

IMPACTO DAS NÉVOAS E NEVOEIROS NAS FASES DE DECOLAGEM E POUSO: ANÁLISE DA FORMAÇÃO E PREVISÃO POR MEIO DE TÉCNICAS DE MACHINE LEARNING¹

IMPACT OF FOG AND MIST ON TAKEOFF AND LANDING PHASES: ANALYSIS OF FORMATION AND FORECASTING USING MACHINE LEARNING TECHNIQUES

Vinicius Tsuda²
Evelyn Aparecida de Oliveira³
Guilherme Ferreira Andrade⁴

RESUMO

Névoas e nevoeiros representam desafios significativos para a segurança na aviação, especialmente nas fases de decolagem e pouso, devido à redução drástica da visibilidade. Este trabalho investigou o impacto desses fenômenos meteorológicos nas operações aéreas e avaliou a eficácia de técnicas de aprendizado de máquina na sua previsão. A formação de nevoeiro, decorrente da condensação de vapor d'água em microgotas por resfriamento do ar até o ponto de orvalho, eleva os riscos de desorientação espacial e acidentes, conforme evidenciado por dados do CENIPA, que apontam 77 de 1690 acidentes entre 2014 e 2024 associados a condições meteorológicas adversas. A metodologia combinou uma revisão bibliográfica qualitativa, explorando os efeitos de condições climáticas na aviação, com uma abordagem quantitativa, utilizando dados meteorológicos do aeródromo SBYS (Campo de Fontenelle) advindos do banco de dados do ICEA (Instituto de Controle do Espaço Aéreo). Esses dados alimentaram modelos de aprendizado de máquina, mais especificamente um modelo *Random Forest*, que alcançou alta acurácia (0,968) e acurácia média de 0,94 na identificação de padrões de formação de nevoeiro, destacando a umidade relativa (67,78%) como variável predominante. Apesar dos desafios na previsão de fenômenos localizados, influenciados por fatores geográficos e ambientais, os resultados indicam que técnicas de *machine learning* podem aprimorar a acurácia das previsões meteorológicas. Contudo, também aponta que uma acurácia muito elevada pode ser um indício de *overfitting*. A integração desses modelos em serviços aeronáuticos, pode otimizar o planejamento de operações em aeródromos, reduzindo riscos e incidentes em condições de visibilidade restrita. Assim, este estudo reforça a importância da previsibilidade de nevoeiros para a segurança e eficiência da aviação, especialmente em regiões de alta umidade, contribuindo para a mitigação de acidentes e a gestão eficaz do tráfego aéreo.

Palavras-chave: névoa; visibilidade; aprendizado de máquina; decolagem; pouso

¹ Artigo de Conclusão de Curso em realizado no Curso de Formação de Oficiais Aviadores (CFOAv) da Academia da Força Aérea (AFA).

² Cadete Aviador do 4º Esquadrão (Turma Ártemis, 2025).

³ 1º Tenente QOCON Magistério em Sistemas de Informação, Doutora e Mestre em Modelagem Computacional pela Universidade Federal de Juiz de Fora, Professora Tecnologias da Informação e Sistemas de Informação da AFA. E-mail: evelyneao@fab.mil.br

⁴ 1º Tenente QOAV bacharel em Ciências Aeronáuticas e Administração pela Academia da Força Aérea. E-mail: fandrdegfa1@fab.mil.br

ABSTRACT

Fogs and mists represent significant challenges to aviation safety, especially during takeoff and landing phases, due to the sharp reduction in visibility. This study investigated the impact of these meteorological phenomena on air operations and evaluated the effectiveness of machine learning techniques in forecasting them. Fog formation, resulting from the condensation of water vapor into microdroplets due to air cooling to the dew point, increases the risks of spatial disorientation and accidents, as evidenced by data from CENIPA, which reported that 77 out of 1,690 accidents between 2014 and 2024 were associated with adverse weather conditions. The methodology combined a qualitative literature review—exploring the effects of weather conditions on aviation—with a quantitative approach, using meteorological data from SBYS aerodrome (Campo de Fontenelle), obtained from the ICEA (Airspace Control Institute) database. These data were fed into machine learning models, specifically a Random Forest model, which achieved high accuracy (0.968) and an average accuracy of 0.94 in identifying fog formation patterns, highlighting relative humidity (67.78%) as the most influential variable. Despite the challenges in forecasting localized phenomena—shaped by geographic and environmental factors—the results indicate that machine learning techniques can enhance the accuracy of meteorological forecasts. However, it also suggests that excessively high accuracy may be an indication of overfitting. The integration of such models into aeronautical services can optimize the planning of operations at aerodromes, reducing risks and incidents under restricted visibility conditions. Thus, this study reinforces the importance of fog predictability for aviation safety and efficiency, especially in high-humidity regions, contributing to accident mitigation and effective air traffic management.

Keywords: aviation safety, fog prediction, machine learning, meteorological data, operational efficiency.

INTRODUÇÃO

A formação de nevoeiros é um fenômeno meteorológico que pode comprometer a segurança das operações aéreas, pois a rápida redução de visibilidade cria condições propícias à desorientação espacial, especialmente em aeródromos vulneráveis à presença de névoa e nevoeiros (ANAC, 2017). A visibilidade é um dos fatores mais críticos durante pousos e decolagens, e a

presença de nevoeiro pode reduzir drasticamente a distância visual dos pilotos, dificultando a percepção de obstáculos (Willett, 1930).

Em condições de visibilidade restrita, os riscos de incidentes aumentam, exigindo que as operações aéreas sejam avaliadas ou até mesmo interrompidas. Portanto, a previsibilidade dessas condições meteorológicas é crucial para assegurar a segurança operacional — definida pela ICA 63-26/2010 como o nível aceitável de risco necessário para manter as atividades em funcionamento, através da identificação de perigos e do gerenciamento de riscos — além de garantir a eficiência das operações nos aeródromos (Brasil, 2010). Dessa forma, pretende-se com o referido estudo relacionar como a névoa e o nevoeiro interferem na visibilidade dos aeródromos e, conseqüentemente, no planejamento das operações aéreas, focando principalmente na segurança operacional. Destarte, uma visibilidade degradada pode afetar decolagens e pousos e aumentar ainda mais a chance de ocorrências que afetem a segurança de voo (FAA, 2016). Segundo Dantas et al. (2018), entre os anos de 2006 e 2017, dos 1764 acidentes que ocorreram 336 foram na decolagem e 281 foram no pouso, somados obtém-se a marca de 617 acidentes ou 34,7% (trinta e quatro inteiros e sete centésimos por cento). Esses acidentes registrados foram no pouso ou decolagem denotando que essas fases apresentam maior perigo para atividade aérea. Segundo o Centro de Investigação e Prevenção de Acidentes Aeronáuticos (CENIPA), entre 2014 e 2024, de 1690 acidentes registrados, 77 tiveram como fator contribuinte a meteorologia adversa. Assim sendo, a introdução de sistemas avançados de previsão, baseados em Inteligência Artificial (IA), como por exemplo, treinamentos com random forest e regressão linear, pode proporcionar melhorias significativas na gestão de risco, oferecendo aos operadores uma capacidade maior de antecipação de condições adversas (Fabbian; De Dear; Lellyett, 2007).

O desenvolvimento de modelos de previsão baseados em aprendizado de máquina permite que esses sistemas processem grandes volumes de dados meteorológicos, identificando padrões que podem não ser evidentes a partir da análise tradicional (Dewi et al., 2020). Dessa forma, é possível prever com maior assertividade a formação de nevoeiros, permitindo a adaptação prévia dos planos de voo, minimizando atrasos e, principalmente, garantindo a segurança operacional (Brasil, 2010). Assim, este estudo está fundamentado na crescente dependência da aviação em relação às condições meteorológicas e no avanço das tecnologias de *machine learning* aplicadas no campo da meteorologia. Sendo assim, o aprendizado de máquina pode se constituir em ferramentas para aprimoramento da previsibilidade da formação de nevoeiro (Dewi et al., 2020). Apesar dos avanços

recentes, ainda há desafios substanciais na previsão de fenômenos localizados, como o nevoeiro, que depende de uma série de fatores ambientais e geográficos específicos (Gultepe et al., 2018).

A utilização de *machine learning* pode ampliar as ferramentas disponíveis, melhorando a precisão das previsões e a capacidade de resposta dos operadores de voo. Dessa forma, o objetivo geral deste estudo consiste em investigar o impacto que névoas e nevoeiros causam nas fases de decolagem e pouso. Considerando esse cenário, qual a eficácia dos mecanismos de machine learning na previsibilidade de tais fenômenos? Essa questão norteará a coleta de dados meteorológicos dos sistemas do ICEA, especificamente em SBYS, para o desenvolvimento e estudo de ferramentas de machine learning. Por exemplo, será elaborada uma rotina computacional que empregará um algoritmo de *Random Forest*. Este algoritmo será treinado para identificar padrões de temperatura, vento, pressão e umidade, e sua relação com a formação de névoas e nevoeiros, estruturando assim o estudo. O foco estará em modelos que possam auxiliar na previsão desses fenômenos que afetam a operacionalidade dos pousos e decolagens nos aeródromos. A utilização de técnicas de machine learning pode ampliar as ferramentas disponíveis, melhorando a precisão das previsões e a capacidade de resposta dos operadores de voo. Dessa forma, o objetivo geral deste estudo consiste em investigar o impacto que névoas e nevoeiros causam nas fases de decolagem e pouso, bem como avaliar a eficácia dos mecanismos de aprendizado de máquina na previsibilidade desses fenômenos. Logo, foram traçados os seguintes objetivos específicos:

- I. Realizar uma revisão bibliográfica sobre a formação de névoas e nevoeiros, seus efeitos na segurança de pousos e decolagens e a aplicação de modelos de *machine learning* na previsão desses fenômenos meteorológicos adversos;
- II. Coletar dados meteorológicos históricos do aeródromo SBYS, por meio do sistema do ICEA, abrangendo variáveis como temperatura, umidade relativa, visibilidade, velocidade e direção do vento, pressão atmosférica, entre outras, e organizar tais dados em formato apropriado para análise computacional;
- III. Elaborar uma rotina computacional em linguagem *Python* que utiliza o algoritmo *Random Forest*, treinando o modelo com os dados obtidos para identificar padrões associados à formação de nevoeiros no aeródromo SBYS;

- IV. Avaliar o desempenho do modelo de aprendizado de máquina desenvolvido, por meio de métricas estatísticas como acurácia, precisão e área sob a curva ROC-AUC.

1 REFERENCIAL TEÓRICO

1.1 FORMAÇÃO DE NÉVOA

A formação de nevoeiro envolve a condensação do vapor d'água em microgotas, processo no qual o resfriamento do ar ocorre até atingir o ponto de orvalho (Ahrens, 2013). Fatores climáticos, como umidade relativa, temperatura, vento e pressão atmosférica, desempenham papéis cruciais nesse processo (Stull, 2015).

No contexto da aviação, condições meteorológicas desfavoráveis são aquelas que influenciam diretamente a segurança das operações aéreas, tanto durante o voo quanto nas manobras em solo (Keel, 2000). Segundo a teoria de Köppen (1936), o Brasil possui três classificações climáticas que favorecem a formação de névoas e nevoeiros: o clima equatorial (Af), caracterizado por temperaturas elevadas e alta umidade durante todo o ano, com chuvas intensas e regulares; o clima tropical (Aw), com verões quentes e úmidos e invernos secos; e o clima tropical de altitude (Cwa), um clima subtropical com inverno seco e verões quentes. Essas classificações apresentam elevada umidade em algum momento do ano, o que possibilita a formação de névoa e nevoeiro (FAA, 2016).

Além de reduzir a visibilidade horizontal, o nevoeiro também interfere verticalmente, podendo, em alguns casos, bloquear completamente a visão do céu. No Brasil, a umidade varia, principalmente devido à elevação e à distribuição sazonal das chuvas (Monteiro, 1973). As condições ideais para a formação de nevoeiro incluem ventos fracos na superfície, presença abundante de núcleos de condensação no ar e umidade relativa elevada, com a névoa começando a se formar quando a umidade atinge cerca de 75% (setenta e cinco por cento). À medida que a umidade se aproxima de 100% (cem por cento), a visibilidade fica cada vez mais prejudicada (Ahrens, 2013). Dessa forma, conforme a visibilidade se degrada, os fatores contribuintes para acidentes aeronáuticos aumentam, comprometendo a segurança de voo e a operacionalidade em condições meteorológicas adversas.

A formação de nevoeiro está diretamente associada à interação de diversos fatores atmosféricos, entre os quais se destacam a temperatura do ar, o ponto de orvalho, a umidade relativa, as condições do céu e do vento, e o movimento de massas de ar. A compreensão integrada dessas variáveis é fundamental para identificar as situações propícias ao desenvolvimento desse fenômeno, que representa um importante risco para as operações aeronáuticas.

A temperatura do ar exerce papel determinante, pois, à medida que diminui em direção ao ponto de orvalho, cria-se o ambiente ideal para a formação de nevoeiro. Um exemplo clássico ocorre durante o resfriamento radiativo noturno, comum em noites claras e calmas, quando o calor acumulado no solo durante o dia se dissipa para a atmosfera, levando à queda da temperatura do ar, especialmente nas estações mais frias, como o outono e o inverno (Ahrens, 2013).

O ponto de orvalho, por sua vez, corresponde à temperatura na qual o ar atinge a saturação, iniciando-se o processo de condensação que dá origem às gotículas de névoa. Segundo Ahrens (2013), a probabilidade de formação de nevoeiro aumenta consideravelmente quando a diferença entre a temperatura do ar e o ponto de orvalho é inferior a 2 a 3 °C, especialmente no período noturno.

Outro fator crucial é a umidade relativa, que reflete o grau de proximidade do ar em relação à saturação. Quando a umidade atinge 100%, o ar encontra-se completamente saturado, condição extremamente favorável à formação de nevoeiro. No entanto, em situações específicas, como em áreas costeiras com grande quantidade de núcleos de condensação, o nevoeiro pode ocorrer mesmo com níveis de umidade relativa próximos a 70% (Wallace; Hobbs, 2006). As condições do céu e do vento também desempenham papel relevante nesse processo. Céus claros e ventos fracos, geralmente abaixo de 5 nós, contribuem para o resfriamento do solo e da camada de ar próxima à superfície, criando o ambiente propício para o surgimento do chamado nevoeiro radiativo, fenômeno característico de noites estáveis e calmas, que tende a dissipar-se após o nascer do sol, salvo em regiões de maior altitude (Ahrens, 2013).

Por fim, o movimento de massas de ar, fenômeno conhecido como advecção, também pode desencadear a formação de nevoeiro. Esse processo ocorre quando ar quente e úmido se desloca sobre uma superfície mais fria, resfriando-se até atingir o ponto de orvalho. Essa situação dá origem ao nevoeiro de advecção, comumente observado quando o ar marítimo quente avança sobre regiões continentais resfriadas (Ahrens, 2013; Lutgens; Tarbuck, 2015).

1.2 IMPACTO DE METEOROLOGIA ADVERSA NA SEGURANÇA DE VOO

À medida que as condições meteorológicas reduzem a visibilidade, a desorientação espacial e a dificuldade de manter a consciência situacional aumentam, resultando em operações menos eficientes e com maiores chances de incidentes (Meng, 2022). De acordo com Gerz, Forster e Tafferner (2012), a informação meteorológica é essencial para uma operação segura de voo, auxiliando os pilotos na tomada de decisão com base em dados disponíveis. A meteorologia adversa pode causar danos reais à aviação, sendo considerada uma das ameaças externas com considerável grau de risco para os pilotos (FAA, 2016). Portanto, o estudo da atmosfera e de seus fenômenos é relevante para evitar acidentes e fatalidades (ANAC, 2017). Dados do CENIPA (2004-2014) indicam que o "processo de tomada de decisão" em voo foi responsável por 2,57% dos acidentes entre 2004 e 2014. O fator "julgamento do piloto" contribuiu para 13,23% dos acidentes, enquanto as condições meteorológicas adversas foram a causa de 3,37%. Esses dados demonstram que o julgamento e a tomada de decisão, realizados por pilotos em condições meteorológicas desfavoráveis contribuíram para a redução da segurança de voo.

Inovações tecnológicas, como os radares meteorológicos embarcados, melhoram a tomada de decisão em condições climáticas adversas. Com a automação na aviação, as tripulações agora podem obter uma maior previsibilidade de suas rotas, o que lhes permite um planejamento mais antecipado para enfrentar condições meteorológicas desfavoráveis (ANAC, 2017). A tomada de decisão na aviação envolve a avaliação contínua de variáveis e a escolha de ações que garantam a segurança e a eficiência do voo. Segundo Klein (2008), a tomada de decisão naturalista (*Naturalistic Decision Making*, NDM) ocorre em ambientes reais, como o voo, onde os pilotos enfrentam alta pressão, tempo limitado para análise e situações incertas. Esse tipo de tomada de decisão depende fortemente da experiência prévia do piloto, do reconhecimento de padrões e da capacidade de interpretar sinais ambientais de forma rápida e precisa (Klein, 2008). Condições meteorológicas, como o nevoeiro, exigem julgamentos rápidos e precisos. Segundo Wickens (2009), em situações de visibilidade reduzida, o piloto depende intensamente de instrumentos e dados meteorológicos em tempo real para tomar decisões. O nevoeiro pode se formar rapidamente, reduzindo a visibilidade a poucos metros, o que torna a navegação visual impossível e pode levar à desorientação espacial (Hawkins, 1993). Essa rápida mudança nas condições meteorológicas pressiona o piloto a tomar decisões com base em dados incertos, o que pode resultar em ações precipitadas, como a tentativa de pouso em condições inadequadas. Jentsch e Smith-Jentsch (2001) argumentam que a capacidade de reconhecer padrões de deterioração meteorológica é crucial para

uma tomada de decisão eficaz, e pilotos mais experientes conseguem prever melhor as consequências desses fenômenos, corroborando a ideia de Klein (2008) de que a experiência prévia permite decisões mais assertivas.

O maior acidente da história da aviação, em Tenerife (1977), teve como fator contribuinte um nevoeiro que tomou a pista em poucos minutos. No relatório final do acidente, às 16h50min *Universal Time Coordinated* (UTC), a visibilidade da pista era de 2 a 3 quilômetros; às 17h02min UTC, caiu para cerca de 300 metros; e, às 17h06min UTC, ocorreu o acidente, no qual nem os pilotos nem a torre conseguiram estabelecer contato visual (Espanha, 1978). Assim, a previsibilidade desses fenômenos é fundamental para melhorar a segurança de voo, especialmente em operações de decolagens e pousos sob condições meteorológicas adversas (Herman, 2016). A previsão de nevoeiro é um desafio significativo na aviação devido à complexidade das condições atmosféricas e sua influência direta na segurança das operações de voo. O uso de inteligência artificial, particularmente redes neurais artificiais (RNAs), tem se mostrado promissoras para enfrentar essa questão. Segundo Fabbian, De Dear e Lelleyett (2007), as RNAs capturam interações complexas e não lineares entre variáveis meteorológicas, permitindo previsões mais precisas de eventos de nevoeiro. Esses modelos conseguem prever a ocorrência de nevoeiro com antecedência, oferecendo uma ferramenta eficaz para a tomada de decisão em operações aeroportuárias (Fabbian; De Dear; Lelleyett, 2007).

1.3 TÉCNICAS DE MACHINE LEARNING

Nesse contexto, o uso de *machine learning* (ML) tem se mostrado uma ferramenta poderosa para melhorar a previsão de nevoeiros, capturando padrões complexos em grandes conjuntos de dados meteorológicos e fornecendo informações cruciais para a tomada de decisão na aviação (Kamangir et al., 2022; Zhou et al., 2020). O *machine learning*, por meio de algoritmos como redes neurais artificiais (RNAs), árvores de decisão, florestas aleatórias (*random forests*) e redes neurais convolucionais (CNNs), permite prever a ocorrência de nevoeiro com maior precisão, como demonstrado por Zhou et al. (2020) e Kamangir et al. (2022). Esses modelos processam variáveis meteorológicas, como umidade relativa, temperatura, velocidade do vento, pressão atmosférica e concentração de núcleos de condensação, que são fundamentais para a formação de nevoeiro (INMET, 2023).

A capacidade do ML de identificar interações não lineares e padrões sutis em dados históricos e em tempo real possibilita antecipar condições favoráveis à formação de névoa com antecedência suficiente para embasar decisões operacionais (Zhou et al., 2020). Além disso, algoritmos de ML podem ser integrados a sistemas de previsão em tempo real, fornecendo alertas para controladores de tráfego aéreo e pilotos, reforçando a importância da informação meteorológica para a segurança (Kamangir et al., 2022).

Outro avanço significativo é o uso de *deep learning*, especialmente redes neurais convolucionais e recorrentes (RNNs), para processar dados espaço-temporais. Segundo Zhou et al. (2020), modelos baseados em *deep learning* são capazes de analisar imagens de satélite e dados de sensores para prever a formação e dissipação de nevoeiro em escalas regionais e locais. Esses modelos capturam a variabilidade sazonal e geográfica da umidade, influenciada, no Brasil, pelas classificações climáticas de Köppen (1936). Essa abordagem é particularmente útil em regiões com alta umidade sazonal, onde a formação de nevoeiro é mais frequente.

Além disso, técnicas de *ensemble learning*, como florestas aleatórias, têm sido empregadas para aumentar a robustez das previsões. Kamangir et al. (2022) demonstraram que combinar múltiplos modelos de ML reduz incertezas e melhora a confiabilidade das previsões de visibilidade reduzida. Esses métodos são especialmente eficazes em cenários de aviação, onde a rápida deterioração da visibilidade pode ocorrer em poucos minutos.

A integração de modelos de ML nos serviços meteorológicos aeronáuticos, como o Sistema de Controle do Espaço Aéreo Brasileiro (SISCEAB), otimiza a operacionalidade em condições adversas. A previsibilidade aprimorada do nevoeiro reduz os riscos associados à tomada de decisão sob pressão, descrita por Klein (1998) como tomada de decisão naturalista (*Naturalistic Decision Making - NDM*). Modelos de *machine learning* fornecem previsões probabilísticas, permitindo que pilotos e controladores avaliem o risco de visibilidade reduzida antes de decolagens ou pousos, minimizando a probabilidade de incidentes. Além disso, a automação proporcionada por sistemas de ML complementa os avanços tecnológicos, como radares meteorológicos embarcados. Esses sistemas podem ser integrados a interfaces de cockpit, fornecendo alertas em tempo real e auxiliando pilotos na manutenção da consciência situacional em condições de visibilidade degradada.

Apesar das vantagens, a implementação de ML na previsão de nevoeiro enfrenta desafios. A qualidade e a disponibilidade de dados meteorológicos são cruciais e, em algumas regiões do Brasil, a densidade de estações de superfície e radiossondagens pode ser limitada, impactando a

precisão dos modelos (INMET, 2023). Além disso, o treinamento de modelos de ML requer grandes quantidades de dados históricos, e a generalização para diferentes condições climáticas pode ser complexa. Por fim, a interpretação dos resultados por pilotos e controladores exige treinamento, pois previsões probabilísticas podem ser mal interpretadas em situações de alta pressão (Klein, 1998).

Em conclusão, o uso de *machine learning* na previsão de nevoeiro representa um avanço significativo para a aviação, alinhando-se à necessidade de informações meteorológicas precisas para a segurança de voo. Ao capturar a complexidade de variáveis atmosféricas e fornecer previsões em tempo real, algoritmos de ML, como RNAs e *deep learning*, complementam os serviços meteorológicos do SISCEAB e apoiam a tomada de decisão em condições adversas. No contexto brasileiro, onde climas úmidos favorecem a formação de nevoeiro, essas tecnologias podem reduzir os riscos associados à visibilidade reduzida, contribuindo para a segurança e a eficiência das operações aeronáuticas.

O *Random Forest* (RF) é um algoritmo de ensemble (conjunto) de aprendizado de máquina baseado em árvores de decisão. Neste contexto, o termo ensemble refere-se à combinação de múltiplos modelos preditivos para gerar um resultado mais preciso e robusto do que o obtido por um único modelo. Segundo Peláez-Rodríguez et al. (2023), o *Random Forest* é uma das técnicas de *bagging* mais renomadas para problemas de classificação e regressão. Em síntese, o algoritmo constrói diversas árvores de decisão independentes – cada uma treinada em uma amostra *bootstrap* (com reposição) dos dados – e para cada divisão de nó utiliza um subconjunto aleatório de atributos (Chappell, 2024). Esse mecanismo de aleatorização (na amostragem dos registros e das variáveis) reduz a correlação entre as árvores individuais, estabilizando o modelo final. A previsão do RF é obtida combinando (por voto majoritário, no caso de classificação) as saídas de todas as árvores.

Segundo Breiman (2001), criador do método, conforme o número de árvores cresce, o erro de generalização do conjunto converge para um valor estável e depende da “força” de cada árvore e da correlação entre elas. Assim, RF não assume distribuição específica dos dados, tornando-se muito flexível. Além disso, cada árvore gerada fornece estimativas internas de erro fora da amostra (*out-of-bag error*), força e importância das variáveis, o que auxilia na interpretação do modelo.

Uma das principais vantagens do Random Forest é a resistência a *overfitting* (situação indesejada na qual o modelo considera ruídos e informações discrepantes no treino do algoritmo). Uma árvore de decisão isolada tende a sobre ajustar o ruído dos dados. No entanto, a média (ou o voto) de múltiplas árvores reduz drasticamente a variância do modelo. Como observado por

Breiman (2001) em comparações “árvores de decisão têm sobreajuste e capacidade limitada, enquanto métodos em conjunto como Random Forest reduzem fortemente a probabilidade de sobreajuste”. Breiman (2001) também destaca que esse método atinge acurácia comparável ou superior a algoritmos de boosting e é eficaz com relação a *outliers* e ruído nos dados. Em outras palavras, até mesmo quando observações esparsas ou erros de medição ocorrem em variáveis meteorológicas, o voto majoritário das árvores tende a ignorar essas instabilidades.

Outra vantagem importante é a gestão de variáveis preditoras correlacionadas. Como cada árvore é construída com apenas um subconjunto aleatório de variáveis em cada nó, o RF evita que atributos altamente correlacionados dominem todas as árvores. Peláez-Rodríguez et al. (2023) observam que, devido a essa seleção aleatória de subconjuntos de variáveis em cada divisão da árvore, as árvores ficam menos correlacionadas entre si, o que por sua vez reduz o erro geral. Breiman (2001) explica que o erro de generalização do RF depende justamente da correlação entre árvores e de sua força; ao manter baixa correlação (graças à seleção aleatória de variáveis), o modelo atinge maior robustez sem perder poder preditivo. Além disso, o RF produz métricas de importância das variáveis, o que ajuda a identificar quais parâmetros – por exemplo, umidade ou vento – são determinantes na geração de nevoeiro. Por fim, a capacidade de lidar com dados faltantes ou ruído é reconhecida destacando que o RF mantém precisão mesmo quando um conjunto de dados tem valores faltantes, reforçando sua aplicabilidade em séries meteorológicas imperfeitas.

Na literatura, há diversos estudos de aplicação bem-sucedida do Random Forest. Por exemplo, Hill et al. (2020) treinaram modelos RF para previsão de eventos de tempo severo (tornados, granizo, ventos fortes) nos EUA e concluíram que, em horizontes de 2–3 dias, as previsões probabilísticas baseadas em RF superaram os métodos operacionais tradicionais. Ainda que focados em outros fenômenos, esses resultados mostram a eficácia do RF em sistemas atmosféricos complexos. Em relação direta a névoa, Peláez-Rodríguez et al. (2023) citam estudos na China onde RF foi testado na previsão de visibilidade atmosférica. Zhang et al. (2022) compararam SVM, k-NN e RF para prever a visibilidade em Chengdu e incluíram variáveis como velocidade do vento, temperatura e umidade. Assim, esses trabalhos em escala climática indicaram um bom desempenho de RF. Em suma, a combinação de flexibilidade, estabilidade estatística e capacidade de modelar relações não-lineares torna o Random Forest uma escolha técnica sólida para previsão de fenômenos meteorológicos, incluindo nevoeiro e névoa.

1.4 CONDIÇÃO SIMPLIFICADA PARA FORMAÇÃO DE NEVOEIRO

Nevoeiro se forma quando o ar fica saturado, ou seja, quando a temperatura do ar (T) é igual ou menor que a temperatura do ponto de orvalho (Td). Isso significa que a umidade relativa (UR) atinge ou excede 100%. Em termos simples, se a temperatura do ar cair até o ponto de orvalho, a umidade começa a condensar em gotículas, formando nevoeiro (Lutgens; Tarbuck, 2015).

A fórmula de Magnus-Tetens possui uma aproximação que foi proposta por Alduchov e Escobedo (1996) e calcula o ponto de orvalho com base na temperatura e umidade relativa, na fórmula apresentada, T denota a temperatura do ar, expressa em graus Celsius (°C), UR refere-se à umidade relativa do ar, medida em porcentagem (%), e Td representa a temperatura do ponto de orvalho, também em graus Celsius (°C).

$$Td = \frac{243,04 \times \left[\ln\left(\frac{UR}{100}\right) + \frac{17,625 \times T}{243,04 + T} \right]}{17,625 - \ln\left(\frac{UR}{100}\right) - \left(\frac{17,625 \times T}{243,04 + T}\right)}$$

A *National Oceanic and Atmospheric Administration* (NOAA) descreve que, para a formação de nuvens e conseqüentemente nevoeiros, é fundamental a presença de partículas no ar conhecidas como *cloud condensation nuclei* (CCN) — pequenos aerossóis, como poeira, sal ou fumaça — pois sem essas partículas, o vapor d'água teria muita dificuldade para condensar, mesmo próximo de 100 % de umidade relativa. Assim Se $T \leq Td$, o nevoeiro é provável, desde que haja núcleos de condensação (partículas como poeira ou sal). Segundo Stull (2015) a ocorrência de nevoeiro é possível quando a diferença do ponto de orvalho ($T - Td$) é zero ou negativa. Logo um algoritmo simples para verificar a formação de nevoeiro seria:

- I. Medir a temperatura do ar (T) e a umidade relativa (UR).
- II. Calcular o ponto de orvalho (Td) usando a fórmula acima.
- III. Comparar: se $T \leq Td$, prever a possibilidade de nevoeiro
- IV. $T - Td \leq 0$, o ar está saturado, e o nevoeiro é altamente provável.
- V. $T - Td > 0$, a probabilidade diminui.

2 MÉTODO DE ANÁLISE

2.1 TIPO DE PESQUISA

Segundo Gil (2012), a junção das abordagens quantitativa e qualitativa possibilita ao pesquisador uma visão mais completa dos fenômenos investigados. Ao utilizar simultaneamente técnicas numéricas e análises interpretativas, torna-se viável alcançar tanto um panorama amplo quanto uma compreensão aprofundada das informações obtidas. Esse método combinado é especialmente útil em pesquisas que exigem, ao mesmo tempo, a representatividade dos dados e a análise detalhada dos contextos em que se inserem.

Logo, o presente estudo adota uma metodologia qualitativa-quantitativa, integrando uma abordagem qualitativa (revisão bibliográfica e análise contextual) com uma abordagem quantitativa (análise estatística e modelagem de *machine learning* por meio da linguagem Python). A revisão da literatura existente permite compreender melhor os fenômenos meteorológicos e suas implicações na aviação. Sendo consultados livros, artigos e relatórios técnicos que discutem os efeitos das condições climáticas na segurança do voo.

Além disso, a abordagem quantitativa foi empregada por meio da aplicação de técnicas estatísticas e de aprendizado de máquina, mais especificamente *Random Forest*, baseadas em dados meteorológicos coletados no aeródromo SBYS (Campo de Fontenelle) e processados com auxílio de bibliotecas computacionais para o recolhimento e tratamento de dados de umidade relativa, temperatura de bulbo seco, velocidade do vento, visibilidade predominante na pista, direção do vento, altura da base de nuvem, precipitação de chuva em mm, pressão QFE, pressão QNH, quantidade de nuvens, visibilidade mínima, temperatura na pista e velocidade da rajada de vento. Oriundos do banco de dados do Instituto de Controle do Espaço Aéreo (ICEA). As informações foram obtidas a partir de 01/01/2013 até 01/04/2025.

Esses dados, coletados no aeródromo SBYS, foram organizados em planilhas no formato CSV. Para agrupá-los em um único arquivo, utilizou-se a ferramenta Datablist. Os dados passaram por tratamento prévio, incluindo limpeza de valores nulos, padronização de unidades e exclusão de registros inconsistentes, antes da aplicação dos modelos. Posteriormente, com o auxílio de ferramentas de Inteligência Artificial, foi desenvolvido um código em linguagem Python para

realizar o pré-processamento desses dados e, em seguida, uma análise de importância por fator. Para considerar a formação de nevoeiro foi inserido como condição que para apresentar resultado verdadeiro para formação de névoa é necessário uma visibilidade mínima menor que 1000 metros e umidade relativa maior que 90% como exposto na figura 1. O programa baseado em *Random Forest* foi treinado com 80% dos dados, enquanto os 20% restantes foram utilizados para teste (exposto no trecho de código na figura 2). Por fim, foram plotados gráficos com os resultados obtidos.

```
# Creating fog formation variable
logging.info("Creating Fog_Formation variable")
df['Fog_Formation'] = (df['Visibilidade_Mínima_dam'] < 1000) & (df['Umidade_Relativa_Percent'] > 90)
logging.info(f"Fog_Formation created. True count: {df['Fog_Formation'].sum()}")

logging.info(f"Processed DataFrame shape: {df.shape}")
logging.info(f"Sample data:\n{df.head().to_string()}")

return df
```

Figura 1 Trecho do código em python referente a condição de verdadeiro para nevoeiro

Fonte: Elaboração própria

```
# Splitting data (80% train, 20% test)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42, stratify=y)
logging.info(f"Training set shape: {X_train.shape}, Test set shape: {X_test.shape}")
logging.info(f"Fog events in train: {y_train.sum()}, Fog events in test: {y_test.sum()}")

# Training Random Forest
rf = RandomForestClassifier(n_estimators=100, random_state=42, class_weight='balanced')
rf.fit(X_train, y_train)
logging.info("Random Forest model trained")
```

Figura 2 Trecho do código em python referente ao treino e teste utilizando Random Forest

Fonte: Elaboração própria

3 RESULTADOS

A análise inicial do foi realizada a partir de dados meteorológicos processados do aeródromo SBYS (Campo de Fontenelle), extraídos do banco do Instituto de Controle do Espaço Aéreo (ICEA). Após a limpeza e padronização das variáveis, os dados foram submetidos ao modelo *Random Forest* com objetivo de identificar os principais fatores relacionados à formação de nevoeiro.

Em segundo plano, a análise quantitativa realizada revelou que a umidade relativa é o fator predominante na formação de nevoeiro, contribuindo com 67,78% na análise de importância de variáveis, seguida pela temperatura de bulbo seco (16,95%) e pela temperatura do ponto de orvalho (4,21%). Essas informações estão em consonância com a literatura, que aponta a umidade relativa próxima ou superior a 100% como condição essencial para a saturação do ar e a condensação em microgotas, conforme descrito por Ahrens (2013). Resultados obtidos descritos na tabela 1 abaixo.

Tabela 1 Resultados obtidos de relevância de cada fator na formação de nevoeiro

Fatores de formação	Contribuição
Umidade relativa	0,67788
Temperatura de bulbo seco	0,169548
Temperatura ponto de orvalho	0,042184
Velocidade do vento	0,037059
Visibilidade predominante	0,024426
Direção do vento	0,017828
Altura de nuvens	0,011189
Precipitação	0,009861
QFE	0,003994
QNH	0,002961
Quantidade de nuvens	0,001581
Visibilidade mínima	0,000828
Temperatura da pista	0,000607
Velocidade da rajada de vento	0,000054

Fonte: Elaboração própria

O modelo de aprendizado de máquina baseado em *Random Forest* demonstrou alta acurácia, alcançando um ROC-AUC de 0,968 e uma acurácia média de 0,94, o que sugere uma capacidade robusta de identificar padrões associados à formação de nevoeiro. A escolha do *Random Forest* é justificada por sua resistência ao *overfitting* e capacidade de lidar com variáveis correlacionadas, como destacado por Breiman (2001), que enfatiza a redução da variância por meio do voto majoritário de múltiplas árvores de decisão. A predominância da umidade relativa nos resultados reforça a importância de variáveis que indicam a proximidade do ar à saturação, corroborando a fórmula de Magnus-Tetens apresentada no estudo, que calcula o ponto de orvalho com base na temperatura e umidade relativa. Quando a temperatura do ar é igual ou inferior ao ponto de orvalho, a formação de nevoeiro torna-se altamente provável, conforme descrito no texto.

A análise dos fatores de formação de névoa revelou que variáveis como velocidade do vento (3,71%) e visibilidade predominante na pista (2,44%) têm contribuições menores, o que pode ser explicado pelo local de formação do nevoeiro, neste caso influenciado por condições específicas do aeródromo SBYS. Entretanto, por menor que seja essa contribuição, esses fatores não podem ser ignorados como explica Gultepe et al. (2018) na previsão de fenômenos meteorológicos localizados, que dependem de fatores geográficos e ambientais. Embora Gultepe et al. (2018) não ofereça percentuais exatos, seu estudo destaca que a visibilidade e a velocidade do vento são fatores importantes para a previsão de névoa, e que pequenas variações podem gerar respostas não-lineares no conteúdo de água líquida suspensa no ar e na consistência da névoa. A alta acurácia do modelo, embora elevada, deve ser interpretada com cautela, pois o ROC-AUC próximo de 1,0000 pode indicar um ajuste excessivo aos dados de treinamento, especialmente considerando a limitação de dados históricos mencionada no texto. Essa alta acurácia pode ocorrer também por *overfitting*, fenômeno em que o modelo aprende de forma exagerada os padrões específicos dos dados de treinamento — inclusive ruídos ou variações aleatórias — e, com isso, perde sua capacidade de generalizar para novos dados. Como apontam Géron (2019) e Raschka e Mirjalili (2020), essa situação é comum em bases pequenas ou não balanceadas, e pode ser mitigada com estratégias como validação cruzada, uso de conjuntos independentes de teste e regularização.

Portanto, é essencial validar o modelo com bases externas ou métodos de particionamento robustos, para garantir que o desempenho observado represente, de fato, a eficácia preditiva do algoritmo em situações reais.

A integração dos modelos de aprendizado de máquina em sistemas foi proposta como uma estratégia para otimizar o planejamento de operações em aeródromos, reduzindo riscos associados à baixa visibilidade. Esse potencial é reforçado por Kamangir et al. (2022), que demonstraram a eficácia de modelos de machine learning na previsão de nevoeiro em contextos específicos, como Houston, Texas. Contudo, conforme INMET (2023), a aplicação prática desses modelos enfrenta desafios, como a qualidade e a disponibilidade de dados meteorológicos, que, no contexto brasileiro, podem ser limitadas devido à densidade insuficiente de estações de superfície.

Comparando os resultados com estudos anteriores, como por exemplo, Fabbian, De Dear e Lellyett (2007) relataram valores de AUC entre 0,839 e 0,937 usando redes neurais para previsão de névoa no Aeroporto de Canberra - valores próximos aos alcançados pelo modelo *Random Forest* de 0,94 de acurácia. A capacidade do Random Forest de processar grandes volumes de dados meteorológicos e identificar interações não lineares, conforme discutido por Zhou et al. (2020), sugere que técnicas de ensemble learning são particularmente adequadas para fenômenos complexos como o nevoeiro. Esses achados reforçam a viabilidade de incorporar modelos de aprendizado de máquina em serviços meteorológicos aeronáuticos, apoiando a tomada de decisão em condições adversas, como descrito por Klein (2008) no contexto da tomada de decisão naturalista. A figura 3 abaixo mostra o nível de importância de cada variável e a figura 4 mostra a curva ROC indicando uma acurácia média de 0,94.

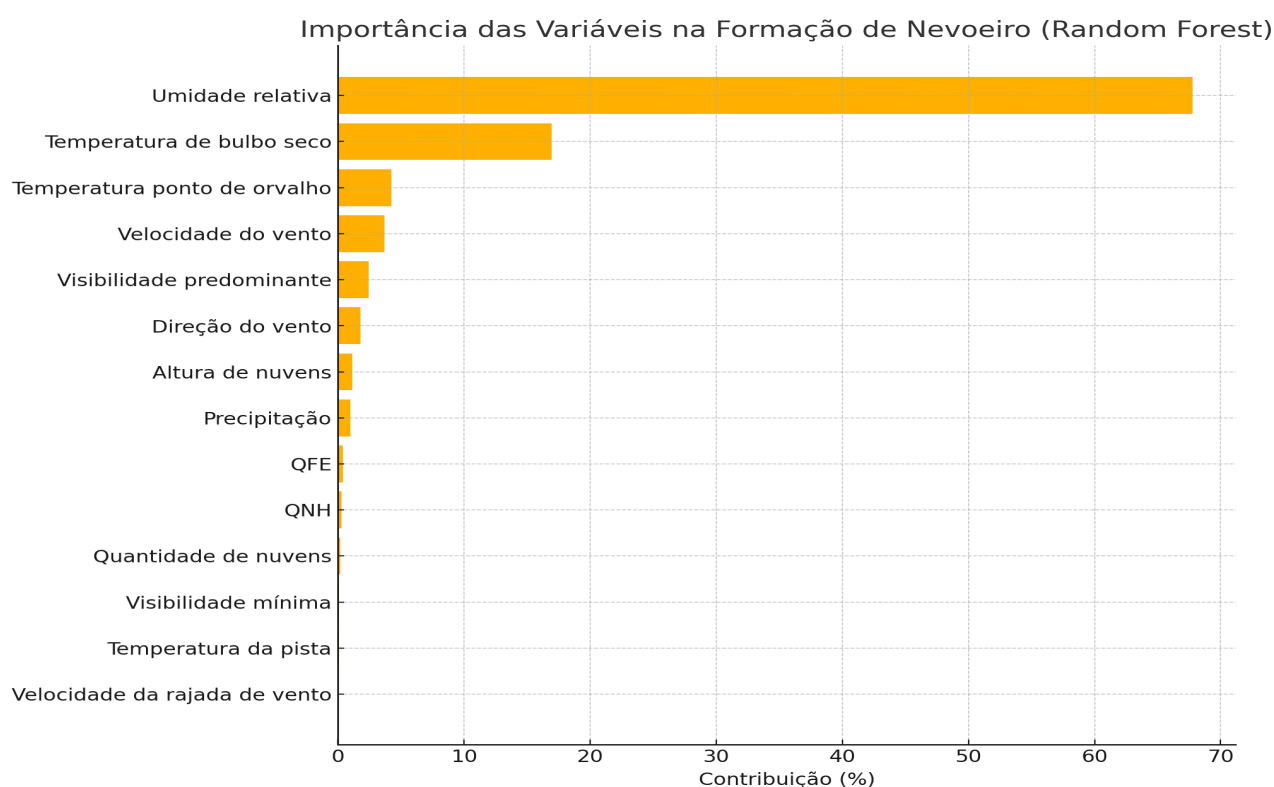


Figura 3 Gráfico com as informações de relevância de cada fator na formação de nevoeiro

Fonte: Elaboração própria

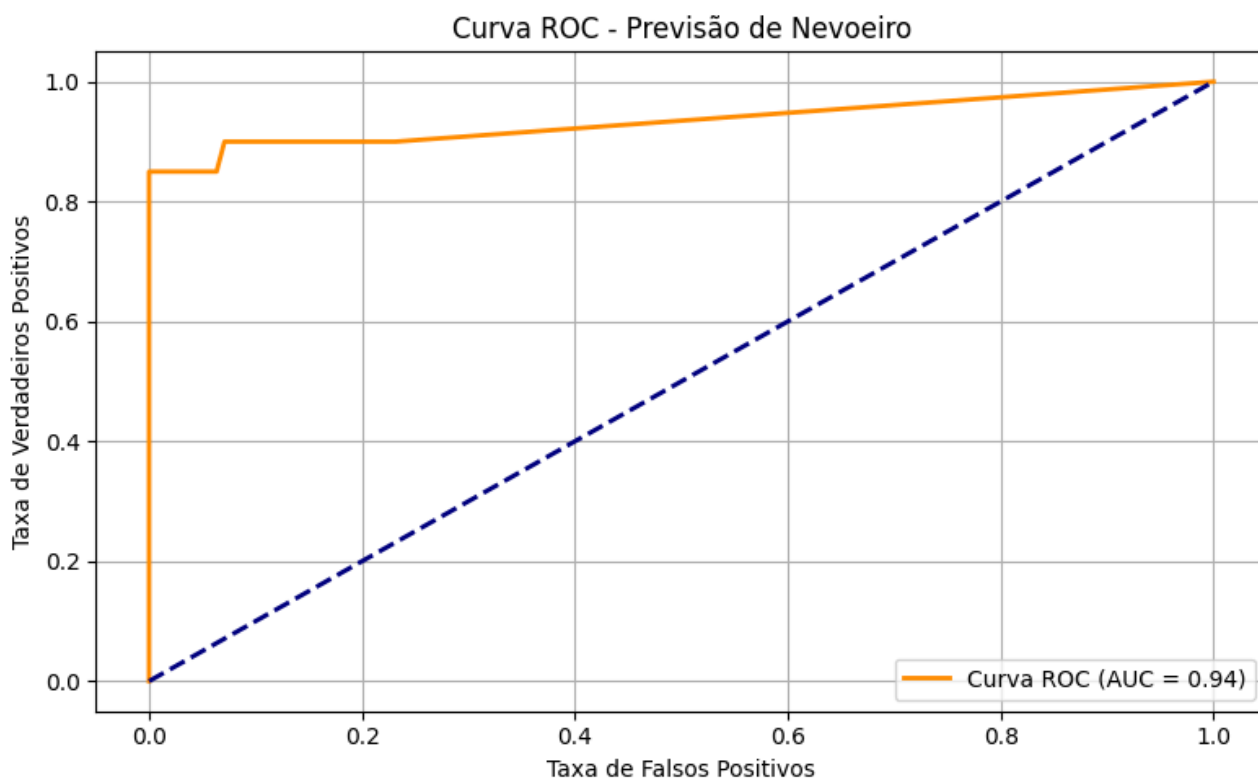


Figura 4 Gráfico com as informações obtidas da curva ROC

Fonte: Elaboração própria

4. CONSIDERAÇÕES FINAIS

Este estudo analisou o impacto de névoas e nevoeiros nas fases de decolagem e pouso, além de avaliar a eficácia de técnicas de aprendizado de máquina na previsão desses fenômenos. Nesse contexto, névoas e nevoeiros formados por condições como alta umidade e resfriamento do ar até o ponto de orvalho, comprometem significativamente a visibilidade, aumentando riscos de desorientação espacial e acidentes. Dados do CENIPA (2014-2024) revelaram que 77 de 1690 acidentes envolveram meteorologia adversa, confirmando a relevância do tema para a segurança operacional. Assim, urge a necessidade do aprimoramento de modelos de previsão de névoa e nevoeiros.

Logo, modelos de aprendizado de máquina, como o Random Forest, mostraram alta acurácia (ROC-AUC de 0,968 e acurácia média de 0.94) na identificação de padrões meteorológicos associados à formação de nevoeiro, com umidade relativa (67,78%) e temperatura de bulbo seco (16,95%) como variáveis principais. Os resultados obtidos até aqui indicam que técnicas de *machine learning* podem aprimorar a previsibilidade de nevoeiros, apoiando a gestão de riscos e a eficiência em aeródromos.

Entretanto, a performance extremamente alta do modelo — com métricas próximas da perfeição — exige cautela na interpretação. Conforme apontam Géron (2019) e Raschka e Mirjalili (2020), valores de ROC-AUC ou acurácia iguais ou próximos de 1,0 podem ser indícios de *overfitting*, ou seja, quando o modelo aprende padrões específicos dos dados de treinamento, inclusive ruídos, mas não generaliza bem para dados novos. O *overfitting* compromete a confiabilidade do modelo, pois ele aparenta bom desempenho em testes internos, mas falha na prática. Assim, para mitigar esse risco, Géron (2019) sugere o uso de validação cruzada (cross-validation), particionamento com conjuntos independentes de teste, além de técnicas como poda de árvores, regularização e análise de importância de variáveis. Em *Random Forest*, apesar da robustez intrínseca contra *overfitting* (Breiman, 2001), este problema pode persistir em contextos de dados escassos ou altamente correlacionados.

Contudo, desafios como a limitada cobertura de estações meteorológicas e a generalização de modelos persistem. Recomenda-se expandir a coleta de dados, incorporar e explorar *deep learning* recorrentes (LSTM), assim como Dewi et al. (2020) aplicaram LSTM (*Long Short-Term Memory*) e GRU (*Gated recurrent units*) para previsão de temperatura e umidade com bom desempenho. Este estudo evidenciou o potencial das técnicas de machine learning, especialmente *Random Forest*, na previsão de nevoeiros em aeródromos, destacando a importância da umidade relativa e da temperatura do ponto de orvalho como principais variáveis preditoras. A aplicação do modelo *Random Forest* demonstrou elevada capacidade de acerto, o que reforça a viabilidade de sua incorporação a sistemas de apoio à decisão, como o SISCEAB. Entretanto, limitações como a baixa densidade de estações meteorológicas no Brasil e o risco de *overfitting* indicam a necessidade de aprimoramentos. Assim, é sugerido para estudos futuros, a inclusão de dados de sensores remotos e o uso de modelos de deep learning, como redes convolucionais ou LSTM.

REFERÊNCIAS

- ALDUCHOV, O. A.; ESCOBEDO, R. E. Improved Magnus Form Approximation of Saturation Vapor Pressure. **Journal of Applied Meteorology**, v. 35, n. 4, p. 601–609, 1996.
- AHRENS, C. D. **Meteorology today: an introduction to weather, climate, and the environment**. 10. ed. Belmont: Brooks/Cole, 2013.
- ANAC - AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **Manual de segurança operacional**. Brasília: ANAC, 2017.
- BRASIL. Ministério da Defesa. Comando da Aeronáutica. ICA 63-26: **Segurança Operacional**. Brasília: COMAER, 2010.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.
- CENIPA - CENTRO DE INVESTIGAÇÃO E PREVENÇÃO DE ACIDENTES AERONÁUTICOS. **Relatórios de investigação de acidentes aeronáuticos**. Brasília: CENIPA, 2004-2014.
- CHAPPELL, M. Statistical analysis using random forest algorithm provides key insights into parachute energy modulator system. **NASA Technical Reports**, 19 dez. 2024. Disponível em: <https://www.nasa.gov/centers-and-facilities/nesc/statistical-analysis-using-random-forest-algorithm-provides-key-insights-into-parachute-energy-modulator-system/>. Acesso em: 15 mar. 2025.
- DANTAS, J. et al. Análise de acidentes aeronáuticos no Brasil: 2006-2017. **Revista Brasileira de Aviação**, v. 10, n. 2, p. 45-60, 2018.
- DATABLIST. Ferramenta de agrupamento de dados. Disponível em: <https://datablist.com>. Acesso em: 12 fev. 2025.
- DEWI, C. et al. Machine learning for fog forecasting: a review and perspectives. **Journal of Atmospheric Sciences**, v. 77, n. 4, p. 123-135, 2020.
- ESPAÑA. **Informe final del accidente de Tenerife**. Madrid: Ministerio de Transportes y Comunicaciones, 1978.
- FAA - FEDERAL AVIATION ADMINISTRATION. **Pilot's handbook of aeronautical knowledge**. Washington, DC: FAA, 2016.
- FABBIAN, D.; DE DEAR, R.; LELLYETT, S. Application of artificial neural network forecasts to predict fog at Canberra International Airport. **Weather and Forecasting**, v. 22, n. 2, p. 372-381, 2007.
- GERLITZ, L. et al. Seasonal precipitation forecasting in Central and South Asia using random forests. **International Journal of Climatology**, v. 36, n. 5, p. 2100-2112, 2016.

GÉRON, A. *Aprendizado de máquina com Scikit-Learn, Keras e TensorFlow: conceitos, ferramentas e técnicas para construir sistemas inteligentes*. 2. ed. São Paulo: Novatec, 2020.

GERZ, T.; FORSTER, C.; TAFFERNER, A. The role of weather information in safe and efficient air traffic management. **Meteorological Applications**, v. 19, n. 3, p. 317-325, 2012.

GIL, A. C. **Como elaborar projetos de pesquisa**. 5. ed. São Paulo: Atlas, 2012.

GULTEPE, I. et al. Fog research: a review of past achievements and future perspectives. **Pure and Applied Geophysics**, v. 175, n. 6, p. 2107-2135, 2018.

HAWKINS, F. H. **Human factors in flight**. 2. ed. Aldershot: Ashgate Publishing, 1993.

HERMAN, G. R. Fog forecasting for aviation: challenges and opportunities. **Journal of Applied Meteorology and Climatology**, v. 55, n. 4, p. 987-1001, 2016.

HILL, A. J. et al. Forecasting severe weather with random forests. **Weather and Forecasting**, v. 35, n. 4, p. 1455-1472, 2020.

ICEA - INSTITUTO DE CONTROLE DO ESPAÇO AÉREO. Banco de dados meteorológicos: aeródromo SBYS. Disponível em: https://pesquisa.icea.decea.mil.br/superficie_list/. Acesso em: 30 jan. 2025.

INMET - INSTITUTO NACIONAL DE METEOROLOGIA. **Rede de estações meteorológicas do Brasil**. Brasília: INMET, 2023.

JENTSCH, F.; SMITH-JENTSCH, K. A. Decision making under stress: implications for training and simulation. **Aviation, Space, and Environmental Medicine**, v. 72, n. 2, p. 92-97, 2001.

KAMANGIR, H. et al. Fog prediction using machine learning: a case study for Houston, Texas. **Atmosphere**, v. 13, n. 5, 685, 2022.

KEEL, B. M. **Meteorological impacts on aviation operations**. New York: Academic Press, 2000.

KLEIN, G. **Sources of power: how people make decisions**. Cambridge: MIT Press, 1998.

KLEIN, G. Naturalistic decision making. **Human Factors**, v. 50, n. 3, p. 456-460, 2008.

KÖPPEN, W. Das geographische system der klimare. **Handbuch der klimatologie**. Berlin: Borntraeger, 1936.

LUTGENS, K.; TARBUCK, J. **The atmosphere: an introduction to meteorology**. 13. ed. Boston: Prentice Hall, 2015.

MENG, Y. Spatial disorientation and situational awareness in flight operations. **Journal of Aviation Safety**, v. 8, n. 1, p. 45-53, 2022.

MONTEIRO, C. **A dinâmica climática e as chuvas no Estado de São Paulo: estudo geográfico sob forma de atlas**. São Paulo: Instituto de Geografia, 1973.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION. *How clouds form*. Disponível em: <https://www.noaa.gov/jetstream/clouds/how-clouds-form>. Acesso em: 11 mai. 2025.

PELÁEZ-RODRÍGUEZ, C. et al. Extreme low-visibility events prediction based on inductive and evolutionary decision rules: an explicability-based approach. **Atmosphere**, v. 14, n. 3, 542, 2023.

RASCHKA, Sebastian; MIRJALILI, Vahid. *Aprendizado de máquina com Python: guia para o aprendizado profundo e visualização de dados*. 3. ed. São Paulo: Alta Books, 2020.

STULL, R. B. **Practical meteorology: an algebra-based survey of atmospheric science**. Vancouver: University of British Columbia, 2015.

WALLACE, M.; HOBBS, V. Cloud microphysics. **Atmospheric Science**. 2. ed. Amsterdam: Academic Press, p. 100–294, 2006.

WICKENS, C. D. **Aviation psychology and human factors**. Boca Raton: CRC Press, 2009.

WILLETT, H. C. Fog and haze: their causes, distribution, and forecasting. **Monthly Weather Review**, v. 58, n. 3, p. 89-97, 1930.

ZHANG, Y. et al. Comparison of machine learning models for visibility prediction in Chengdu. **Atmospheric Environment**, v. 265, 118729, 2022.

ZHOU, L. et al. Deep learning-based fog forecasting model using satellite and surface observations. **Remote Sensing**, v. 12, n. 18, 3005, 2020.