



ESCOLA DE APERFEIÇOAMENTO DE OFICIAIS DA AERONÁUTICA  
DIVISÃO DE ENSINO  
CURSO DE APERFEIÇOAMENTO DE OFICIAIS 1º/2024

RICARDO **CAMILO** PINTO, Cap Av

**A utilização do *machine learning* como ferramenta para fortalecer a segurança de voo no Grupo Especial de Inspeção em Voo**

Rio de Janeiro

2024

ESCOLA DE APERFEIÇOAMENTO DE OFICIAIS DA AERONÁUTICA  
DIVISÃO DE ENSINO  
CURSO DE APERFEIÇOAMENTO DE OFICIAIS 1º/2024

RICARDO CAMILO PINTO, Cap Av

**A utilização do *machine learning* como ferramenta para fortalecer a segurança de voo no Grupo Especial de Inspeção em Voo**

Trabalho de conclusão de curso apresentado no Curso de Aperfeiçoamento de Oficiais da Aeronáutica como requisito parcial para aprovação no Curso de Pós-graduação *Lato Sensu* em Liderança com Ênfase em Gestão no COMAER.  
Linha de Pesquisa: Segurança de voo  
Orientador: Bruno Bitencourt Carvalho De Oliveira, Maj Int

Rio de Janeiro

2024

RICARDO **CAMILO** PINTO, Cap Av

**A utilização do *machine learning* como ferramenta para fortalecer a segurança de voo no Grupo Especial de Inspeção em Voo**

Trabalho de conclusão de curso apresentado no Curso de Aperfeiçoamento de Oficiais da Aeronáutica.

Aprovado por:

---

Bruno **Bitencourt** Carvalho De Oliveira, Maj Int  
EAOAR

---

**Isabel** Corrêa Da **Costa** Mileski, Maj Dent  
EAOAR

Rio de Janeiro

2024

## RESUMO

No Grupo Especial de Inspeção em Voo (GEIV) foi percebida uma grande dificuldade de realizar uma gestão preditiva da segurança, de forma a implementar barreiras com antecedência. Para auxiliar neste processo de análise de dados e percepção dos perigos, fatores importantes da gestão preditiva, um algoritmo chamado *machine learning* (ML) demonstrou-se valiosíssimo. Por isso, este ensaio defende que a utilização do *machine learning* como ferramenta de análise de dados fortalece a segurança de voo no GEIV. Durante as pesquisas, esta ferramenta demonstrou-se excelente para realizar previsões dos indicadores de segurança de voo, baseados em relatos de prevenção. A ferramenta apresentou extrema precisão no traçado das linhas de tendência nos gráficos, que pode ser utilizado para verificar se alguma área da organização está precisando de um maior cuidado, de forma antecipada. Uma outra utilidade dessa ferramenta é a identificação de anomalias nos parâmetros de voo, colhidos diretamente da aeronave. Mesmo com uma vasta quantidade de dados, o ML foi capaz de apontar desvios nos parâmetros, alertar sobre falsos negativos e identificar as suas causas. Utilizando a ferramenta destas duas formas, é possível que ações de prevenção sejam tomadas previamente. Com os diagnósticos avançados deste instrumento, o modelo de gestão da segurança de voo passa de um modelo proativo para uma forma preditiva. Ao fim do estudo, percebeu-se que a ferramenta deveria extrapolar os limites do GEIV e ser utilizada em toda a FAB. Com este utensílio, uma gestão mais preditiva pode ser realizada com qualidade, salvando um maior número de vidas.

**Palavras-chave:** Gestão Preditiva. Segurança de Voo. *Machine Learning*.

## 1 INTRODUÇÃO

A Gestão da Segurança de Voo no Grupo Especial de Inspeção em Voo (GEIV) é feita através de um modelo padronizado pelo Centro de Investigação e Prevenção de Acidentes Aeronáuticos (CENIPA). A norma que define como a gestão deve ser feita se baseia em um modelo de gerenciamento consolidado, que possui como base o *Safety Management Manual* (SMM) redigido pela *International Civil Aviation Organization* (ICAO).

O fato motivador deste estudo tem uma relação direta com esse modelo de gerenciamento atual. Em alguns incidentes que aconteceram com aeronaves do GEIV, foi percebido durante as investigações que houve alguns sinais de que estes incidentes pudessem ocorrer. Porém, os sinais não foram percebidos devido ao tipo de gestão da segurança de voo.

A forma de gerenciar a segurança vem mudando com o avançar da aviação. Nos primórdios, a grande atenção era dada à gestão reativa. Ou seja, acontecia um acidente e ele era investigado com o intuito de aprender ao máximo o que não deve ser feito. Atualmente já existe uma gestão mais proativa, em que se coloca mais ação para identificar os pontos fracos da segurança e implantar as melhores barreiras, de forma a prevenir acidentes.

No GEIV, a gestão do risco e a de indicadores de performance, que fazem parte da gestão da segurança de voo, aumentaram muito o nível de consciência acerca do nível de segurança em que se encontrava a unidade. De uma forma geral, com a gestão do risco é possível perceber que alguma situação de perigo está se repetindo e, assim, implantar barreiras antes que estes acidentes ocorram. No entanto, a viabilidade não implica necessariamente em simplicidade.

A Seção de Investigação e Prevenção de Acidentes Aeronáuticos (SIPAA) do GEIV, que é responsável por fazer essa gestão citada, nem sempre conseguia identificar conexões entre os relatos de prevenção (RELPREV), de forma a verificar que alguma situação insegura estava se repetindo. Um outro grande problema dessa forma de gerenciar o risco é que, em algumas situações, o indicador entrava na zona de alerta, porém o incidente acontecia por não haver tempo hábil para implantar alguma barreira.

Por essa razão, existe uma necessidade de haver uma evolução da gestão da segurança para uma forma preditiva. Segundo Bartulović e Steiner (2023), o

gerenciamento preditivo da segurança de voo acontece quando se consegue identificar o problema antes que ele ocorra.

Com o advento das novas tecnologias de inteligência artificial, muitas atividades que eram extremamente trabalhosas e difíceis de realizar, tornaram-se mais simples. Uma subunidade da inteligência artificial é o *machine learning* (ou aprendizado de máquina) que é o campo de estudo interessado no desenvolvimento de algoritmos para transformar dados em ação inteligente. Estes algoritmos utilizam métodos estatísticos para analisar grandes conjuntos de dados (Lantz, 2013). Como resultado, verificam correlações, identificam tendências e ainda conseguem identificar anomalias que podem passar despercebidas pelo olhar humano.

Desse modo, este ensaio defende que a utilização do *machine learning* (ML) como ferramenta de análise de dados fortalece a segurança de voo no GEIV. Argumenta-se que utilizando o *machine learning* é possível realizar previsões dos indicadores de segurança de voo, advindos de relatos de prevenção. Uma outra grande vantagem de utilizar o aprendizado de máquina é a possibilidade de identificar anomalias nos parâmetros de voo, a partir de dados colhidos diretamente do avião.

## 2 DESENVOLVIMENTO

Segundo Reason (1997), os acidentes organizacionais possuem múltiplas causas, envolvendo muitas pessoas que operam em diferentes níveis da organização. Este conceito de acidente organizacional nos mostra que diferentes causas podem ser responsáveis e ter influenciado em um acidente, como máquinas, pessoas, processos ou doutrina. Se há várias causas para um acidente acontecer, então há vários pontos em que devem ser colocadas barreiras para evitar o acidente. Porém, a parte mais desafiadora é identificar esses pontos antes que o acidente aconteça.

Para resolver esse desafio, o *machine learning* torna-se um instrumento inestimável. A aprendizagem de máquina progrediu dramaticamente nas últimas décadas, passando de uma curiosidade de laboratório para uma tecnologia de uso amplo (Jordan e Mitchell, 2015). A tendência é que a evolução seja cada vez mais rápida, justamente pelo fato de como ela funciona – um computador aprendendo a evoluir um computador.

Com a habilidade de analisar uma grande quantidade de dados de várias formas, o *machine learning* é capaz de correlacionar dados entre as diversas áreas da organização e verificar anomalias em um grande conjunto de dados. Além disso, o algoritmo pode traçar linhas de tendência dos indicadores de performance, fazendo o gestor da segurança de voo identificar com antecedência que alguma área está precisando de uma maior atenção.

## 2.1 O *machine learning* como ferramenta para a realização de previsões dos indicadores de segurança de voo

Os indicadores tornaram-se extremamente necessários para realizar um bom gerenciamento de uma organização. Eles devem ser acordados e estabelecidos para monitorar os riscos e a eficácia das ações de mitigação (ICAO, 2018). Um aspecto importante é que os indicadores de segurança também são números, entretanto carregam uma bagagem de subjetividade, pois estes indicadores derivam de RELPREV, que são relatos escritos por pessoas envolvidas com a aviação.

Uma característica muito importante do *machine learning* é a capacidade de fazer correlações, elucidando muito melhor os vínculos entre os dados (Mangortey *et al.*, 2020). Porém, sabendo utilizar esta ferramenta da forma correta podemos ir além e, através da correlação entre os dados, ter informações antecipadas do nível ao qual determinado indicador pode chegar. Cabe ressaltar que essas informações antecipadas, que são as análises de tendências ou previsões, ainda não conseguiram ter sucesso na precisão das suas análises feitas sem o aprendizado de máquina.

Zeng *et al.* (2022) realizaram um estudo para verificar qual seria o melhor modelo de previsão para utilizar com o *machine learning*. Foram utilizados dados derivados de um acidente ocorrido em 2019. Um modelo de previsão de múltiplas camadas de *Long Short-Term Memory*, o ML-LSTM, foi o que se destacou no estudo, apresentando uma altíssima precisão das previsões.

A intenção dos cientistas de dados é fazer com que os métodos de previsão cheguem cada vez mais próximos do 100% de precisão, porém é lógico que nunca irão atingir este nível de certeza. Sempre haverá uma porcentagem de incerteza. Contudo, só o fato de existir linhas de tendência em um gráfico, que alerte sobre a probabilidade de algum indicador chegar a certo nível indesejado já é suficiente para

que haja um grande salto rumo à gestão preditiva da segurança de voo.

Bartulović e Steiner (2023) realizaram uma pesquisa implementando métodos preditivos na gestão da segurança de voo em uma organização de instrução aérea que já efetuava uma gestão reativa e proativa de forma bem estabelecida. A partir dos dados conhecidos foi feito um comparativo de gráficos em que era mostrado o momento do alerta do indicador e qual era o momento da implantação de barreiras.

De acordo com o esperado, na forma reativa as barreiras foram colocadas bem depois de um acidente ocorrer. Na gestão proativa, as barreiras foram colocadas logo que os indicadores atingiram certos limites de alerta. Utilizando modelos de previsão foi possível perceber a probabilidade daquele índice extrapolar o nível de alerta estipulado, sendo exibido em linhas de tendência no gráfico. Desta forma, soluções para que o índice não extrapolasse o nível de alerta poderiam ser implementadas com brevidade.

A implantação de barreiras no método proativo possui sua eficácia na prevenção, porém existe uma probabilidade razoável de não haver tempo suficiente para haja a ação de prevenção entre a extrapolação do nível de alerta e o acidente. Por este motivo, o modelo preditivo torna-se tão interessante. Com a verificação da tendência do índice de extrapolar o nível, há um maior tempo de segurança para que medidas sejam adotadas. Sabendo da capacidade do *machine learning* de realizar boas previsões, esta ferramenta se apresenta como um instrumento extremamente forte para ajudar na gestão da segurança de voo.

## **2.2 O *machine learning* como ferramenta para identificar anomalias nos parâmetros de voo**

Há diversas formas de adquirir dados do voo para realizar uma verificação posterior. Um equipamento muito difundido é o *Flight Data Recorder* (FDR), que é uma parte da famosa “caixa preta”, onde se pode verificar os parâmetros do motor, dos instrumentos, altitude, etc. Através deste equipamento, por exemplo, o CENIPA consegue fazer animações para entender como algum acidente aconteceu.

Com o propósito de deixar a aviação cada vez mais segura, muitas empresas aéreas têm buscado monitorar constantemente seus voos. Para fazer este acompanhamento, equipamentos como *Flight Data Monitoring* (FDM) e *Flight Operations Quality Assurance* (FOQA) têm ganhado muito espaço no cenário da

aviação comercial. Eles funcionam de forma bem parecida com o FDR, porém a própria empresa, dona da aeronave, pode decidir que parâmetros vai querer gravar (Mangortey *et al.*, 2020).

A grande dificuldade de trabalhar com estes equipamentos é que uma quantidade enorme de dados resultam destas gravações. É neste momento que o *machine learning* reaparece como uma ferramenta extremamente valiosa para a segurança de voo. Utilizando o algoritmo é possível filtrar os dados e verificar somente as anomalias que realmente podem afetar a segurança. Muitas dessas anomalias que não seriam percebidas facilmente por uma análise humana, podem ser percebidas pelo algoritmo e são conhecidas como falsos negativos.

Oehling e Barry (2019) realizaram um estudo para verificar a possibilidade de gerar novos conhecimentos relevantes a partir dos dados de voo existentes, usando métodos de ML e tendo como foco a identificação de anomalias no voo. Durante as verificações, os pesquisadores focaram na fase de aproximação para pouso. Eles identificaram desvios incomuns da trajetória esperada da linha reta na aproximação final, inclusive desvios que poderiam sugerir uma arremetida, para evitar um acidente. Além disso, foram detectadas manobras instáveis que não tinham grandes desvios que fossem suficientes para acionar um evento no equipamento, porém o *machine learning* conseguiu identificar múltiplos pequenos desvios que juntos elevaram a classificação do risco da situação.

Buscando também uma ação conjunta do aprendizado de máquina com um equipamento de FOQA, Lee *et al.* (2020) realizaram um estudo para verificar se havia aumento da detecção de ocorrências relacionadas à segurança em dados reais de companhias aéreas. Com a metodologia usada, eles conseguiram identificar quais foram os parâmetros críticos de determinados eventos e também quais foram as suas causas, demonstrando a tamanha capacidade deste algoritmo.

A quantidade de dados que os equipamentos de FDM e FOQA são capazes de armazenar são extremamente grandes. Ter acesso a um enorme banco de dados e não conseguir extrair o que realmente importa não implica em ganho para a segurança de voo. Porém, nos estudos citados, pôde-se perceber que o *machine learning* é um aliado ideal para verificar anomalias que muitas vezes passam despercebidas, ressaltando a importância desta ferramenta para o fortalecimento da segurança de voo, elevando-a para um nível preditivo.

### 3 CONCLUSÃO

Após algumas ocorrências aeronáuticas ocorridas no GEIV, em que não foi percebida a correlação de dados novos com dados preexistentes, foi percebida uma necessidade de evolução da gestão da segurança de voo para uma forma preditiva. Como forma de auxiliar nesta evolução tão importante para a segurança, a ferramenta *machine learning* apresentou-se como uma virada de chave para essa mudança de nível.

No que tange à capacidade de realizar previsões com os dados existentes, o aprendizado de máquina demonstrou-se extremamente importante. Foi realizado um teste em que o modelo ML-LSTM, utilizado com *machine learning*, demonstrou-se profusamente confiável para realizar previsões. Essas previsões, ou linhas de tendências, são muito importantes para que haja a implantação de barreiras antes que algum indicador chegue a níveis críticos. Dessa forma, as defesas para impedir algum acidente seriam implantadas antes que algum índice chegasse a um nível de alto risco.

Uma outra característica extremamente valiosa da ferramenta que foi verificada, foi a capacidade de identificar anomalias dentro de uma vasta quantidade de dados. Equipamentos como FDM e FOQA estão cada vez mais comuns nas aeronaves. Eles gravam uma quantidade enorme de parâmetros de voo. Com o *machine learning*, é possível distinguir desvios dentro destes parâmetros que podem ser trabalhados de forma preditiva.

Sendo assim, através do estudo pudemos verificar que a utilização do *machine learning* como ferramenta de análise de dados fortalece a segurança de voo no GEIV. Devido ao tamanho dos benefícios citados que o *machine learning* pode proporcionar, sugere-se que esta ferramenta não seja implantada somente no Grupo Especial de Inspeção em Voo, mas também em todas as unidades aéreas da FAB.

A gestão preditiva da segurança de voo, pensando a nível organizacional, ainda está no seu início em todo o mundo. Com a inserção dessa ferramenta, a Força Aérea Brasileira despontaria perante as grandes organizações como um modelo a ser seguido, além de aumentar o indicador mais importante, que é o da quantidade de vidas salvas.

## REFERÊNCIAS

BARTULOVIĆ, D.; STEINER, S. Conceptual model of predictive safety management methodology in aviation. **Aerospace**, [S.L.], v. 10, n. 3, p. 268, 2023.

INTERNATIONAL CIVIL AVIATION ORGANIZATION. **Safety Management Manual: Doc. 9859**. 4th ed. Quebec, 2018.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**, New York, v. 349, n. 6245, p. 255–260, 2015.

LANTZ, B. **Machine Learning with R**. Birmingham, England: Packt Publishing, 2013.

MANGORTEY, E. et al. Application of Machine Learning Techniques to Parameter Selection for Flight Risk Identification. *In: AIAA Scitech Forum, 2020, Orlando*. **Anais [...]**. Orlando: American Institute of Aeronautics and Astronautics, 2020.

OEHLING, J.; BARRY, D. J. Using machine learning methods in airline flight data monitoring to generate new operational safety knowledge from existing data. **Safety science**, Cranfield, v. 114, p. 89–104, 2019.

REASON, J. **Managing The Risks Of Organizational Accidents**. Aldershot: Ashgate Publishing Limited, 1997.

ZENG, H.; ZHANG, H.; REN, B.; CUI, L.; WU, J. Aviation safety prediction method research based on improved LSTM model. **Systems Engineering and Electronics**, Louyang, v. 44, n. 2, p. 569-576, 2022.