



## A ANÁLISE DE DADOS NA AVIAÇÃO A PARTIR DAS DIRETRIZES DO DOC 10159 DA ICAO: EVOLUÇÃO NORMATIVA E APLICAÇÕES PRÁTICAS

ISSN 2763-7697 – QUALIS A4

Lorenzo Fritz<sup>1</sup>  
André Luís Boff<sup>2</sup>

### RESUMO

Este estudo contextualiza o processo da análise de dados na indústria da aviação, a partir das diretrizes trazidas pelo novo DOC 10159 da ICAO (*Safety Intelligence*), analisando a evolução normativa dos regulamentos e algumas aplicações práticas já existentes na indústria. A metodologia baseou-se em uma busca bibliográfica/documental de regulamentos aeronáuticos e estudos selecionados, submetidos à técnica da Análise de Conteúdo de Bardin (2016). Os estudos trazem cinco aplicações práticas de *Machine Learning* (ML) e Inteligência Artificial (IA) nas áreas de predição de turbulências, fadiga humana, aproximações desestabilizadas, interferências de sinais (*jamming* e *spoofing*) e motores. Os resultados apontam um descompasso regulatório, onde enquanto o DOC 10159 se limita a fundamentos elementares, trata pouco sobre IA e carece de exemplos práticos, a indústria e a comunidade científica já aplicam sistemas preditivos para aproximar o setor da meta global de zerar as fatalidades na aviação comercial após o ano de 2030. Ademais, o cenário brasileiro ainda se concentra na coleta em detrimento do processamento de dados, e, sobretudo, destaca-se que o *Safety Intelligence* ainda se trata de uma recomendação internacional e não um requisito mandatório.

**Palavras-chave:** *Safety Intelligence*; *Machine Learning*; Análise de Dados.

<sup>1</sup> Graduando em Ciências Aeronáuticas pela Pontifícia Universidade Católica do Rio Grande do Sul (2023 - 2026). Piloto Comercial (PC/MLTE/IFR/INVA) com 190 horas de voo, atuando como docente no Aeroclube de Eldorado do Sul nas disciplinas de "Peso & Balanceamento" e "Navegação". Áreas de interesse em pesquisa envolvem transporte aéreo, data analysis e eficiência operacional. PUC/RS. E-mail: [lorenzo.fritz@edu.pucrs.br](mailto:lorenzo.fritz@edu.pucrs.br)

<sup>2</sup> Graduado em Ciências Aeronáuticas pela Pontifícia Universidade Católica do Rio Grande do Sul (2006), com Mestrado em Administração e Negócios pela mesma instituição (2009). Elemento Certificado - Prevenção (EC-PREV). Atualmente atua como Comandante/Instrutor/Checkador de Rota no ATR 72-600 da Azul Linhas Aéreas Brasileiras S.A.. Docente no Curso de Ciências Aeronáuticas da PUCRS. PUC/RS. E-mail: [andre.boff@pucrs.br](mailto:andre.boff@pucrs.br)

## **AVIATION DATA ANALYSIS BASED ON ICAO DOC 10159 GUIDELINES: REGULATORY EVOLUTION AND PRACTICAL APPLICATIONS**

### **ABSTRACT**

*This study contextualizes the data analysis process within the aviation industry based on the guidelines introduced by the new ICAO DOC 10159 (Safety Intelligence), analyzing the normative evolution of regulations and existing practical applications in the sector. The methodology was based on a bibliographic and documentary search of aeronautical regulations and selected studies, which were subjected to Bardin's (2016) Content Analysis technique. The reviewed studies present five practical applications of Machine Learning (ML) and Artificial Intelligence (AI) in the fields of turbulence prediction, human fatigue, destabilized approaches, signal interference (jamming and spoofing), and aircraft engines. The results highlight a regulatory mismatch: while DOC 10159 is limited to elementary fundamentals, briefly addresses AI, and lacks practical examples, the industry and the scientific community are already implementing predictive systems to bring the sector closer to the global goal of zero fatalities in commercial aviation after 2030. Furthermore, the Brazilian scenario remains focused on data collection rather than data processing, and, above all, it is highlighted that Safety Intelligence is still an international recommendation rather than a mandatory requirement.*

**Keywords:** Safety Intelligence; Machine Learning; Data Analysis.

## **1 INTRODUÇÃO**

O contexto recente do desempenho da segurança de voo no modal aéreo vem apresentando números positivos, passando de 3,53 acidentes por milhão de voos, em 2007, para a razão de 1,61, em 2016; atingindo, atualmente, o valor registrado de 1,25 acidentes por milhão de voo, relativos à aviação comercial regular, na média móvel dos últimos 5 anos (IATA, 2025). Como resultado da evolução

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

destes indicadores, a aviação comercial passa a fazer parte dos segmentos classificados como “ultrasseguros”, em que se incluem a indústria nuclear e o sistema ferroviário europeu (Amalberti, 2001).

Estes resultados positivos surgem devido aos constantes projetos de desenvolvimento da segurança de voo, implementando cada vez melhores sistemas de gestão da segurança, além destes se mostrarem cada vez mais enraizados na cultura de segurança das empresas (Thereza, 2020). Essa gestão da segurança operacional, desenvolvida pelo documento 9859 da *International Civil Aviation Organization* (ICAO), é conhecida como *Safety Management System* (SMS), e desempenha um papel fundamental na manutenção e melhora dos indicadores de segurança. O modelo proposto pelo documento busca a proatividade na identificação de perigos e na mitigação de riscos, auxiliado por um ciclo contínuo de planejamento, execução, avaliação e melhoria. Este processo permite que os prestadores de serviços de aviação civil (PSAC) não apenas reajam a eventos de segurança, mas, também, antecipem falhas e fortaleçam a cultura de segurança, além da possibilidade de reduzir custos operacionais ao revelar ineficiências no sistema (ICAO, 2018).

Visando essa continuidade positiva, chegando ao objetivo estipulado de zero fatalidades em operações comerciais até 2030 e em diante (ICAO, 2025c), a ICAO vem desenvolvendo a ideia de trabalhar com a prevenção de acidentes de maneira proativa/preditiva. O marco mais recente desse esforço é a publicação do DOC 10159 (2025), apelidado de *Safety Intelligence Manual*, que estabelece diretrizes para a coleta, processamento, análise e gestão de dados, além de abordar taxonomias padronizadas, governança e o compartilhamento destes. A proposta central do manual é orientar a indústria na transformação de grandes volumes de dados brutos em conhecimento acionável, processo que depende diretamente do suporte de novas tecnologias de processamento.

Sob essa ótica, o *Machine Learning* (ML) surge como uma ferramenta fundamental para a viabilização desses processos preditivos (Alpaydin, 2020), em que, diferentemente da programação tradicional, ele permite que sistemas computacionais identifiquem padrões complexos e relações não lineares em vastos

conjuntos de dados, aprendendo com ocorrências passadas para antecipar comportamentos futuros sem serem explicitamente programados para cada variável (FAETERJ, 2018). Essa capacidade de 'aprendizado' facilita e aprimora a transformação dos dados brutos em inteligência, permitindo, por exemplo, que a gestão da segurança operacional identifique precursores de acidentes antes que eles se manifestem em eventos críticos.

Todo esse suporte tecnológico converge para o processo da análise de dados, que é, de forma geral, definido como um método que envolve desde a inspeção e limpeza, até a transformação e modelagem dos dados para descobrir informações úteis e tirar conclusões, garantindo uma tomada de decisão numericamente sustentada (Islam, 2020). No que tange à aviação, a rápida evolução tecnológica possibilita, hoje, a coleta de uma grande quantidade de informações em tempo real, disponibilizadas a partir de diversas fontes, referentes ao desempenho de voo, por meio dos gravadores de dados de voo (FDR – *Flight Data Recorders*), condições do aeroporto e do tráfego aéreo, escalas dos tripulantes, meteorologia, reportes dos operadores, dentre muitas outras.

Embora esse volume massivo de dados seja uma realidade contemporânea, o esforço dos órgãos reguladores para estruturar a coleta/análise de dados no setor começou a se consolidar há duas décadas, quando, em 2006, por exemplo, foi publicada a primeira edição do documento *Safety Management Manual* (DOC 9859), que, apesar de não mencionar “*Safety Intelligence*” (conceito que surge a partir da quarta edição, de 2018), abordagens proativas já são recomendadas, tratando de análise de dados de voo (FDA - *Flight Data Analysis Program*), da coleta de dados com FOQA (*Flight Operations Quality Assurance*) e as análises de tendência dos dados obtidos (ICAO, 2006).

Essa gradual introdução da análise de dados na aviação, com enfoque em segurança, acompanha um movimento global de transformação digital dos variados mercados, nos quais o conceito já é aplicado em áreas como saúde, varejo, produção, marketing, educação e, mesmo dentro do modal aéreo, nas previsões de demanda por voos, precificação de passagens, contratações, dentre outras (Sarker, 2021).

Quando direcionado para a segurança de voo, o uso da análise de dados combinado ao ML assume um papel essencialmente preditivo. Essa abordagem desenvolve a capacidade de antecipar e mitigar riscos antes que eles se manifestem, se diferenciando da segurança de maneira reativa e preventiva ao ir além da simples correção de falhas passadas ou da aplicação de medidas para evitar eventos conhecidos, e focar na identificação de ameaças ainda não manifestadas no ambiente operacional (ICAO, 2006).

Portanto, este estudo contextualiza o processo de análise de dados na indústria da aviação, a partir das diretrizes trazidas pelo novo DOC 10159 da ICAO (*Safety Intelligence*), analisando a evolução normativa dos regulamentos e algumas aplicações práticas já existentes na indústria.

## 2 A CIÊNCIA DA ANÁLISE DE DADOS

A mesma ciência que nos permite traçar e tabular os índices passados, nos possibilita, também, prever eventos futuros, quando estes são modelados e trabalhados por fórmulas matemáticas (Shmueli, 2010). Esse primeiro método fica denominado “análise descritiva”, e se concentra em resumir e organizar os dados históricos para revelar padrões e tendências, como mostram os gráficos na Figura 2, representando a variação do preço do combustível, em conjunto com a eficiência dos motores, e o lucro das empresas aéreas. Por sua vez, o segundo, denominado “análise preditiva”, nos permite determinar a possibilidade da ocorrência de determinados eventos no futuro, o que é feito por meio do uso de ferramentas e processos mais complexos, ficando nomeada “ciências de dados” a área que as desenvolve e executa (Datacamp, 2023).

Como ramo dessa ciência, a análise de dados, em sua essência, estabelece uma progressão de complexidade e valor estratégico, onde quanto mais avançado o tipo de análise (passando da descritiva para a prescritiva), maior é a sofisticação técnica requerida, e maior é o impacto e o *insight* gerado para a tomada de decisão estratégica (ICAO, 2025b). A etapa mais básica/fundamental desse processo é a análise descritiva, que se concentra em responder à questão “O que aconteceu?”.

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

Este tipo de análise utiliza estatísticas sumárias, como média, mediana e desvio-padrão, em conjunto com as visualizações por meio de gráficos e *dashboards*, para organizar e simplificar dados históricos, facilitando, então, a identificação e interpretação de padrões e tendências (Sharda *et al.*, 2019).

Mas o valor da análise de dados vai além da descrição, evoluindo para abordagens mais sofisticadas que fundamentam o campo da ciência de dados, definido como um conjunto de princípios, processos e técnicas para extrair conhecimento de dados, unificando a estatística, a computação e métodos analíticos para entender fenômenos complexos e não óbvios, ocultos entre os dados (Kelleher *et al.*, 2018).

Essa evolução é necessária porque, embora a análise descritiva forneça o fundamento, ao resumir os dados históricos ("o que aconteceu?"), ela é limitada em sua capacidade de oferecer conclusões precisas que levam à tomada de decisão/ação (*insights* acionáveis) ou de abordar a complexidade inerente aos dados. Para que a ciência de dados possa realizar seu objetivo de desvendar os fenômenos não óbvios e entregar seu máximo potencial e valor estratégico, exige-se uma progressão metodológica. É esta necessidade de ir além da descrição (passado) para a explicação, a previsão e a otimização que se definem os próximos passos da análise de dados (Shmueli, 2010), ficando definidos, como análise diagnóstica, preditiva e prescritiva.

A análise diagnóstica, que procede a descritiva, avança da simples descrição para uma explicação, buscando responder à pergunta "Por que isso aconteceu?". Para isso, partindo do extraído da análise anterior, ela emprega técnicas como mineração de dados, análise de regressão e testes de hipóteses para identificar relações de causa e efeito, correlacionar variáveis e isolar fatores que mais influenciaram no resultado histórico observado (Morrow, 2024). Essa análise pode ser usada para identificar fatores que causam ou contribuem para um risco, utilizando o *insight* gerado para orientar as ações de prevenção (ICAO, 2025b).

Posteriormente, tem-se a análise preditiva, na qual o foco deixa de ser o passado e migra para o futuro, respondendo a "O que provavelmente acontecerá?". Nesta fase, os dados históricos são utilizados para treinar algoritmos de ML e

estatística avançada, processos em que os computadores aprendem a partir de dados passados, identificando padrões complexos, imperceptíveis sem o uso de ferramentas de análise, e constroem modelos, com base no conhecimento extraído, que podem ser usados para fazer previsões, estimar probabilidades ou realizar classificações (Ramakrishnan, 2023).

Por último, tem-se a análise prescritiva, *Prescriptive Analytics* (PSA), reconhecida como a mais sofisticada ferramenta analítica, respondendo à pergunta: "O que deve ser feito?" ou "Como fazer determinado cenário acontecer?". Neste ponto, ela se diferencia das demais, pois, enquanto as análises descritivas e preditivas ficam limitadas em informar o que aconteceu ou vai acontecer, a PSA vai além e propõe um melhor/mais vantajoso curso de ação ou decisão a ser tomada, o que é feito por meio do uso de técnicas como otimização, simulação e algoritmos de decisão, visando maximizar um objetivo (lucro) ou minimizar um risco (acidentes...), dessa forma, esta é a análise que oferece o maior potencial de impacto na tomada de decisão baseada em dados (DDDM - *data-driven decision making*) (Lepeniotti, 2020). Entretanto, este tipo de análise ainda está em seus primórdios, se restringindo devido à complexidade de seus modelos, à alta demanda por recursos computacionais e a expertise requerida para o desenvolvimento das ferramentas (Frazzetto *et al.*, 2019).

Em suma, a ciência da análise de dados fornece a base teórica necessária para transformar registros históricos em inteligência acionável, progredindo da simples descrição do passado para a antecipação de cenários futuros, a partir do suporte de tecnologias mais avançadas de processamento. Nesse sentido, os campos de *Machine Learning*, Inteligência Artificial e *Big Data* permitem agilizar e automatizar a descoberta de padrões e viabilizar a tomada de decisão inteligente em ambientes operacionais complexos com grandes volumes de dados.

## 2.1. MACHINE LEARNING, INTELIGÊNCIA ARTIFICIAL E BIG DATA

Sobre o tema *Machine Learning* (ML), ao contrário do que prega a programação algorítmica tradicional, que exige a definição explícita de cada etapa

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

que o programa deve executar para obter um resultado, o ML utiliza algoritmos para entender o modelo (a lógica, o padrão) e, assim, faz com que o sistema aprenda os passos necessários para se chegar a um resultado/condição de forma autônoma (FAETERJ, 2018). A vantagem de seu uso ocorre ao trabalhar com problemas complexos onde o algoritmo, ou o passo a passo para se chegar a um resultado (Docusign, 2025), não é bem definido. Como exemplo, temos a dificuldade de escrever um programa tradicional que identifique pessoas em fotos, devido à variedade de cenários possíveis (poses, ângulos, iluminação...), onde o ML, nesse caso, permitiria que o computador aprenda a realizar essa tarefa (identificar uma pessoa) com base em exemplos previamente passados (fotos com pessoas), sem a necessidade de programar o passo-a-passo (FAETERJ, 2018).

Nesse contexto, o ML é um dos principais subcampos da Inteligência Artificial (IA), e o campo atual mais amplo da ciência da computação. Seu objetivo final é o desenvolvimento de sistemas que consigam “perceber o ambiente”; ou seja, coletar, processar e interpretar dados do mundo real ou de seu ambiente operacional, e tomar decisões que maximizem suas chances de sucesso; buscando tornar as máquinas tão inteligentes quanto o cérebro humano, conhecido pela sua capacidade análoga de aprender e solucionar problemas (Shinde et al., 2018).

Ao utilizar os modelos desenvolvidos pelo ML, a IA atua transformando os dados brutos e seus padrões complexos nas desejadas tomadas de decisões operacionais baseadas nos dados (Sandeep et al., 2022). Cabe-se mencionar que, caso forem utilizados dados incorretos ou inverídicos no treinamento dos modelos preditivos, as conclusões e previsões por este geradas serão comprometidas, culminando no princípio conhecido como “*Garbage In, Garbage Out*” (“Lixo que entra, Lixo que sai”) (Kilkenny, 2018).

Outro termo comumente utilizado quando se tratando de análise de dados é *Big Data*. Este conceito aplica-se na descrição de um conjunto gigante de dados, por vezes desestruturados (informações aleatórias, sem estrutura definida) e de diferentes tipos (Zanela et al., 2015), sobre os quais são aplicadas técnicas de mineração (*data mining*), procurando “pepitas de ouro entre pedras e terra” (Sharda et al., 2019), visando tirar algum proveito destes inúmeros dados para se chegar a

uma tomada de decisão com a maior possibilidade de sucesso/acerto (Zanela *et al.*, 2015). Existem 5 características por trás do *Big Data*, apelidadas de “5 V’s”:

Figura 1 – Cinco características por trás do conceito “*Big Data*”



Fonte: Gerada por Gemini, em 24 jul. 2026, com base em Zanela *et al.*, (2015), Marquesone (2016) e Souza *et al.* (2018).

Os 5 V's revelam o verdadeiro potencial do *Big Data* ao não residir apenas no acúmulo massivo de registros, mas, sim, na transformação desses em conhecimento/inteligência. Ao integrar de forma equilibrada o volume, a variedade e a velocidade, garantindo a veracidade dos dados, o *Big Data* consolida-se como pilar essencial para mitigar inconsistências (ao lidar com inúmeros dados de variadas fontes), priorizar informações relevantes (ao armazenar/processar dados que carecem de valor para determinada análise) e viabilizar modelos analíticos avançados (sem as limitações das ferramentas convencionais), servindo para gerar *insights* preditivos eficientes e assegurar tomadas de decisão ágeis e com maior probabilidade de sucesso (Marquesone, 2016; ICAO, 2025b).

A integração de tecnologias como ML, IA e *Big Data* representam, além de um avanço computacional, excelentes oportunidades de aprimoramento para a atual fase de amadurecimento da aviação e a área de análise de dados (Mcfadden, 1999; Amalberti, 2001; Demir *et al.*, 2024; Lee *et al.*, 2020). O entendimento de sua

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

importância requer uma análise sobre como a gestão de riscos evoluiu ao longo das décadas, para, então, compreender como o setor migrou de uma visão focada apenas na falha mecânica para um sistema de 'monitoramento total' e preventivo.

### 3 HISTÓRICO DA PREVENÇÃO DE ACIDENTES NA INDÚSTRIA DA AVIAÇÃO

A segurança na aviação é definida como o estado em que os riscos associados às suas atividades são reduzidos e controlados a um nível aceitável (ICAO, 2018). Historicamente, a indústria alcançou recordes significativos, transformando o que era inicialmente um “sistema frágil”, com taxas de acidentes por volta de um a cada 1 milhão de milhas voadas (Mackinac, 2003), para o primeiro sistema "ultrasseguro" da história dos transportes (Yeun, 2015) com a ocorrência de 0,16 acidentes fatais por milhão de voos, na média dos últimos 5 anos (IATA, 2025).

Tais avanços são alcançados não somente pelas evoluções tecnológicas trazidas – como a introdução de sistemas de alerta e consciência situacional (EGPWS/TCAS), e a confiabilidade e redundância de componentes críticos – mas também por meio de processos de gerenciamento dos riscos, com identificação de perigos e a implementação de defesas que visam mitigar a probabilidade e a severidade de consequências adversas (Yeun, 2015).

A trajetória dessa evolução pode ser compreendida através das periodizações propostas por Krichevsky (2023) e pelas *Safety Eras* (eras de segurança), apresentadas por Reason (1997) e no Documento 9859 da ICAO (2018), sendo dividida em três estágios principais:

- a. O primeiro estágio, abrangendo as décadas de 10 a 40 do século XX, focou na geração de ideias, tecnologias e sistemas básicos de voo. Este período coincide com a "era técnica" descrita pela ICAO, caracterizada como um momento no qual as deficiências de segurança eram diretamente relacionadas a falhas tecnológicas, período em que a segurança dependia do gerenciamento de risco individual e de treinamentos voltados, especificamente, para a pilotagem em caso das recorrentes falhas estruturais, perdas de potência, etc. (Yeun, 2015);

- b. No segundo estágio, situado entre as décadas de 50 e 80, estabeleceram-se os sistemas nacionais e internacionais de segurança, além do fortalecimento da pesquisa científica e da formação de pessoal voltado à área da segurança (Krichevsky, 2023). A partir de 1970, pela linha do tempo da ICAO, a aviação ingressou na "era humana", na qual, devido à evolução tecnológica, o número reduzido de acidentes passou a ser relacionado aos fatores humanos e não mais as falhas técnicas. Esta fase foi marcada pela compreensão de que o erro humano, embora manifestado na ponta da operação, era frequentemente induzido por falhas inerentes a um ambiente complexo (*complex environment*). Exemplos dessas falhas incluem deficiências na interface homem-máquina, processos de comunicação ineficazes, ambiguidade de procedimentos e pressões operacionais que degradam a tomada de decisão (Reason, 1997; ICAO, 2018);
- c. Atualmente, a indústria vive o terceiro estágio da periodização de Krichevsky (2023), iniciado na década de 90, com foco no desenvolvimento de sistemas de gestão ativa e novas tecnologias de monitoramento. Esta é a 'era organizacional', onde a aviação passou a ser considerada como um sistema "ultrasseguro" (Amalberti, 2001), que experimenta 0,16 falhas catastróficas a cada 1 milhão de ciclos de produção (IATA, 2025). O pilar desta era é o Sistema de Gerenciamento da Segurança Operacional (SGSO), que adota uma abordagem de gestão baseada na coleta e análise rotineira de dados operacionais. Essa evolução consolida a transição de uma postura reativa para métodos proativos, permitindo que as organizações monitorem os riscos e tendências de segurança (*safety trends*).

Embora a consolidação prática dessas metodologias seja contemporânea, a fundamentação teórica para se trabalhar a segurança de maneira preditiva e baseada em dados já era discutida no final do século XX.

A nova estrutura para o estudo de erros do piloto concentra-se na identificação precoce de problemas de segurança e é mais proativa do que

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

Assim, a evolução histórica da segurança de voo demonstra que esta deixou de ser um atributo puramente técnico para se tornar um processo organizacional dinâmico e sistêmico. Esse avanço exige que as regulamentações acompanhem a complexidade tecnológica atual, transformando conceitos, inicialmente, teóricos/acadêmicos em recomendações e, posteriormente, normas regulamentares, conforme apresentado no capítulo seguinte.

A gestão da segurança na aviação civil internacional é regida pelo Anexo 19 da ICAO, intitulado *Safety Management*, que consolida os SARPs (*Standards and Recommended Practices*) como a base para a padronização global. Este documento apresenta normas/padrões internacionais gerais e superficiais sobre determinada área da aviação, neste caso, gestão da segurança (ICAO, 2025a). A partir deste Anexo, outras normas e guias são estabelecidos para um maior detalhamento do assunto em questão, como o DOC 9859 (*Safety Management Manual*); e o DOC



**Revista Brasileira de Aviação Civil & Ciências Aeronáuticas**

**CREA-SC**

10159 (*Safety Intelligence Manual*). No que tange os objetivos desta pesquisa, destacam-se aqui algumas normas, definidas no Anexo 19, que colaboram para a explicação dos documentos 9859 e 10159;

3.1.1 Estados devem estabelecer e gerenciar um Programa de Segurança de Estado (SSP) e prover uma descrição do sistema. Nota. A orientação para o desenvolvimento deste programa é apresentada no Doc. 9859.

3.3.4.1 Os Estados devem estabelecer e manter um processo para identificar perigos em nível estadual a partir de dados e informações de segurança coletados." 5.1.1 Recomendação. Os Estados devem estabelecer uma estratégia para o desenvolvimento de inteligência de segurança que apoie a gestão da segurança e a tomada de decisões.

Nota. Orientações relacionadas à estratégia para o desenvolvimento de inteligência de segurança estão contidas no *Safety Intelligence Manual*.

5.2.1 Os Estados devem estabelecer um sistema de coleta e processamento de dados de segurança (SDCPS) composto por uma série de processos e esquemas integrados para capturar, armazenar, agregar, processar e permitir a análise de dados e informações de segurança. Nota. Orientações relacionadas a um SDCPS estão contidas no *Safety Intelligence Manual* (ICAO, 2025a, tradução própria).

Os Estados, então, assumem o compromisso de estabelecer e gerir um Programa de Segurança de Estado (SSP) (3.1.1), que deve ser suportado por processos de identificação de perigos em nível nacional (3.3.4.1). Para viabilizar essa gestão baseada em evidências, se exige a criação de um Sistema de Coleta e Processamento de Dados de Segurança (SDCPS) (5.2.1), fazendo referência ao entendimento comum do processo da análise de dados, iniciando com a captura e armazenamento, chegando ao processamento e análise desses dados/informações, nesse caso relacionados à segurança (*safety data*) (ICAO, 2025b).

Entretanto, destaca-se que, embora essa coleta e processamento de dados sejam normas obrigatórias, o desenvolvimento de uma estratégia de *Safety Intelligence* é, ainda, classificado como uma recomendação (ICAO, 2025a), conforme indicado no item 5.1.1. Isso sugere que, embora a indústria já deva coletar e processar dados, a transição para uma análise mais avançada e preditiva — que suporte, efetivamente, a tomada de decisão complexa — ainda representa um estágio de maturidade desejável, mas não impositivo. Pode-se explicar o fato da atual classificação como recomendação, também, pela recém introdução do DOC 10159 (2025), que, só então, apresenta as instruções para operacionalizar o *Safety Intelligence*.

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

No que se refere ao cenário nacional, a operacionalização das diretrizes internacionais ocorre, inicialmente, através do Programa de Segurança Operacional Brasileiro (PSO-BR), apresentado pela Agência Nacional de Aviação Civil (ANAC) e o Comando da Aeronáutica (COMAER), onde fica determinado que: “Art. 16. A ANAC e o COMAER devem estabelecer mecanismos para: 1. A coleta de dados e informações de segurança operacional, voluntárias e mandatórias (Brasil, 2017)”. Esta base normativa é, novamente, apresentada pelo Programa de Segurança Operacional Específico da ANAC (PSOE-ANAC):

Art. 74. A ANAC deve estabelecer os meios e mecanismos necessários para a coleta, armazenamento e utilização de dados e informações de segurança operacional oriundos tanto de seu ambiente interno quanto de seu ambiente externo, que constituem as entradas de seus processos da garantia da segurança operacional (ANAC, 2015).

No escopo dos operadores de serviços aéreos públicos, regidos pelo RBAC 121 (ANAC, 2026), a operacionalização destes requisitos é determinada por guias específicos, como a IS 119-002 (ANAC, 2012), que fornece as diretrizes para a elaboração do Sistema de Gerenciamento da Segurança Operacional (SGSO). Segundo esta Instrução Suplementar;

O Gestor Responsável deve apresentar o processo formal desenvolvido, e como pretende mantê-lo atualizado, para coletar, registrar, atuar e gerar retroalimentação acerca dos perigos nas operações, em uma combinação dos seguintes métodos de aquisição de dados: a) reativos; b) preventivos; e c) preditivos (ANAC, 2012, site).

Nesta trajetória de evolução da prevenção acidentes no cenário nacional, um marco recente é o lançamento do Portal Único de Notificação, com entrada em vigor em 2023, que, conforme apresentado pela Agência (ANAC, 2024), representa o primeiro passo do Brasil em direção ao desenvolvimento de inteligência de segurança, focando, justamente, na inicial coleta de dados em larga escala para posteriores processamentos e análises. Neste sistema, são coletadas informações sobre uma vasta gama de ocorrências que impactam a segurança da aviação civil, permitindo o reporte de perigos, riscos e eventos específicos de forma categorizada, como a notificação de acidentes e incidentes, eventos de fauna, drones, raio laser atividades baloieira, dentre outros.

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

O portal também integra diferentes canais para reportes, como o RCSV (Relato de Prevenção do CENIPA), o *Air Safety Report*, focado em reportes voluntários no âmbito do controle do espaço aéreo, além do Programa de Notificação de Desvios da ANAC, voltado para denúncias de irregularidades nos serviços e operadores regulados pela agência. Essa estrutura unificada centraliza e facilita a coleta de dados, fornecendo a “matéria-prima” necessária para a futura implementação de processos de inteligência e análise preditiva.

## 5 MÉTODO

O objetivo geral deste trabalho é contextualizar o processo de análise de dados na indústria da aviação, a partir das diretrizes trazidas pelo novo DOC 10159 da ICAO (*Safety Intelligence*), analisando a evolução normativa dos regulamentos e algumas aplicações práticas existentes na indústria. Para atingir este objetivo, este trabalho caracteriza-se como uma pesquisa qualitativa de natureza exploratória, visando identificar e analisar as principais ferramentas e métodos de análise de dados, com foco na segurança de voo, conforme as diretrizes do DOC 10159 da ICAO, que trata do tema “*Safety Intelligence*”. Como entendimentos definidos para este estudo, a pesquisa qualitativa busca a tradução de fenômenos observados e a atribuição de significados experimentais, que visam identificar os fatores-chave na ocorrência dos fenômenos estudados; enquanto a abordagem exploratória visa proporcionar uma visão geral e maior familiaridade com o tema, nesse caso, pouco discutido no meio acadêmico, visando desenvolver e clarificar conceitos (Gil, 2022; Sampieri *et al.*, 2013; Cecília, 2001).

Como técnica primária para a obtenção das informações para a análise proposta, se utilizou a “pesquisa bibliográfica”, a qual se define como uma investigação elaborada a partir de material já publicado, visando colocar o pesquisador em contato direto com o que já existe escrito sobre o assunto da pesquisa (Sousa *et al.*, 2021).

Para esta estratégia de pesquisa bibliográfica se utilizou também a técnica de “análise documental” (Given, 2008), a qual se conceitua como um procedimento

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

sistemático para revisar ou avaliar documentos específicos, requerendo que os dados sejam examinados e interpretados a fim de extrair significado, obter compreensão e desenvolver conhecimento empírico (Bowen, 2009). Como estratégia na busca das informações que serão utilizadas na análise posterior, os materiais foram divididos nas seguintes fontes:

- a. Regulamentos aeronáuticos nacionais e internacionais: busca de regulamentos voltados para a área de *safety* e análise de dados, nas bases de dados da ICAO e da ANAC. Foram então selecionados os seguintes materiais:
  - ICAO: novo DOC 10159 da ICAO (2025); DOC 9859 (2018) e o Anexo 19 (2025). Esta etapa permitiu a contextualização teórica necessária para a posterior identificação de aplicações práticas dos conceitos de *Safety Intelligence*;
  - ANAC: PSO BR (2017), PSOE (2015), RBAC 121 (2026), IS119-002 (2012), além do Painel de *Safety Intelligence* apresentado no Digital Week da ANAC (ANAC, 2024).
- b. Estudos acadêmicos em bases de dados: busca de estudos voltados para as conceituações de ML, Análise de dados, IA e demais necessários para referenciar conceitos dos regulamentos e normas, além daqueles voltados para explicação das aplicações práticas:
  - As buscas foram conduzidas na base de dados Google Scholar e nos anais do XXII Simpósio de Transporte Aéreo (SITRAER)<sup>1</sup>, mediante busca livre com os termos, em língua inglesa – *Aviation AND ("Machine Learning" OR "datadriven" OR algorithm\*) AND ("Data Analysis" OR predictive OR forecasting)* – selecionados por sua conexão com a aviação e análise de dados voltada à predição de cenários.

<sup>1</sup>A escolha dos anais do SITRAER como base de dados complementar justifica-se pela relevância do evento como fórum de debate técnico-científico sobre o setor aeroespacial e de transporte aéreo no cenário nacional. Além disso, os anais do evento apresentam um panorama atualizado sobre a segurança operacional e a inovação tecnológica no ano de 2025, permitindo mapear os projetos e as aplicações práticas desenvolvidas especificamente dentro da realidade da aviação brasileira.

Na base de dados *Google Scholar*, obteve-se cerca de 113.000 resultados, enquanto nos anais SITRAER, obteve-se apenas um resultado.

Diante do elevado número de documentos na base *Google Scholar*, inviável para uma revisão qualitativa integral, a triagem foi conduzida sobre as 400 primeiras publicações ordenadas por algoritmo de relevância da própria plataforma. Como critério de exclusão adicional, para o refinamento dessa amostra, foram descartados os trabalhos voltados ao gerenciamento de tráfego aéreo (ATM), *Advanced Air Mobility* (AAM), manutenção preditiva, gestão de infraestrutura aeroportuária e previsão de atrasos comerciais.

A partir desse universo filtrado, a busca concentrou-se em pesquisas que atendessem a dois requisitos concomitantes: (I) abordassem os fatores de risco e os desafios contemporâneos da aviação determinados por órgãos reguladores internacionais em diretrizes globais — especificamente o *Global Aviation Safety Plan* (GASP) da ICAO e o anuário da Associação Internacional de Transporte Aéreo (IATA) — e (II) apresentassem o desenvolvimento de modelos preditivos cuja métrica de acurácia ou confiabilidade do sistema fosse superior a 90%.

A aplicação desses critérios, somada a necessidade de manter a concisão e a extensão deste trabalho, delimitou a seleção final de cinco artigos para compor as unidades de análise da pesquisa, não visando um esgotamento da base de dados, mas sim a construção de uma amostra de casos típicos, onde o objetivo reside na riqueza e na qualidade da informação, abdicando-se da quantidade (Sampieri *et al.*, 2013), combinada à abordagem de amostras conceituais, na qual o pesquisador cria amostras de casos que o ajudem a compreender determinado conceito, ou seja, as unidades são escolhidas pois possuem atributos que contribuem para o desenvolvimento da teoria. (Sampieri *et al.*, 2013).

Estes estudos escolhidos abrangem as possibilidades do uso de ML na aviação contemporânea, cobrindo eixos distintos como a previsão meteorológica, o gerenciamento de fadiga, processamento de dados de voo e a detecção de interferências em sistemas de navegação por satélite. Eles abordam sistemas de ML treinados com dados de voos passados, tanto daqueles rotineiros que ocorreram

sem intercorrências, quanto aqueles em que determinado evento estudado aconteceu (arremetida, baixo desempenho dos motores, turbulência,...):

Quadro 1 – Estudos selecionados para análise das aplicações práticas

| Área de Aplicação | Estudo / Projeto                     | Foco da Prevenção                                         |
|-------------------|--------------------------------------|-----------------------------------------------------------|
| Meteorologia      | MUÑOZ-ESPARZA <i>et al.</i> , (2020) | Previsão de turbulência em níveis superiores.             |
| Navegação         | MOURA; GARCIA; LEGG (2026)           | Minimização de riscos de interferência em GNSS.           |
| Engenharia        | KURT (2024)                          | Monitoramento de desempenho de motores na decolagem.      |
| Operações de Voo  | MISRA (2021)                         | Alertas em tempo real para aproximações desestabilizadas. |
| Fatores Humanos   | SEAH <i>et al.</i> , (2021)          | Gestão de risco ocupacional ligado à fadiga.              |

Fonte: os Autores (2026).

Todos os estudos selecionados serão analisados por meio da técnica de Análise de Conteúdo de Bardin (2016), definida como uma técnica de análise de dados qualitativos que permite interpretar vários tipos de materiais coletados:

Um conjunto de instrumentos metodológicos cada vez mais sutis em constante aperfeiçoamento, que se aplicam a 'discursos' [...] extremamente diversificados. O fator comum dessas técnicas [...] é uma hermenêutica controlada, baseada na dedução: a inferência (Bardin, 2016).

O autor estrutura esta técnica em três etapas: a pré-análise, que se resume às ações de coleta e filtragem dos materiais; a exploração do material; e a etapa do tratamento dos resultados e interpretação, a qual é rotulada pelo autor como a fase da inferência controlada, onde o autor deve fazer as associações dos assuntos coletados, com categorias definidas, para o desenvolvimento das argumentações, objetivando à solução da questão de pesquisa (Bardin, 2016). Para a segunda etapa definida por Bardin (2016), a partir da questão de pesquisa definida neste estudo, as seguintes categorias foram identificadas, e serão utilizados para na seção de análise de dados:

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

- a. Evolução regulatória da segurança da aviação;
- b. Ferramentas de análise de dados utilizadas na prevenção de acidentes.

## 6 EVOLUÇÃO REGULATÓRIA DA SEGURANÇA DA AVIAÇÃO

A transição da gestão de segurança reativa para a proativa, impulsionada, principalmente, pela modelagem preditiva, tem se mostrado, não somente como o novo objetivo dos operadores aéreos, mas, também, como o novo enfoque regulatório. Neste contexto, a organização internacional de aviação civil (ICAO), vem desenvolvendo o conceito de *Safety Intelligence* com a publicação do novo documento 10159, 2025, que traz instruções mais aprofundadas sobre o trabalho com e uso de dados para promover a segurança operacional, abordados de forma mais superficial no Anexo 19 e no 9859 – Safety Management System (SMS).

Além do direcionamento apontado por Mcfadden (1999), o próprio DOC 9859, corrobora a necessidade dessa mudança de paradigma ao focar no mapeamento preventivo de ameaças. Em suas diretrizes sobre identificação e priorização de perigos, o manual estabelece formalmente que:

2.5.2.5 Hazards exist at all levels in the organization and are detectable through many sources. The goal is to proactively identify hazards before they lead to accidents, incidents or other safety-related occurrences (ICAO, 2018).

Portanto, a transição para um modelo de segurança preditiva representa o estágio mais avançado de um processo de amadurecimento que busca identificar e mitigar perigos ainda não manifestados no ambiente operacional. Embora essa visão proativa já estivesse fundamentada em discussões acadêmicas e iniciativas pioneiras da indústria há décadas, sua consolidação definitiva no cenário global dependia da adequação desses conceitos em marcos regulatórios pelas agências reguladoras. É nesse cenário que os órgãos reguladores assumem o papel de converter a teoria em diretrizes práticas, através da análise da evolução normativa e do papel central do novo manual de *Safety Intelligence* da ICAO.

A constante evolução tecnológica e a crescente complexidade das operações aéreas exigem que os regulamentos se atualizem para manter a aviação em seu

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

patamar “ultrasseguro”. O lançamento do DOC 10159, em 2025, materializa esse esforço, estabelecendo diretrizes para transformar grandes volumes de dados operacionais em conhecimento preditivo acionável. Neste quesito, a nova publicação atua como um aprofundamento do que já era previsto em documentos anteriores, como Anexo 19 e o DOC 9859, preenchendo lacunas sobre o papel dos dados na tomada de decisão, governança, taxonomia e processamento destas informações.

Em se tratando desta evolução normativa, percebe-se que algumas atualizações/alterações estão presentes, por exemplo, no que tange as fontes de dados de segurança (*source safety data*) e métodos analíticos (*types of analysis*), visando, a adaptação à realidade tecnológica e operacional contemporânea. Destacam-se as seguintes alterações:

- a. A integração de dados provenientes de sistemas de aeronaves remotamente pilotadas (RPAS/UAS *Remotely Piloted Aircraft System/unmanned aircraft system*), refletindo a necessidade de gerenciar o risco dessa nova vertente do tráfego aéreo;
- b. Transição na terminologia dos registros internos, que evoluem de "registros de avaliação de risco" para "registros de perigos e riscos" (*Risk/hazard register*), dando destaque ao perigo antes de sua avaliação(risco) e posterior mitigação;
- c. Incorporações de categorias mais específicas e especialmente críticas para a segurança operacional, como relatos de colisões com fauna, reportes de condições de pista (importante, considerando excursões de pista como o acidente mais recorrente atualmente (ICAO, 2025c)) e o uso de dados de vigilância automática (ADS-B).

No que diz respeito a evolução dos métodos analíticos (*types of analysis*), a comparação entre o Doc 9859 (2018) e o Doc 10159 (2025) revela uma transição de uma estatística puramente inferencial para uma abordagem mais avançada da ciência de dados, visto que, enquanto o documento anterior se limitava às análises Descritiva, Inferencial e Preditiva, a nova normativa de 2025 expande essa taxonomia para os níveis Descritivo, Diagnóstico, Preditivo e Prescritivo. Esta mudança introduz a análise diagnóstica, que visa compreender as causas e

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

conexões de eventos passados (“Por que isso aconteceu?”), e a análise prescritiva, que utiliza simulações para recomendar as melhores ações a serem tomadas para se chegar a um determinado resultado (“O que deve ser feito?”).

O destaque do novo documento é o reconhecimento formal de que modelos preditivos podem ser amplamente potencializados por tecnologias como ML e IA, que possibilitam o trabalho com maiores volumes de dados e a identificação de relações mais complexas entre estes, colaborando, então, com a otimização da tomada de decisão e identificação de riscos.

Apesar disso, o termo “*Artificial Intelligence (AI)*” é pouco mencionado ao longo do documento, aparecendo apenas duas vezes em todo o texto, demonstrando que as diretrizes da ICAO ainda se encontram em um estágio inicial de absorção dessa tecnologia, evidenciando que novos documentos ou futuras atualizações normativas precisarão abordar o tema de forma mais profunda e detalhada para acompanhar o ritmo de inovação da indústria.

Esse distanciamento temporal evidencia que a comunidade científica e a indústria operam em um estágio de desenvolvimento mais avançado em relação às publicações oficiais do órgão regulador internacional, onde enquanto a ICAO consolidou essas diretrizes apenas em 2025 com o DOC 10159, estudos práticos aplicando tais modelos no setor de tráfego aéreo (Nogami; Nakasuka; Tanabe, 1996), meteorologia (Wolfson *et al.*, 1994), dinâmica de voo (Iliff; Maine, 1976) e fatores humanos (Rault, 1976) já eram desenvolvidos e testados entre 29 e 49 anos antes de qualquer formalização normativa global. Portanto, a consolidação tardia promovida pela ICAO não inaugura o uso de Dados, ML e IA na aviação, mas institucionaliza uma realidade técnica preexistente na qual a iniciativa privada e a academia já extraíam inteligência de dados brutos para mitigar riscos operacionais há décadas.

Avaliando o cenário brasileiro, conforme mencionado na seção 4, percebe-se que, apesar destes avanços regulamentares internacionais, o termo *Safety Intelligence* (ou inteligência de segurança) ainda não está formalmente consolidado/definido nos documentos normativos vigentes, apesar de já ganhar destaque em fóruns de inovação, sendo discutido em painéis da agência, como

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

mentionado anteriormente. Nestas ocasiões, a autoridade aeronáutica apresentou as suas primeiras visões sobre o uso de tecnologias avançadas para o suporte à decisão, indicando que, embora a inteligência de dados ainda não seja uma exigência regulatória, ela já se posiciona como a próxima evolução para a sustentação dos níveis “ultrasseguros” na aviação.

Neste quesito, percebe-se que as atenções e os esforços institucionais ainda se concentram majoritariamente na etapa de captação e centralização dos dados operacionais, em detrimento do seu efetivo processamento e da geração automatizada de inteligência preditiva. Um reflexo dessa maturidade regulatória é a implementação do "Portal Único de Notificação", em 2023, uma inovação recente que visa, fundamentalmente, otimizar a coleta e ampliar o volume de ocorrências reportadas para, em um segundo momento, iniciar as análises estatísticas e preditivas mais robustas. Assim, evidencia-se uma lacuna entre o potencial das ferramentas tecnológicas disponíveis e a prática normativa atual, que, no cenário brasileiro, ainda prioriza o abastecimento de bancos de dados antes de avançar na conversão dessas informações em *Safety Intelligence*.

#### 6.1 LACUNAS PRÁTICAS NAS PUBLICAÇÕES SOBRE SAFETY INTELLIGENCE E A NECESSIDADE DE REFERENCIAIS EXTERNOS

Embora o novo documento seja um avanço institucional necessário para apresentar o tema *Safety Intelligence* aos estados membros e gestores de segurança, ele permanece em um nível conceitual básico para um cientista de dados. Em outras palavras, o documento foca no "quê" fazer, mas não no "como" técnico mais aprofundado (algoritmos, tratamento dos dados, lidar com grandes volumes...), o que ficará a cargo de um especialista da área da ciência de dados. Este fato pode ser visto, por exemplo, quando o documento comenta sobre os tipos de análises, onde ele apresenta quais análises podem ser feitas, mas não indica exatamente como fazê-las (com qual software, com quais dados, com qual modelo de *Machine Learning*...).

Sobretudo, esta prática faz sentido, afinal, o objetivo deste documento não é ensinar a fundo processos específicos da análise de dados, o que exigiria uma

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

imersão em competências alheias ao escopo da formação aeronáutica, em disciplinas como a estatística matemática, a engenharia de *software*, a modelagem estatística, dentre outras, cujas fazem parte, especificamente, da formação de um cientista de dados, mas, sim, o documento visa apresentar o tema e algumas possibilidades a comunidade aeronáutica. Logo, para a aplicação do previsto pelo documento, outras fontes de consulta específicas da área são necessárias. Nesse sentido, o documento 10159 vai apresentar, por exemplo, onde o cientista de dados, possivelmente de fora da aviação, pode coletar dados, enquanto este, com seu conhecimento na sua área, vai determinar em qual banco de dados é mais fácil de armazenar essas informações, qual software melhor se encaixa no tipo de análise que se pretende fazer, quantos dados serão necessários, dentre outros.

Contudo, visando possibilitar e facilitar a atuação desse profissional no meio aeronáutico, entende-se que a inclusão de exemplos de aplicações das técnicas analíticas em cenários reais é um elemento crucial. Afinal, a formação do cientista de dados não engloba conceitos intrínsecos da aviação, como a dinâmica de voo, interpretação de parâmetros dos gravadores de voo ou questões relacionadas a fatores humanos na operação. Sem um direcionamento contextualizado que una a área do cientista de dados ao ambiente operacional da aviação, o desenvolvimento de ferramentas, sejam descritivas ou preditivas, torna-se um desafio entre os setores de análise/tecnologia, que possuem a expertise analítica e o domínio de algoritmos, e os gestores de segurança, que possuem o conhecimento operacional e a sensibilidade ao risco.

É nesse ponto que se evidencia uma lacuna da nova diretriz, onde o DOC 10159 carece de maneiras/metodologias para efetivar a implementação prática do que ele prevê, focando em instruir sobre os mecanismos gerais de coleta de dados (*data collection*), governança de dados (*data governance*), taxonomia dos dados, compartilhamento de informações e objetivos do *Safety Intelligence*. Neste quesito, apesar do manual apresentar pouco mais de 70 locais para coleta dos dados (reportes anuais de segurança, *flight data recorders*, auditorias internas, históricos de treinamento, colisões com fauna, meteorologia, fator de atraso dos voos, etc.) ele falha ao não ilustrar cenários reais de como esses inúmeros dados, quando

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

comparados com determinados outros, podem disparar alertas de segurança e gerar ações preventivas. Essa superficialidade impede que organizações de diferentes portes e níveis de maturidade digital compreendam o real valor agregado da transição preditiva.

Diante disso, a ausência de guias práticos e de exemplos apresentado "como fazer", obriga a comunidade aeronáutica, os órgãos reguladores e as empresas aéreas a buscar metodologias na academia, em teses de engenharia ou em *papers* técnicos externos para operacionalizar a teoria proposta pela ICAO. Consequentemente, para que o conceito de *Safety Intelligence* saia do campo das recomendações regulamentares e se converta em barreiras contra acidentes, a indústria deve atuar como a verdadeira desenvolvedora dos métodos, buscando em publicações científicas independentes as aplicações práticas que os manuais oficiais ainda não fornecem.

Apesar da atual falta de exemplos na regulamentação, a ICAO já aborda o problema com a criação da aba de exemplos relacionados ao DOC 10159 em seu site (ICAO, 2025d), embora se destaca que, dentre os 24 resultados, nada se fala especificamente sobre determinadas análises que algum país membro ou prestador de serviço de aviação civil (PSAC) esteja conduzindo, mas, sim, encontram-se vários projetos sobre sistemas de reportes voluntários e mandatórios (para coleta de dados), taxonomias padronizadas dos dados e, um exemplo, que parte da agência Colombiana, apresentando seu sistema centralizado para a coleta e visualização de dados de segurança, permitindo análises de segurança mais completas (Aerocivil, 2024) – esta plataforma foi nomeada de “IRIS” (*Integrador de Reportes e Información de Seguridad*).

## 7 FERRAMENTAS DA ANÁLISE DE DADOS UTILIZADAS NA PREVENÇÃO DE ACIDENTES AERONÁUTICOS

Nesta seção, serão apresentadas aplicações práticas de *Machine Learning* e ferramentas de análise de dados, com base nos estudos selecionados, descritos no método, visando demonstrar a aplicabilidade desta ciência nas mais variadas áreas, além de suas contribuições para a segurança de voo.

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

Um primeiro exemplo demonstra a aplicação de *Machine Learning* na predição de turbulência em altos níveis fator que a ICAO apresenta como uma das preocupações operacionais da atualidade no GASP (*Global Aviation Safety Plan*) 2026~2028, onde o encontro com turbulência (*Turbulence Encounter — TURB*) é categorizado como um risco global, embora não da categoria principal de “alto risco”, mas da secundária (“*other global risk categories of occurrences*”), por se tratar de um fator listado entre os acidentes e incidentes graves mais frequentes nas operações aéreas globais (Muñoz-Esparza *et al.*, 2020).

O estudo propõe o desenvolvimento de um modelo preditivo baseado em ML para estimar a intensidade da turbulência em altitudes de cruzeiro. O treinamento deste sistema envolveu o processamento de dados acumulados ao longo de 16 meses, gerando, com estes, simulações meteorológicas focadas em previsões de curto prazo (6 horas de antecedência). Para validar a precisão do modelo gerado, as predições foram cruzadas com 2,4 milhões de dados reais medidos por sensores a bordo de aeronaves das companhias parceiras *United*, *Delta* e *Southwest Airlines* e constatou-se que o sistema fora superior a predições meteorológicas tradicionais, com o principal ganho operacional concentrando-se na faixa de turbulências leves, onde o novo modelo reduziu falsas indicações pela metade e eliminou a tendência do sistema antigo de superestimar a intensidade das condições atmosféricas, alcançando uma acurácia de 91% na detecção de turbulência moderada, contra 79% do modelo convencional (Muñoz *et al.*, 2020).

O segundo exemplo escolhido aborda a aplicação de ML em dados de ADS-B para mitigar os riscos de interferência nos sistemas de navegação por satélite (Moura; Garcia; Legg, 2026), fator apontado pelas agências como uma ameaça complexa da atualidade, onde tanto o relatório anual da IATA (2025) quanto o GASP (2026 ~2028) citam uma apreensão devido ao crescimento de interrupções, bloqueios (*jamming*) e clonagens de sinal (*spoofing*), onde as falhas e degradações provocadas por estas se apresentam como fator contribuinte para as principais categorias de alto risco da aviação global.

Na prática, essas interferências degradam a consciência situacional dos pilotos, onde o *jamming* pode causar a perda completa do GNSS e o *spoofing*, ao

induzir dados errôneos, possivelmente indetectáveis pelos sistemas da aeronave, pode provocar curvas inesperadas com o piloto automático engajado e desvios no *navigation display* (AIRBUS, 2026). Diante disso, sistemas de vigilância e de comunicação tornam-se indisponíveis ou geram falsos alertas, afetando funções como o TAWS (*Terrain Avoidance and Warning System*) – para alertas de proximidade com o solo, o ROPS (*Runway Over run Prevention System*) – para alertas de comprimento de pista insuficiente, ADS-B (*Automatic Dependent Surveillance–Broadcast*) - para transmissão de dados de vigilância, dentre outros (Airbus, 2026).

O trabalho propõe um sistema para otimizar a identificação da área de atuação dessas anomalias nos sinais de satélite a partir dos dados de monitoramento/vigilância de voo (ADSB). O modelo proposto vai além das ferramentas convencionais de integridade que costumam falhar diante de bloqueios intermitentes ou muito localizados (Moura; Garcia; Legg, 2026).

A otimização foi alcançada treinando e validando o modelo com base no histórico de dados de eventos de interferência ocorridos em 2024, analisando tanto o comportamento isolado de cada voo quanto o comportamento geográfico das aeronaves vizinhas nas imediações do aeroporto de Guarulhos. Os resultados práticos demonstraram que o algoritmo alcançou uma acurácia de 93%, ou seja, a cada 100 horas analisadas, o algoritmo classificou corretamente a situação (operação normal/interferência real) em 93 delas, registrando um índice de eficiência de 79,6% (métrica estatística que avalia a precisão e a sensibilidade do modelo) e um poder de discriminação de falhas de 95,8%, o que representa um avanço frente às metodologias tradicionais, as quais possuem um menor desempenho pois dependem de limites fixos de um único indicador de integridade, enquanto o novo modelo correlaciona simultaneamente anomalias de altitude, variações de posição geográfica e o comportamento coletivo das aeronaves na região para identificar a área exata sob interferência (Moura; Garcia; Legg, 2026), análises que se tornam possíveis devido a aplicação de ferramentas de análise mais modernas como, neste caso, o *Machine Learning*.

Um terceiro exemplo analisa a aplicação de ML voltada ao monitoramento do desempenho dos motores aeronáuticos (Turbofan) durante a fase de decolagem, Kurt (2024), classifica como um dos momentos mais críticos do voo, exigindo que os motores desempenhem a tração prevista. Embora o artigo original tenha como foco principal a quantificação e redução de emissões ambientais — um dos objetivos estratégicos da ICAO —, a capacidade de modelar com precisão o fluxo de combustível (*Fuel Flow - FF*) nessa fase da operação possui uma ligação direta com a segurança, onde flutuações ou a degradação desse parâmetro servem como precursores para falhas de componentes ou perdas de desempenho em momentos em que é pequena a margem para tomadas de decisão.

Para construir esse sistema preditivo, o estudo utilizou dados extraídos do Banco de Dados de Emissões de Motores Aeronáuticos (EEDB) da ICAO, consolidados entre os anos de 2019 e 2021 (Kurt, 2024). para treinar o modelo com parâmetros como o tipo do motor, razão de Bypass (*Bypass Ratio*), Temperatura, Pressão e Umidade ambiente, além dos dados de empuxo durante a decolagem, fluxo de ar e temperatura dos gases de exaustão. Com base no cruzamento dessas variáveis, os algoritmos conseguiram estimar o comportamento do *Fuel Flow* com grande precisão, onde os testes de validação demonstraram um coeficiente de 99,9%, ou seja, prevendo em praticamente todas as decolagens o valor do Fluxo de Combustível e suas variações, o que comprova a acurácia do sistema no mapeamento do consumo esperado para as variadas condições nesta fase do voo.

Contudo, observa-se uma limitação operacional na arquitetura desse modelo, pois como o algoritmo utiliza de parâmetros reais observados no motor (temperatura dos gases de exaustão, razão de pressão dos gases...) como variáveis de entrada para prever o fluxo de combustível, o sistema cria uma relação de dependência inversa, onde, usualmente, o Fuel Flow determina EGT (*Exhaust Gas Temperature*) e EPR (*Engine Pressure Ratio*), enquanto o estudo aborda a situação com EGT e EPR determinando o FF. Logo, em um cenário real de pane na unidade controladora de combustível (FCU) que, por exemplo, restrinja o fluxo de combustível, os sensores indicarão uma queda consequente na temperatura e na pressão dos gases do motor e, então, o modelo preditivo recalculará um fluxo de combustível proporcionalmente

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

menor, indicando falsamente que o motor está operando dentro do previsto. Sob essa ótica, o elevado coeficiente de determinação ( $R^2 = 99,9\%$ ) acaba atuando mais como um validador do funcionamento da FCU em motores saudáveis do que como um real diagnosticador de falhas mecânicas independentes. Assim, a criação e treinamento do modelo com seus respectivos gráficos de desempenho e testes, apresentam as capacidades e possibilidades de uso do ML. Essa mesma estrutura metodológica poderia ser replicada em outros conjuntos de dados, buscando descobrir outras correlações e informações possivelmente mais valiosas e robustas para a segurança operacional.

Um quarto exemplo aborda a aplicação de ML para a geração de alertas preditivos em tempo real contra aproximações desestabilizadas na aviação geral (Misra, 2021), evento classificado pela ICAO no GASP 2026–2028 como recorrente fator contribuinte para excursões de pista (*Runway Excursion — RE*). O artigo aborda o chamado "viés de expectativa de pouso" (*Landing Expectancy*), uma falha cognitiva que afeta a tomada de decisão do piloto e o impede de iniciar uma arremetida em momento oportuno, o que pode acarretar problemas durante a fase final do voo. Visando evitá-los, o estudo propõe a criação de uma barreira de defesa automatizada através de áudio sintético na cabine (*call-outs*), antecipando a instabilidade antes que o cenário se torne crítico (Misra, 2021).

Para treinar este modelo preditivo, os autores utilizaram dados de voos reais coletados através do programa de monitoramento de dados de voo de centros de instrução de aviação, onde o banco de dados foi estruturado a partir de informações extraídas dos cartões de memória de sistemas da avionica Garmin G1000, integrada das aeronaves Diamond DA42NG, com a coleta de dados abrangendo um período de 3 anos, totalizando o processamento de mais de 42.000 voos. No teste de validação final, o algoritmo alcançou uma acurácia de 95,4% na detecção antecipada das aproximações desestabilizadas, ou seja, em cada cem aproximações analisadas, o sistema classifica corretamente mais de 95 delas, mostrando-se uma ferramenta confiável para mitigar possíveis eventos de excursão de pista, *hard landings*, ou, mesmo, *Controlled Flight into Terrain* (CFIT) (Misra, 2021).

Um quinto exemplo direciona a análise de dados, desta vez sem ferramentas de ML, para o campo dos fatores humanos, focando na gestão do risco da fadiga de tripulantes (Seah *et al.*, 2021), novamente, apontada, no GASP 2026–2028, como um fator contribuinte frequente para ocorrências de colisão controlada contra o solo (CFIT), atuando na degradação da prontidão cognitiva, dos reflexos e da coordenação motora dos pilotos. O grande desafio para os Sistemas de Gerenciamento de Risco de Fadiga (FRMS) tradicionais sempre foi a dependência de relatos subjetivos dos tripulantes. Para solucionar essa lacuna, o artigo estudou a criação de um protocolo padronizado e matemático baseado em biomonitoramento ativo, realizado por meio de sensores de movimento e *smartphones* (para avaliar o histórico de sono e realizar testes de vigilância psicomotora), convertendo o estado fisiológico do piloto em dados quantificáveis.

A base de dados utilizada para estruturar e validar o estudo foi construída a partir da coleta de dados envolvendo 19 pilotos em voos de longa duração (média de 14,75 horas), onde concluiu-se que os algoritmos de triagem conseguiram prever o nível de degradação da atenção e dos tempos de reação dos pilotos na cabine. Além disso, o modelo proposto de biomonitoramento é tecnicamente viável e utiliza de instrumentos capazes de fornecer uma avaliação consistente, objetiva e confiável da fadiga e do desempenho de trabalho dos tripulantes, permitindo a formulação de recomendações de segurança operacionais eficazes (Seah *et al.*, 2021). Ao utilizar ferramentas de análises de dados, ML e IA para localizar interferências nos sinais de satélite, detectar aproximações desestabilizadas, quantificar estados fisiológicos, prever intensidade de turbulências e avaliar parâmetros de motores, demonstra-se que a inteligência de segurança (*Safety Intelligence*) não se limita aos específicos dados de voo, mas abrange toda a infraestrutura de suporte necessária para sustentar a aviação em seu patamar de sistema “ultrasseguro”.

## 7.1 CORRELAÇÃO COM OS CONCEITOS DO DOC 10159

Os cinco estudos materializam os níveis de análise de dados preconizados pelo DOC 10159, onde a análise descritiva, por exemplo, se relaciona aos

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

parâmetros dos motores *Turbofan* (Estudo 3), enquanto a análise destes para determinar o fluxo de combustível ilustra uma análise *diagnóstica*. Já a evolução para o estágio *preditivo* consolida-se na predição de curto prazo para regiões de turbulência (Estudo 1), demonstrando a capacidade dos algoritmos de estimar cenários futuros antes que os perigos se manifestem. Por fim, é atingido o *prescritivo* com o sistema de geração de alertas contra aproximações desestabilizadas no Diamond DA42 (Estudo 4); ao emitir alertas em tempo real ("Go-Around"), sistemas de ML e IA deixam de ser ferramentas informativas, passando a atuar como barreiras de proteção na cabine. Adicionalmente, os 5V's *Big Data* se apresentam nas pesquisas analisadas assim:

Figura 2 – Associações entre os estudos analisados e os "5V's"



Fonte: Gerada por Gemini, em 24 jul. 2026.

No que tange os *Dashboards* para tomada de decisão, o estudo que aborda o mapeamento de áreas sob interferência dos sinais de satélites (*jamming* e *spoofing*) ilustra a plotagem em tempo real das regiões de interferência sobre um mapa digital, caracterizando-se como um *Dashboard* interativo. Essa interface auxilia a consciência situacional, permitindo que contramedidas redefinindo rotas, mitigando o risco do ingresso na região afetada.

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

## 8 CONSIDERAÇÕES FINAIS

A análise do novo panorama normativo revela um descompasso entre a regulação e o estado da arte tecnológico, evidenciando que a indústria aeronáutica e a comunidade científica encontram-se significativamente à frente das publicações oficiais da ICAO, uma vez que, muito antes da promulgação do DOC 10159, em 2025, diversos projetos inovadores envolvendo algoritmos preditivos já estavam em curso e promovendo a segurança operacional nas operações aéreas.

Além disso, percebe-se uma falta de diretrizes mais específicas no que diz respeito ao uso da Inteligência Artificial e de seus potenciais analíticos, termo que é pouco mencionado no novo documento, ademais, o DOC 10159 carece de exemplos práticos da aplicação das ferramentas analíticas apresentadas, o que dificulta a atuação de um profissional da área de dados no setor aéreo. No que tange ao cenário brasileiro, estudos e projetos ainda se concentram na coleta e armazenamento de dados, enquanto as etapas de processamento e a efetiva transformação desses registros em inteligência permanecem pouco abordadas. Sobretudo, ressalta-se que a aplicação da *Safety Intelligence* ainda se reduz a uma recomendação regulamentar do Anexo 19, e não a um requisito mandatório.

Diante do exposto, o amadurecimento tecnológico se torna indispensável para aprimorar as métricas do setor, onde, as variadas aplicações práticas corroboram diretamente a mitigação preditiva de riscos operacionais. É por meio da transição para a cultura de dados e da consolidação dessas ferramentas computacionais avançadas, que a indústria conseguirá aproximar o modal aéreo do cenário proposto pela ICAO de zerar as fatalidades na aviação comercial após o ano de 2030. Futuros projetos podem abordar as dificuldades da implementação/gerenciamento de sistemas trazidas pelo *Safety Intelligence*, tendo-se como ponto de partida, alguns desafios trazidos pela Agência Colombiana de Aviação Civil (2023):

- a. Bancos de dados muito distribuídos, sem conexões entre si;
- b. Péssima qualidade dos dados (duplicados, incompletos e irregulares);
- c. Falta de mão de obra e conhecimento.

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

## REFERÊNCIAS

ACKOFF, R. From data to wisdom. **Journal of Applied Systems Analysis**, 16(1), 3–9.1989. Disponível em: <https://faculty.unq.edu/kmeltton/documents/datawisdom.pdf>

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). Instrução Suplementar - IS nº 119-002: Processo de certificação de operadores aéreos conduzidos segundo os RBAC nº 121 ou nº 135. 2012. Disponível em: <https://www.anac.gov.br/assuntos/legislacao/legislacao-1/iac-e-is/is/is-119-002>

\_\_\_\_\_. PSOE-ANAC: Programa de Segurança Operacional Específico da Agência Nacional de Aviação Civil. 2015. [https://www.gov.br/anac/pt-br/assuntos/seguranca-operacional/gerenciamento-daseguranca-operacional/arquivos/psoe\\_anac.pdf](https://www.gov.br/anac/pt-br/assuntos/seguranca-operacional/gerenciamento-daseguranca-operacional/arquivos/psoe_anac.pdf)

\_\_\_\_\_. Apostila do curso "Familiarização em SGSO". 2016.

\_\_\_\_\_. Digital Week ANAC - Tecnologias digitais para aprimorar a gestão de créditos. 2024. Disponível em: <https://www.youtube.com/watch?v=5f03ay3ATks>

\_\_\_\_\_. Regulamento Brasileiro de Aviação Civil (RBAC) nº 121: Operações de transporte aéreo público com aviões com grande capacidade. 2025. Disponível em: <https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-erbac/rbac/rbac-121>

AIRBUS. GNSS interference. **Safety First: The Airbus Flight Safety Magazine**, 1–12.2026. Disponível em: <https://safetyfirst.airbus.com/>

ALONGE, E. O., DUDO, F., & BABATUNDE, O. Utilizing advanced data analytics to boost revenue growth and operational efficiency in technology firms. **International Journal of Frontiers in Science and Technology Research**, 7(2), 39–59. 2024. Disponível em: <https://doi.org/10.53294/ijfstr.2024.7.2.0056>

ALPAYDIN, E. **Introduction to machine learning**. MIT Press.4th ed. 2020.

AMALBERTI, R. The paradoxes of almost totally safe transportation systems. **Safety Science**, 37(2-3), 109–126. 2001. Disponível em: <https://www.sciencedirect.com/science/article/pii/S092575350000045X>

BARDIN, L. **Análise de conteúdo** (ed. rev. e ampl.). Ed. 70. 2016.

BENTALEB, A., Toumlal, K., & Abouchabaka, J. Predicting aircraft engine failures using artificial intelligence. **International Journal of Advanced Computer Science and Applications**, 15(2). 2024. Disponível em: <https://thesai.org/Publications/ViewPaper?Volume=15&Issue=2&Code=IJACSA&SerialNo=95>

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

BOWEN, G. A. Document analysis as a qualitative research method. **Qualitative Research Journal**, 9(2), 27–40. 2009. Disponível em: <https://doi.org/10.3316/QRJ0902027>

BRASIL. Comando da Aeronáutica. **MCA 3-3: Manual de Prevenção do SIPAER**. CENIPA. 2012. Disponível em: <https://www2.fab.mil.br/cenipa/>

\_\_\_\_\_. Comando da Aeronáutica. **NSCA 3-17: Sistema de Reportes do SIPAER para a Aviação Civil Brasileira**. CENIPA. 2022. Disponível em: <https://www2.fab.mil.br/cenipa/>

\_\_\_\_\_. Ministério da Infraestrutura. **PSO-BR: Programa Nacional de Segurança Operacional**. Ministério da Infraestrutura. 2017. Disponível em: <https://www.gov.br/anac/ptbr/assuntos/seguranca-operacional/programas-de-segurancaoperacional/arquivos/PSOBR.pdf>

CECÍLIA, M. **Pesquisa social: Teoria, método e criatividade**. Vozes. 2001.

CHEN, R., & JIN, J. Detection of influential features of hard landing based on QAR data. Proceedings of the **3rd International Conference on Civil Aviation Safety and Information Technology (ICCASIT)**, 526–529. 2021. Disponível em: <https://ieeexplore.ieee.org/document/9633658>

CHUNG, S.-H., MA, H.-L., HANSEN, M., & CHOI, T.-M. Data science and analytics in aviation. **Transportation Research Part E: Logistics and Transportation Review**, 134, 2020. Disponível em: <https://doi.org/10.1016/j.tre.2020.101837>

COLÔMBIA. Unidad Administrativa Especial de Aeronáutica Civil. **Sharing and exchange of safety intelligence in Colombia – A first approach**. Aerocivil. 2024. Disponível em: <https://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/iris-integrador-dereportes-e-informacion-de-seguridad-operacional>

DATA CAMP. **What is data science?** Definition, examples, tools & more. 2023. Disponível em: <https://www.datacamp.com/blog/what-is-data-science-the-definitive-guide>. Acesso em: 20 out 2025.

DEMIR, G., MOSLEM, S., & DULEBA, S. Artificial intelligence in aviation safety: Systematic review and biometric analysis. **International Journal of Computational Intelligence Systems**, 17(1). 2024. Disponível em: <https://doi.org/10.1007/s44196-024-00671-w>

DOCUSIGN. **O que é algoritmo?** Como funciona, tipos e exemplos. 2025. Disponível em: <https://www.docuSign.com/pt-br/blog/o-que-e-algoritmo>. Acesso em: 25 fev 2026.

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

FAETERJ. **Desmistificando a programação em machine learning**. 2018. Disponível em: <https://www.faeterj-rio.edu.br/desmistificando-a-programacao-em-machine-learning/>. Acesso em: 01 out 2025.

FLIGHT SAFETY FOUNDATION (FSF). **Benefits of FOQA analysis**. 2016. Disponível em: [https://flightsafety.org/wp-content/uploads/2016/09/OFSH\\_english.pdf](https://flightsafety.org/wp-content/uploads/2016/09/OFSH_english.pdf) Acesso em: 08 nov 2025.

FORBES. **The data science revolution that's transforming aviation**. 2017. Disponível em: <https://www.forbes.com/sites/oliverwyman/2017/06/16/the-data-science-revolutiontransforming-aviation/> Acesso em: 13 out 2025.

FRAZZETTO, D., NIELSEN, T. D., PEDERSEN, T. B., & ŠALTENIS, S. Prescriptive analytics: A survey of emerging trends and technologies. **The VLDB Journal**, 28(4), 575–595. 2019. Disponível em: <https://doi.org/10.1007/s00778-019-00539-y>

GIL, Antonio Carlos. **Como Elaborar Projetos de Pesquisa**. 7. São Paulo: Atlas, 2022. Print.

GIVEN, L. M. (Ed.). **The Sage encyclopedia of qualitative research methods** (Vol. 1). SAGE Publications. 2008.

ILIFF, K. W., & MAINE, R. E. Practical aspects of using a maximum likelihood estimation method to extract stability and control derivatives from flight data. **NASA Technical Note** (TN D-8209). 1976. Disponível em: <https://ntrs.nasa.gov/citations/19760016184>

INTERNATIONAL CIVIL AVIATION ORGANIZATION (ICAO). **Doc 9859: Safety Management Manual (SMM)** (1. ed.). 2006. Disponível em: <https://elibrary.icao.int/>

\_\_\_\_\_. **IATA's annual review**. 2025. Disponível em: <https://www.iata.org/en/publications/annual-review/>

\_\_\_\_\_. **DOC 9859: Safety Management Manual (SMM)** (4. ed.). 2018. Disponível em <https://elibrary.icao.int/>

\_\_\_\_\_. **Annex 19 to the Convention on International Civil Aviation: Safety management** (3 ed.). 2025a. Disponível em: <https://elibrary.icao.int/product/686615>

\_\_\_\_\_. **DOC 10159: Safety Intelligence Manual**. 2025b. Disponível em: <https://elibrary.icao.int/product/657205>

\_\_\_\_\_. **DOC 10004: Global Aviation Safety Plan 2026 - 2028 (GASP)**. 2025c. Disponível em: <https://www.icao.int/GASP>

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

\_\_\_\_\_. **SafetyIntelligence Manual examples** (Doc 10159). 2025d. Disponível em: <https://www.icao.int/safety-management/SMI/SI/Examples>

ISLAM, M. Data analysis: Types, process, methods, techniques and tools. **International Journal on Data Science and Technology**, 6(1), 10. 2020. Disponível em: <https://www.sciencepublishinggroup.com/article/10.11648/j.ijdst.20200601.12>

KELLEHER, J. D., & TIERNEY, B. (2018). **Data Science**. MIT Press.

KILKENNY, M. F., & ROBINSON, K. M. Data quality: "Garbage in - garbage out". **Health Information Management Journal**, 47(3), 103–105. 2018. Disponível em: <https://journals.sagepub.com/doi/full/10.1177/1833358318774357>

KRICHEVSKY, S. V. The history of flight safety: Methodology, experience, prospects. **Civil Aviation High Technologies**, 26(2), 8–17. 2023. Disponível em: <https://doi.org/10.26467/2079-0619-2023-26-2-8-17>

KURT, B. Evaluation of aircraft engine performance during takeoff phase with machine learning methods. **Neural Computing and Applications**, 36(30), 19173–19190. 2024. Disponível em: <https://doi.org/10.1007/s00521-024-10220-3>

LEE, H., CHAE, Y., CHOI, S., & SHIN, S. Critical parameter identification for safety events in commercial aviation using machine learning. **Aerospace**, 7(6), Artigo 73. 2020. Disponível em: <https://doi.org/10.3390/aerospace7060073>

LEPENIOTI, K., BOUSDEKIS, A., APOSTOLOU, D., & MENTZAS, G. Prescriptive analytics: Literature review and research challenges. **International Journal of Information Management**, 50, 57–70. 2020. Disponível em: <https://doi.org/10.1016/j.ijinfomgt.2019.04.003>

MACKINAC CENTER FOR PUBLIC POLICY. **Air travel: A hundred years of safety**. 2003. Disponível em: <https://www.mackinac.org/V2003-30>. Acesso em: 16 set 2025.

MARQUESONE, R. **Big Data: Técnicas e tecnologias para extração de valor dos dados**. 2016.

MCFADDEN, K. L., & TOWELL, E. R. Aviation human factors: A framework for the new millennium. **Journal of Air Transport Management**, 5(4), 177–184. 1999. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0969699799000113>

MISRA, S. Machine learning-based live predictive warnings for unstabilized approaches in aircraft. **Discovery Day 2021**, Embry-Riddle Aeronautical University, Daytona Beach, FL, Estados Unidos. 2021. Disponível em: <https://commons.erau.edu/discovery-day/dbdiscovery-day-2021/poster-session-grad/3/>

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

MORROW, J. **Seja um analista de dados**: Como usar a análise para transformar dados em valor. Alta Books.2024.

MOURA, C. G. F. DE, GARCIA, J. S. D., & LEGG, A. P. Leveraging open data and machine learning to minimize the risks of aviation satellite navigation interference. **Anais do XXII Simpósio de Transporte Aéreo**. 2026. Disponível em: <https://doi.org/10.29327/9786527220244.1239773>

MUÑOZ-ESPARZA, D., SHARMAN, R., UNDERHILL, S., & MEYMARIS, J. Aviation turbulence forecasting at upper levels with machine learning techniques based on regression trees. **Journal of Applied Meteorology and Climatology**, 59(11), 1883–1899. 2020. Disponível em: <https://journals.ametsoc.org/view/journals/apme/59/11/JAMC-D-20-0116.1.xml>

NATIONAL ACADEMIES OF SCIENCES, ENGINEERING, AND MEDICINE. **In-time aviation safety management**: Challenges and research for an evolving aviation system. The National Academies Press. 2018. Disponível em: <https://doi.org/10.17226/24962>

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA). In-Time Aviation Safety Management Systems (IASMS) [PowerPoint Slides]. **NASA Technical Reports**. Apresentação para reunião técnica entre FAA e NASA. 2023. Disponível em: [https://ntrs.nasa.gov/api/citations/20230005340/downloads/IASMS\\_FAASWSRTT\\_04\\_112023.pdf](https://ntrs.nasa.gov/api/citations/20230005340/downloads/IASMS_FAASWSRTT_04_112023.pdf)

NOGAMI, J., NAKASUKA, S., & TANABE, T. Real-time decision support for air traffic management, utilizing machine learning. **Control Engineering Practice**, 4(8), p. 1129–1141. 1996. Disponível em: [https://doi.org/10.1016/0967-0661\(96\)00113-X](https://doi.org/10.1016/0967-0661(96)00113-X)

NORWEGIAN SAFETY INVESTIGATION AUTHORITY. Safety in Norwegian aviation during the process of change. **Accident Investigation Board Norway**. 2025. Disponível em: <https://nsia.no/Aviation/Published-reports/2005-35-eng>

PROVOST, F., & FAWCETT, T. **Data science for business**: What you need to know about data mining and data-analytic thinking. O'Reilly Media.2013.

RAMAKRISHNAN, S. The importance of data mining & predictive analysis. **International Journal of Engineering Technology and Management Sciences**, 7(4), 593–598. 2023. Disponível em: <https://doi.org/10.46647/ijetms.2023.v07104.081>

RAULT, A. **Pilot workload analysis**. Em T. B. Sheridan & G. Johannsen (Eds.), Monitoring behavior and supervisory control (pp. 139–155). Springer US. 1976. Disponível em: [https://link.springer.com/content/pdf/10.1007/978-1-4684-2523-9\\_13?pdf=chapter+toc](https://link.springer.com/content/pdf/10.1007/978-1-4684-2523-9_13?pdf=chapter+toc)

R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

REASON, J. **Managing the risks of organizational accidents**. Ashgate.1997.

SAMPIERI, R. H., COLLADO, C. F., & LUCIO, M. DEL P. B. **Metodologia de pesquisa**. Penso.2013.

SANDEEP, S. R., AHAMAD, S., SAXENA, D., SRIVASTAVA, K., JAISWAL, S., & BORA, A. To understand the relationship between machine learning and artificial intelligence in large and diversified business organisations. **Materials Today: Proceedings**, 56, p.2082–2086. 2022. Disponível em: <https://doi.org/10.1016/j.matpr.2021.11.409>

SARKER, I. H. Data science and analytics: An overview from data-driven smart computing, decision-making and applications perspective. **SN Computer Science**, 2(5). 2021. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8274472/>

SEAH, B. Z. Q., GAN, W. H., WONG, S. H., LIM, M. A., GOH, P. H., SINGH, J., & KOH, D. S. Q. Proposed data-driven approach for occupational risk management of aircrew fatigue. **Safety and Health at Work**, 12(4), p. 462–470. 2021. Disponível em: <https://doi.org/10.1016/j.shaw.2021.06.002>

SHARDA, R., DELEN, D., & TURBAN, E. **Business intelligence e análise de dados para gestão do negócio** (4. ed.). Bookman.2019.

SHINDE, P. P., & SHAH, S. A review of machine learning and deep learning applications. **IEEE**. 2018. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8697857>

SHMUELI, G. To explain or to predict? **Statistical Science**, 25(3), p. 289–310. 2010. Disponível em: <https://doi.org/10.1214/10-STS330>

SOUSA, A. S. DE, OLIVEIRA, G. S. DE, & ALVES, L. H. A pesquisa bibliográfica: Princípios e fundamentos. **Cadernos da FUCAMP**, 20(43). 2021. Disponível em: <https://revistas.fucamp.edu.br/index.php/cadernos/article/view/2336>

SOUZA, M. DE, ALMEIDA, F. G., & SOUZA, R. R. **O termo big data: Quebra de paradigma dos n-V's** [Monografia de graduação, Universidade Federal de Minas Gerais]. Repositório Institucional da UFMG. 2018. Disponível em: <https://repositorio.ufmg.br/items/cdc44048-f980-4302-9568-6f9ac4f5f0b6>

THEREZA, C. G. P. F. **Cultura de segurança operacional: Tradução e validação de uma escala para avaliação de organizações provedoras de serviços de navegação aérea no Brasil** [Tese de doutorado, Universidade Federal da Paraíba]. Repositório Institucional da UFPB. 2020. Disponível em: <https://repositorio.ufpb.br/jspui/handle/123456789/20497>

WOLFSON, M. M., DELANOY, R. L., FORMAN, B. E., HALLOWELL, R. G., PAWLAK, M. L., & SMITH, P. D. Automated microburst wind-shear prediction. **The Lincoln Laboratory Journal**, 7(2), p. 399–426. 1994. Disponível em: <https://www.ll.mit.edu/sites/default/files/publication/doc/automated-microburst-windshear-prediction-wolfson-ja-7199.pdf>

YEUN, R. C. K. **The impact of safety management systems on safety performance:** Commercial aviation operations [Tese de doutorado, Griffith University]. Griffith Research Online. 2015. Disponível em: <http://dx.doi.org/10.25904/1912/3359>

ZANELA, E. H. R., NASCIMENTO, D. L., COUTO, F. R. P., SANTANA, M. A. S., & SANSON, A. L. Big Data: A nova fórmula para a inovação, a concorrência e produtividade. **Anais** do Congresso Acadêmico de Tecnologia e Informática, p. 55–62. 2015. Disponível em: <https://www.researchgate.net/publication/313468003>



R. bras. Av. civil. ci. Aeron., Florianópolis, v. 6, n. 3, esp., p. 11-48, jul/ago. 2026.

