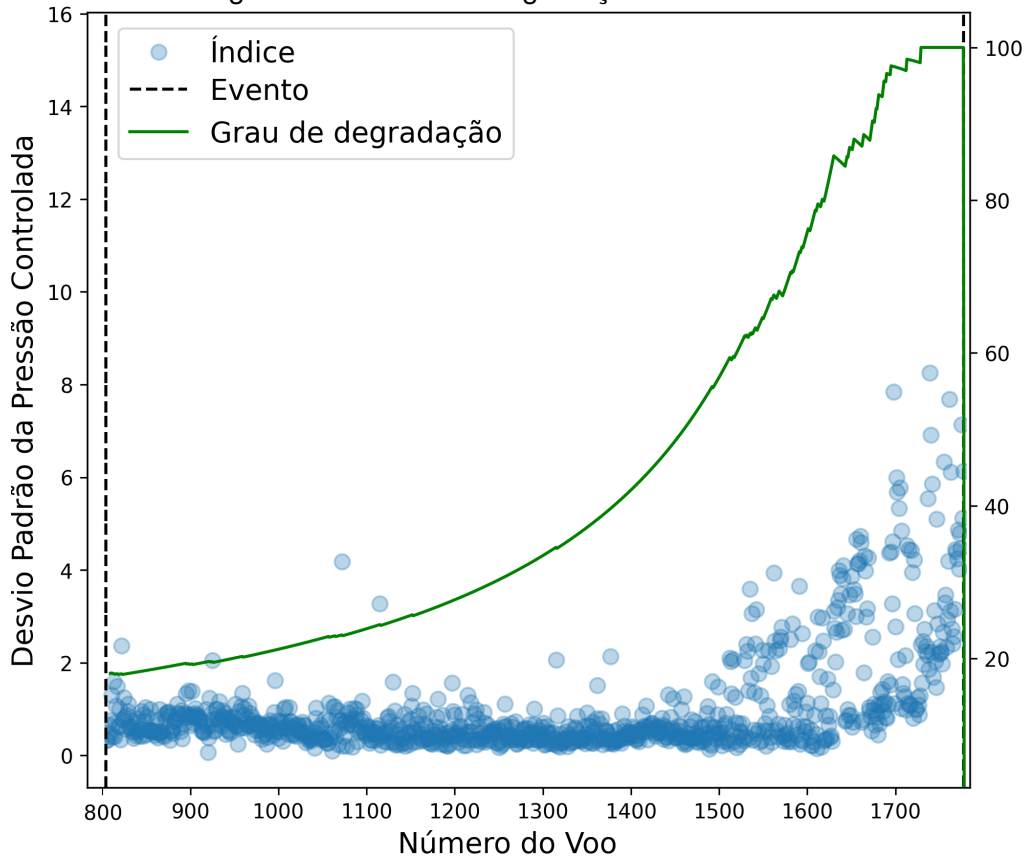


aeronaves. Observa-se que, para voos distantes do evento, a maioria dos pontos está abaixo do limite, com exceção de alguns valores discrepantes. À medida que o evento se aproxima, os pontos tendem a ficar acima do limite, mas não completamente.

Mesmo com o componente degradado, os efeitos da degradação são estimulados por distúrbios externos, como oscilação de pressão de entrada, sendo que o impacto desses distúrbios pode variar com a condição de operação. Os efeitos são diferentes se a pressão média de entrada for maior ou menor e também mudam conforme o ponto de operação, que muda com a missão planejada para um determinado voo.

A ideia é obter a porcentagem do número de pontos acima do limite ao lado direito da linha vertical móvel. À medida que essa linha se move para a direita, essa porcentagem aumenta, porque um número maior de pontos se encontra acima do limite em relação ao número total de pontos restantes. Isso é chamado grau de degradação, cujo comportamento é ilustrado pela Figura 4.13. Os dados

Figura 4.13 - Grau de degradação - único evento.



ilustrados representam uma aeronave específica e um único evento de troca. Há um claro aumento em seu valor à medida que o evento se aproxima, simplesmente porque há mais pontos acima do limite em relação ao total à medida que a linha móvel caminha para o lado direito do gráfico, aproximando-se do evento.

No entanto, a curva ainda é ruidosa. O grau de degradação de todos os eventos de troca desta aeronave específica é ilustrado na Figura 4.14. É possível observar que, embora haja um aumento no grau de degradação à medida que cada evento se aproxima, o valor máximo é diferente a cada vez.

Um filtro de Kalman foi então aplicado a essa curva para extrair uma tendência mais suave para cada janela de evento separadamente e em seguida a curva resultante foi normalizada em cada janela. O resultado dessa operação é ilustrado em 4.15. O motivo da normalização se deve ao fato de que, entre cada evento, o processo é reiniciado e a degradação deve ser reduzida a zero, resultando em um aumento no valor ainda claro, mas mais suave. No entanto, os valores máximos diferem para cada evento.

Figura 4.14 - Grau de degradação - múltiplos eventos.

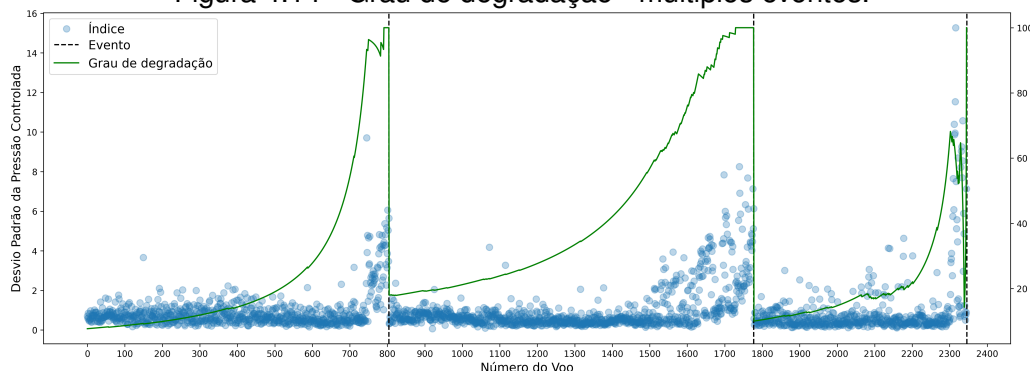
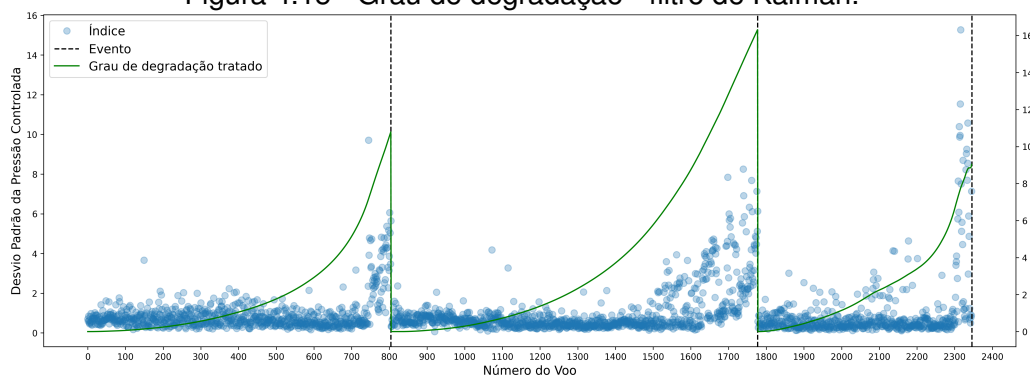


Figura 4.15 - Grau de degradação - filtro de Kalman.



O grau de degradação foi usado para construir o alvo de classificação para o aprendizado de máquina. Uma análise comparativa considerando diversas frações do valor máximo de grau de degradação filtrado para todo o conjunto de dados permitiu a identificação de um critério para cada evento. Metade do grau máximo de degradação de cada evento, após a aplicação do filtro de Kalman, foi considerado um ponto de inflexão em que a degradação atinge um estado Alto, vindo de um estado Baixo anterior. Este valor foi definido por ser relativo à cada troca, pois os valores máximos do grau de degradação são diferentes para cada evento de troca. A observação da construção para a base de dados completa permitiu estimar um valor inicial para estimar o nível de degradação.

Esse processo cria um indicador, baseado em classe, chamado *nível de degradação*. Ele conterá apenas dois valores possíveis: *baixo* e *alto*, sendo o primeiro quando estiver antes da linha de alta degradação e o segundo após ela. A Figura 4.17 ilustra o resultado do processo. Esse índice foi calculado para todos os eventos de todas as aeronaves, criando o alvo para os algoritmos de aprendizado de máquina que serão explorados em um capítulo posterior. Devido às limitações de

Figura 4.16 - Construção do nível de degradação - aplicação de filtro.





Figura 4.17 - Nível de degradação.



alguns algoritmos para trabalhar com dados categóricos, os nomes das classes foram alterados para Falso (Baixo) e Verdadeiro (Alto), mudando a interpretação para se o componente está em um estado de alta degradação ou não.

Este passo conclui o tratamento preliminar e organização do dados de campo, advindos de frotas de aeronaves reais.

4.8 Análise Exploratória de Dados

Um passo importante em trabalhos que utilizam dados abundantes chama-se Análise Exploratória de Dados (AED). John Tukey (TUKEY, 1977) a definiu como um procedimento para analisar dados, maneiras de planejar o acúmulo de dados de forma que sua análise seja mais fácil e precisa, bem como a definição dos artifícios matemáticos e estatísticos a serem aplicados durante a análise.

A AED aplicada neste trabalho possui os seguintes objetivos:

- Descobrir comportamentos inesperados.
- Encontrar lacunas onde não se possui dados.

- Sugerir hipóteses iniciais.
- Selecionar índices apropriados.
- Verificar a validade das premissas.


Os dados são provenientes da operação de diversas aeronaves e linhas aéreas diferentes, realizando rotas aéreas variadas. Portanto, é natural que existam muitas diferenças entre si, como protocolos, linhas aéreas e países. Tais diferenças podem ser refletidas nos dados, introduzindo comportamentos inesperados que podem ser interpretados como *outliers*. Protocolos de operação diferentes podem levar a condições de operação diferentes, que complementados por condições ambientes diferentes podem estimular o sistema de forma diferente, de modo que as diferenças de componente para componente provenientes do processo produtivo somadas às diferenças provenientes do processo de degradação e envelhecimento levam a efeitos diferentes.

Existem muitas lacunas nos dados analisados de campo. Podem não existir dados de sensores para um grande intervalo de tempo, por diversos motivos: erros de gravação ou armazenamento, compartilhamento parcial, manutenção de sensores e elementos de gravação. Porém, podem existir dados de manutenção e falha para o mesmo período. Isto ocorre porque estes dados provêm de bases diferentes. A falta total de dados pode atrapalhar a correlação entre dados de sensores e falhas. Além disso, a criação dos índices para a análise cria outra categoria de lacuna, pois muitos voos ao serem reduzidos aos índices acabam sendo filtrados e não são criados por conta da operação. Por exemplo, a aeronave possui duas válvulas PRSOV que em operação normal agem independentemente, uma em cada lado da aeronave. Existe a possibilidade de utilizar apenas uma, mas a operação fica restrita e já não é mais representativa de um cenário de degradação gradual. Portanto, voos que apresentam tal situação devem ser descartados.

Parte da AED consiste em observar o comportamento dos dados com o auxílio de gráficos. Certos tipos como histogramas, *boxplot* e gráficos de distribuição pontual podem ser ferramentas poderosas na análise. Ao escolher cuidadosamente a categoria de gráfico, os dados se tornam observáveis visualmente, e com a experiência do especialista, é possível identificar tendências e limites que podem ser difíceis que se detectar matematicamente ou computacionalmente.

Após cada voo ter sido reduzido a uma coleção de índices, um gráfico de um dos mesmos pode ser usado para observar a degradação da válvula temporal-

Figura 4.18 - Índice para uma única aeronave por data.

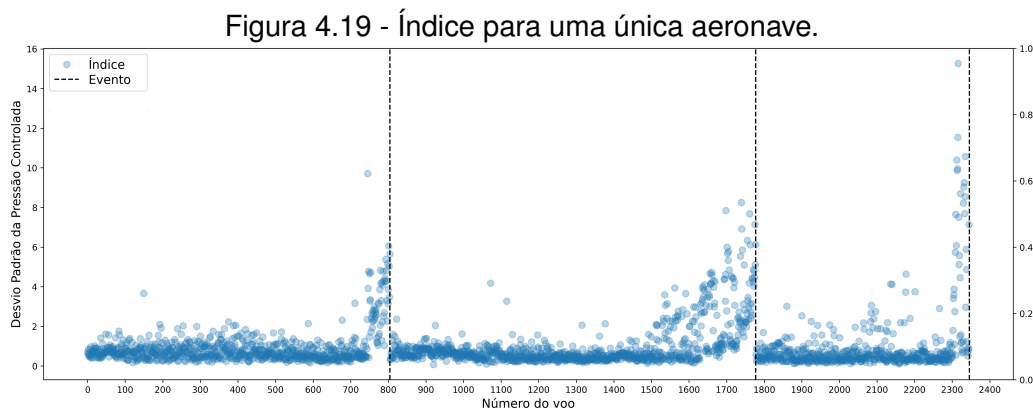


mente, considerando os eventos de substituição. Pode-se observar que, embora o comportamento mude, é difícil identificar uma tendência clara nos dados ruidosos, como visto na Figura 4.18. Os dados são ilustrados como uma coleção de pontos, cada um representando uma linha do banco de dados para um índice específico, neste caso, limitado a uma aeronave específica.

Os dados são provenientes de vários voos de uma única aeronave, ao longo de muitos meses. É possível observar que os dados estão em um intervalo específico até que ocorre uma mudança repentina no comportamento à medida que os dados se aproximam do evento que se deseja prever, no caso a troca do equipamento de interesse. No entanto, ainda há um grupo de pontos na faixa inferior, com baixos valores. Isto se deve ao fato da operação conter sutilezas não presentes em modelos computacionais ou experimentais, além da degradação ser um fenômeno não-linear e complexo. As lacunas nos dados ocorrem porque eles estão ilustrados pela data do voo e faltam dados para os períodos em branco. Os motivos incluem falta de registro para esses voos específicos, corrupção dos arquivos registrados no computador da aeronave e operação fora do envelope considerado.

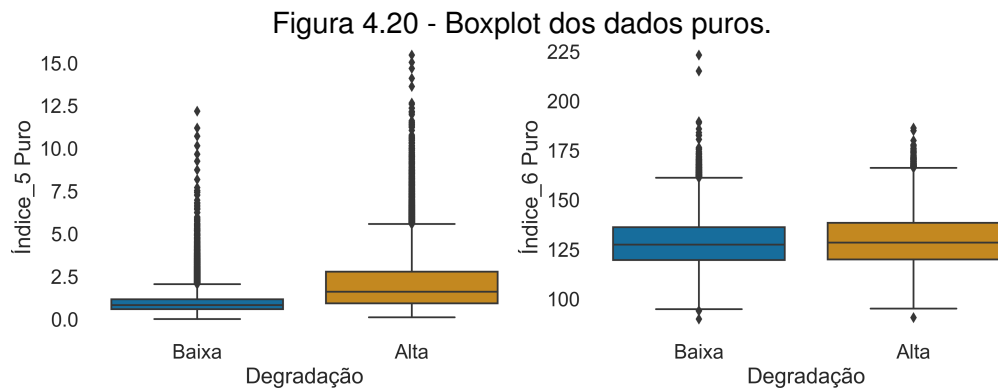
As técnicas de análise usadas, desde histogramas simples até algoritmos de aprendizado de máquina, interpretam esses dados como uma coleção de pontos. A Figura 4.19 ilustra os dados sem lacunas, já que valores inexistentes não são computados nesses cálculos. Para o índice ilustrado, é possível identificar que, à medida que um evento se aproxima, o valor do índice começa a aumentar. Entretanto, não há um padrão fácil de identificar, pelo menos visualmente, mesmo quando se observam os mesmos gráficos para o restante das aeronaves na base de dados.

Como pode ser visto na Figura 4.19 para os dois primeiros eventos, o aumento do valor à medida que cada evento se aproxima é muito acentuado e próximo ao evento. No entanto, para o terceiro evento, o aumento começa mais cedo e é mais suave. Por esse motivo, técnicas de tendência e filtragem serão usadas antes do aprendizado de máquina. Contudo, antes foi necessário aplicar os conceitos de AED para selecionar os índices que realmente foram apresentados aos algoritmos de aprendizado de máquina.




4.8.1 Seleção de índices

Para obter uma melhor compreensão dos dados, foi realizada uma análise bivariada em relação à classe-alvo. A Figura 4.20 ilustra um *boxplot* para dois índices, separados por classe-alvo. Pode-se observar que as distribuições estão muito próximas para o índice seis, o que pode indicar não haver diferença no comportamento das classes-alvo para esse índice específico. Entretanto, há uma clara diferença em ambas as distribuições por classe para o índice cinco. Isso significa que esse índice apresenta alguma diferença e pode ser útil para identificar o nível de degradação.



Outra ferramenta interessante e útil na análise exploratória é um mapa de calor (*heatmap*), uma representação gráfica dos dados em cores que mostra a correlação de Pearson (DESHPANDE, 2018) entre as variáveis. Nessa aplicação, a informação obtida é a correlação entre os índices. A Figura 4.21 revela haver alguns índices ligados, como os índices três, cinco e dez. Isso significa que esses índices podem se comportar de maneira semelhante à medida que a degradação aumenta com o tempo.



A análise do mapa de calor também revela que alguns índices têm uma correlação negativa. Isso significa que, à medida que cada evento se aproxima, esses índices terão um comportamento inverso. Em outras palavras, eles diminuirão à medida que outros aumentarem, como a relação entre os índices um e cinco. Isso pode prejudicar o desempenho de alguns algoritmos de aprendizado de máquina, portanto, esse índice deve ser usado com cuidado. O uso de todas essas informações guiou a seleção dos índices (NETTLETON, 2005) que compuseram a entrada dos algoritmos de aprendizado de máquina. Os índices com alta correlação podem ser redundantes e os índices que agem de forma oposta uns aos outros podem prejudicar o desempenho do algoritmo.

Os índices escolhidos baseiam-se em ferramentas estatísticas, como médias e desvios. Além de simples operações, critérios de estabilidade como número de cruzamentos de um determinado valor em um intervalo específico também compõem os índices escolhidos, que são baseados em características físicas como pressão, vazão e corrente do motor de torque da válvula.

4.9 Filtragem dos índices

É difícil identificar uma tendência nos dados puros, por isso pode ser útil a aplicação de técnicas de filtragem de dados para tentar identificar tendências. Além disso, alguns filtros podem conseguir diminuir ruídos nos dados ou até removê-los, embora com a desvantagem de dificultar a observação de alguma eventual tendência. A comparação dos resultados de todas as técnicas de filtragem foi parte do foco deste trabalho, para descobrir se há um filtro específico que produza bons resultados para essa classe de problema. As técnicas escolhidas foram:

- Média móvel
- Máximo móvel
- Desvio padrão móvel
- Mediana móvel
- Média ponderada exponencialmente
- Filtro de Kalman

Algumas dessas técnicas são básicas, sendo escolhidas para estabelecer um padrão de referência, como a média móvel. O filtro máximo móvel foi escolhido porque alguns índices tendem a aumentar de valor à medida que o evento a ser previsto se aproxima. O desvio padrão foi escolhido para complementar a média.

A mediana foi selecionada para capturar informações quando houver distorção nos dados, além de ser menos suscetível a valores extremos e discrepantes.

A média ponderada exponencialmente apresentou resultados interessantes na detecção da variabilidade do processo (HUWANG et al., 2009). Esse filtro também se mostrou eficaz ao lidar com lacunas vazias de dados para previsão em tempo real (FINCK; PEDROLLO, 2021). O filtro de Kalman é uma técnica mais avançada que se mostrou útil na filtragem de dados de sensores para estimativa de vida útil restante (BAPTISTA, 2018). Esses filtros mais avançados também foram escolhidos para verificar se são necessários ou se uma abordagem mais simples pode ser suficiente. É esperado de certa forma que tais técnicas apresentem desempenho superior às mais simples, no entanto a aplicação irá confirmar ou rejeitar tal hipótese.

Para analisar melhor a tendência visualmente, os diferentes filtros serão aplicados nos dados de um único evento de uma mesma aeronave. As diferentes técnicas de filtragem são apresentadas na Figura 4.22. É importante observar que os filtros de janela móvel ainda são ruidosos, o que pode significar que não conseguiram extrair uma tendência suave dos dados puros, tal é o nível de ruído contido nos mesmos. O filtro de Kalman apresenta um aumento pequeno no valor ao longo do eixo horizontal, indicando a presença ainda de um grande número de pontos de baixo valor próximo ao evento.

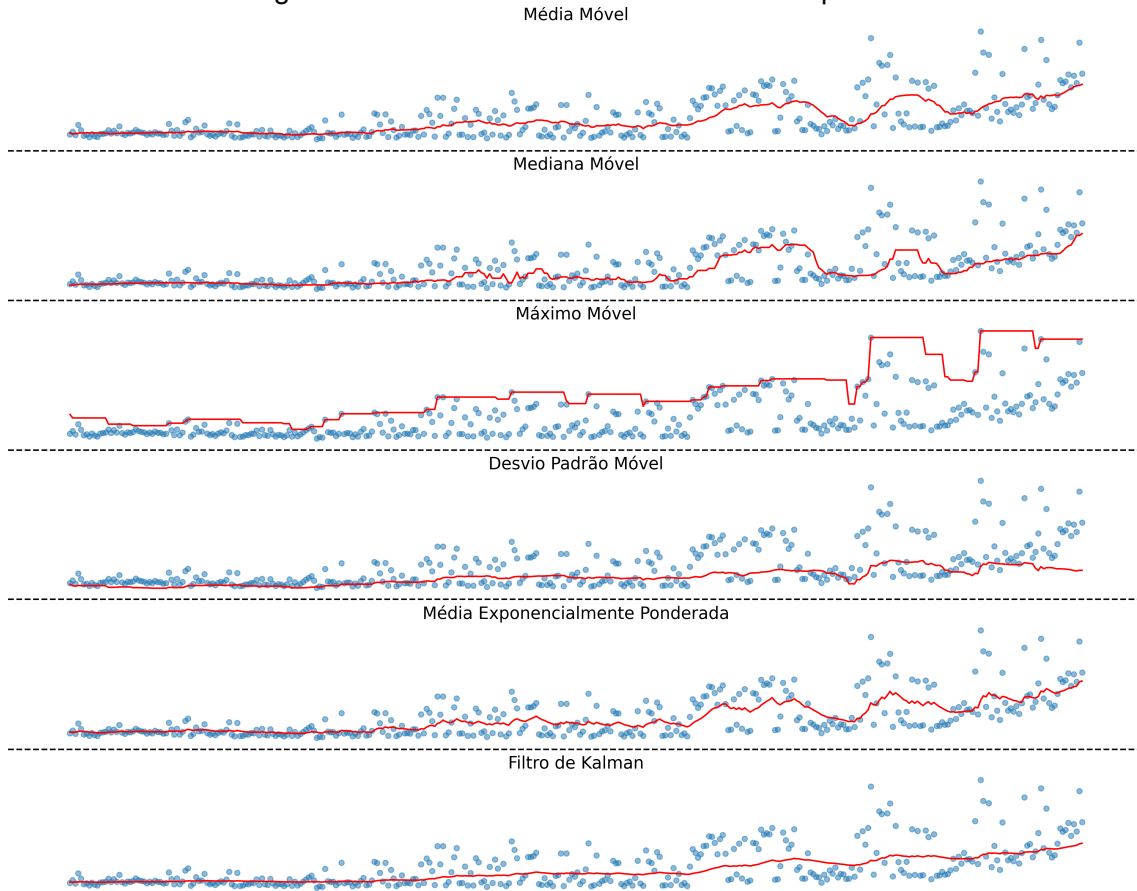
É possível observar que alguns ainda são ruidosos, mesmo quando se aproximam do evento. O filtro de Kalman parece ter captado melhor a dinâmica do que os outros, com o menor nível de ruído, mas o aumento da tendência ainda é pequeno, mesmo após rodadas de ajuste das covariâncias.

Pode-se observar claramente que a média e a mediana móveis ainda são ruidosas, dada a variabilidade do próprio processo físico e dos fatores que o afetam, como as decisões de campo da tripulação da aeronave e as decisões de manutenção da companhia aérea. O mesmo pode ser concluído para o desvio padrão móvel.

O máximo móvel parece ter capturado melhor a tendência, pois muitos índices sempre aumentarão seu valor à medida que cada evento se aproxima. A média ponderada exponencial apresenta algum nível de ruído, como os filtros móveis. A aplicação do filtro de Kalman resulta em uma boa linha crescente, mas não tão pronunciada quanto os próprios dados puros.

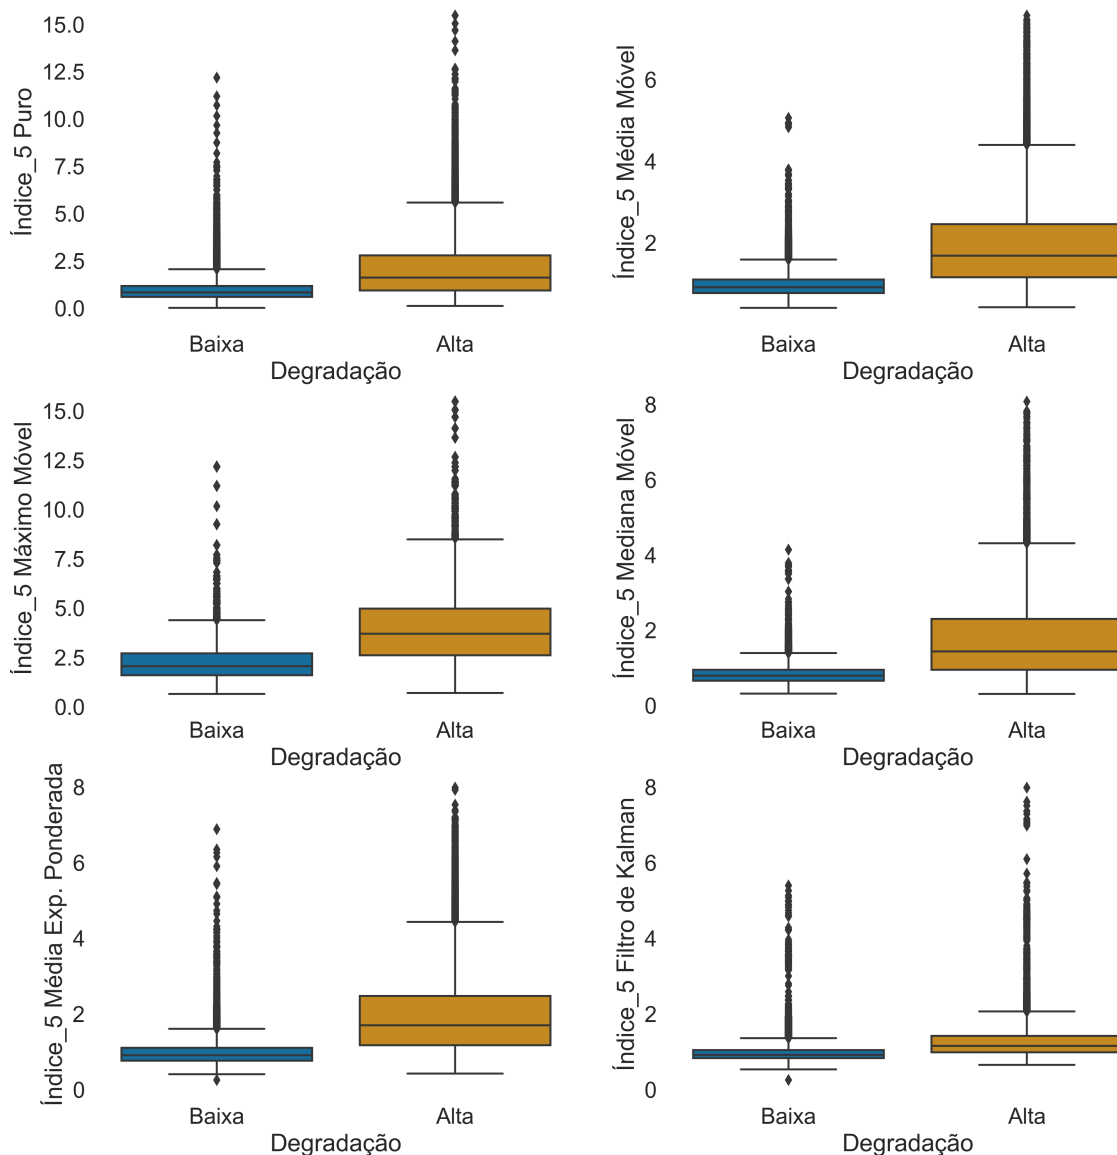
A análise exploratória dos dados filtrados revelou informações úteis. Um único

Figura 4.22 - Efeito de cada filtro nos dados puros.



Índice foi escolhido para ilustrar essa análise, o índice cinco, porque apresenta uma tendência de aumento mais pronunciada à medida que o evento se aproxima. Os *boxplots* bivariados dos dados filtrados são apresentados na Figura 4.23.

Figura 4.23 - Boxplot dos dados filtrados.



É possível observar que os filtros de fato oferecem um benefício. Por exemplo, a média móvel simples. O primeiro quartil da classe Alta agora começa depois que o terceiro quartil da classe Baixa termina, indicando que a sobreposição desse índice específico está diminuindo. A média móvel e a mediana móvel apresentam uma distribuição muito semelhante, o que indica que a distribuição deste índice tende a ser normal. A média ponderada exponencialmente também é semelhante aos outros filtros de média. O filtro de Kalman resulta em um intervalo interquartil mais restrito. Algumas aeronaves apresentam uma degradação muito súbita, o que contribui para a dificuldade de generalizar as suposições inferidas pelos filtros.

4.10 Aprendizado de máquina

Os algoritmos de aprendizado de máquina avaliados foram:

- Árvore de classificação
- Floresta aleatória
- *Gradient boost*
- *K-Neighbors*
- *Support Vectors*
- Redes Neurais

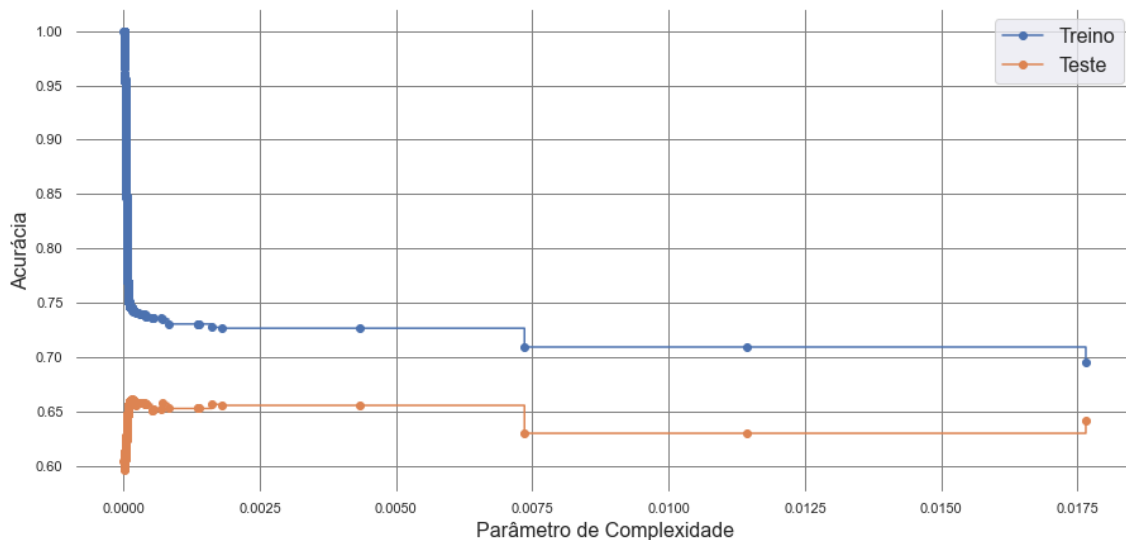
Esta seleção ocorreu por conta do nível de complexidade diferente de cada uma, além da capacidade para classificação, diferenças da facilidade de acesso às regras de classificação e recursos computacionais necessários. Estas diferentes características serão discutidas posteriormente, avaliando a adequação para aplicações como a deste trabalho, além de considerações sobre desempenho e complexidade.

Os dados foram separados em treinamento e teste com uma proporção desejada de 75% para o treinamento/validação e 25% para o teste. A divisão foi feita no nível da aeronave, não no nível do voo, já que os voos estão em uma linha do tempo e precisam estar juntos. Entretanto, como o número de voos por aeronave é diferente, a divisão entre treinamento e teste não foi uma proporção perfeita. Quando esses fatos são levados em consideração, a divisão final ficou em 77% / 23%, com o número de observações sendo 42535 para o conjunto de treinamento e 12567 para o conjunto de teste.

Como um dos focos da parte direcionada por dados de frota é avaliar os filtros, foi escolhida uma técnica simples de aprendizado de máquina, a árvore de classificação, com uma configuração simples: critério de impureza de Gini para a classificação, sem limites para a profundidade da árvore e sem pesos para as folhas ou para as classes. O único parâmetro definido de forma diferente de uma construção padrão foi a consideração da poda de complexidade de custo mínimo para evitar uma árvore com *overfitting*.

Para encontrar o parâmetro de complexidade que produziu os melhores resultados, foi realizada uma análise que retorna o parâmetro de complexidade efetivo (α) e as impurezas em cada etapa do processo de poda. À medida que α aumenta, mais da árvore é podada. Isso, por sua vez, eleva as impurezas a níveis

Figura 4.24 - Poda de complexidade de custo mínimo.




mais altos, o que faz com que a árvore cometa mais erros e afeta a pontuação. Um α ideal deve ser escolhido para que a árvore seja um bom generalizador, mas também apresente uma taxa de erro aceitável. Essa análise foi executada no conjunto de treinamento e cada árvore resultante foi então aplicada no conjunto de teste. Ao observar a precisão da árvore à medida que α aumenta, foi possível escolher um ponto ideal, conforme ilustrado na Figura 4.24. O ponto com a melhor relação entre a precisão do conjunto de treinamento e do conjunto de teste está em $\alpha = 0.005$. A árvore final foi então construída e treinada com esse valor.

A floresta foi criada com 100 árvores, sem poda. O *Gradient Boost* teve 100 estimadores com critério de qualidade sendo o erro quadrático médio. O *K-Neighbors* foi configurado com 5 vizinhos com pesos uniformes e métrica de distância sendo a normal euclidiana. Para o SVM, o kernel escolhido foi o *Radial Basis Function* pois é uma escolha comum para classificação. A Rede Neural foi criada com três camadas escondidas com 20 neurônios cada.

4.11 Geração de dados sintéticos

Os objetivos da geração de dados sintéticos são: emular o comportamento real através da utilização do modelo validado e gerar dados adicionais para aumentar a assertividade dos algoritmo de aprendizado de máquina. A Figura 4.25 ilustra um exemplo de evento de troca para uma aeronave, provenientes dos dados de campo e utilizado como exemplo para a geração sintética. O índice apresentado se correlaciona com a variabilidade da pressão controlada. Conforme o tempo

Figura 4.25 - Exemplo de dados de campo para a geração de dados sintéticos.



passa e válvula envelhece, o controlador não consegue mais compensar a degradação e a pressão passa a ser mais oscilatória, característica discutida na Seção 4.5 e esta oscilação se traduz em um desvio padrão maior.

A geração de dados sintéticos utiliza o modelo validado, descrito na Seção 4.2.1. As diferenças do modelo no modo de validação e de execução estão nas entradas. No modelo em modo de validação, as entradas são as leituras dos sensores do voo. No modo de execução, as entradas dinâmicas do modelo são a pressão de entrada da válvula, a pressão ambiente e a pressão de referência. Os índices da base de dados mais importantes, isto é, mais bem correlacionados com as trocas, foram extraídos da fase de cruzeiro do voo, conforme visto na Seção 4.8.1. Sendo assim, a geração de dados sintéticos focou nesta fase, onde a altitude e a pressão de entrada da válvula podem ser consideradas constantes, pois não há demandas que possam causar oscilações na pressão.

No entanto, impor valores constantes nas entradas significa que o modelo sempre trará a mesma resposta para o mesmo nível de degradação. A pressão lida na entrada da válvula em um voo possui ruído, pois é advinda do motor. A aeronave possui sistemas que controlam a tração do motor para manter o voo na velocidade e altitude corretas, o que faz com a pressão apresente certo nível de ruído. Além disso, características construtivas do motor e do sistema causam

pequenas variações ao longo do voo. Através de uma análise estatística da base de dados, encontra-se a distribuição estatística para as variáveis de entrada do modelo.

Para simular uma entrada como a de campo, um ruído marrom é inserido na entrada sintética constante de modo que a pressão se torne similar à de campo. O ruído marrom é a integral do ruído branco (GARDINER, 2004) e sua aplicação em teoria de sinais é chamada de processo de Weiner (GALLEANI; COHEN, 2006). Este tipo de ruído foi selecionado em favor do branco para filtrar frequências muito altas não observadas nos processos físicos envolvidos nas pressões na entrada da válvula.

Assim, é utilizado um ruído branco seguido de um integrador, na forma de uma função de transferência de primeira ordem (OGATA, 2010), descrita na Equação 4.9, onde τ é a constante de tempo e K o ganho de estado estacionário. Esta função também é conhecida como filtro passa-baixa. Este ruído é somado pressão média entre todos os voos reais, criando uma pressão ruidosa cujo comportamento é similar a de campo.

$$F(s) = \frac{k}{\tau s + 1} \quad (4.9)$$

A Figura 4.26 ilustra um exemplo de sinal de pressão real e dois sinais sintéticos, obtidos através do ajuste dos parâmetros da função de transferência. Adicionalmente, a semente utilizada para iniciar o algoritmo gerador de números pseudo-aleatórios também é variada, gerando uma nova distribuição de ruído branco a cada rodada, que por sua vez é integrado e então somado ao valor médio da pressão.

Para obter voos do modelo que representem os voos de frota, é necessário variar os fatores associados à degradação da válvula, aumentando-os a cada voo. Para representar fielmente a degradação ao longo do tempo, serão observados exemplos de dados reais, provenientes da base de dados apresentada na Seção 4.6.1. Um processo iterativo visual foi utilizado para selecionar o vetor de degradação, rodando a simulação diversas vezes e observando a resposta até encontrar o conjunto de parâmetros de degradação que emula o comportamento do exemplo, ilustrado na Figura 4.27. Note que o comportamento é similar, demonstrando a adequação do modelo para diversos níveis de degradação.

Contudo, apesar de similar, o índice é muito regular, o que faria com que algoritmos de aprendizado de máquina capturassem perfeitamente a degradação, com

Figura 4.26 - Entrada de pressão para a geração de dados sintéticos.




Figura 4.27 - Dados sintéticos perfeitos.





Figura 4.28 - Dados sintéticos não perfeitos.

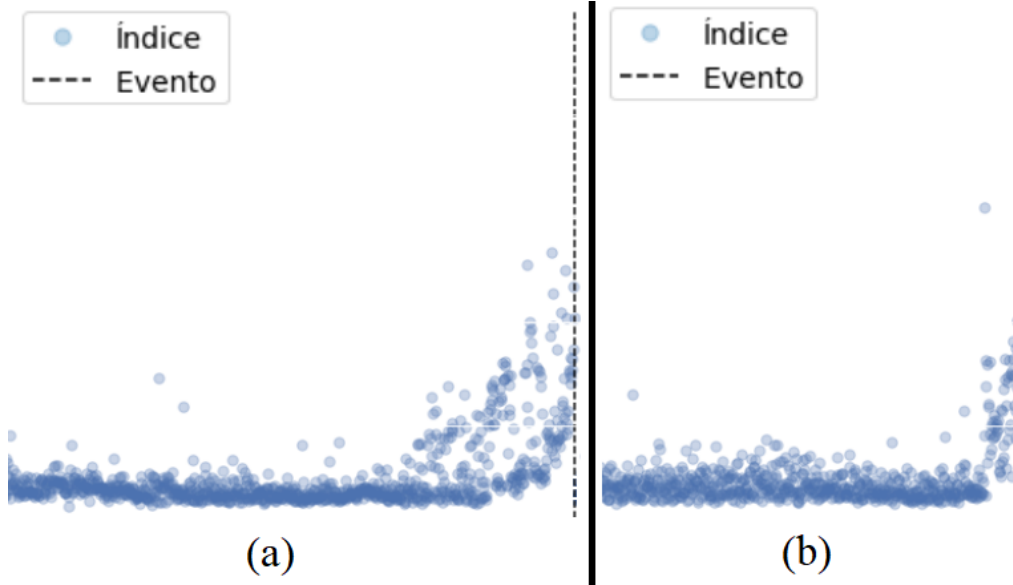


o risco do algoritmo utilizar o número de amostras para fazer inferências, ignorando outros índices caso a correlação apresente níveis mais altos. Existe uma variabilidade na física associada ao movimento do pistão da válvula em função de pequenas folgas e certo desalinhamento do pistão em relação à camisa, que por sua vez afeta o nível de atrito e a qualidade do assentamento do selo de vedação do pistão.

Para evitar tal comportamento, o aumento de degradação é adicionado de um ruído, na forma de uma distribuição normal deslocada, com média diferente de zero e desvio padrão diferente de um. Isto causa um efeito aleatório leve nas variáveis do modelo que controlam a degradação, que ainda mantém a tendência de crescimento mas deixa de ser facilmente previsível. O resultado desta operação é ilustrado na Figura 4.28. O objetivo é emular o comportamento médio dos índices observados na base completa dos voos de campo.

A observação dos dados de frota revela ainda dois principais tipos de degradação: gradual e súbita, ilustrados na Figura 4.29 pelo índice que acompanha o desvio padrão da leitura do sensor de pressão. As condições que ditam a degradação dependem de diversos fatores como características construtivas da válvula, pressão de entrada, carga de operação, ações de manutenção, entre outros. Assim, é possível que a degradação se manifeste de maneira diferente para válvulas diferentes, mesmo que pertençam à mesma aeronave.

Figura 4.29 - Degradação nos dados de frota (a) Gradual e (b) Súbita.



Portanto, a geração de dados sintéticos deve considerar ambos tipos de degradação. É importante dizer que embora possam existir outros tipos, estes dois são os mais comuns e foram representados pelo modelo do equipamento.

4.12 Análise exploratória de dados sintéticos

A geração de dados sintéticos prosseguiu com um processo iterativo, utilizando o modelo validado e as entradas descritas na subseção anterior para gerar milhares de voos sintéticos, que passam pelo mesmo tratamento e processo de criação de índices do que os voos de campo, criando uma base de dados de voos sintéticos que emula a base de dados de campo, demonstrada na Tabela 4.3.

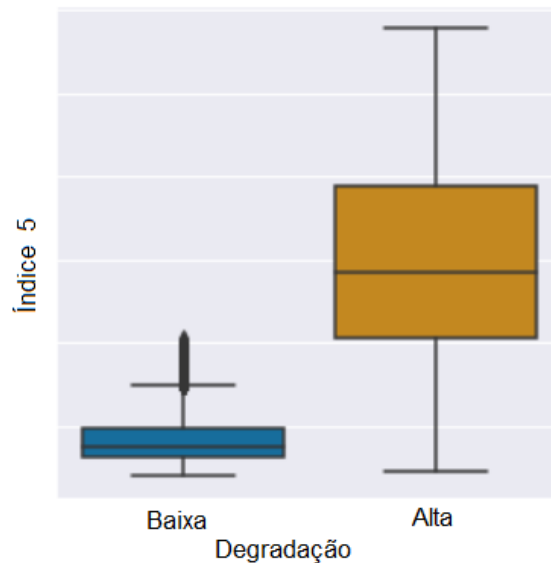
No entanto, como o modelo é utilizado para simular apenas uma fase do voo, nem todos os índices existem na base sintética, pois alguns estão associados a transientes que ocorrem em fases de voo que não estão representadas no modelo. Contudo, após a seleção dos índices na Seção 4.8.1, onde apenas alguns foram selecionados e mantidos para as análises de aprendizado de máquina, a base de dados sintéticos foi gerada com os mesmos índices, que contém apenas aqueles que podem ser reproduzidos pelo modelo.

O objetivo da utilização do modelo é representar a operação da válvula livre de efeitos externos, como instalação, manutenção sem troca, efeitos do controlador e do piloto e considerações operacionais. Os parâmetros do modelo consideram variações de pressão associadas aos diferentes perfis de voo, ação do piloto

Tabela 4.3 - Base de dados de voos sintéticos.

Aeronave e Voo	Índice 1	Índice 2	[...]	Índice 5	Índice 6
Aeronave 1 Voo 1	0.181	1.170	[...]	1.181	5.170
Aeronave 1 Voo 2	0.51	1.280	[...]	1.645	6.274
[...]	[...]	[...]	[...]	[...]	[...]
Aeronave 30 Voo 1999	6.685	4.960	[...]	6.715	7.168
Aeronave 30 Voo 2000	5.715	5.860	[...]	4.716	11.583

Figura 4.30 - Boxplot dos dados puros sintéticos.



automático bem como acelerações e desacelerações comandadas pelo piloto.

A partir da base de dados sintéticos, foram realizadas as mesmas análises exploratórias para verificar se os índices da base sintética estão capturando os fenômenos reais corretamente. A Figura 4.30 apresenta o boxplot bivariado para o índice que representa a dispersão dos dados de pressão. Em comparação com os dados de frota, existe uma separação mais pronunciada nos dados de modelo. Isso se deve ao fato de que a degradação no modelo pode ser controlada e para que o algoritmo de aprendizado consiga diferenciar classes com mais facilidade, os parâmetros que associados à degradação foram selecionados de forma que esta separação apresentasse maior diferença entre as classes.

4.13 Análise híbrida

A análise híbrida utiliza dados de frota e dados sintéticos no treinamento com o objetivo de enriquecer a base de dados e apresentar ao algoritmo de aprendizado

de máquina exemplos de degradação gradual ideal, pois este é o comportamento esperado teoricamente. Na prática, as questões operacionais e variações de manufatura tendem a criar dados ruidosos que desviam do padrão de degradação comum e atrapalham o treinamento do algoritmo de aprendizado de máquina.

Para analisar com maior precisão a influência dos dados sintéticos no treinamento em conjunto com dos dados de frota, a proporção de dados sintéticos para dados de frota foi considerada. Assim, foi possível analisar se o aumento da quantidade de dados sintéticos no treinamento se traduz em aumento de desempenho do aprendizado de máquina. Em relação ao dados de teste, estes foram mantidos apenas com dados de frota, pois o objetivo é aplicar o algoritmo treinado na operação real.

A utilização de dados híbridos tem o objetivo de esclarecer para o algoritmo de aprendizado de máquina como é a evolução esperada da degradação do componente. O fato do sistema possuir um controlador que está constantemente tentando compensar a degradação pode dificultar a interpretação dos dados em relação à degradação, conforme observado na Figura 4.31. Antes do primeiro evento de troca, a tendência de aumento do índice é clara. No entanto, para o último evento, muitos pontos ainda se mantêm com baixo valor mesmo quando a troca está próxima.

Compensar variações e degradações é uma das funções dos sistemas de controle. A figura ilustra dados de frota, todos da mesma aeronave. A degradação o primeiro evento de troca é bem mais ruidosa e menos pronunciada do que a do segundo. Isto pode significar que a troca da válvula pode ter sido prematura, visto que a degradação do segundo evento atinge níveis bem mais altos antes do evento de troca.

A utilização de dados sintéticos em conjunto com os dados de frota durante o treinamento tem o objetivo aumentar a importância das observações de degradação próxima à ideal e diminuir o peso das degradações não ideais, onde a troca pode ter sido prematura. Na prática, estas trocas ocorrem por conta de mensagens de falha, que são ativadas em determinadas condições. Para este sistema em particular, estas mensagens tendem a ser estritas demais. Estas mensagens são utilizadas para monitorar diversos parâmetros do sistema, e ditam se o componente está em estado de falha ou não.

Estas mensagens são emitidas quando, de acordo com os resultados dos cálculos e comparações das lógicas de monitoramento, os limites definidos como não aceitáveis são atingidos. No entanto, os algoritmos dessas lógicas não acompa-

Figura 4.31 - Degradação não-ideal / Degradação ideal.





Figura 4.32 - Exemplo de degradação não contínua ao longo do tempo.



nam a degradação no tempo, apenas o estado atual, o que as torna vulneráveis a picos espúrios, levando à troca precoce.

Nos dados de frota a degradação não é estritamente crescente, o que dificulta a correlação dos dados com a classe de degradação. A Figura 4.32 ilustra outro exemplo de uma degradação não contínua, onde o mesmo índice das figuras anteriores ainda apresenta muitos pontos na parte inferior do gráfico, mesmo próximo do evento de troca da válvula.

Tal comportamento anômalo causa problemas para os algoritmos de classificação supervisionados, pois há observações com valores similares para ambas

as classes. Embora ainda se perceba que há um aumento no valor do índice quando o evento de troca se aproxima, muitos pontos ainda permanecem com valores baixos, típicos de baixa degradação. Estes pontos causarão erros durante o aprendizado ao apresentar exemplos de entrada similares mas com rótulos de saída diferentes.

Para melhorar o aprendizado, o modelo foi usado para gerar exemplos onde tais características não ocorrem, com o objetivo de apresentar exemplos para o aprendizado de máquina nos quais a evolução da degradação está mais próxima do ideal, tanto para evitar falhas inesperadas como para tentar prolongar a vida útil do equipamento.


É importante deixar claro que tipicamente vários parâmetros podem ser utilizados nos monitores das falhas, no entanto, quando não bem projetados ou quando projetados com margens mínimas, esses monitores podem ser acionados de forma espúria e causar remoções precoces.

A análise híbrida considerou apenas dados de frota para o conjunto de teste. Para o treinamento, a proporção de dados sintéticos foi variada de 0% a 50% em relação aos dados de frota. Dessa maneira, foi possível analisar o efeito da quantidade de dados sintéticos no treinamento híbrido. Caso a mudança de desempenho continue a crescer, esta proporção poderia aumentar. No entanto, para uma proporção maior do que 50%, seria impreciso dizer que os dados de frota são auxiliados pelos sintéticos e não o contrário.

A hipótese é que haja uma melhora, pois os algoritmos de aprendizado de máquina terão mais exemplos de degradações nominais. As trocas ao início da degradação, interpretadas como trocas precoces, que ocorrem na operação de frota terão menos exemplos relativamente às trocas que ocorrem quando a válvula está em um estado avançado, porém aceitável, de degradação.

A Figura 4.33 ilustra como ficam os boxplots do índice que mede a variabilidade da pressão para dados puros em comparação com os mesmos dados porém acrescidos de dados de modelo até que estes componham 50% da base de dados. A mudança é sutil e está presente no fato que a sobreposição das classes diminuiu, com a classe Alta se iniciando após o término da classe Baixa. Além disso, as classes abrangem um maior intervalo antes dos dados serem considerados *outliers*. A inclusão dos dados sintéticos é considerada adequada, pois não altera a composição fundamental dos dados de frota, apenas insere novas informações que tendem a aliviar problemas de classificação ao eliminar casos ambíguos.

Figura 4.33 - Boxplot para o mesmo índice com proporções diferentes.



Conforme as análises exploratórias de dados revelaram, os dados de frota e de modelo possuem características semelhantes quando observados apenas as degradações graduais e com baixo ruído da frota, ou seja, excluídos os casos anômalos. Tais casos podem ser tratados em operação real pelas mensagens de falha da aeronave, pois em alguns casos a válvula ainda poderia operar por mais tempo, pois ela pode não estar na zona de alta degradação quando aplicado o mesmo critério para todas as aeronaves.

4.14 Resultados esperados

O principal resultado esperado é uma melhoria na estimativa do nível de degradação do equipamento quando dados sintéticos são utilizados em conjunto com dados de frota. A melhoria foi suportada por dados reais de frotas aéreas e pelo conhecimento da física do sistema para dar significado para a análise estatística e de aprendizado de máquina.

Adicionalmente, uma comparação entre os métodos mais clássicos de aprendizado de máquina trouxe informações valiosas sobre suas aplicabilidades no campo de PHM. Alguns métodos são muito mais complexos e custosos computacionalmente do que outros — SVM e Árvores de Classificação, por exemplo. Caso uma árvore apresente desempenho como uma rede neural, a preferência é de técnicas mais simples, pois são mais fáceis de projetar e compreender, além de apresentarem menor tempo de processamento. Outra característica que foi considerada foi a facilidade de acesso às regras de aprendizado. Por exemplo, obter o raciocínio usado por uma árvore é mais fácil do que para um SVM, que

se trata de uma técnica que não permite acesso às suas regras de classificação.

O algoritmo de aprendizado de máquina utilizado em primeiro lugar foi a *Árvore de Classificação*, com a finalidade de verificar o desempenho de uma técnica de aprendizado de máquina relativamente simples, computacionalmente não demandante e que permite acesso às regras de classificação. Esta última característica é importante para avaliação de técnicas de aprendizado de máquina aplicadas à classe de problema analisada neste trabalho, pois permite ao pesquisador avaliar quais os índices mais importantes e quais valores destes índices determinam pontos de atenção. Outro algoritmo analisado com mais detalhes foi o SVM, devido à alta dimensionalidade dos dados de entrada, além do grande volume e das diferentes fontes.

Os efeitos das aplicações dos diferentes filtros apresentados na [Seção 4.9](#) foram analisados. Os dados de frota são ruidosos e apresentam alto nível de dispersão, tornando a aplicação de filtros natural. É esperado que os efeitos dos filtros melhorem as respostas dos algoritmos de aprendizado, pois tendem a diminuir a dispersão e o ruído.

5 RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados das análises conduzidas. Primeiramente, aquelas com apenas dados de campo. Em seguida, apenas dados de modelo. Finalmente, com ambos conjuntos de dados juntos. Para todas as análises, serão verificados os efeitos da aplicação de diferentes filtros, assim como a utilização de diversos algoritmos de aprendizado de máquina de complexidade diferentes. Para analisar o desempenho dos algoritmos e seus conjuntos de entradas, serão utilizados os conceitos definidos na Seção 3.5. A matriz de confusão e as métricas que dela derivam descrevem o desempenho dos algoritmos de aprendizado sob uma ótica absoluta e permitem uma comparação objetiva dos mesmos.

Idealmente, o algoritmo de aprendizado perfeito produzirá uma matriz de confusão que é uma matriz diagonal, o que significa que absolutamente todos os valores preditos foram iguais aos seus valores verdadeiros, que é um resultado pouco provável. Aceitando que a previsão não será completamente perfeita, o desempenho de um algoritmo de aprendizado de máquina deve ser avaliado conforme o objetivo da análise, o que inclui considerações quantitativas e qualitativas. No caso deste trabalho, a previsão de falhas, deseja-se uma pequena quantidade de falsos negativos, pois se o algoritmo rotular um estado de alta degradação como baixo, poderá ocorrer uma falha inesperada que na pior das hipóteses poderá ser durante a operação. Um falso positivo significará que a operação foi erroneamente interrompida, o que é uma preocupação operacional pois poderá causar uma ação de manutenção sem necessidade.

É importante esclarecer que nestes casos não existem problemas de segurança, pois o sistema é desenvolvido atendendo à relações entre criticidade e probabilidade. Uma falha de uma válvula de sangria tem sua criticidade entre *minor* e *major*, exigindo probabilidades entre 10^{-3} e 10^{-5} , o que define a qualidade do componentes (MTBF) e arquitetura (redundância) ([FEDERAL AVIATION ADMINISTRATION, 1988](#)).

Neste caso teríamos um impacto operacional, justamente o que este trabalho se propõe a ajudar reduzir, eventos de manutenção não planejadas podendo ocorrer em bases aéreas que não se tenha estruturas adequadas.

Adicionalmente, a interpretação do melhor resultado pode ser subjetiva e dependente da intenção do usuário. Por exemplo, caso um algoritmo como o SVM apresentar um resultado marginalmente melhor do que outro algoritmo mais simples como a árvore de classificação, seria mais indicado escolher o algoritmo mais

simples, por conta de vários fatores como tempo de treinamento, facilidade de reprodução e de interpretação das regras de classificação. As mesmas considerações aplicam-se para os filtros, como a comparação entre a média móvel e o filtro de Kalman, por exemplo.

Além das considerações quantitativas, há decisões de caráter qualitativo. Algumas métricas podem ser mais importantes do que outras, a depender das diretrizes de operação dos clientes. Por exemplo, para alguns é desejável realizar a troca do equipamento assim que um estado de alta degradação é detectado. Outros podem optar por continuar a operar enquanto o equipamento permanecer funcional, estendendo a vida ao máximo até a falha. Assim, mais importância será dada para diferentes métricas, como as taxas de verdadeiro positivo ou negativo.

Por mais que se troque precocemente uma válvula (ou não se troque), o comportamento anormal poderá ser detectado pelos alarmes de proteção e o sistema ambiental irá desligar, por segurança. Os impactos dos erros são econômicos, operacionais e logísticos e acabam afetando a imagem do produto e reduzindo a sua competitividade no mercado.

5.1 Aprendizado de máquina direcionado por dados de frota

Para estabelecer uma base de comparação, a avaliação do desempenho dos algoritmos de aprendizado de máquina foi realizada primeiramente apenas para os dados de frota. Assim, serão obtidas as métricas quantitativas que permitem a comparação com as abordagens por apenas modelo e híbrida.

Inicialmente, serão apresentados resultados da classificação do conjunto de teste para todos os filtros considerando a árvore de classificação, devido à sua simplicidade em relação aos outros algoritmos de aprendizado de máquina. A Tabela 5.1 apresenta as métricas de desempenho para a árvore de classificação para vários os filtros estudados. O aumento na taxa de verdadeiros positivos é notável com a aplicação de qualquer filtro em relação aos dados puros.

Isto significa que a taxa de falsos negativos diminui, característica desejável, pois evita-se classificar uma válvula que possui degradação alta como se tivesse degradação baixa. Esse erro levaria a que uma válvula degradada não fosse identificada e deixando operador vulnerável a um evento de manutenção não planejada. Assim, é necessário que a taxa de falsos negativos seja a menor possível para a aplicação em detecção de falhas. No entanto, se a taxa de falsos positivos for alta, significa que a operação foi erroneamente interrompida, o que

é indesejável, porém menos prioritário que a métrica anterior.

No caso da previsão de falhas, é tolerável uma pequena quantidade de falsos positivos, pois se o algoritmo de previsão rotular um estado de degradação realmente alto como baixo, poderá ocorrer uma falha inesperada.

O coeficiente de correlação de Matthews (MATTHEWS, 1975) considera todas as métricas básicas juntas e é uma escolha adequada atualmente para descrever o desempenho de um algoritmo de aprendizado de máquina quando existe um desequilíbrio entre a quantidade de observações das classes. No caso deste trabalho, como esta quantidade foi normalizada através da remoção de observações da classe *falsa* até a quantidade se igualar com as observações da classe *verdadeira*, as outras métricas podem ser observadas sem considerações adicionais quanto ao desequilíbrio de classes.

Por critérios quantitativos, o uso da média exponencialmente ponderada levou à obtenção de resultados melhores. Contudo, o desempenho da aplicação da média móvel ainda apresentou resultados semelhantes, com 0.7% de diferença. Como esta última é mais simples que a primeira, tanto em sua concepção como em sua parametrização, ela se mostrou uma escolha mais adequada. É notável que o efeito do filtro de Kalman é menor que as outras técnicas, mesmo sendo mais complexo e mais demandante computacionalmente.

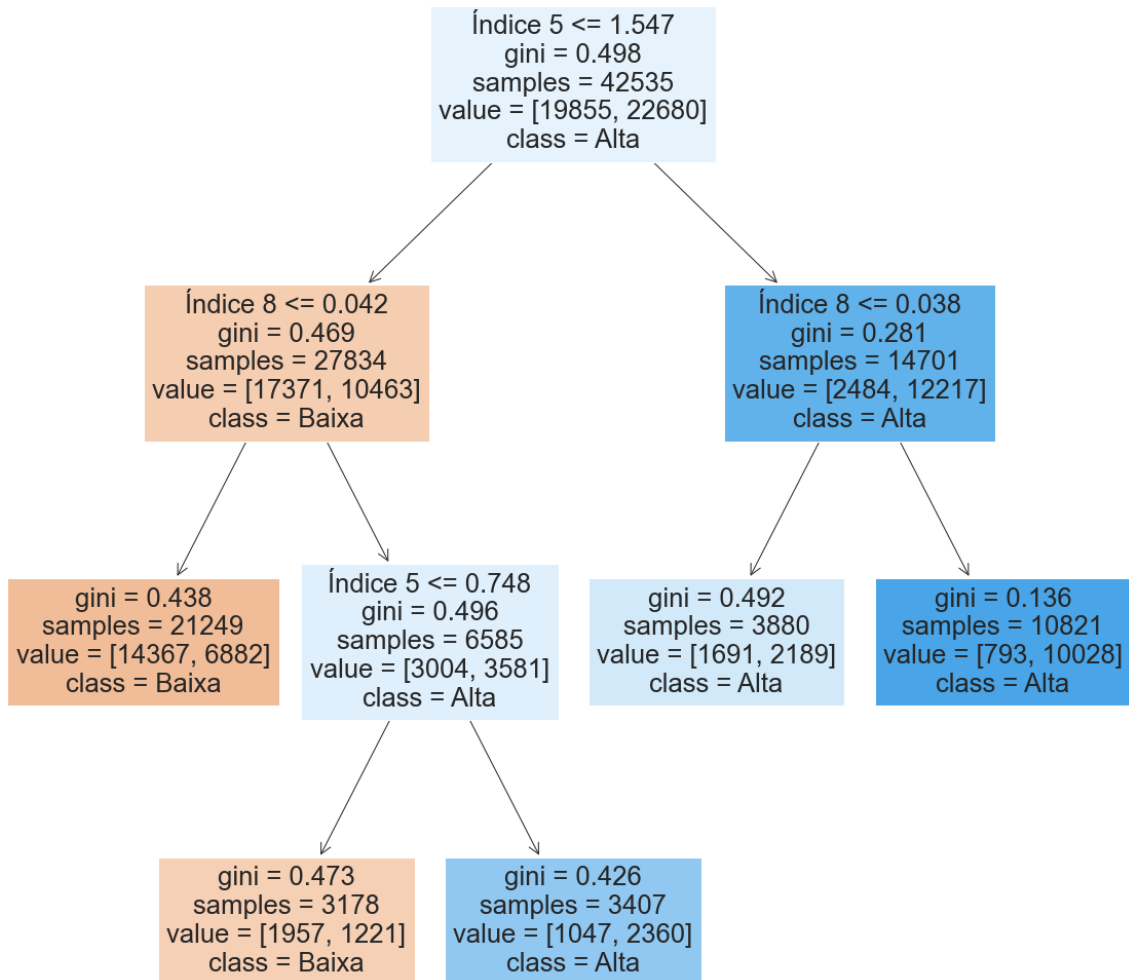
Tabela 5.1 - Desempenho da árvore de classificação para dados de frota.

Métrica de Desempenho	Puros	Filtro					
		Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.631	0.730	0.689	0.696	0.693	0.737	0.685
Taxa Verdadeiros Negativos	0.918	0.939	0.866	0.864	0.964	0.939	0.962
Taxa Falsos Positivos	0.082	0.061	0.134	0.136	0.036	0.061	0.038
Taxa Falsos Negativos	0.369	0.270	0.311	0.304	0.307	0.263	0.315
Precisão	0.885	0.923	0.837	0.837	0.951	0.924	0.948
Acurácia	0.774	0.834	0.777	0.780	0.829	0.838	0.823
Coef. Correlação Matthews	0.573	0.684	0.563	0.569	0.683	0.691	0.673

A árvore resultante para os dados puros é ilustrada na Figura 5.1. As informações contidas nos nós são o critério de divisão, impureza, número de amostras naquele nível e classe.

Para o caso estudado, o melhor cenário é um filtro que apresenta alta precisão e alta taxa de verdadeiros positivos. Entretanto, isso não significa que as outras métricas devam ser ignoradas. O filtro com a maior precisão é o Kalman, e

Figura 5.1 - Árvore de classificação.



a maior taxa de verdadeiro positivo é a máximo móvel. É desejável capturar o estado de alta degradação de forma confiável, portanto, uma alta taxa de verdadeiro positivo é indicada. Assim, a média móvel foi escolhida como o filtro mais adequado para esse caso, pelo bons resultados, simplicidade e facilidade de implementação.

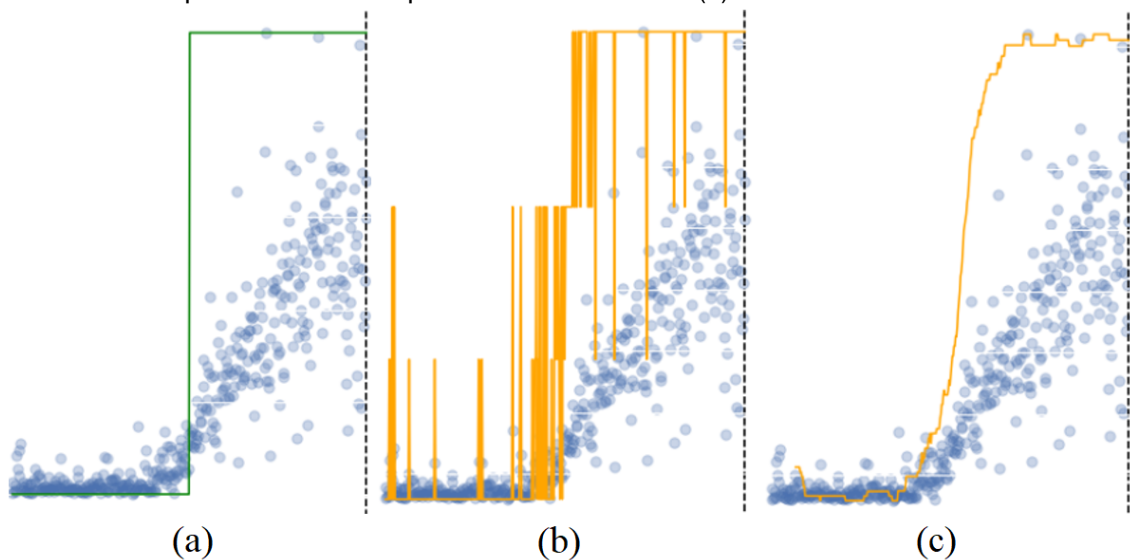
A menor taxa de falsos positivos foi obtida com a mediana móvel e mesmo que a aplicação de qualquer outro filtro a aumentou, os falsos negativos foram reduzidos, uma característica desejável para previsões dessa classe de problema, em que estados de alta degradação não percebidos podem ser mais impactantes do que a rotulação de baixa degradação como alta. Por fim, o filtro de Kalman não apresentou um resultado significativamente melhor do que a média móvel, indicando que uma abordagem mais simples é suficiente para esse tipo de análise.

A Figura 5.2 ilustra um evento para uma das aeronaves do conjunto de testes.

Os pontos ilustram o índice que representa o desvio padrão médio da pressão durante a fase de voo cruzeiro. A subfigura 5.2(a) é o alvo da classificação. No caso do conjunto de teste, esta informação não é conhecida pelo algoritmo de aprendizado de máquina. A subfigura 5.2(b) é a probabilidade de pertencimento à classe (LIU; WU, 2011) que representa um patamar de alto nível de degradação. A subfigura 5.2(c) ilustra um filtro média móvel aplicada à informação anterior. É possível perceber que existe um aumento ao longo do tempo, indicando que a degradação do equipamento está aumentando.

Do ponto de vista de aplicação em um sistema real de previsão de falhas, esta métrica é mais adequada do que a previsão pura, pois esta se baseia em um limite de probabilidade para cada amostra, o que pode causar um alerta precoce. No entanto, tal probabilidade amostral é uma métrica quantitativa mais direta e portanto será utilizada primeiramente para comparação das diferentes abordagens: dados puros, dados de modelo e híbrida.

Figura 5.2 - Objetivo do aprendizado de máquina (a), probabilidade de pertencimento (b) e probabilidade de pertencimento filtrada (c).



Além da comparação entre diferentes filtros com o algoritmo de aprendizado de máquina fixado, a análise do desempenho dos diferentes algoritmos de aprendizado de máquina revelou que para esta classe de problema, algoritmos mais simples foram adequadas, visto que o aumento de desempenho pode não justificar o uso de algoritmos mais complexos, que podem exigir considerações e análises.

lises adicionais. Estes resultados significam que para esta classe de problema, a utilização de algoritmos de aprendizado e máquina mais avançadas não incorre em um aumento de desempenho que justifique a complexidade adicional que tais algoritmos trazem.

Além de questões computacionais, onde algoritmos como redes neurais e SVM são mais demandantes em relação às outras como árvores e florestas, existem características relacionadas à complexidade de parametrização dos algoritmos e o acesso às suas regras de classificação. Para árvores, é trivial acessar as regras de divisão dos nós em ramos e folhas, especialmente após o processo de poda, que diminui a quantidade de regras e facilita a compreensão pelo especialista.

Para técnicas como SVM, caso os dados tenham passado pelo processo de elevação do espaço amostral diversas vezes em sequência, não será mais possível visualizar facilmente a fronteira de separação sem o uso de projeções, por exemplo se o SVM julgar que as classes forem separáveis apenas a partir do domínio \mathbb{R}^4 . Para redes neurais, embora exista a possibilidade de acessar os pesos das sinapses, a conversão em regras de decisão não é trivial e se a rede for profunda, isto é, com diversas camadas escondidas.

A Tabela 5.2 revela o desempenho das redes neurais para os dados puramente de frota. Em relação à árvore de classificação, houve um aumento de 8% quando não são aplicados filtros. No entanto, para tanto atingir tal resultado, a rede precisou de três camadas escondidas, dificultando mais o acesso às regras de classificação, em especial quando comparado à árvore de classificação. No entanto, este fato apenas se torna um problema caso este acesso seja importante para a tarefa que o classificador deve realizar.

Tabela 5.2 - Desempenho da rede neural para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.711	0.766	0.709	0.756	0.755	0.759	0.758
Taxa Verdadeiros Negativos	0.890	0.892	0.784	0.795	0.908	0.923	0.797
Taxa Falsos Positivos	0.110	0.108	0.216	0.205	0.092	0.077	0.203
Taxa Falsos Negativos	0.289	0.234	0.291	0.244	0.245	0.241	0.242
Precisão	0.866	0.876	0.767	0.787	0.891	0.908	0.789
Acurácia	0.800	0.829	0.747	0.775	0.831	0.841	0.778
Coef. Correlação Matthews	0.611	0.663	0.495	0.551	0.670	0.691	0.556

Assim, é necessária uma estratégia que considere os requisitos e a finalidade

para tomada de decisão sobre qual algoritmo utilizar. Para as aplicações deste trabalho, o acesso às regras de classificação é importante pois permite identificar quais índices os algoritmos de aprendizado de máquina consideraram como mais importantes para a tarefa de classificação do nível de degradação do equipamento. Visto que os índices das observações são as entradas dos algoritmos, e por sua vez tais índices são baseados em grandezas físicas e cálculos feitos com as mesmas, o conhecimento dos índices mais valiosos tende a auxiliar no rastreamento do causa raiz da degradação e das eventuais falhas.

Estes índices foram definidos juntamente aos especialistas do sistema, que já tem experiência nas grandezas que podem mais ou menos afetar a operação correta do equipamento. No entanto, é importante obter uma confirmação sobre quais fenômenos devem ser observados com mais atenção.

A Tabela 5.3 mostra os resultados para todos os algoritmos explorados neste trabalho, para a análise com apenas dados de frota sem a aplicação de filtros. É notável o aumento de desempenho dos algoritmos mais complexos, a custo de se lidar com uma caixa-preta em relação às regras de classificação internas.

Tabela 5.3 - Desempenho dos algoritmos de classificação para dados de frota sem filtragem.

Métrica de Desempenho	Algoritmo					
	Árvore	Floresta	Gradiente	KNN	SVM	Redes Neurais
Taxa Verdadeiros Positivos	0.631	0.687	0.684	0.691	0.633	0.711
Taxa Verdadeiros Negativos	0.918	0.893	0.899	0.817	0.916	0.890
Taxa Falsos Positivos	0.082	0.107	0.101	0.183	0.084	0.110
Taxa Falsos Negativos	0.369	0.313	0.316	0.309	0.367	0.289
Precisão	0.885	0.866	0.871	0.791	0.883	0.866
Acurácia	0.774	0.790	0.791	0.754	0.774	0.800
Coef. Correlação Matthews	0.573	0.593	0.597	0.512	0.572	0.611

A aplicação de técnicas de filtragem tende a melhorar o desempenho dos algoritmos de aprendizado de máquina, conforme evidenciado pela Tabela 5.4. Para qualquer um dos algoritmos estudados, a aplicação de filtros nos dados puros causa uma diminuição no ruído dos dados, tornando a tendência de degradação mais evidente e portanto mais fácil de ser identificada pelo aprendizado de máquina.

O maior aumento de desempenho para a métrica da taxa de verdadeiros positivos em relação aos algoritmos de aprendizado de máquina sem filtragem foi

Tabela 5.4 - Desempenho dos algoritmos de classificação para dados de frota com filtro média móvel.

Métrica de Desempenho	Algoritmo					
	Árvore	Floresta	Gradiente	KNN	SVM	Redes Neurais
Taxa Verdadeiros Positivos	0.730	0.786	0.801	0.789	0.752	0.766
Taxa Verdadeiros Negativos	0.939	0.898	0.879	0.814	0.932	0.892
Taxa Falsos Positivos	0.061	0.102	0.121	0.186	0.068	0.108
Taxa Falsos Negativos	0.270	0.214	0.199	0.211	0.248	0.234
Precisão	0.923	0.886	0.869	0.809	0.917	0.876
Acurácia	0.834	0.842	0.840	0.801	0.842	0.829
Coef. Correlação Matthews	0.684	0.689	0.682	0.603	0.695	0.663

de 8%, causado pela rede neural. A aplicação isolada do filtro média móvel ocasiona um aumento de 9.9% na taxa de verdadeiros positivos para a árvore de classificação, sendo este o filtro mais indicado, pois o aumento de desempenho compensa a simplicidade do filtro. Para a rede neural, o aumento de desempenho para a mesma métrica foi de 5.5% com a aplicação do mesmo filtro, evidenciando que este algoritmo é menos sensível a filtros nos dados de entrada.

A aplicação de um filtro de média móvel nos dados de entrada antes do treinamento leva a uma melhoria no desempenho do classificador maior do que a aplicação isolada de um algoritmo mais complexo. As próximas seções exploram os resultados das alternativas para a melhoria do desempenho, que se valem da utilização do modelo computacional da válvula.

5.2 Aprendizado de máquina direcionado por modelo

Antes da exploração da análise com dados híbridos, os dados puramente sintéticos tiveram seu desempenho avaliado para os mesmos algoritmos de aprendizado de máquina, no entanto desta vez com o treinamento feito para considerar apenas dados de modelo, bem como os teste também contiveram apenas dados gerados pelo modelo validado da válvula.

Para os dados gerados apenas com o uso do modelo, a Tabela 5.5 apresenta os resultados da árvore de classificação. É notável o desempenho superior em relação aos dados de frota, visto que a separação entre classes é mais evidente e não existem muitos exemplos de classes conflitantes como nos dados de frota. Os dados sintéticos representam degradações contínuas e crescentes, com poucas variações nas entradas e operação controlada. Assim, podem gerar dados que capturam perfeitamente o processo de degradação, com o objetivo de trazer informações não contaminadas por processos externos, garantido pelo processo

de modelagem da válvula e pelo modelo de envelhecimento proposto.

Tabela 5.5 - Desempenho da árvore de classificação para dados de modelo.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.967	0.989	0.991	0.978	0.990	0.984	0.988
Taxa Verdadeiros Negativos	0.972	0.991	0.981	0.981	0.997	0.992	0.994
Taxa Falsos Positivos	0.028	0.009	0.019	0.019	0.003	0.008	0.006
Taxa Falsos Negativos	0.033	0.011	0.009	0.022	0.010	0.016	0.012
Precisão	0.972	0.991	0.982	0.981	0.997	0.992	0.994
Acurácia	0.970	0.990	0.986	0.980	0.994	0.988	0.991
Coef. Correlação Matthews	0.939	0.980	0.972	0.959	0.987	0.976	0.982

Devido à clareza da separação entre as classes, todas as métricas demonstraram bons resultados, com uma pequena variação entre os diferentes filtros. A diferença entre a utilização dos dados puros e a aplicação do filtro com maior desempenho, máximo móvel, fica em torno de 2.4% para a análise puramente baseada em dados provenientes de modelo ao observar a taxa de verdadeiros positivos. Aqui é possível entrar com um critério qualitativo, no qual pode ser decidido que um aumento de desempenho tão pequeno, em relação ao valor absoluto superior a 90%, não justifica a aplicação de nenhum filtro.

5.3 Aprendizado de máquina híbrido

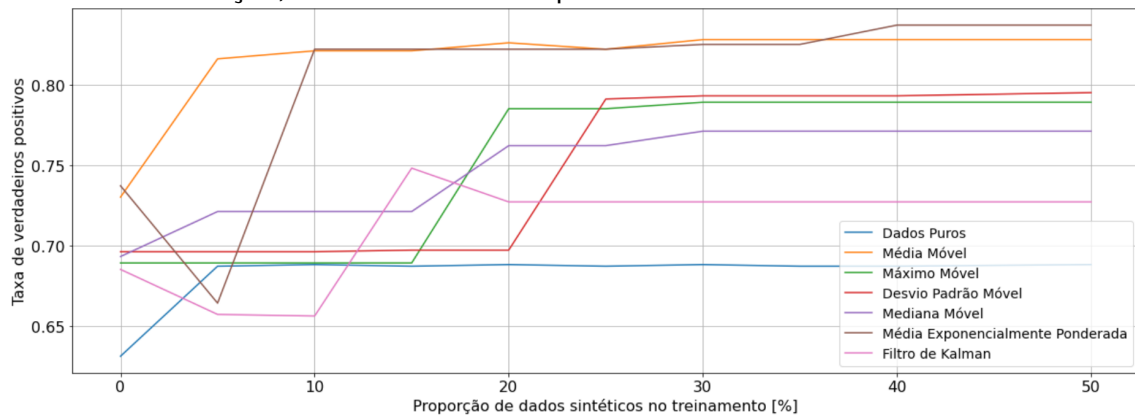
A análise híbrida utiliza ambos dados de frota e dados sintéticos para o treinamento, com o objetivo de enriquecer a base de dados. As proporções de dados sintéticos para dados de frota no treinamento dos algoritmos de aprendizado de máquina foram variadas para os seguintes valores em porcentagem: [0, 10, 20, 30, 40, 50]. Cada uma gera um novo conjunto de treinamento, e após o teste, uma tabela de desempenho para cada valor de proporção. Os algoritmos treinados foram aplicados em um conjunto de teste que contém apenas dados de campo.

Por conta da quantidade grande de resultados, em vez de apresentar uma tabela de desempenho para cada proporção e cada algoritmo de aprendizado de máquina, a comparação será feita de forma gráfica, pois a quantidade de resultados dificulta a interpretação por outras formas. Além disso, a apresentação gráfica escolhe apenas uma métrica de desempenho por figura, para evitar poluição visual. Será ilustrada a taxa de verdadeiros positivos, pois esta métrica dita a proporção de casos em alta degradação que foram corretamente identificados

como tal.

A Figura 5.3 ilustra a taxa de verdadeiros positivos para as diversas proporções de filtros considerados, utilizando a árvore de classificação. É possível observar que a variação de desempenho é diferente para cada filtro, mas há uma saturação em todos, onde existe um máximo aumento de desempenho que ocorre para determinadas proporções entre dados sintéticos e dados de frota. Isto significa que existe uma proporção ótima para cada filtro. Por exemplo, para os dados puros e a média móvel, este valor é em torno de 10%, mas para o filtro de Kalman é em torno de 15%.


Figura 5.3 - Influência da quantidade de dados sintéticos no treinamento, árvore de classificação, taxa de verdadeiros positivos.



Além disso, o efeito da adição de dados sintéticos ao treinamento dos dados de frota varia com os filtros. O efeito para os dados filtrados pela média móvel é mais pronunciado do que para os dados puros. O primeiro demonstrou um aumento na taxa de verdadeiros positivos de em torno de 10%, enquanto que para o segundo este aumento foi de por volta de 7%. Portanto, a combinação de ambas técnicas, filtragem e treinamento híbrido, ocasionou um efeito maior do que a utilização separada para a métrica apresentada.

A Figura 5.4 ilustra a taxa de verdadeiros negativos para as mesmas proporções e filtros considerados, também utilizando a árvore de classificação.

Figura 5.4 - Influência da quantidade de dados sintéticos no treinamento, árvore de classificação, taxa de verdadeiros negativos.



Enquanto há um aumento da taxas de verdadeiros positivos, há uma diminuição da taxa de verdadeiros negativos através de todas as proporções. Isto significa que o algoritmo de aprendizado, neste caso a árvore de classificação, passou a compreender melhor os estados de alta degradação do equipamento em vez dos estados de baixa degradação. Assim, há melhoria na identificação correta de estados de degradação onde realmente o equipamento estava realmente degradado.

Neste caso, cabe uma reflexão sobre o que o usuário valoriza na operação do sistema de classificação da degradação. No caso apresentado, os voos identificados como alta degradação serão mais confiáveis, isto é, quando e se a operação da aeronave for interrompida, será porque o equipamento possui alta probabilidade de realmente estar na zona de alta degradação. O custo disso é que poderá haver mais alarmes falsos, com a operação interrompida quando o equipamento não estava ainda na zona de degradação alta.

Para os propósitos deste trabalho, essa troca foi considerada justa, pois quanto menos falhas inesperadas em campo, melhor o sistema de predição. O efeito negativo na taxa de falsos positivos é considerado aceitável para manter a taxa de falsos negativos o mais baixa possível.

As Tabelas 5.6 e 5.7 representam o desempenho da árvore de classificação para dados puramente de frota e dados de treinamento com 30% de dados sintéticos, respectivamente. É importante notar que os dados de teste são os mesmos em ambos os casos, e compostos apenas por dados de frota. Esta escolha foi feita porque durante a implementação do sistema para determinação do estado de

degradação da válvula em campo, os únicos dados apresentados para avaliação do algoritmo de aprendizado de máquina foram dados de frota.

Tabela 5.6 - Desempenho da árvore de classificação para dados híbridos, proporção 0%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.631	0.730	0.689	0.696	0.693	0.737	0.685
Taxa Verdadeiros Negativos	0.918	0.939	0.866	0.864	0.964	0.939	0.962
Taxa Falsos Positivos	0.082	0.061	0.134	0.136	0.036	0.061	0.038
Taxa Falsos Negativos	0.369	0.270	0.311	0.304	0.307	0.263	0.315
Precisão	0.885	0.923	0.837	0.837	0.951	0.924	0.948
Acurácia	0.774	0.834	0.777	0.780	0.829	0.838	0.823
Coef. Correlação Matthews	0.573	0.684	0.563	0.569	0.683	0.691	0.673

Para o treinamento com apenas dados de frota, ou seja, proporção 0%, a tabela é igual à da Seção 5.1, ilustrada aqui novamente para facilitar a comparação com os resultados da análise híbrida. Para o treinamento híbrido, a Tabela 5.7 revela que houve um aumento de desempenho da métrica taxa de verdadeiros positivos, que por sua vez significa que houve uma diminuição da taxa de falsos negativos, resultados que contribuem para a confiabilidade do sistema de classificação.

Tabela 5.7 - Desempenho da árvore de classificação para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.687	0.822	0.785	0.791	0.762	0.822	0.727
Taxa Verdadeiros Negativos	0.895	0.846	0.810	0.808	0.941	0.863	0.949
Taxa Falsos Positivos	0.105	0.154	0.190	0.192	0.059	0.137	0.051
Taxa Falsos Negativos	0.313	0.178	0.215	0.209	0.238	0.178	0.273
Precisão	0.868	0.843	0.806	0.805	0.928	0.858	0.935
Acurácia	0.791	0.834	0.798	0.800	0.851	0.843	0.838
Coef. Correlação Matthews	0.595	0.669	0.596	0.599	0.714	0.686	0.694


É notável que o maior aumento de desempenho da análise híbrida foi para o filtro média móvel. A aplicação isolada do filtro média móvel nos dados puros causou um aumento de 9.9% na taxa de verdadeiros positivos. Quando foi aplicado o treinamento híbrido além do filtro, ocorreu um aumento de desempenho adicional de 9.2%. Ou seja, ambas as técnicas aliadas, filtragem e treinamento híbrido, apre-

sentam melhor resultado do que aplicadas separadamente. Para esta classe de problema, pode ser interessante se valer da aplicação demonstrada, lembrando que a taxa de verdadeiros negativos pode cair, o que contribui para o aumento de alarmes falsos.

Lembrando dos resultados apresentados na Seção 5.1, a aplicação da rede neural nos dados puros, isto é, sem filtros, proveu um aumento de 8% na taxa de verdadeiros positivos. Este aumento já é menor do que a aplicação isolada do filtro média móvel nos dados puros, que é 9.9%. A utilização da técnica híbrida com 30% de proporção entre dados sintéticos e de frota proveu um aumento de 5.6% para mesma métrica, que embora seja menor, permite que a interpretação do resultado seja facilitada em relação à rede neural ou o SVM, que tem como característica desafios de configuração de arquitetura e parâmetros de treinamento, além de exigir maiores capacidades computacionais.

A análise híbrida para algoritmos de aprendizado de máquina mais complexos, em particular o SVM, revelou neste estudo que a aplicação da técnica híbrida não surte o mesmo efeito que para a árvore de decisão, conforme evidenciado pela Figura 5.5. Ao elevar o espaço amostral, o SVM pode ter separado os dados sintéticos adicionais junto às mesmas regiões criadas para as classes quando apenas dados de frota estão presentes.

Figura 5.5 - Influência da quantidade de dados sintéticos no treinamento, SVM, taxa de verdadeiros positivos.



A Tabela 5.8 apresenta o resultado para a análise com dados de frota e SVM. Para dados puros, não houve aumento de desempenho em relação à árvore de classificação. O maior aumento foi para o filtro de Kalman, 10%. Para os resul-

tados do treinamento híbrido, a Tabela 5.9 demonstra que não houve mudança no desempenho quando dados sintéticos foram utilizados em conjunto com os dados de frota durante o treinamento do SVM.

Tabela 5.8 - Desempenho do SVM para dados híbridos, proporção 0%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.633	0.752	0.704	0.743	0.712	0.756	0.781
Taxa Verdadeiros Negativos	0.916	0.932	0.861	0.865	0.955	0.927	0.933
Taxa Falsos Positivos	0.084	0.068	0.139	0.135	0.045	0.073	0.067
Taxa Falsos Negativos	0.367	0.248	0.296	0.257	0.288	0.244	0.219
Precisão	0.883	0.917	0.836	0.846	0.941	0.913	0.921
Acurácia	0.774	0.842	0.782	0.804	0.833	0.842	0.857
Coef. Correlação Matthews	0.572	0.695	0.572	0.612	0.688	0.694	0.722

Tabela 5.9 - Desempenho do SVM para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.616	0.751	0.721	0.759	0.712	0.757	0.781
Taxa Verdadeiros Negativos	0.918	0.933	0.855	0.859	0.955	0.929	0.931
Taxa Falsos Positivos	0.082	0.067	0.145	0.141	0.045	0.071	0.069
Taxa Falsos Negativos	0.384	0.249	0.279	0.241	0.288	0.243	0.219
Precisão	0.883	0.918	0.833	0.844	0.940	0.914	0.919
Acurácia	0.767	0.842	0.788	0.809	0.833	0.843	0.856
Coef. Correlação Matthews	0.561	0.696	0.582	0.621	0.687	0.696	0.720

Os resultados apresentados mostram que a análise híbrida neste caso aumenta o desempenho da classificação, considerando a escolha adequada do filtro e do algoritmo de aprendizado de máquina, trazendo a resposta da pergunta científica apresentada na Seção 1.2. Utilizar dados de um modelo matemático validado e representativo do fenômeno analisado em conjunto dos dados de campo de uma frota de aeronaves durante o treinamento de um algoritmo de aprendizado de máquina permitiu que se obtivesse um aumento de desempenho na classificação do estado de degradação do equipamento. A aplicação de filtros nos dados de entrada antes do treinamento leva a uma melhora adicional no desempenho.

Uma comparação entre os tempos de treinamento dos diferentes algoritmos de aprendizado pode ser observada na Tabela 5.10. Note que a árvore é mais rápida do que outras técnicas. Caso seu desempenho seja considerado satisfató-

rio, pode ser uma escolha interessante pois a rapidez no treinamento permite diversas rodadas de projeto, escolhendo índices e configurando parâmetros do modelo, por exemplo. A máquina utilizada possui um processador Intel Core i7, 32GB de RAM, rodando Windows 10 com bibliotecas de aprendizado de máquina em Python 3.

Tabela 5.10 - Tempo de treinamento.

Algoritmo de Aprendizado de Máquina	Tempo médio (s)
Árvore de Decisão	4.4
Floresta Aleatória	87.4
Gradiente	160.5
KNN	42.0
SVM	4871.3
Rede Neural	389.9

6 CONCLUSÕES

Para concluir, respondendo à pergunta científica da Seção 1.2: “Como o uso combinado de dados de campo e modelos pode aumentar a assertividade de prognóstico de falhas?”, este trabalho explorou com sucesso um método para melhorar o prognóstico de saúde de sistemas complexos combinando o uso técnicas de aprendizagem de máquina com o uso de um modelo matemático computacional que representa adequadamente o comportamento de um sistema ou componente. Neste trabalho o objeto de estudo foi uma válvula do sistema pneumático de uma aeronave, utilizada no controle de pressão do ar sangrado do compressor de um motor aeronáutico.

A afirmação de sucesso pode ser suportada pela análise das tabelas das métricas de desempenho, observando especialmente a taxa de verdadeiros positivos (e seu complemento, a taxa de falsos negativos). Na Tabela 6.1 a aplicação do filtro média móvel nos dados de frota antes do treinamento da árvore de classificação, o aumento da taxa de verdadeiros foi de 9.9% em relação aos dados não filtrados. Para a rede neural, a aplicação do mesmo filtro promoveu um aumento de 5.5% conforme a Tabela 6.2. O uso de dados do modelo matemático em conjunto com os dados de frota no treinamento, a análise híbrida, promove um aumento de 5.6% para a árvore de classificação nos dados sem filtro e 19.1% quando o treinamento híbrido é utilizado em conjunto com a aplicação do filtro média móvel. Já a rede neural apresentou perda de desempenho no treinamento híbrido de 1.7% mas aumento de 11.8% quando utilizado em conjunto com o filtro média móvel.

Tabela 6.1 - Desempenho da árvore de classificação para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.631	0.730	0.689	0.696	0.693	0.737	0.685
Taxa Verdadeiros Negativos	0.918	0.939	0.866	0.864	0.964	0.939	0.962
Taxa Falsos Positivos	0.082	0.061	0.134	0.136	0.036	0.061	0.038
Taxa Falsos Negativos	0.369	0.270	0.311	0.304	0.307	0.263	0.315

Para analisar os dados de sensores e determinar sua relação com o envelhecimento da válvula, os dados foram reduzidos de séries temporais para dados unidimensionais, chamados de índices. Estes representam grandezas estatísticas de diversos sensores ao longo de um voo, como médias, desvios, sobressinais e critérios de estabilidade como número de cruzamentos de um sinal com

Tabela 6.2 - Desempenho das Redes Neurais para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.711	0.766	0.709	0.756	0.755	0.759	0.758
Taxa Verdadeiros Negativos	0.890	0.892	0.784	0.795	0.908	0.923	0.797
Taxa Falsos Positivos	0.110	0.108	0.216	0.205	0.092	0.077	0.203
Taxa Falsos Negativos	0.289	0.234	0.291	0.244	0.245	0.241	0.242

Tabela 6.3 - Desempenho da árvore de classificação para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.687	0.822	0.785	0.791	0.762	0.822	0.727
Taxa Verdadeiros Negativos	0.895	0.846	0.810	0.808	0.941	0.863	0.949
Taxa Falsos Positivos	0.105	0.154	0.190	0.192	0.059	0.137	0.051
Taxa Falsos Negativos	0.313	0.178	0.215	0.209	0.238	0.178	0.273

Tabela 6.4 - Desempenho das Redes Neurais para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.661	0.774	0.715	0.736	0.789	0.777	0.809
Taxa Verdadeiros Negativos	0.916	0.881	0.793	0.817	0.902	0.888	0.787
Taxa Falsos Positivos	0.084	0.119	0.207	0.183	0.098	0.112	0.213
Taxa Falsos Negativos	0.339	0.226	0.285	0.264	0.211	0.223	0.191

seu valor médio. Estes índices então foram utilizados para compor uma base de dados, onde cada voo é uma observação composta de diversos índices. Outra fonte de informação considerada foram os dados de manutenção, que podem ser relatórios nos quais são descritas as ações tomadas nas paradas de manutenção. O foco foram ações de troca da válvula por falha dela mesma, ignorando trocas planejadas e trocas devido a eventos associados a outros equipamentos.

O cruzamento entre a base de dados de voos e as informações de manutenção revelou quando ocorreram trocas, permitindo uma análise da evolução dos índices ao longo do tempo e sua relação com as trocas. Observou-se que os índices mudam, podendo crescer ou decrescer ao longo do tempo. Após uma troca, os índices voltam aos níveis iniciais onde a saúde do equipamento era alta.

A análise da mudança dos índices ao longo dos voos permitiu a construção da saída esperada dos algoritmos de aprendizado de máquina supervisionados,

através de um cálculo que considera a mudança de um índice ao longo do tempo e sua relação com um limite imposto para o valor do mesmo. Aplicando o cálculo para os dados agrupados por aeronave e evento de troca, foi obtido o nível de degradação, que dita se a válvula se encontra em um estado de degradação baixo ou alto. Este nível foi considerado como o alvo dos algoritmos de aprendizado de máquina.

A análise exploratória de dados revelou a natureza da base de dados de frota, se valendo de ferramentas estatísticas, como *boxplots* e *heatmaps*. Este estudo foi utilizado para a seleção dos índices mais importantes e a exclusão de índices considerados ruins, como índices que não alteravam seu comportamento com o passar do tempo ou índices que estavam fortemente correlacionados uns com os outros, tornando alguns redundantes e possivelmente prejudiciais ao aprendizado de máquina.

Diferentes filtros foram aplicados à base de dados de índices, com o objetivo de extrair tendências dos dados puros, pois estes apresentam alto nível de ruído, apesar da clara mudança na tendência causada pelo envelhecimento da válvula. A escolha dos filtros foi baseada em uso comum na literatura, como média móvel sendo um exemplo explorado e provado em casos de redução de ruído de dados temporais. Outros filtros conhecidos da academia, como o filtro de Kalman, foram selecionados para estabelecer uma comparação entre filtros simples e complexos. Este passo associado à seleção e aplicação dos filtros é uma etapa importante para melhorar o desempenho do prognóstico de problemas de manutenção complexos.

A partir dos dados de frota, diferentes tipos de algoritmos de aprendizado de máquina foram aplicados. O objetivo foi testar o desempenho de algoritmos de classes de complexidades diferentes. Algoritmos de classe de complexidade mais altas, como SVM e redes neurais, apresentaram desempenhos superiores aos algoritmos relativamente mais simples, como as árvores de classificação. No entanto, algoritmos mais complexos são mais sensíveis à parametrização, como as redes neurais. Outros, como o SVM, dificultam o acesso às regras de classificação, o que atrapalha a interpretação e a identificação dos índices mais importantes e seus valores limite. Por outro lado, as técnicas com menor desempenho apresentam fácil acesso às regras de classificação, em especial as árvores de classificação. É importante dizer que o desempenho, apesar de menor, pode ser considerado satisfatório para diversas aplicações, como foi o caso deste estudo, o que destaca a importância da discussão do aumento de complexidade frente

ao ganho de desempenho.

Outra solução proposta para melhorar o desempenho do prognóstico de problemas de manutenção complexos foi a aplicação de um modelo matemático fiel ao sistema real e a utilização de dados do modelo, denominados dados sintéticos, em conjunto dos dados de frota durante o treinamento dos algoritmos de aprendizado de máquina. Visto que o modelo representa a válvula com fidelidade satisfatória, a utilização de dados sintéticos teve o objetivo de enriquecer a base de dados, apresentando aos algoritmos de aprendizado de máquina exemplos adicionais do comportamento ideal da degradação do equipamento estudado.

A partir da consideração da física do equipamento e de seu envelhecimento, os mecanismos de degradação puderam ser representados no modelo computacional, que por sua vez foi utilizado para gerar dados que representam o intervalo de degradação no qual a válvula geralmente opera em campo. Ao variar os parâmetros que controlam a degradação do equipamento, foi possível representar a válvula em diversos estágios do processo de degradação. A observação de dados de aeronaves de frota possibilitou a criação de vetores para estimar a degradação ao longo dos voos. A criação de voos sintéticos também considerou a entrada do modelo, que também foi criada observando dados de campo, comparando-os para que a representação fosse fiel. A geração de dados sintéticos seguiu com a simulação de diversos voos, utilizando ruído marrom na entrada para representar diferentes voos da mesma aeronave, além de degradação crescente, até um ponto onde ocorreria um evento de troca da válvula em campo.

A criação de índices para os voos sintéticos foi realizada da mesma maneira dos dados de frota, construindo os mesmos índices, e portanto, a base de dados sintéticos. Em seguida, a análise exploratória de dados revelou a natureza dos dados sintéticos, que, como esperado, é diferente dos dados de frota pois os dados sintéticos foram projetados para representar degradações ideais e são livres de ruídos excessivos e decisões de manutenção preliminar ou tardia. Os algoritmos de aprendizado de máquina foram treinados novamente e então testados com dados puramente sintéticos, com a finalidade de estabelecer uma base de comparação entre os desempenhos das diferentes bases de dados. Visto que os dados sintéticos são livres de ruídos excessivos e ações de troca fora da faixa recomendada, o desempenho da previsão dos algoritmos de aprendizado de máquina foi superior ao caso de apenas dados de frota.

A filtragem dos dados de frota apresentou bons resultados em relação aos dados

puros, visto que a classe deste problema é construída por dados que possuem tendências crescentes ou decrescentes temporalmente.

A utilização de cada técnica separada já adiciona um nível de melhoria em cada passo, sendo possível utilizá-las em conjunto. A adição de dados do modelo computacional à base de dados de campo, além da aplicação de métodos de filtragem, juntamente com algoritmos de aprendizado de máquina, alcança um desempenho superior ao obtido por cada técnica separadamente. Filtragem de dados ruidosos é uma técnica conhecida e padronizada em análises de ciência de dados, assim como os algoritmos de aprendizado de máquina. No entanto, geralmente são utilizados dados provenientes de ensaios de laboratório, ou operação controlada, onde não há influência da degradação.

Algumas estratégias e práticas operacionais mirando redução de custos podem dificultar a obtenção de dados apropriados para o uso em análises de ciência de dados, como a Análise Exploratória de Dados, ou até mesmo comprometer o desempenho de algoritmos de aprendizado de máquina. Essa restrição pode ocorrer em termos de quantidade e qualidade dos dados, nesse contexto, mudanças de cultura e treinamento podem fazer a diferença.

Estes fatores podem fazer com que a aplicação de aprendizado de máquina não apresente resultados desejáveis. Para melhorar o prognóstico de falhas de sistema complexos, a solução proposta explorou a aliança das técnicas de aprendizado de máquina, filtragem e a utilização de um modelo computacional da válvula, validado com dados de voo. O modelo é capaz de reproduzir o envelhecimento de uma válvula até a troca, replicando o comportamento do mesmo índice, baseado na mesma grandeza física.

Através da utilização do modelo, uma nova base de dados foi construída, desta vez sintética, através da simulação de voos com característica semelhantes aos voos da frota. Ao explorar os dados de modelo e juntá-los com os dados de frota, foi realizada uma análise híbrida, que se valia de ambas fontes de dados: frota de aeronaves em operação de campo e modelo computacional validado. Assim, foi possível providenciar mais exemplos aos algoritmos de aprendizado de máquina e aos filtros, enriquecendo a base de dados. Com maior quantidade e qualidade dos dados de treinamento, as técnicas escolhidas proveram um aumento de desempenho na classificação do nível de degradação da válvula em comparação com a análise puramente focada nos dados de frota.

A avaliação da abordagem híbrida foi realizada variando a proporção de dados sintéticos para dados de frota, indo de 5% a 50% dos dados de treinamento,

sendo o restante dados de frota, enquanto o teste consistiu sempre em apenas dados de frota.

Foi observado que algumas técnicas de aprendizado de máquina são mais beneficiadas do treinamento híbrido do que outras, especialmente a árvore de decisão. SVM e Redes Neurais não apresentaram melhora significativa ao trabalhar com dados híbridos, evidenciando a pouca influência dos dados sintéticos para estes algoritmos em particular. Apesar disso, a melhoria ocasionada para a árvore, quando aliada à técnicas de filtragem dos dados de entrada, obteve desempenho superior.

A vantagem deste método é que a avaliação do modelo permite uma compreensão dos mecanismos que regem a degradação e subsequente falha do equipamento estudado. Além disso, um algoritmo mais simples é mais fácil de ser configurado e seu treinamento pode exigir menos recursos computacionais. Outra vantagem é o fato de que algoritmos como a árvore de decisão permite acesso às regras de classificação de maneira mais fácil do que outros como as redes neurais, especialmente com o aumento do número de camadas escondidas.

No fim, os resultados de um sistema de previsão de falhas ou de inferência de degradação são sugestões de ações para os proprietários das aeronaves ou frota. Podem haver casos onde o cliente não aceita lidar com falha alguma, e prefere substituir o componente ao menor sinal de degradação, mesmo que este seja capaz de operar com alguma degradação por mais tempo. Outros casos preferem lidar com falhas e continuar a aplicar passos para sua mitigação durante a operação, para que o seja utilizado até o limite de sua vida útil.

Uma questão que merece atenção é o valor de um sistema de análise de saúde de equipamentos ou previsão de falhas. Resultados quantitativos como os apresentados são fundamentais para embasar a recomendação de sistemas de prevenção de falhas. Pode não ser simples quantificar o benefício de se implementar uma metodologia de previsão de degradação, no entanto a apresentação de evidências concretas, mesmo que utilizem dados de falhas inesperadas passadas, reforça o discurso das vantagens dos sistemas de prevenção de falhas.

Entendem-se como contribuições acadêmicas deste trabalho os seguintes tópicos explorados. O trabalho apresentou a comparação de alguns algoritmos de aprendizagem de máquina e destacou que alguns mais simples apresentam desempenho superior aos mais complexos para esta classe de problema, fato que pode auxiliar a direcionar trabalhos na mesma área. Também mostrou que o uso de um modelo computacional é benéfico e um modelo validado que atenda

essa finalidade permite a geração de dados similares aos dados de campo. O uso de dados de campo em conjunto com dados sintetizados por um modelo computacional validado melhora a detecção de estados de alta degradação em equipamentos.

Sugestões de trabalhos futuros incluem a exploração extensa do impacto das configurações dos algoritmos de aprendizado de máquina quando dados de frota são aliados a dados de modelos computacionais. Também há a possibilidade de utilizar técnicas de exploração de espaços amostrais e otimização para encontrar índices de degradação mais precisos nos dados de frota. Técnicas do mesmo campo de estudo podem ser aplicadas na busca pelos parâmetros que influenciam a degradação em modelos matemáticos computacionais. A exploração das influências externas de campo na degradação pode ser um caminho frutífero, que pode levar a novos controladores ou meios de operação.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDURAKIPOV, S. S.; BUTAKOV, E. B. Comparative analysis of algorithms of machine learning for predicting pre-failure and failure states of aircraft engines. **Optoelectronics, Instrumentation and Data Processing**, v. 56, n. 6, p. 586–597, Nov. 2020. ISSN 1934-7944. Disponível em: <<<https://doi.org/10.3103/S8756699020060023>>>. 2
- AHMADZADEH, F.; LUNDBERG, J. Remaining useful life estimation: review. **International Journal of System Assurance Engineering and Management**, v. 5, 12 2013. 18
- AL-MOHAMAD, A.; HOBLOS, G.; PUIG, V. A hybrid system-level prognostics approach with online rul forecasting for electronics-rich systems with unknown degradation behaviors. **Microelectronics Reliability**, v. 111, p. 113676, 2020. ISSN 0026-2714. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0026271419312399>>>. 17
- ANDERSEN, B. **Analysis and design of pneumatic systems**. [S.l.]: Wiley, 1967. ISBN 9780471026358. Disponível em: <<<https://books.google.com.br/books?id=FawYAQAIAAJ>>>. 49
- ARUNKUMAR, K.; KALAGA, D. V.; SAI KUMAR, C. M.; CHILKOOR, G.; KAWAJI, M.; BRENZA, T. M. Forecasting the dynamics of cumulative COVID-19 cases for top-16 countries using statistical machine learning models: Auto-Regressive Integrated Moving Average ARIMA and Seasonal Auto-Regressive Integrated Moving Average SARIMA. **Applied Soft Computing**, v. 103, p. 107161, 2021. ISSN 1568-4946. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S1568494621000843>>>. 21
- BAPTISTA, M. L. **Machine learning and deep learning for prognostics and predictive maintenance of aeronautical equipment**. 92 p. Tese (Doutorado) — Universidade de Lisboa - Instituto Superior Técnico, Lisboa, 2018. 10, 14, 74
- BARALDI, P.; MANGILI, F.; ZIO, E. Investigation of uncertainty treatment capability of model-based and data-driven prognostic methods using simulated data. **Reliability Engineering And System Safety**, v. 112, p. 94–108, 2013. ISSN 0951-8320. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0951832012002591>>>. 21
- BARLAS, Y. Multiple tests for validation of system dynamics type of simulation models. **European Journal of Operational Research**, v. 42, n. 1, p. 59–87, 1989. ISSN 0377-2217. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/0377221789900593>>>. 52
- _____. Formal aspects of model validity and validation in system dynamics. **System Dynamics Review**, v. 12, n. 3, p. 183–210, 1996. 55
- BASORA, L.; OLIVE, X.; DUBOT, T. Recent advances in anomaly detection methods applied to aviation. **Aerospace**, 2019. 11

CASOLI, P.; RICCÒ, L.; CAMPANINI, F.; BEDOTTI, A. Hydraulic hybrid excavator—mathematical model validation and energy analysis. **Energies**, v. 9, n. 12, 2016. ISSN 1996-1073. Disponível em: <<<https://www.mdpi.com/1996-1073/9/12/1002>>>. 52

CASTILHO, H. M. **Classificação de falhas de uma válvula borboleta de um sistema de sangria de uma aeronave**. 149 p. Dissertação (Mestrado em Engenharia Aeronáutica) — Instituto Tecnológico de Aeronáutica, São José dos Campos, 2016. 3, 10, 28, 31, 32, 37

CHAIKA, N. K. Aircraft economics in an era of import substitution. **Russian Engineering Research**, v. 43, n. 7, p. 895–898, Jul 2023. ISSN 1934-8088. Disponível em: <<<https://doi.org/10.3103/S1068798X23070079>>>. 1

CHAKRAVARTI, I.; LAHA, R.; ROY, J. **Handbook of methods of applied statistics**. [S.l.]: Wiley, 1967. (Handbook of Methods of Applied Statistics, 1). Disponível em: <<<https://books.google.com.br/books?id=Idl-AAAIAAJ>>>. 52

CHAO, M. A.; KULKARNI, C.; GOEBEL, K.; FINK, O. Aircraft engine run-to-failure dataset under real flight conditions for prognostics and diagnostics. **Data**, v. 6, n. 1, 2021. ISSN 2306-5729. Disponível em: <<<https://www.mdpi.com/2306-5729/6/1/5>>>. 15

CORTES, C.; VAPNIK, V. Support vector networks. **Machine Learning**, v. 20, p. 273–297, 1995. 14, 36

CUSATI, V.; CORCIONE, S.; MEMMOLO, V. Potential benefit of structural health monitoring system on civil jet aircraft. **Sensors**, v. 22, n. 19, p. 7316, Sep 2022. ISSN 1424-8220. Disponível em: <<<http://dx.doi.org/10.3390/s22197316>>>. 1

CUSUMANO, J.; CHELIDZE, D.; CHATTERJEE, A. A dynamical systems approach to damage evolution tracking, part 2: model-based validation and physical interpretation. **Journal of Vibration and Acoustics**, v. 124, 04 2002. 19

DANGUT, M. D.; SKAF, Z.; JENNIONS, I. K. An integrated machine learning model for aircraft components rare failure prognostics with log-based dataset. **ISA Transactions**, v. 113, p. 127–139, 2021. ISSN 0019-0578. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0019057820301750>>>. 3

DEKKING, F. **A modern introduction to probability and statistics: understanding why and how**. [S.l.]: Springer, 2005. ISBN 9781852338961. 42

DEMUTH, H.; BEALE, M. **Neural network toolbox**. [S.l.: s.n.], 2000. 25, 26

DENG, L.; YU, D. **Deep learning: methods and applications**. [S.l.: s.n.], May 2014. 61

DESHPANDE, V. K. B. **Data science**. 2.ed.. ed. [S.l.]: Morgan Kaufmann, 2018. 72

DJEZIRI, M.; BENMOUSSA, S.; MOUCHAWEH, M. S.; LUGHOFER, E. Fault diagnosis and prognosis based on physical knowledge and reliability data: application to MOS field-effect transistor. **Microelectronics Reliability**, v. 110, p. 113682, 2020. ISSN 0026-2714. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0026271419300393>>>. 19

DONG, G.; CHEN, Z.; WEI, J.; LING, Q. Battery health prognosis using brownian motion modeling and particle filtering. **IEEE Transactions on Industrial Electronics**, v. 65, n. 11, p. 8646–8655, 2018. 20

FARSHAD, M.; KARIMI, M. Intelligent protection of csc-hvdc lines based on moving average and maximum coordinate difference criteria. **Electric Power Systems Research**, v. 199, p. 107439, 2021. ISSN 0378-7796. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S037877962100420X>>>. 22

FEDERAL AVIATION ADMINISTRATION. **Advisory circular 25.1309-1A: system design and analysis**. 1988. Disponível em: <https://www.faa.gov/documentLibrary/media/Advisory_Circular/AC_25_1309-1A.pdf>. 91

_____. **Advisory circular 120-82: flight operational quality assurance**. 2004. Disponível em: <https://www.faa.gov/documentLibrary/media/Advisory_Circular/AC_120-82.pdf>. 57

FELÍCIO, L. **Modelagem da dinâmica de sistemas e estudo da resposta**. [S.l.]: RiMa, 2007. ISBN 9788576561187. 50

FINCK, J. S.; PEDROLLO, O. C. Facing losses of telemetric signal in real time forecasting of water level using artificial neural networks. **Water Resources Management**, v. 35, n. 3, p. 1119–1133, Feb 2021. ISSN 1573-1650. Disponível em: <<<https://doi.org/10.1007/s11269-021-02782-x>>>. 74

FOX, R.; PRITCHARD, P.; MCDONALD, A. **Introduction to fluid mechanics**. [S.l.]: John Wiley & Sons, 2010. ISBN 9780470547557. Disponível em: <<<https://books.google.com.br/books?id=kiFJRQAACAAJ>>>. 48, 49

GALAR, D.; BERGES-MURO, L.; LAMBAN-CASTILLO, M.; TALÓN, J.; TORMOS-MARTINEZ, B. RUL prediction using moving trajectories between svm hyper planes. **Interciencia**, v. 38, p. 556–562, 08 2013. 14

GALLEANI, L.; COHEN, L. The generalized wiener process for colored noise. **IEEE Signal Processing Letters**, v. 13, n. 10, p. 608–611, 2006. 80

GARDINER, C. **Handbook of stochastic methods for physics, chemistry, and the natural sciences**. Berlin: Springer, 2004. (Springer complexity). ISBN 9783540208822. Disponível em: <<<https://books.google.com.br/books?id=wLm7QgAACAAJ>>>. 80

GOLDBERG, C.; NALIANDA, D.; SETHI, V.; PILIDIS, P.; SINGH, R.; KYPRIANIDIS, K. Assessment of an energy-efficient aircraft concept from a

techno-economic perspective. **Applied Energy**, v. 221, p. 229–238, 2018. ISSN 0306-2619. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0306261918305117>>>. 1

GROSSO, L. A.; MARTIN, A. D.; JACAZIO, G.; SORLI, M. Development of data-driven PHM solutions for robot hemming in automotive production lines. **International Journal of Prognostics and Health Management**, v. 11, n. 1, 2020. 20

GUNN, S. R. **Support vector machines for classification and regression**. [S.l.: s.n.], 1998. 33, 34, 35

GUO, T.-H. A roadmap for aircraft engine life extending control. In: AMERICAN CONTROL CONFERENCE, 2001. **Proceedings...** Arlington: IEEE, 2001. 11

HAIYAN, X. A CAS message simulation module used in civil aircraft for air management system failure diagnosis. **IOP Conference Series: Materials Science and Engineering**, v. 608, n. 1, p. 012019, aug 2019. Disponível em: <<<https://dx.doi.org/10.1088/1757-899X/608/1/012019>>>. 3

HAO, S.; YANG, J.; BERENQUER, C. Nonlinear step-stress accelerated degradation modelling considering three sources of variability. **Reliability Engineering and System Safety**, v. 172, p. 207–215, 2018. ISSN 0951-8320. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S095183201730621X>>>. 16

HAYKIN, S. **Neural networks: a comprehensive foundation**. [S.l.]: Prentice Hall PTR, 1998. ISBN 0132733501. 25

HEGDE, G. G. Life cycle cost: a model and applications. **IIE Transactions**, v. 26, n. 6, p. 56–62, 1994. 1

HERP, J.; RAMEZANI, M. H.; BACH-ANDERSEN, M.; PEDERSEN, N. L.; NADIMI, E. S. Bayesian state prediction of wind turbine bearing failure. **Renewable Energy**, v. 116, p. 164–172, 2018. ISSN 0960-1481. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0960148117301556>>>. 16

HIYAMA, T.; SUZUKI, N.; FUNAKOSHI, T. On-line identification of power system oscillation modes by using real time FFT. In: POWER ENGINEERING SOCIETY WINTER MEETING, 2000. **Proceedings...** Singapore: IEEE, 2000. p. 1521–1526. 52

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural Computation**, v. 9, p. 1735–80, 12 1997. 14

HOUSHMAND, N.; ESMAEILI, K.; GOODFELLOW, S.; ORDÓÑEZ-CALDERÓN, J. C. Predicting rock hardness using gaussian weighted moving average filter on borehole data and machine learning. **Minerals Engineering**, v. 204, p. 108448, 2023. ISSN 0892-6875. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0892687523004624>>>. 22

HU, C.; PEI, H.; WANG, Z.; SI, X.-s.; ZHANG, Z.-X. A new remaining useful life estimation method for equipment subjected to intervention of imperfect maintenance activities. **Chinese Journal of Aeronautics**, v. 31, 01 2018. 11

HU, C.; YOUN, B. D.; WANG, P.; YOON, J. T. Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life. **Reliability Engineering and System Safety**, v. 103, p. 120 – 135, 2012. ISSN 0951-8320. Disponível em: <<<http://www.sciencedirect.com/science/article/pii/S0951832012000427>>>. 12

HU, Y.-W.; ZANG, H.-C.; SHU-JIE, L.; LU, H.-T. Sequential Monte Carlo method toward online RUL assessment with applications. **Chinese Journal of Mechanical Engineering**, v. 31, n. 5, p. 2870–2878, 2018. 16

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C. Extreme learning machine: a new learning scheme of feedforward neural networks. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2004. **Proceedings...** Budapest: IEEE, 2004. p. 985–990. 14

HUWANG, L.; WANG, Y.-H. T.; YEH, A. B.; CHEN, Z.-S. J. On the exponentially weighted moving variance. **Naval Research Logistics (NRL)**, v. 56, n. 7, p. 659–668, 2009. Disponível em: <<<https://onlinelibrary.wiley.com/doi/abs/10.1002/nav.20369>>>. 74

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Plano diretor 2016-2019**. 2016. Disponível em: <<http://www.inpe.br/gestao/planejamento/plano-diretor/arquivos/Plano_Diretor_2016-2019.pdf>>. 4

JAVED, K.; GOURIVEAU, R.; ZERHOUNI, N.; NECTOUX, P. Enabling health monitoring approach based on vibration data for accurate prognostics. **IEEE Transactions on Industrial Electronics**, v. 62, n. 1, p. 647–656, 2015. 13

JAZWINSKI, A. H. **Stochastic processes and filtering theory**. New York: Academic Press, 1970. ISBN 0123815509. Disponível em: <<http://gso.gbv.de/DB=2.1/CMD?ACT=SRCHA&SRT=YOP&IKT=1016&TRM=ppn+021832242&sourceid=fwb_bibsonomy>>. 41

JORDAN, M. I. **The Kernel Trick**. 2004. Disponível em: <<<https://people.eecs.berkeley.edu/~jordan/courses/281B-spring04/lectures/lec3.pdf>>>. 37, 39

KALITA, D.; LYAKHOV, P. Moving object detection based on a combination of Kalman filter and median filtering. **Big Data and Cognitive Computing**, v. 6, n. 4, 2022. ISSN 2504-2289. Disponível em: <<<https://www.mdpi.com/2504-2289/6/4/142>>>. 22, 23

KALMAN, R. E. A new approach to linear filtering and prediction problems. **Journal of Basic Engineering**, v. 82, n. 1, p. 35–45, 03 1960. ISSN 0021-9223. Disponível em: <<<https://doi.org/10.1115/1.3662552>>>. 39

KELLEHER, J.; NAMEE, B.; D'ARCY, A. **Fundamentals of machine learning for predictive data analytics, second edition: algorithms, worked examples, and case studies**. [S.l.]: MIT Press, 2020. ISBN 9780262361101. Disponível em: <<https://books.google.com.br/books?id=UM_tDwAAQBAJ>>. 2

KOTSIANTIS, S. B. Supervised machine learning: a review of classification techniques. In: CONFERENCE ON EMERGING ARTIFICIAL INTELLIGENCE APPLICATIONS IN COMPUTER ENGINEERING, 2007. **Proceedings...** Amsterdam: IOS Press, 2007. p. 3–24. ISBN 9781586037802. 2

LASHERAS, F. S.; JUEZ, F. J. de C.; SÁNCHEZ, A. S.; KRZEMIENI, A.; FERNÁNDEZ, P. R. Forecasting the comex copper spot price by means of neural networks and ARIMA models. **Resources Policy**, v. 45, p. 37 – 43, 2015. ISSN 0301-4207. Disponível em: <<<http://www.sciencedirect.com/science/article/pii/S030142071500029X>>>. 15

LAW, A.; KELTON, W. **Simulation modeling and analysis**. [S.l.]: McGraw-Hill, 1982. (McGraw-Hill series in industrial engineering and management science). ISBN 9780070366961. Disponível em: <<<https://books.google.com.br/books?id=xOBQAAAAMAAJ>>>. 52

LEI, Y.; LI, N.; GUO, L.; LI, N.; YAN, T.; LIN, J. Machinery health prognostics: a systematic review from data acquisition to RUL prediction. **Mechanical Systems and Signal Processing**, v. 104, p. 799 – 834, 2018. ISSN 0888-3270. Disponível em: <<<http://www.sciencedirect.com/science/article/pii/S0888327017305988>>>. 12

LIMA, N. A. F. S. **Development of an aircraft health monitoring program for predictive maintenance**. 118 p. Dissertação (Mestrado em Engenharia Aeroespacial) — Universidade de Lisboa - Instituto Superior Técnico, Lisboa, 2017. 10

LIU, H. H. Z. Y.; WU, Y. Hard or soft classification. large-margin unified machines. **Journal of the American Statistical Association**, v. 106, n. 493, p. 166–177, 2011. 95

LIU, J.; ZIO, E. A scalable fuzzy support vector machine for fault detection in transportation systems. **Expert Systems with Applications**, v. 102, p. 36–43, 2018. ISSN 0957-4174. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0957417418300952>>>. 20

LU, J.; HUANG, J.; LU, F. Distributed kernel extreme learning machines for aircraft engine failure diagnostics. **Applied Sciences**, v. 9, n. 8, p. 1707, 2019. ISSN 2076-3417. Disponível em: <<<http://dx.doi.org/10.3390/app9081707>>>. 2

MARTIN, A. D.; JACAZIO, G.; SORLI, M. Design of a PHM system for electro-mechanical flight controls: a roadmap from preliminary analyses to iron-bird validation. In: EASN INTERNATIONAL CONFERENCE ON INNOVATION IN AVIATION AND SPACE, 9., 2019. **Proceedings...** Athens,

2019. p. 4–18. Disponível em:

<<<https://doi.org/10.1051/mateconf/201930404018>>>. 17

MATTHEWS, B. Comparison of the predicted and observed secondary structure of t4 phage lysozyme. **Biochimica et Biophysica Acta Protein Structure**,

v. 405, n. 2, p. 442–451, 1975. ISSN 0005-2795. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/0005279575901099>>>. 44, 93

METZ, C. Basic principles of ROC analysis. **Seminars in Nuclear Medicine**,

v. 8, n. 4, p. 283–298, Oct. 1978. ISSN 0001-2998. 42

MINOUX, M. **Mathematical programming: theory and algorithms**. [S.l.]:

Wiley, 1986. 34, 36

MOIR, I.; SEABRIGDE, A. **Aircraft systems: mechanical, electrical and**

avionics subsystems integration. 3. ed. England: Wiley, 2008. 45, 46

MOREIRA, R. P. **Prognóstico de sistemas aeronáuticos utilizando o algoritmo SVM treinado com dados de voo e registros de manutenção**.

82 p. Dissertação (Mestrado em Engenharia Aeronáutica) — Instituto

Tecnológico de Aeronáutica, São José dos Campos, 2012. 9

MORETTIN, P.; BUSSAB, W. **Estatística básica**. [S.l.]: Saraiva Educação,

2010. ISBN 9788547220235. 55

MOSALLAM, A.; MEDJAHAR, K.; ZERHOUNI, N. Data-driven prognostic method based on bayesian approaches for direct remaining useful life prediction.

Journal of Intelligent Manufacturing, v. 27, n. 5, p. 1037 – 1048, 2016. ISSN

09565515. 13

NETTLETON, D. **Commercial data mining: processing, analysis and**

modeling for predictive analytics projects. [S.l.]: Springer, 2005. ISBN

9781852338961. 73

NGUYEN, K. T. P.; FOULADIRAD, M.; GRALL, A. New methodology for improving the inspection policies for degradation model selection according to prognostic measures.

IEEE Transactions on Reliability, v. 67, n. 3, p.

1269–1280, 2018. 21

NOBREGA, J. P.; OLIVEIRA, A. L. A sequential learning method with kalman filter and extreme learning machine for regression and time series forecasting.

Neurocomputing, v. 337, p. 235–250, 2019. ISSN 0925-2312. Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0925231219300980>>>. 22

OGATA, K. **Engenharia de controle moderno**. [S.l.]: Pearson Universidades,

2010. ISBN 9788576058106. 80

OKOH, C.; ROY, R.; MEHNEN, J.; REDDING, L. Overview of remaining useful life prediction techniques in through-life engineering services. **Proceedings**

CIRP, v. 16, p. 158–163, 2014. 9

ORDÓÑEZ, C.; LASHERAS, F. S.; ROCA-PARDIÑAS, J.; JUEZ, F. J. de C. A hybrid ARIMA–SVM model for the study of the remaining useful life of aircraft engines. **Journal of Computational and Applied Mathematics**, v. 346, p. 184 – 191, 2019. ISSN 0377-0427. Disponível em: <<<http://www.sciencedirect.com/science/article/pii/S037704271830428X>>>. 15

PARK, Y.; O’KELLY, M. E. Examination of cost-efficient aircraft fleets using empirical operation data in US aviation markets. **Journal of Air Transport Management**, v. 69, p. 224–234, 2018. ISSN 0969-6997. 1

PASCOAL, R. M. **Estimação de parâmetros de falha de APU empregando regressão linear e redes neurais artificiais**. 92 p. Dissertação (Mestrado em Engenharia Aeronáutica) — Instituto Tecnológico de Aeronáutica, São José dos Campos, 2013. 10

PELLEGRINO, J.; JUSTINIANO, M.; RAGHUNATHAN, A.; WEISS, B. A. Measurement science roadmap for prognostics and health management for smart manufacturing systems. **NIST Publications**, n. 100-2, 2016. 13

PENG, W.; YE, Z.; CHEN, N. Joint online RUL prediction for multivariate deteriorating systems. **IEEE Transactions on Industrial Informatics**, v. 15, n. 5, p. 2870–2878, 2019. 16

PENHALE, M.; BARNARD, A. Direction of arrival estimation in practical scenarios using moving standard deviation processing for localization and tracking with acoustic vector sensors. **Applied Acoustics**, v. 168, p. 107421, 2020. ISSN 0003-682X. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0003682X20305259>>>. 22

RAMAKRISHNAN, A.; PECHT, M. A life consumption monitoring methodology for electronic systems. **IEEE Transactions on Components and Packaging Technologies**, v. 26, n. 3, p. 625–634, 2003. 18

RAY, A. Life extending control of large scale dynamical systems. In: AMERICAN CONTROL CONFERENCE, 2001. **Proceedings...** Arlington: IEEE, 2001. 10

REIBENSPIES, J. H. Moving median filters for area-detector data. **Journal of Applied Crystallography**, v. 31, n. 2, p. 305–307, 1998. 22

RIBEIRO, A. S. **Seleção de variáveis e proposta de indicador para determinar a degradação de uma válvula aeronáutica**. 117 p. Dissertação (Mestrado em Engenharia Aeronáutica) — Instituto Tecnológico de Aeronáutica, São José dos Campos, 2015. 9

RINGUEST, J. L. A chi-square statistic for validating simulation-generated responses. **Computers and Operations Research**, v. 13, n. 4, p. 379–385, 1986. ISSN 0305-0548. 52

ROSS, G. J.; ADAMS, N. M.; TASOULIS, D. K.; HAND, D. J. Exponentially weighted moving average charts for detecting concept drift. **Pattern**

Recognition Letters, v. 33, n. 2, p. 191–198, 2012. ISSN 0167-8655.

Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0167865511002704>>>. 22

SANTOS, M. M. dos; SILVA FILHO, A. G. da; SANTOS, W. P. dos. Deep convolutional extreme learning machines: filters combination and error model validation. **Neurocomputing**, v. 329, p. 359–369, 2019. ISSN 0925-2312.

Disponível em:

<<<https://www.sciencedirect.com/science/article/pii/S0925231218312967>>>. 22

SARGENT, R. Verification and validation of simulation models. In: WINTER SIMULATION CONFERENCE, 2007. **Proceedings...** Phoenix: IEEE, 2007. v. 37, p. 166–183. 52

SAXENA, A.; CELAYA, J.; SAHA, B.; SAHA, S.; GOEBEL, K. Metrics for offline evaluation of prognostic performance. **International Journal of Prognostics and Health Management**, v. 1, p. 2153–2648, 01 2010. 15

SAXENA, A.; GOEBEL, K.; SIMON, D.; EKLUND, N. Damage propagation modeling for aircraft engine run-to-failure simulation. In: INTERNATIONAL CONFERENCE ON PROGNOSTICS AND HEALTH MANAGEMENT, 2008. **Proceedings...** Denver: IEEE, 2008. p. 1–9. 3

SHAHID, N.; GHOSH, A. Trajecnets: online failure evolution analysis in 2D space. **International Journal of Prognostics and Health Management**, 2014. 11

SLOTA, G. P.; LATASH, M. L.; ZATSIORSKY, V. M. Grip forces during object manipulation: experiment, mathematical model, and validation. **Experimental Brain Research**, v. 213, n. 1, p. 125–139, Aug 2011. ISSN 1432-1106. Disponível em: <<<https://doi.org/10.1007/s00221-011-2784-y>>>. 51

SONG, X.; ZHANG, Q.; SEKIMOTO, Y.; SHIBASAKI, R.; YUAN, N. J.; XIE, X. A simulator of human emergency mobility following disasters: knowledge transfer from big disaster data. **Proceedings of the AAAI Conference on Artificial Intelligence**, v. 29, n. 1, 2015. Disponível em: <<<https://ojs.aaai.org/index.php/AAAI/article/view/9237>>>. 19

SORNETTE, D.; DAVIS, A. B.; IDE, K.; VIXIE, K. R.; PISARENKO, V.; KAMM, J. R. Algorithm for model validation: theory and applications. **Proceedings of the National Academy of Sciences**, v. 104, n. 16, p. 6562–6567, 2007. 52

STEHMAN, S. V. Selecting and interpreting measures of thematic classification accuracy. **Remote Sensing of Environment**, v. 62, n. 1, p. 77–89, 1997. ISSN 0034-4257. 42

SUN, B.; LI, Y.; WANG, Z.; REN, Y.; FENG, Q.; YANG, D.; LU, M.; CHEN, X. Remaining useful life prediction of aviation circular electrical connectors using vibration-induced physical model and particle filtering method. **Microelectronics**

Reliability, v. 92, p. 114–122, 2019. ISSN 0026-2714. Disponível em:
<<<https://www.sciencedirect.com/science/article/pii/S0026271418303950>>>. 18

SUN, H.; CAO, D.; ZHAO, Z.; KANG, X. A hybrid approach to cutting tool remaining useful life prediction based on the Wiener process. **IEEE Transactions on Reliability**, v. 67, n. 3, p. 1294–1303, 2018. 20

SUN, J.; LI, C.; LIU, C.; GONG, Z.; WANG, R. A data-driven health indicator extraction method for aircraft air conditioning system health monitoring. **Chinese Journal of Aeronautics**, v. 32, n. 2, p. 409 – 416, 2019. ISSN 1000-9361. Disponível em:
<<<http://www.sciencedirect.com/science/article/pii/S1000936118301377>>>. 11

SUN, T.; XIA, B.; LIU, Y.; LAI, Y.; ZHENG, W.; WANG, H.; WANG, W.; WANG, M. A novel hybrid prognostic approach for remaining useful life estimation of lithium-ion batteries. **Energies**, v. 12, p. 3678, 09 2019. 14

TAN, X.; QIU, J.; LIU, G.; LV, K.; YANG, S.; WANG, C. A novel approach of testability modeling and analysis for PHM systems based on failure evolution mechanism. **Chinese Journal of Aeronautics**, v. 26, n. 3, p. 766 – 776, 2013. ISSN 1000-9361. Disponível em:
<<<http://www.sciencedirect.com/science/article/pii/S1000936113000952>>>. 12

TERZIC, J.; NAGARAJAH, C.; ALAMGIR, M. Fluid level measurement in dynamic environments using a single ultrasonic sensor and support vector machine (svm). **Sensors and Actuators A: Physical**, v. 161, n. 1, p. 278–287, 2010. ISSN 0924-4247. Disponível em:
<<<https://www.sciencedirect.com/science/article/pii/S0924424710002189>>>. 22

TIMOFEEV, R. **Classification and Regression Trees (CART) theory and applications**. 100 p. Dissertação (Mestrado) — Humboldt University, Berlin, Germany, 2004. 27

TOM, M.; YUN, S.; WANG, H.; OU, F.; ORKOULAS, G.; CHRISTOFIDES, P. D. Machine learning-based run-to-run control of a spatial thermal atomic layer etching reactor. **Computers and Chemical Engineering**, v. 168, p. 108044, 2022. ISSN 0098-1354. Disponível em:
<<<https://www.sciencedirect.com/science/article/pii/S0098135422003763>>>. 22

TSENG, S.-T.; WEN, Z.-C. Step-stress accelerated degradation analysis for highly reliable products. **Journal of Quality Technology**, v. 32, n. 3, p. 209–216, 2000. Disponível em:
<<<https://doi.org/10.1080/00224065.2000.11979997>>>. 16

TUKEY, J. **Exploratory data analysis**. [S.l.]: Addison-Wesley, 1977. ISBN 9780201076165. 68

TURCIO, W. **Projeto de um controlador não-linear utilizando escalonamento de ganhos considerando a abordagem LPV para um**

sistema pneumático aeronáutico. Tese (Doutorado) — Instituto Tecnológico de Aeronáutica, São José dos Campos, 2014. 47, 49, 50, 53

VALERI, S. G. Design to DOC framework: a model to support aircraft direct operating cost reduction. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, v. 37, n. 4, p. 1183–1196, Jul 2015. ISSN 1806-3691. Disponível em: <<<https://doi.org/10.1007/s40430-014-0236-x>>>. 1

VERDIÈRE, N.; JAUBERTHIE, C.; TRAVÉ-MASSUYÈS, L. Functional diagnosability and detectability of nonlinear models based on analytical redundancy relations. **Journal of Process Control**, v. 35, p. 1–10, 2015. ISSN 0959-1524. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0959152415001614>>>. 18

VIANNA, W. O. L. **Prognostics and health monitoring of concurrent damage progressions.** Tese (Doutorado) — Instituto Tecnológico de Aeronáutica, São José dos Campos, 2017. 40

VIANNA, W. O. L.; YONEYAMA, T.; RODRIGUES, L. R. Aircraft line maintenance planning based on PHM data and resources availability using large neighborhood search. In: ANNUAL CONFERENCE OF THE PHM SOCIETY, 2015. **Proceedings...** Coronado: PHM Society, 2015. 11

WANG, C.; LU, N.; SENLIN, W.; CHENG, Y.; JIANG, B. Dynamic long-short term memory neural network based indirect remaining useful life prognosis for satellite lithium-ion battery. **Applied Sciences**, v. 8, p. 2078, 10 2018. 14

WANG, C.; ZHANG, X.; YUN, X.; FAN, X. A novel hybrid machine learning coulomb counting technique for state of charge estimation of lithium-ion batteries. **Journal of Energy Storage**, v. 63, p. 107081, 2023. ISSN 2352-152X. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S2352152X23004784>>>. 21

WANG, X. **Aircraft fuel system prognostics and health management.** 145 p. Dissertação (Mestrado) — Cranfield University, Cranfield, 2012. 10

WANG, X.; JIANG, B.; LU, N. Adaptive relevant vector machine based RUL prediction under uncertain conditions. **ISA Transactions**, v. 87, p. 217–224, 2019. ISSN 0019-0578. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0019057818304592>>>. 16

WEATHERS, J.; LUCK, R.; WEATHERS, J. An exercise in model validation: comparing univariate statistics and Monte Carlo based multivariate statistics. **Reliability Engineering and System Safety**, v. 94, n. 11, p. 1695–1702, 2009. ISSN 0951-8320. 52

WELCH, G.; BISHOP, G. **An introduction to the Kalman filter.** [S.l.: s.n.], 2006. 39

WIDODO, A.; YANG, B.-S. Application of relevance vector machine and survival probability to machine degradation assessment. **Expert Systems with Applications**, v. 38, n. 3, p. 2592 – 2599, 2011. ISSN 0957-4174. Disponível em: <<<http://www.sciencedirect.com/science/article/pii/S0957417410008456>>>. 13, 14

WYLEN, G. V.; SONNTAG, R.; BORGNAKKE, C. **Fundamentos da termodinâmica clássica**. [S.l.]: Edgard Blucher, 1994. ISBN 9788521217862. Disponível em: <<<https://books.google.com.br/books?id=eTH7DwAAQBAJ>>>. 48, 49

XI, X.; CHEN, M.; ZHOU, D. Remaining useful life prediction for multi-component systems with hidden dependencies. **Science China Information Sciences**, v. 62, n. 2, 2018. 17

XIA, T.; DONG, Y.; XIAO, L.; DU, S.; PAN, E.; XI, L. Recent advances in prognostics and health management for advanced manufacturing paradigms. **Reliability Engineering and System Safety**, v. 178, p. 255–268, 2018. ISSN 0951-8320. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S095183201731459X>>>. 18

YANG, F.; HABIBULLAH, M. S.; ZHANG, T.; XU, Z.; LIM, P.; NADARAJAN, S. Health index-based prognostics for remaining useful life predictions in electrical machines. **IEEE Transactions on Industrial Electronics**, v. 63, n. 4, p. 2633–2644, 2016. 15

YOU, Y.; BULUC, A.; DEMMEL, J. Scaling deep learning on GPU and knights landing clusters. In: INTERNATIONAL CONFERENCE FOR HIGH PERFORMANCE COMPUTING, NETWORKING, STORAGE AND ANALYSIS, 2017. **Proceedings...** New York: ACM, 2017. Disponível em: <<<https://doi.org/10.1145/3126908.3126912>>>. 61

YU, W.; JUN, L.; ZHI, D.; TONG, C. Study on the direct operation cost model of primary training aircraft. **IOP Conference Series: Earth and Environmental Science**, v. 587, n. 1, p. 012032, oct 2020. 1

ZENG, Y.; SONG, D.; ZHANG, W.; ZHOU, B.; XIE, M.; TANG, X. A new physics-based data-driven guideline for wear modelling and prediction of train wheels. **Wear**, v. 456-457, p. 203355, 2020. ISSN 0043-1648. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0043164819318022>>>. 21

ZHANG, Z.; SI, X.; HU, C.; LEI, Y. Degradation data analysis and remaining useful life estimation: a review on Wiener-process-based methods. **European Journal of Operational Research**, v. 271, n. 3, p. 775–796, 2018. ISSN 0377-2217. Disponível em: <<<https://www.sciencedirect.com/science/article/pii/S0377221718301486>>>. 19

APÊNDICE A - RESULTADOS APRENDIZADO DE MÁQUINA DADOS DE FROTA

Tabela A.1 - Desempenho da árvore de classificação para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.631	0.730	0.689	0.696	0.693	0.737	0.685
Taxa Verdadeiros Negativos	0.918	0.939	0.866	0.864	0.964	0.939	0.962
Taxa Falsos Positivos	0.082	0.061	0.134	0.136	0.036	0.061	0.038
Taxa Falsos Negativos	0.369	0.270	0.311	0.304	0.307	0.263	0.315
Precisão	0.885	0.923	0.837	0.837	0.951	0.924	0.948
Acurácia	0.774	0.834	0.777	0.780	0.829	0.838	0.823
Coef. Correlação Matthews	0.573	0.684	0.563	0.569	0.683	0.691	0.673

Tabela A.2 - Desempenho da floresta para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.685	0.789	0.787	0.772	0.781	0.797	0.829
Taxa Verdadeiros Negativos	0.893	0.890	0.763	0.826	0.887	0.902	0.865
Taxa Falsos Positivos	0.107	0.110	0.237	0.174	0.113	0.098	0.135
Taxa Falsos Negativos	0.315	0.211	0.213	0.228	0.219	0.203	0.171
Precisão	0.865	0.878	0.769	0.816	0.874	0.891	0.861
Acurácia	0.789	0.840	0.775	0.799	0.834	0.850	0.847
Coef. Correlação Matthews	0.591	0.683	0.550	0.599	0.672	0.703	0.695

Tabela A.3 - Desempenho do gradiente para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.684	0.801	0.764	0.762	0.776	0.807	0.830
Taxa Verdadeiros Negativos	0.899	0.879	0.776	0.824	0.900	0.891	0.841
Taxa Falsos Positivos	0.101	0.121	0.224	0.176	0.100	0.109	0.159
Taxa Falsos Negativos	0.316	0.199	0.236	0.238	0.224	0.193	0.170
Precisão	0.871	0.869	0.774	0.812	0.886	0.881	0.840
Acurácia	0.791	0.840	0.770	0.793	0.838	0.849	0.836
Coef. Correlação Matthews	0.597	0.682	0.540	0.586	0.681	0.700	0.671

Tabela A.4 - Desempenho do KNN para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.691	0.789	0.699	0.741	0.757	0.798	0.792
Taxa Verdadeiros Negativos	0.817	0.814	0.728	0.757	0.815	0.832	0.783
Taxa Falsos Positivos	0.183	0.186	0.272	0.243	0.185	0.168	0.217
Taxa Falsos Negativos	0.309	0.211	0.301	0.259	0.243	0.202	0.208
Precisão	0.791	0.809	0.721	0.753	0.804	0.827	0.785
Acurácia	0.754	0.801	0.714	0.749	0.786	0.815	0.787
Coef. Correlação Matthews	0.512	0.603	0.428	0.498	0.573	0.630	0.575

Tabela A.5 - Desempenho do SVM para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.633	0.752	0.704	0.743	0.712	0.756	0.781
Taxa Verdadeiros Negativos	0.916	0.932	0.861	0.865	0.955	0.927	0.933
Taxa Falsos Positivos	0.084	0.068	0.139	0.135	0.045	0.073	0.067
Taxa Falsos Negativos	0.367	0.248	0.296	0.257	0.288	0.244	0.219
Precisão	0.883	0.917	0.836	0.846	0.941	0.913	0.921
Acurácia	0.774	0.842	0.782	0.804	0.833	0.842	0.857
Coef. Correlação Matthews	0.572	0.695	0.572	0.612	0.688	0.694	0.722

Tabela A.6 - Desempenho das Redes Neurais para dados de frota.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.711	0.766	0.709	0.756	0.755	0.759	0.758
Taxa Verdadeiros Negativos	0.890	0.892	0.784	0.795	0.908	0.923	0.797
Taxa Falsos Positivos	0.110	0.108	0.216	0.205	0.092	0.077	0.203
Taxa Falsos Negativos	0.289	0.234	0.291	0.244	0.245	0.241	0.242
Precisão	0.866	0.876	0.767	0.787	0.891	0.908	0.789
Acurácia	0.800	0.829	0.747	0.775	0.831	0.841	0.778
Coef. Correlação Matthews	0.611	0.663	0.495	0.551	0.670	0.691	0.556

APÊNDICE B - RESULTADOS APRENDIZADO DE MÁQUINA DADOS HÍBRIDOS

Tabela B.1 - Desempenho da árvore de classificação para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.687	0.822	0.785	0.791	0.762	0.822	0.727
Taxa Verdadeiros Negativos	0.895	0.846	0.810	0.808	0.941	0.863	0.949
Taxa Falsos Positivos	0.105	0.154	0.190	0.192	0.059	0.137	0.051
Taxa Falsos Negativos	0.313	0.178	0.215	0.209	0.238	0.178	0.273
Precisão	0.868	0.843	0.806	0.805	0.928	0.858	0.935
Acurácia	0.791	0.834	0.798	0.800	0.851	0.843	0.838
Coef. Correlação Matthews	0.595	0.669	0.596	0.599	0.714	0.686	0.694

Tabela B.2 - Desempenho da floresta para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.684	0.786	0.792	0.773	0.782	0.798	0.836
Taxa Verdadeiros Negativos	0.891	0.892	0.763	0.825	0.894	0.899	0.862
Taxa Falsos Positivos	0.109	0.108	0.237	0.175	0.106	0.101	0.138
Taxa Falsos Negativos	0.316	0.214	0.208	0.227	0.218	0.202	0.164
Precisão	0.863	0.879	0.770	0.816	0.881	0.888	0.859
Acurácia	0.787	0.839	0.777	0.799	0.838	0.849	0.849
Coef. Correlação Matthews	0.588	0.682	0.555	0.599	0.680	0.701	0.699

Tabela B.3 - Desempenho do gradiente para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.688	0.793	0.766	0.768	0.771	0.810	0.821
Taxa Verdadeiros Negativos	0.899	0.867	0.796	0.821	0.908	0.889	0.841
Taxa Falsos Positivos	0.101	0.133	0.204	0.179	0.092	0.111	0.159
Taxa Falsos Negativos	0.312	0.207	0.234	0.232	0.229	0.190	0.179
Precisão	0.872	0.856	0.790	0.811	0.893	0.880	0.839
Acurácia	0.793	0.830	0.781	0.795	0.839	0.850	0.831
Coef. Correlação Matthews	0.600	0.661	0.563	0.590	0.685	0.702	0.663

Tabela B.4 - Desempenho do KNN para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.693	0.784	0.699	0.741	0.759	0.797	0.791
Taxa Verdadeiros Negativos	0.816	0.817	0.732	0.756	0.813	0.832	0.784
Taxa Falsos Positivos	0.184	0.183	0.268	0.244	0.187	0.168	0.216
Taxa Falsos Negativos	0.307	0.216	0.301	0.259	0.241	0.203	0.209
Precisão	0.791	0.811	0.724	0.753	0.803	0.826	0.786
Acurácia	0.754	0.800	0.716	0.749	0.786	0.815	0.787
Coef. Correlação Matthews	0.513	0.601	0.432	0.497	0.572	0.630	0.575

Tabela B.5 - Desempenho do SVM para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.616	0.751	0.721	0.759	0.712	0.757	0.781
Taxa Verdadeiros Negativos	0.918	0.933	0.855	0.859	0.955	0.929	0.931
Taxa Falsos Positivos	0.082	0.067	0.145	0.141	0.045	0.071	0.069
Taxa Falsos Negativos	0.384	0.249	0.279	0.241	0.288	0.243	0.219
Precisão	0.883	0.918	0.833	0.844	0.940	0.914	0.919
Acurácia	0.767	0.842	0.788	0.809	0.833	0.843	0.856
Coef. Correlação Matthews	0.561	0.696	0.582	0.621	0.687	0.696	0.720

Tabela B.6 - Desempenho das Redes Neurais para dados híbridos, proporção 30%.

Métrica de Desempenho	Filtro						
	Puros	Média Móvel	Máximo Móvel	Desvio Móvel	Mediana Móvel	Média Exp. Ponderada	Filtro de Kalman
Taxa Verdadeiros Positivos	0.661	0.774	0.715	0.736	0.789	0.777	0.809
Taxa Verdadeiros Negativos	0.916	0.881	0.793	0.817	0.902	0.888	0.787
Taxa Falsos Positivos	0.084	0.119	0.207	0.183	0.098	0.112	0.213
Taxa Falsos Negativos	0.339	0.226	0.285	0.264	0.211	0.223	0.191
Precisão	0.887	0.867	0.776	0.801	0.890	0.874	0.792
Acurácia	0.788	0.827	0.754	0.776	0.846	0.832	0.798
Coef. Correlação Matthews	0.596	0.659	0.509	0.554	0.696	0.669	0.597