

Avaliação da Disponibilidade Operacional: Estudo de Caso de Introdução de Frota de Sistemas de Alta Complexidade

Carlos Monteiro Barbosa Filho, Danilo Garcia Figueiredo Pinto e Fernando Teixeira Mendes Abrahão

Instituto Tecnológico de Aeronáutica, São José dos Campos/SP - Brasil

Resumo—Este artigo apresenta uma análise exploratória de dados operacionais de uma frota de sistemas de alta complexidade, durante aproximadamente 3 anos e 3.000 horas de operação. Os dados, extraídos do sistema de gerenciamento da frota, compreendem registros de mudanças de estado operacional, solicitações de material, envios para reparo e intervenções. A análise compara a disponibilidade operacional (A_o) à meta de projeto e confronta a confiabilidade observada — com ênfase no MTBUR — aos parâmetros nominais do fabricante para o sistema e seus principais subsistemas. Sob a ótica dos indicadores de suportabilidade, busca-se identificar desvios de desempenho e gargalos operacionais e logísticos que influenciam a disponibilidade da frota, bem como oportunidades para estudos futuros de *Condition-Based Maintenance Plus* (CBM+). Os resultados subsidiam o aprimoramento da suportabilidade e o direcionamento de análises preditivas futuras.

Palavras-Chave—Disponibilidade Operacional, Engenharia de Sistemas, Análise de Frota.

I. INTRODUÇÃO

Sistemas complexos (especialmente aqueles cuja operação pode afetar a segurança de usuários ou terceiros, como antenas de radar, embarcações e aeronaves) demandam planos de manutenção estruturados, voltados a preservar a disponibilidade e o desempenho operacional ao longo de seu ciclo de vida, haja vista o retorno esperado ante o elevado custo de aquisição e sustentação característico destes sistemas.

Em tais sistemas, de alto custo, os planos de manutenção são tipicamente estruturados por metodologias como a MSG-3, combinando intervenções baseadas em parâmetros de envelhecimento. Contudo, a expectativa inicial de desempenho e disponibilidade frequentemente não é alcançada, sobretudo nos primeiros anos de operação, em virtude da maturidade incompleta do sistema e de seu ecossistema de suporte [1].

O que chamamos desse ecossistema de suportabilidade é o que a literatura consolida sob o conceito de *Integrated Product Support* (IPS), no qual múltiplos elementos de suporte devem interagir de forma equilibrada para assegurar continuidade operacional a custo sustentável [2]. Um eventual desvio de performance em relação às métricas previstas — usualmente expressas por indicadores de suportabilidade, sistematizados por Blanchard sob a sigla RAM4S-C, que estende a tríade *Reliability*, *Availability* e *Maintainability* com os quatro “S” (*Safety*, *Supportability*, *Sustainability* e *Survivability*) e com o custo de ciclo de vida (*Cost*) — representa impacto direto sobre o retorno do investimento em sistemas cujo custo de aquisição e sustentação é elevado [3].

Paralelamente, a crescente disponibilidade de dados operacionais tem aberto novas perspectivas para a gestão da manutenção [4]. Sistemas modernos contam com sensores embarcados que monitoram continuamente o estado dos componentes, viabilizando o *Condition-Based Maintenance Plus* (CBM+) [5], [6] — estratégia que abrange tanto o diagnóstico do estado de saúde atual quanto o prognóstico de estados futuros. Nessa abordagem, a decisão de intervenção deixa de ser ditada por parâmetros de envelhecimento fixos e passa a ser orientada pela condição real do item, inferida a partir de *features* extraídas dos dados [7]. Os setores militar e industrial vêm adotando progressivamente esse modelo, migrando das estratégias tradicionais de manutenção corretiva e programada em direção ao CBM+ [8], [9].

No entanto, a transição para uma abordagem orientada por dados não é trivial. Como será discutido na revisão da literatura, ela exige uma base analítica prévia que caracterize o comportamento da frota antes de qualquer generalização automatizada [7], [10]. Diante desse contexto, o presente artigo propõe uma análise exploratória dos dados operacionais de uma frota em fase de entrada em operação.

Os dados analisados provêm de um sistema de gerenciamento de frota que registra eventos como mudanças de estado (disponível, indisponível, em manutenção), solicitações e envio de materiais para reparo, entre outros.

O trabalho tem dois objetivos principais: (i) oferecer uma visão consolidada do desempenho da frota frente às expectativas iniciais, por meio de indicadores de falha e disponibilidade; e (ii) identificar os principais sistemas com dificuldade para atingir as métricas previstas, e que, portanto, merecem estudo futuro aprofundado.

II. REVISÃO DA LITERATURA

O tema abordado por esta pesquisa tem apresentado crescimento nos últimos anos, considerando o número anual de publicações [11]. Todavia, observa-se uma escassez de estudos de caso específicos: a maioria dos trabalhos foca em análises pontuais de sistemas, subcomponentes ou conjuntos de *features*, ao invés de traçar um panorama da situação de uma frota de sistemas como um todo.

Nesse contexto, o presente trabalho se diferencia ao adotar a frota como unidade de análise, caracterizando o desempenho real de múltiplos sistemas frente às expectativas de projeto. Essa perspectiva de *fleet-level analysis* é apontada como lacuna relevante na literatura [11] e constitui a principal contribuição deste estudo.

A. Desempenho projetado versus obtido

A gestão de sistemas de alta complexidade exige que a infraestrutura de suporte seja tratada como parte integrante do próprio sistema. A literatura consolida esse entendimento no conceito de *Integrated Product Support* (IPS), composto por 12 elementos interdependentes que devem operar de forma equilibrada para assegurar continuidade operacional a custo sustentável [2]. Blanchard define suportabilidade como o grau em que um sistema pode ser efetivamente suportado, tanto em termos das características de projeto quanto da infraestrutura geral de suporte [3].

A métrica central para avaliar o resultado desse ecossistema é a disponibilidade. Dentre os indicadores disponíveis, a Disponibilidade Operacional (A_o) é o mais abrangente, por incorporar não apenas os tempos de manutenção corretiva e preventiva, mas também os atrasos logísticos e administrativos [3]. É justamente esse indicador que se observa na prática: o valor de A_o efetivamente realizado pela frota em operação frequentemente diverge das metas de projeto, especialmente nos primeiros anos de serviço [1].

Assim, a primeira hipótese deste trabalho é que a maturidade do ecossistema de suporte é tão crítica quanto a maturidade do sistema em si (H1). Essa divergência não decorre necessariamente de falhas de projeto: a ausência de requisitos de suporte adequados na fase de preparação pode atrasar a curva de maturidade logística, evidenciada pela degradação dos indicadores RAM4S-C [1], [12]. Mesmo quando o projeto é bem executado, ineficiências nos elementos do IPS são suficientes para manter a frota abaixo das metas. A oportunidade de correção concentra-se nas fases iniciais do ciclo de vida: uma vez em serviço, as alavancas disponíveis são mais limitadas e mais custosas [3].

B. A questão da qualidade dos dados

Se a disponibilidade operacional é o termômetro do ecossistema de suporte, os dados operacionais são o insumo para lê-lo com precisão. Pinto destaca que os dados constituem o elemento integrador da estrutura de suporte, conectando os demais elementos e possibilitando sua evolução contínua [11]. Sem dados de qualidade, as decisões são reativas, sem capacidade de identificar padrões sistêmicos [10].

Para fins de CBM, Jardine et al. classificam os dados em dois tipos principais: dados de eventos "*event data*", que registram o que ocorreu com o ativo e as intervenções realizadas; e dados de monitoramento de condição (*condition monitoring data*), que correspondem às medições do estado de saúde do sistema [13]. Ambos são igualmente necessários: priorizar um em detrimento do outro compromete a análise.

A segunda hipótese deste trabalho é que, sem dados de qualidade coletados de forma estruturada ao longo da vida em serviço, qualquer decisão de manutenção será sistematicamente ineficiente (H2). A evidência é direta: a baixa qualidade dos dados coletados durante a operação tem sido apontada como fator limitante para melhorias que poderiam resultar de uma melhor compreensão do desempenho do sistema em serviço [3]. Entradas manuais introduzem ruídos e incoerências; registros incompletos de manutenção dificultam a rotulagem do estado de saúde dos componentes; e o conhecimento tácito do operador na linha raramente é capturado de forma estruturada [8], [14]. O resultado é uma base de

dados que exige tratamento antes de uma análise, seja ela exploratória ou automatizada.

C. CBM+ como evolução natural

Os setores militar e industrial vêm gradualmente migrando das estratégias tradicionais de manutenção corretiva e baseada em intervalos fixos para abordagens de CBM+ [8], [9]. Essa transição busca maximizar a vida útil dos componentes e reduzir intervenções desnecessárias, orientando a decisão de manutenção pela condição real do item, inferida a partir de dados de sensores e histórico operacional [6]. O gerenciamento de integridade (*health management*) é definido como o processo de selecionar e executar ações de manutenção no momento mais adequado, considerando os resultados de diagnóstico e prognóstico, a disponibilidade de recursos e as demandas operacionais [7].

Assim, a terceira hipótese deste trabalho é que a adoção de CBM e PdM (*Predictive Maintenance*) não substitui o entendimento prévio do comportamento da frota: esse entendimento é um pré-requisito técnico (H3). A transição não é direta: a migração de tarefas programadas para tarefas baseadas em predição pode elevar a indisponibilidade se não houver integração com o plano geral de manutenção [11]. Além disso, aplicações bem-sucedidas de PHM (*Prognostics and Health Management*) tipicamente requerem pré-processamento manual dos sinais — processo conhecido como *feature engineering* [7] —, cuja execução depende do conhecimento acumulado sobre os mecanismos de degradação e de como eles se manifestam nos dados [7]. O diagnóstico orientado por dados é mais eficiente quando precedido de uma análise de sintomas que guia a coleta e ativa os módulos analíticos apropriados [8], [13].

D. O olhar do analista

O avanço das técnicas de aprendizado de máquina tem impulsionado expectativas de automação plena da manutenção. Contudo, a capacidade de interpretação dos modelos no contexto operacional industrial ainda é um desafio crítico [7], e a validação física dos resultados segue dependente de pessoal altamente treinado [8], [13]. Na prática, variáveis de difícil modelagem matemática, tais como disponibilidade de mão de obra em ambiente militar, fatores políticos em contratos de suporte, entre outros, escapam dos modelos quantitativos [1]. Investigações de mineração de dados servem primariamente para alertar especialistas, e não para substituir seu julgamento; a combinação de mineração de dados com conhecimento especializado sobre a frota é o caminho mais robusto [10].

Complementarmente, analisar a frota como unidade de observação permite alavancar informações de múltiplos sistemas operando em condições reais, entregando um valor sistêmico que análises de itens isolados falham em capturar [11]: padrões de degradação e anomalias que não seriam evidentes em uma única unidade tornam-se identificáveis no agregado [9], [14]. Assim, a quarta e a quinta hipóteses deste trabalho — sendo a última sua principal contribuição metodológica — são que a análise exploratória orientada pelo especialista é etapa necessária antes da aplicação de técnicas automatizadas (H4), e que a *fleet-level analysis* é a escala de observação adequada para essa etapa (H5). Padrões de falha podem ser específicos a configurações ou condições

de operação, dificultando a transferência direta de modelos entre unidades [7], o que reforça a necessidade de caracterizar previamente o comportamento da frota como um todo, precisamente o que o presente trabalho se propõe a realizar.

III. METODOLOGIA

A metodologia empregada neste trabalho caracteriza-se como uma análise exploratória de dados operacionais, orientada pelo conhecimento especializado sobre o sistema estudado, conforme fundamentado na revisão da literatura [9], [10]. Essa abordagem justifica-se também pelas incertezas inerentes aos registros de manutenção e pela dificuldade frequente em estabelecer uma *ground truth* fidedigna apenas por meio de logs automatizados, exigindo o julgamento do especialista para validar os estados do sistema [14].

Os dados analisados foram extraídos do sistema de gerenciamento da frota, com aproximadamente 3 anos e 3.000 horas de operação. As fontes de dados compreendem registros de mudanças de estado operacional (disponível, indisponível, em manutenção), solicitações de material, envios para reparo e histórico de intervenções (dados de eventos (*event data*) [13]).

O processo analítico foi estruturado em duas etapas, em consonância com a abordagem de diagnóstico em dois estágios descrita por Saxena et al. [9]: na primeira etapa, realizou-se a análise exploratória dos registros disponíveis, com o objetivo de identificar quais variáveis e extratos de dados forneceriam as informações mais relevantes para caracterizar o desempenho da frota [10]; na segunda etapa, os padrões e tendências identificados foram confrontados com os parâmetros nominais de desempenho estabelecidos pelo fabricante original (OEM), incluindo as taxas de falha previstas para o sistema e seus principais subsistemas.

Os resultados são expressos por meio do indicador de disponibilidade operacional (A_o), que reflete o desempenho efetivo da frota em campo ao incorporar, além das manutenções corretiva e preventiva, os atrasos logísticos e administrativos [3]. No que tange à confiabilidade e prontidão, os dados observados são comparados aos valores nominais de projeto por meio de quatro métricas distintas [3]:

- **MTBF** (*Mean Time Between Failures*): considera apenas interrupções causadas por falhas funcionais confirmadas;
- **MTBUR** (*Mean Time Between Unscheduled Removals*): contabiliza todas as remoções não programadas de componentes, independentemente da motivação; e
- **MTBUMA** (*Mean Time Between Unscheduled Maintenance Actions*): métrica mais abrangente, que engloba todas as intervenções de manutenção não planejadas, incluindo aquelas que não envolvem remoção de itens; e
- **MTBS** (*Mean Time Between Stops*): qualquer mudança de estado operacional do sistema, sendo diretamente observável a partir dos registros de mudança de estado.

A adoção desses indicadores em nível de frota permite identificar oportunidades de otimização sistêmica que análises isoladas de componentes não seriam capazes de capturar [11]. Dentre tais indicadores, o MTBF foi escolhido como uma das bases de referência por se tratar do valor nominal estabelecido em contrato. Para representar a confiabilidade observada em campo, utilizou-se o MTBUR, indicador que pode ser medido por meio do programa de gestão da frota.

A obtenção do MTBF observado e do MTBUMA demandaria informações sobre a motivação e a duração das intervenções, indisponíveis nesta extração. Assim, a análise concentra-se no MTBUR e no MTBS, que podem ser obtidos a partir dos registros de mudança de estado, além da disponibilidade operacional. Ressalta-se que o MTBS, por abranger também paradas programadas, não se confunde com o MTBUMA.

Essa escolha é coerente com o enfoque do trabalho: confiabilidade e manutenibilidade são características de projeto imputáveis ao fabricante, isto é, representam o desempenho previsto em projeto, enquanto os dados de campo revelam o desempenho efetivamente observado. A comparação entre essas duas perspectivas permite discutir as possíveis causas dos desvios identificados [3].

IV. RESULTADOS E DISCUSSÃO

A. Evolução da Confiabilidade da Frota

A Fig. 1 apresenta a evolução trimestral do MTBUR e do MTBS da frota, normalizados pelo valor de referência do fabricante (MTBF nominal, OEM = 1,0). Os dados desconsideram dados registrados antes da entrega oficial dos sistemas.




Fig. 1. Evolução do MTBUR e do MTBS da frota por trimestre, normalizados pelo OEM (índice = 1,0). No último trimestre, barra vermelha = MTBUR percebido pelos técnicos. Linha verde tracejada = referência OEM.

Ao longo de todo o período analisado, o MTBUR da frota manteve-se significativamente abaixo da referência OEM, não superando 60% do valor nominal. Apesar disso, observa-se tendência consistente de crescimento, compatível com a curva de aprendizado típica de sistemas de alta complexidade em fase inicial de serviço [1]. Esse comportamento sugere maturidade progressiva tanto do ecossistema de suporte quanto da qualidade dos sistemas entregues, conforme evidenciado pela Fig. 2: o último lote de sistemas incorporados apresenta desempenho muito próximo da referência OEM.

Poder-se-ia argumentar que a janela operacional reduzida e a natureza censurada dos dados — itens longevos ainda

em operação tendem a elevar as médias futuras — limitam a relevância estatística das estimativas pontuais. Esse é precisamente o motivo da representação cumulativa adotada, e também o valor deste registro: o presente trabalho constitui uma radiografia do início da operação, referência contra a qual atualizações futuras da mesma frota poderão ser comparadas.

A decomposição por janelas iniciais na própria Fig. 2 acrescenta ainda uma nuance à análise: nos primeiros lotes, o índice dos primeiros três meses é inferior ao acumulado total, evidenciando um período de falhas infantis (*burn-in*) seguido de estabilização [3], [11].

A magnitude desse efeito, contudo, diminui a cada lote, isto é, o desempenho inicial do último lote supera o desempenho maduro dos anteriores. Conjugados, esses padrões indicam que a tendência de crescimento da Fig. 1 decorre menos da recuperação das unidades pioneiras e mais da incorporação de sistemas que ingressam em operação sob um ecossistema de suporte já calibrado e com correções absorvidas em linha de produção [1].

Merece destaque o desempenho do Batch 3 — os sistemas mais recentes —, cujo MTBUR praticamente alcança a referência do fabricante. Esse resultado não se explica apenas pela maturação do ecossistema de suporte: ele reflete também ganhos intrínsecos de confiabilidade. De um lado, melhorias de qualidade construtiva absorvidas ao longo da produção; de outro, atualizações de *software* que, ao elevarem os limiares de detecção, reduzem o registro de falhas espúrias — indicações sem correspondência a uma falha funcional efetiva. Como o MTBUR contabiliza apenas remoções confirmadas como falha, essa depuração diminui a contagem de eventos atribuídos ao sistema e aproxima o indicador observado do valor projetado, sugerindo que parte do desvio dos primeiros lotes decorria de imprecisão de classificação, e não de indisponibilidade real [1], [11].




Fig. 2. MTBUR por *batch* de sistemas, em janelas de observação: primeiros 3, 6 e 12 meses e toda a vida de operação de cada sistema, normalizados pelo OEM.

O MTBS, por sua vez, esboça leve melhoria ao longo

do período, mas mantém-se em patamar bastante reduzido. Isso, todavia, não constitui necessariamente um indicador negativo: uma informação adicional relevante é que o sistema foi concebido para permitir intervenções rápidas, e a métrica contabiliza qualquer mudança de estado operacional, ainda que breve. Adicionalmente, os próprios mantenedores relataram preferir, em diversas situações, fracionar demandas de manutenção a indisponibilizar uma unidade de forma contínua por períodos prolongados — prática que contribui artificialmente para reduzir o MTBS observado.

A Fig. 1 apresenta ainda o MTBUR percebido pelos técnicos de manutenção, obtido a partir de planilha de controle própria dos mantenedores, externa ao sistema oficial de gerenciamento da frota. Esse indicador situa-se em torno de 75% do OEM — sensivelmente superior ao calculado pelos registros sistêmicos. A planilha dos técnicos em questão, contudo, desconsidera diversas ocorrências de falha e apresenta inconsistências e irregularidades de classificação. Ainda assim, representa a percepção do cliente direto do serviço de manutenção, constituindo um dado qualitativo relevante. Esse fenômeno, todavia, reforça a necessidade de reduzir a dependência de entradas manuais e avançar na automação da coleta e, sobretudo, da classificação dos dados de eventos, de forma a mitigar o viés introduzido pelo conhecimento tácito dos mantenedores [10], [13], [14].

B. Desvios de Confiabilidade por Subsistema

Se a análise agregada da seção anterior estabelece a convergência da frota para a referência, as Figs. 3 e 4 introduzem a comparação da performance observada com os valores esperados por subsistemas. De forma análoga à comparação do sistema com a referência global, esses gráficos mostram como cada subsistema contribui para esse resultado final, elucidando onde os desvios se concentram do ponto de vista da confiabilidade de subsistemas.

A Fig. 3 em específico apresenta a razão $MTBUR_{obs}/MTBF_{OEM}$ por subsistema e por lote (eixo truncado em 2; marcador “)” indica razões superiores, incluindo casos sem falha registrada no lote). O gráfico revela que o gradiente entre lotes identificado na Fig. 2 não é uniforme: em subsistemas como Subsystem A e B, o último lote já supera a referência, enquanto em Subsystem T o desvio persiste em todos os lotes. Nesse sentido, caberia argumentar que, nesses grupos, parte significativa da causa de falhas não reside na maturidade do suporte, mas em características intrínsecas de projeto, fatores ambientais ou de perfil de emprego, introduzindo comportamentos de falha não contemplados no modelo de referência [11]. Esse resultado reforça a necessidade de adaptar os parâmetros nominais à realidade de cada frota antes da aplicação de técnicas automatizadas de diagnóstico [8].

Por sua vez, a Fig. 4 apresenta a evolução semestral da composição proporcional das falhas. A leitura revela dois regimes distintos. No primeiro semestre, um único subsistema (Subsystem M) concentrava cerca de um terço das ocorrências, participação que se reduz a menos de 10% já no semestre seguinte — comportamento compatível com falhas infantis localizadas ou com ação corretiva pontual, e coerente com o período de *burn-in* identificado na seção IV-A.

Em contraste, um conjunto intermediário de subsistemas mantém participação aproximadamente constante ao longo de




Fig. 3. Razão $MTBF_{obs}/MTBF_{OEM}$ por subsistema, decomposta por lote de incorporação (Batch 1 a 3) e frota completa. Barra da frota mais larga, colorida por faixa: verde=razão $\geq 0,9$; amarelo= $[0,4; 0,9)$; vermelho $< 0,4$. Eixo truncado em 2; marcador “)” = razão superior ao limite. Ordenação pela razão da frota.

todo o período, caracterizando carga de manutenção estrutural, não eliminada pela maturação do ecossistema de suporte. São esses os candidatos prioritários a estudos de CBM: sistemas




Fig. 4. Evolução semestral (S1 a S6) da composição proporcional das falhas por subsistema. Séries = união dos cinco subsistemas menos confiáveis do primeiro e do último semestre; demais agregados em “Outros”. Valores normalizados pelo total de falhas de cada semestre.

com falhas persistentes e situados nas faixas inferiores de desempenho da Fig. 3 [6], [13].

Observa-se ainda a dispersão progressiva da composição: a participação agregada dos principais sistemas contribuintes para desvios de falhas diminui semestre a semestre, indicando que, à medida que a frota amadurece, intervenções concentradas em poucos grupos tendem a diminuir, reforçando a necessidade de priorização orientada por dados [11].

C. Disponibilidade Operacional final

A Fig. 5 encerra a análise ao apresentar a evolução trimestral da disponibilidade da frota. Por restrições de confidencialidade dos dados operacionais, omitem-se os valores absolutos e a meta de projeto, preservando-se apenas a forma relativa da série; ainda assim, a análise apresenta uma disponibilidade que se manteve abaixo da meta de projeto ao longo de todo o período, oscilando sem tendência clara de convergência — em contraste com a melhoria consistente do MTBUR observada na Fig. 1. Essa assimetria é reveladora sob a ótica da suportabilidade: se a confiabilidade evolui mas a disponibilidade não a acompanha, os demais componentes da equação — manutenibilidade e, sobretudo, os atrasos logísticos e administrativos que compõem a disponibilidade operacional — podem passar a ter maior influência sobre o tempo de indisponibilidade [1], [3].

Esse diagnóstico, porém, é encorajador: com a confiabilidade intrínseca, de correção mais onerosa, já em maturação, a defasagem restante concentra-se nos elementos logísticos e administrativos do IPS, mais sensíveis a ações de gestão e com margem concreta de melhoria da disponibilidade.

Reforça essa leitura o comportamento do Batch 3: quando introduzido, o lote apresentou taxa de falha muito próxima da referência de projeto (Fig. 2). Sua disponibilidade final




Fig. 5. Disponibilidade da frota por trimestre

(omitida por constituir dado sensível) também apresentou tal comportamento. Esse descompasso do restante da frota, embora demande investigação mais aprofundada, sugere que parcela relevante da indisponibilidade decorre da maturidade ainda incompleta da suportabilidade, e não do sistema em si.

Em outras palavras, as falhas funcionais, objeto central deste estudo, explicam apenas parte do desvio em relação à meta: tempos de reparo, espera por material e fluxos administrativos do ecossistema de suporte respondem pela parcela restante, e sua caracterização demanda dados de duração das intervenções que extrapolam o escopo da presente análise. A maturação da confiabilidade intrínseca do sistema é condição necessária, porém não suficiente, para o atingimento das metas de disponibilidade — o desempenho da frota é limitado pelo elemento menos maduro do seu ecossistema de Suporte Integrado ao Produto (IPS) [2].

V. CONCLUSÃO

Este trabalho apresentou uma análise exploratória de dados operacionais de uma frota de sistemas de alta complexidade ao longo de aproximadamente três anos, cumprindo os dois objetivos propostos. Quanto ao primeiro objetivo, os resultados proporcionaram uma visão consolidada do desempenho em relação às expectativas e apoiaram a primeira hipótese do estudo: o sistema, ainda que com confiabilidade em melhoria contínua, não atinge as métricas previstas, e a disponibilidade permanece abaixo do projetado (H1). Sob a ótica da suportabilidade, essa assimetria indica que as falhas funcionais explicam apenas parte do desvio, cabendo aos demais elementos do IPS (principalmente a manutenibilidade e os atrasos logísticos e administrativos) a parcela restante [1], [3]. Quanto ao segundo objetivo, a decomposição por subsistema priorizou objetivamente os candidatos a CBM, grupos com razão $MTBUR_{obs}/MTBF_{OEM}$ persistentemente baixa e participação estável nas falhas, fornecendo a base analítica prévia que a literatura aponta como pré-requisito à manutenção preditiva [6], [11] (H2).

A análise validou, ainda, as demais hipóteses construídas na revisão: dados operacionais são fundamentais para gestão do suporte, mas, mesmo com um bom sistema, sua qualidade e coerência (H2) podem levar a serem subaproveitadas por dependerem, em último caso, do fator humano de classificação (H3); o que se correlaciona com o fato de que uma análise computacional depende de uma exploração analítica prévia, que isole eventuais inconsistências através do olhar de um analista experiente (H4), que é capaz de identificar padrões que podem passar despercebidos na análise de componentes isolados (H5).

REFERÊNCIAS

- [1] L. S. Martins, “Suportabilidade de aeronaves de defesa: Modelo de processo para avaliação dos impactos de fatores de confiabilidade e manutenibilidade na fase de serviço,” 2023. [Online]. Available: https://aerologlab.ita.br/static/documents/lucas_martins.pdf
- [2] AEROSPACE, D. I. A. O. E. (ASD), A. I. A. O. A. (AIA), “International specification for integrated product support s-series ips specifications block release ii,” 2025. [Online]. Available: https://umbraco.asd-europe.org/media/1khh2vck/sx000i.issue_4-0.pdf?rmode=pad&v=1dc6740e3566490
- [3] B. S. Blanchard J. E. Blyler, *System Engineering Management*, 1st ed. Wiley, 3 2016.
- [4] H. He E. A. Garcia, “Learning from imbalanced data,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 21, pp. 1263–1284, 9 2009. [Online]. Available: <https://ieeexplore-ieee-org.ez63.periodicos.capes.gov.br/document/5128907>
- [5] D. O. D. (DoD), “Dod instruction 4151.22 condition-based maintenance plus for materiel maintenance,” 2020. [Online]. Available: <https://www.esd.whs.mil/DD/>
- [6] J. Lee M. Mitici, “Multi-objective design of aircraft maintenance using gaussian process learning and adaptive sampling,” *Reliability Engineering & System Safety*, vol. 218, p. 108123, 2 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0951832021006189>
- [7] O. Fink, Q. Wang, M. Svensén, P. Dersin, W.-J. Lee, et al., “Potential, challenges and future directions for deep learning in prognostics and health management applications,” *Engineering Applications of Artificial Intelligence*, vol. 92, p. 103678, 6 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0952197620301184?via%3Dihub>
- [8] A. Saxena, B. Wu, G. Vachtsevanos, “Integrated diagnosis and prognosis architecture for fleet vehicles using dynamic case-based reasoning,” in *IEEE Autotestcon*, 2005., 9 2005, pp. 96–102. [Online]. Available: <https://ieeexplore-ieee-org.ez63.periodicos.capes.gov.br/document/1609109>
- [9] —, “A hybrid reasoning architecture for fleet vehicle maintenance,” *IEEE Instrumentation & Measurement Magazine*, vol. 9, pp. 29–36, 8 2006. [Online]. Available: <https://ieeexplore-ieee-org.ez63.periodicos.capes.gov.br/document/1664039>
- [10] T. Young, M. Fehskens, P. Pujara, M. Burger, G. Edwards, “Utilizing data mining to influence maintenance actions,” *AUTOTESTCON (Proceedings)*, pp. 267–271, 2010. [Online]. Available: <https://ieeexplore-ieee-org.ez63.periodicos.capes.gov.br/document/5613610>
- [11] D. G. F. Pinto, “A military aircraft fleet support management model based on the optimal integration of predictive and scheduled maintenance,” Ph.D. dissertation, 2022. [Online]. Available: https://aerologlab.ita.br/static/documents/tese_figueiredo.pdf
- [12] J. N. D. M. Filho F. T. M. Abrahão, “A study on maintenance task interval optimization by metaheuristics,” in *Simpósio de Pesquisa Operacional e Logística Da Marinha - Publicação Online*. Editora Blucher, 5 2020, pp. 137–151. [Online]. Available: https://aerologlab.ita.br/static/documents/spolm_nogueira.pdf
- [13] A. K. S. Jardine, D. Lin, D. Banjevic, “A review on machinery diagnostics and prognostics implementing condition-based maintenance,” *Mechanical Systems and Signal Processing*, vol. 20, pp. 1483–1510, 10 2006. [Online]. Available: <https://doi-org.ez63.periodicos.capes.gov.br/10.1016/j.ymssp.2005.09.012>
- [14] L. Basora, P. Bry, X. Olive, F. Freeman, “Aircraft fleet health monitoring with anomaly detection techniques,” *Aerospace*, vol. 8, p. 103, 4 2021. [Online]. Available: <https://www.mdpi.com/2226-4310/8/4/103>