

Classificação das Companhias Aéreas com Base na Eficiência Operacional: Uma Abordagem de Aprendizado de Máquina

João Antônio Vieira Barbosa¹, Rodrigo Martins da Silva Fajoses¹, Victor Andrade de Assis¹, João Vitor Brunheroto Anacleto¹, Álvaro Luiz Campos Justen da Costa¹, Mateus Habermann¹, Daniel Alberto Pamplona¹

¹Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

Resumo – A classificação de companhias aéreas é um tema de considerável relevância para diversos *stakeholders*, sendo tradicionalmente dominada por modelos de negócios como Tradicional (*Legacy*), Baixo Custo (LCC) e Híbrido. Contudo, essas classificações frequentemente carecem de critérios operacionais objetivos e padronizados, o que pode comprometer sua utilidade analítica e a capacidade de refletir a crescente convergência estratégica no setor. Este estudo tem como objetivo principal avaliar a eficácia da classificação tradicional e, concomitantemente, propor e validar um modelo alternativo de classificação fundamentado na eficiência operacional da frota. Para tal, foram utilizadas métricas operacionais reais de companhias aéreas norte-americanas, abrangendo o período de 1995 a 2020. Técnicas de aprendizado de máquina supervisionado, incluindo *Random Forest*, *Support Vector Machines* e Regressão Logística, foram empregadas para construir e comparar modelos preditivos baseados tanto na classificação tradicional quanto na abordagem proposta, esta última utilizando indicadores sintéticos de Produtividade da Frota (PF) e Intensidade Operacional Ajustada (IOA). Os resultados indicam que os modelos de *machine learning*, especialmente o *Random Forest*, demonstraram alta capacidade preditiva para ambas as abordagens de classificação. A classificação proposta, baseada em eficiência operacional, revelou-se não apenas robusta em termos de desempenho preditivo, com acurácias frequentemente superiores a 90%, mas também ofereceu maior interpretabilidade quanto aos fatores operacionais determinantes. Conclui-se que abordagens orientadas por dados, como a proposta, são promissoras para fornecer diagnósticos mais objetivos, replicáveis e acionáveis sobre a eficiência das companhias aéreas, complementando ou refinando as classificações tradicionais.

Palavras-Chave – Eficiência Operacional, Companhias Aéreas, Classificação Supervisionada.

I. INTRODUÇÃO

O setor de transporte aéreo é caracterizado por sua natureza intrinsecamente dinâmica e pela constante necessidade de adaptação dos modelos de negócio para assegurar a viabilidade comercial em um cenário de intensa competição e pressões externas.

As empresas aéreas são normalmente classificadas em dois grandes grupos de acordo com suas políticas gerenciais: *low-cost carriers* (LCC) e *full-service carriers* (FSC). O primeiro se destaca pela uniformização de frota e venda avulsa de serviços a fim de minimizar os custos operacionais

e logísticos [1]. Por outro lado, as FSC se caracterizam por frotas heterogêneas, serviços de bordo inclusos no preço da passagem e rotas mistas (longas e curtas) [2].

Tendo em vista o escopo do artigo, destaca-se que nos EUA esses mesmos grupos se distribuem em *Legacy* (FSC), LCC (*Low Cost Carriers*) e ULCC (*Ultra Low Cost Carriers*). Tem-se também uma terceira classificação, híbrida, que abrange empresas que usam modelos mistos de gestão.

Como foi observado por Magdalena e Bouzaima [3], cada vez mais as empresas são obrigadas a adotar estratégias de mercado mistas, fazendo com que classificações tradicionais fiquem defasadas e complexas, uma vez que exigem uma investigação excessivamente pormenorizada das políticas empresariais.

Este estudo propõe, portanto, um modelo de classificação supervisionada baseado em dados quantitativos e publicamente acessíveis, voltado à classificação de companhias aéreas conforme sua eficiência operacional de frota. A partir da construção de variáveis-alvo sintéticas representativas dessa eficiência, serão empregados algoritmos de aprendizado de máquina supervisionado, como Regressão Logística, *Random Forest*, *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), *Naive Bayes*, *Linear Discriminant Analysis* (LDA) e Árvore de Decisão, com vistas à previsão automatizada da classe de eficiência.

A base de dados utilizada nesta pesquisa inclui variáveis como horas médias diárias em voo, utilização média em horas de bloco, capacidade média de assentos, extensão média por etapa de voo e frota operacional total. Essas variáveis fornecem uma caracterização adequada do perfil de operação das companhias e possibilitam a construção de uma medida sintética de eficiência operacional centrada na frota.

O objetivo deste artigo é avaliar a eficácia da classificação tradicional de companhias aéreas, baseada em modelos de negócio, e propor uma nova abordagem de classificação fundamentada na eficiência operacional da frota. Para isso, são utilizadas métricas operacionais e técnicas de aprendizado de máquina supervisionado, com o intuito de comparar o desempenho preditivo e a interpretabilidade entre os modelos. Um dos principais aspectos que norteiam a discussão acerca da tradicional classificação é a tendência geral das companhias aéreas estarem adotando modelos de negócio cada vez mais semelhantes, o que torna difícil a sua distinção por modelo de negócio.

O modelo proposto visa ser aplicável à realidade do setor, oferecendo suporte às decisões com base em dados publicamente disponíveis e de fácil acesso. Busca-se, portanto, oferecer aos gestores e analistas uma ferramenta

J.A.V. Barbosa, joao.barbosa.20861@ga.ita.br; R.M.S. Fajoses, rodrigo.fajoses.20868@ga.ita.br; V.A. Assis, victor.assis.20869@ga.ita.br; J.V.B. Anacleto, joao.anacleto.20862@ga.ita.br; A.L.C.J. Costa, alvaro.costa.20853@ga.ita.br; M. Habermann, habermann@ita.br; D.A. Pamplona, pamplona@ita.br.

que permita a avaliação das empresas aéreas com base nos seus dados operacionais, facilitando a tomada de decisões quanto ao seu desempenho. Os métodos de *machine learning* foram utilizados a fim de agilizar e facilitar a classificação dos dados, sem contar na facilidade que oferecem para replicabilidade e análise de outras variáveis que porventura venham a ser discutidas.

Cientificamente, este estudo contribui para a literatura de gestão da aviação ao testar empiricamente a coerência das classificações tradicionais de companhias aéreas em relação a dados operacionais, utilizando metodologias robustas de aprendizado de máquina. Ele responde ao chamado de pesquisadores como Mason e Morrison [4] por abordagens mais consistentes para analisar modelos de negócio de companhias aéreas e oferece um novo arcabouço de classificação orientado por dados, baseado na eficiência operacional.

II. REFERENCIAL TEÓRICO

A indústria aérea tem historicamente categorizado seus participantes com base em modelos de negócios distintos. No contexto dos EUA, estes incluem as companhias de Rede (frequentemente denominadas companhias de Serviço Completo – FSC – ou companhias *Legacy*), as companhias de Baixo Custo (LCCs), as companhias de Ultrabaixo Custo (ULCCs) e uma categoria Híbrida cada vez mais reconhecida. As companhias *legacy*, como American Airlines, Delta Air Lines e United Airlines, tipicamente originaram-se antes da Lei de Desregulamentação das Companhias Aéreas dos EUA de 1978 e são caracterizadas por extensas redes *hub-and-spoke*, frotas diversificadas servindo rotas de curta e longa distância, tarifas agregadas frequentemente incluindo serviços complementares (refeições, bagagem), e participação em alianças globais e programas de passageiro frequente [1], [3], [5], [6], [7].

As companhias aéreas no espectro *legacy* geralmente operam modelos de rede em *hub-and-spoke* [1], com rotas de alta frequência [5], voando tanto rotas curtas quanto longas com frotas diversificadas. Suas estratégias de precificação são complexas e geralmente envolvem tarifas agrupadas e uma ampla gama de serviços, normalmente oferecendo programas de fidelidade e outros diferenciais como refeições de cortesia a bordo [6]. A oferta de descontos corporativos é outra característica das FSCs [7].

As companhias não *legacy* são divididas em duas categorias: as companhias de baixo custo (LCCs) — como a Southwest e a JetBlue — geralmente operam com custos mais baixos do que as companhias *legacy*. Tradicionalmente, operam modelos de rede ponto a ponto, sendo a uniformidade da frota uma característica frequentemente destacada como uma das ferramentas essenciais de redução de custos [4]. Seus fatores econômicos incluem frotas mais jovens, maior densidade de assentos, maior utilização das aeronaves e maior produtividade da mão de obra. Suas estratégias de precificação focam em tarifas desmembradas, com serviços adicionais mediante taxas extras [8].

Como observado por Magdalina *et al.* [3], as companhias nos extremos opostos do espectro estão se tornando mais

semelhantes. LCCs estão mirando viajantes de negócios e aderindo a sistemas globais de distribuição, enquanto FSCs estão adotando estratégias como aumento da densidade de assentos e padronização da frota.

A classificação baseada exclusivamente na eficiência operacional ganha, portanto, nova relevância, principalmente na avaliação da utilização de recursos. Estudos com essa abordagem podem apoiar decisões estratégicas de diversos agentes interessados. No desenvolvimento de um método para classificação por desempenho operacional, surgem desafios quanto aos critérios mais adequados, especialmente diante da abundância de dados.

A eficiência operacional está diretamente ligada à utilização dos recursos — frota, combustível, pessoal e capital — para maximizar a oferta de serviços, minimizando custos e desperdício [9].

Kiraci e Yasar [10] investigaram os principais fatores que influenciam o desempenho operacional, utilizando o RPK (*Revenue Passenger Kilometers*) como variável dependente, e fatores como passageiros transportados, fator de carga, número de voos, horas de voo e capacidade de carga como independentes. A métrica ASK (*Available Seat Kilometers*) foi usada para estimar capacidade, e o *load factor* como métrica da taxa de ocupação.

Durante a revisão bibliográfica, destacou-se o uso da Análise Envoltória de Dados (DEA) como método amplamente utilizado para mensurar eficiência relativa entre companhias. Essa técnica não-paramétrica permite a avaliação de múltiplos insumos e produtos sem imposição de pesos arbitrários [9]. Mhlanga [11], aplicando DEA em companhias da África Austral, destacou o número de aeronaves e o volume transportado como indicadores-chave de eficiência técnica.

Contudo, o DEA apresenta limitações, especialmente no que diz respeito à generalização e à capacidade preditiva. Por ser um método não supervisionado, não oferece um modelo replicável nem aplicável a novos dados [12].

Nesse sentido, métodos supervisionados como regressão, *random forest* e redes neurais têm sido propostos como complementares para melhorar a capacidade de classificação.

Wang *et al.* [13] modelaram consumo de combustível com dados de desempenho, utilizando redes neurais, regressão linear múltipla e *random forest*. Embora o foco não fosse a classificação de companhias, os algoritmos empregados fornecem base relevante.

Feng e Wang [12] também propuseram a incorporação de indicadores financeiros, além dos operacionais, na avaliação da sustentabilidade das companhias.

Assim, métodos supervisionados surgem como alternativa promissora para superar as limitações do DEA e permitir classificações robustas do desempenho operacional.

Tang [14] utilizou sete algoritmos para prever atrasos em voos, destacando o bom desempenho do *random forest* e *gradient boosting*. O estudo evidenciou a capacidade dos algoritmos de identificar padrões complexos com alta precisão.

Magdalina e Bouzaima [3], ao analisar 49 companhias europeias, propuseram um modelo de *clustering* para

redefinir perfis híbridos, reforçando a tendência de convergência entre LCC e FSC.

Wang *et al.* [13] obtiveram alta acurácia na modelagem de consumo de combustível com técnicas supervisionadas, e Rahman *et al.* [15] utilizaram métodos como *AdaBoost*, *XGBoost*, *CatBoost* e *Random Forest* para detectar anomalias em voos comerciais com precisão superior a 99%.

Esses exemplos demonstram que os métodos supervisionados combinam boa capacidade preditiva com possibilidade de replicação e atualização. Além disso, algoritmos baseados em árvores, como *Decision Trees* e *Random Forest*, oferecem interpretabilidade ao evidenciar variáveis preditoras relevantes, facilitando diagnósticos e decisões gerenciais [14].

III. METODOLOGIA

A. Procedimentos de coleta, preparação e análise dos dados

Os dados utilizados no presente estudo foram retirados do *MIT Airline Data Project*, abrangendo o período de 1995 a 2020. A base contempla 330 registros anuais, cada um representando os dados operacionais de uma companhia aérea em um determinado ano.

O banco de dados inclui as seguintes variáveis operacionais das companhias aéreas norte-americanas: média diária de horas voadas (mdhv); média diária de utilização por bloco de hora (mdubh); capacidade média de assentos (cma); distância média por estágio (dme); decolagens por aeronave por dia (dapd); consumo de combustível por bloco de hora (cbh); total de horas voadas (thv); total de horas em bloco (thb); e total de aeronaves da frota (taf).

Foram aplicadas as seguintes técnicas de aprendizado supervisionado: Regressão Logística, *Random Forest*, *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), *Naive Bayes*, *Linear Discriminant Analysis* (LDA) e *Árvore de Decisão*. Para avaliação dos modelos, utilizaram-se as métricas: acurácia, F1-score, precisão, revocação (*recall*) e área sob a curva ROC (AUC-ROC).

Com o objetivo de reduzir o impacto de valores extremos na construção do indicador de eficiência, adotou-se a técnica de *robust scaling* para normalização das variáveis, utilizando a mediana e o intervalo interquartil (IQR) como parâmetros de centralização e escala. Tal abordagem proporciona maior robustez frente à presença de assimetrias e outliers nos dados operacionais.

A validação dos modelos foi realizada por meio da técnica de *stratified k-fold cross-validation*. Considerando-se tratar de um problema de classificação multiclasse com classes desbalanceadas, a escolha dessa técnica garante que cada *fold* preserve a proporção original entre as classes, reduzindo o risco de *overfitting* e assegurando maior representatividade dos subconjuntos. Os resultados indicaram que o número ideal de *folds* é 5. Dado o número limitado de observações ($n = 330$), o uso de valores elevados de k tende a gerar subconjuntos com baixa representatividade de cada classe, o que compromete o desempenho dos modelos de classificação.

B. Formulação dos indicadores operacionais da frota

Neste estudo, foram testadas duas abordagens distintas de classificação das companhias aéreas: uma baseada na categorização tradicional adotada no setor, e outra proposta pelos autores, construída a partir de métricas operacionais.

A classificação tradicional foi formada a partir da literatura setorial e da categorização amplamente empregada em análises de mercado e regulação. As empresas aéreas norte-americanas são classificadas em: Tradicionais, Baixo Custo; Ultrabaixo Custo e Híbrida.

A classificação proposta no presente artigo explora a hipótese de que as empresas aéreas podem ser agrupadas com base em seu desempenho operacional. Os seguintes indicadores foram utilizados para reclassificar as empresas aéreas:

$$pf = thv/taf. \quad (1)$$

Onde:

pf: Produtividade da Frota. Indica quanto tempo cada aeronave, em média, voou

no período (quanto mais usada, mais produtiva).

thv: total de horas voadas

taf: total de aeronaves da frota

Com base nessa métrica, foram formadas duas versões de classificação:

- 2 classes: corte na mediana da eficiência (Alta e Baixa produtividade da frota)

- 3 classes: divisão em tercís (Baixa, Média e Alta produtividade da frota)

Adicionalmente, foi testada uma outra métrica de eficiência:

$$ioa = (mdhv \times dapd) / cbh \quad (2)$$

Onde:

ioa: Intensidade Operacional Ajustada. Une a intensidade diária e eficiência energética

mdhv: média diária de horas voadas

dapd: decolagens por aeronave por dia

cbh: consumo médio de combustível por bloco de hora

Essa métrica foi igualmente testada nos formatos binário e triclasse. Todas as classificações foram utilizadas como variável-alvo (*target*) nos modelos de aprendizado supervisionado.

IV. RESULTADOS E ANÁLISE DOS RESULTADOS

A. Resultado com a classificação tradicional

Os algoritmos testados incluíram: *Random Forest* (rf), *Support Vector Machine* com núcleo radial (svmRadial), *K-Nearest Neighbors* (knn), Regressão Logística Multinomial (multinom), *Linear Discriminant Analysis* (lda), *Naive Bayes*

(naive_bayes) e Árvore de Decisão (*rpart*). A avaliação do desempenho dos modelos foi realizada por meio das métricas: acurácia, F1-score (média), precisão (média), revocação (média) e área sob a curva ROC (AUC), esta última computada como média ponderada no contexto multiclasse (Fig.1).

O modelo *Random Forest* apresentou desempenho consistentemente superior na predição das classes tradicionais. Conforme apresentado na Tabela de Métricas de Desempenho dos Modelos e no gráfico comparativo, o *Random Forest* obteve acurácia média de 0,932, F1-score de 0,914, precisão de 0,926, revocação de 0,917 e AUC de 0,993. Esses resultados indicam uma elevada capacidade do modelo em identificar padrões operacionais coerentes com as categorias tradicionais de modelos de negócio.

Os modelos *Naive Bayes* (acurácia de 0,857; AUC de 0,965) e *KNN* (acurácia de 0,861; AUC de 0,967) também apresentaram resultados robustos, com acurácias superiores a 85%, reforçando a hipótese de que as variáveis operacionais contêm informação discriminatória relevante para as classificações históricas.

Em contraste, modelos como *SVM* (acurácia de 0,564) e Árvore de Decisão simples (*rpart*, acurácia de 0,767) tiveram desempenho inferior nesta tarefa específica.




Fig. 1. Comparação gráfica de métricas de avaliação por modelo de ML para classificação tradicional.

A alta acurácia obtida pelo *Random Forest* sugere que, apesar das críticas quanto à subjetividade e à crescente hibridização, os rótulos tradicionais ainda mantêm certa correspondência com perfis operacionais distintos — padrões que podem ser capturados por um modelo de aprendizado de máquina. No entanto, é importante ressaltar que essa capacidade preditiva não valida, por si só, tais classificações como as mais significativas ou adequadas para uma análise aprofundada da eficiência operacional, que constitui o cerne da investigação deste artigo.

A questão subsequente que se impõe é se classificações fundamentadas explicitamente em indicadores de eficiência operacional podem fornecer diagnósticos adicionais — ou mesmo mais diretos — sobre o desempenho das companhias aéreas, em comparação com as categorias tradicionais.

B. Resultado com a classificação proposta

As mesmas técnicas de aprendizado supervisionado foram aplicadas para prever as classificações de eficiência operacional propostas, baseadas nos indicadores de Produtividade da Frota (PF) e Intensidade Operacional Ajustada (IOA), considerando tanto a versão binária (Alta/Baixa eficiência) quanto a segmentação por tercís (Baixa, Média e Alta eficiência).

B1. Classificação baseada na Produtividade da Frota (PF)

Nos modelos binários utilizando o indicador PF como variável-alvo (Fig.2), o *Random Forest* novamente se destacou, mantendo a maioria dos indicadores de desempenho acima de 95%. Especificamente, obteve acurácia de 0,962, F1-score de 0,958, precisão de 0,985, revocação de 0,938 e AUC de 0,990. Outros modelos, como *KNN* (acurácia de 0,879; AUC de 0,940) e *SVM* (acurácia de 0,849; AUC de 0,944), também apresentaram bom desempenho, embora inferiores ao *Random Forest*.




Fig. 2. Comparação gráfica de métricas de avaliação por modelo de ML para classificação PF (binária).

Para a classificação da PF em tercís (Fig.3), o *Random Forest* manteve um desempenho robusto, com acurácia de 0,910, F1-score de 0,909, precisão de 0,911, revocação de 0,910 e AUC de 0,980¹. Modelos como *KNN* e *SVM* apresentaram acurácias em torno de 0,77 a 0,78 nessa tarefa mais granular.

B2. Classificação baseada na Intensidade Operacional Ajustada (IOA)

Para a variável IOA, o desempenho dos modelos foi levemente inferior ao observado com PF, embora ainda satisfatório. Na classificação binária da IOA, o *Random Forest* apresentou acurácia e demais métricas geralmente situadas entre 80% e 93% (Fig. 4).




Fig. 3. Comparação gráfica de métricas de avaliação por modelo de ML para classificação PF (tercis).

Na predição por tercís da IOA, os resultados também se mostraram robustos, com o *Random Forest* mantendo bom desempenho, com indicadores em sua maioria acima de 85%. Observou-se que a classe intermediária ("Média") foi consistentemente a mais difícil de discriminar pelos modelos na classificação por tercís, tanto para PF quanto para IOA — o que é esperado em problemas de classificação ordinal envolvendo categorias centrais (Fig. 5).




Fig. 4. Comparação gráfica de métricas de avaliação por modelo de ML para classificação IOA (Binária).

A comparação entre os resultados da predição da classificação tradicional e das classificações propostas (PF e IOA, binárias e em tercís) revela uma notável capacidade dos modelos de aprendizado de máquina — em particular o *Random Forest* — em alcançar altos níveis de desempenho preditivo em todos os cenários. Uma análise mais detalhada das métricas revela nuances interessantes. Por exemplo, o *Random Forest* obteve acurácia de 0,962 na classificação binária da PF, superando ligeiramente os 0,932 obtidos na predição da classificação tradicional. Este desempenho consistentemente elevado sugere que as variáveis operacionais disponíveis contêm sinais fortes e discerníveis para ambos os tipos de categorização.




Fig. 5. Comparação gráfica de métricas de avaliação por modelo de ML para classificação IOA (Binária).

As classificações propostas, PF e IOA, são, por construção, operacionalmente coerentes, uma vez que derivam diretamente de métricas de desempenho da frota. A questão central é se os agrupamentos formados por essas classificações (por exemplo, companhias com "Alta PF") exibem características operacionais intuitivamente consistentes — o que pode ser verificado por meio da análise exploratória de dados. A análise de importância das variáveis nos modelos *Random Forest* para PF e IOA confirmou que atributos como mdhv, thv, taf, cbh e dapd foram determinantes. Essa identificação de direcionadores é fundamental para a interpretabilidade, tornando possível explicar por que uma companhia foi classificada como de "Alta PF" (por exemplo, devido a muitas horas voadas e frota otimizada), de forma mais direta e objetiva do que justificar por que ela foi rotulada como "Híbrida" com base em critérios tradicionais, frequentemente qualitativos e multifacetados. A capacidade de associar a classificação a fatores operacionais específicos confere aos indicadores PF e IOA um poder diagnóstico valioso.

Enquanto as classificações propostas são inerentemente consistentes com as métricas operacionais, a avaliação da classificação tradicional sob essa ótica revela maior complexidade. A acurácia de 93,24% do *Random Forest* na predição dos rótulos tradicionais indica que eles não estão completamente dissociados da realidade operacional — há, de fato, arquétipos operacionais que os modelos conseguem aprender. No entanto, como discutido na análise exploratória e no referencial teórico, a variabilidade interna das categorias (especialmente a "Híbrida") e a crescente convergência dos modelos de negócio indicam que a consistência operacional dentro de cada rótulo tradicional pode estar enfraquecida.

PF e IOA capturam dimensões distintas da eficiência: PF se concentra na taxa de trabalho bruta da frota, enquanto IOA introduz uma perspectiva de intensidade diária ajustada pelo consumo de combustível. Caso os modelos de PF apresentem desempenho ligeiramente superior, como sugerem os resultados, é possível que as variáveis de entrada estejam mais bem alinhadas à mensuração da "taxa de trabalho" do que à "intensidade ajustada por consumo". Esta última pode representar um construto mais complexo. A classificação

binária oferece simplicidade, enquanto a abordagem em três categorias provê maior nuance, embora a classe intermediária ("Média") se revele, como observado, mais difícil de delimitar.

V. CONCLUSÃO

Este estudo teve como objetivo central avaliar a eficácia da classificação tradicional de companhias aéreas, predominantemente baseada em modelos de negócio, e propor uma nova abordagem de classificação fundamentada na eficiência operacional da frota. Para alcançar esse propósito, foram utilizadas métricas operacionais quantitativas e técnicas de aprendizado de máquina supervisionado, permitindo uma comparação direta do desempenho preditivo e da interpretabilidade entre os modelos derivados de ambas as abordagens classificatórias.

Os resultados demonstraram que modelos de aprendizado de máquina — com destaque para o *Random Forest* — possuem uma capacidade robusta de predição tanto para as categorias tradicionais quanto para as classificações propostas, baseadas nos indicadores de Produtividade da Frota (PF) e Intensidade Operacional Ajustada (IOA). A classificação tradicional, embora criticada por sua subjetividade e crescente desatualização frente à hibridização dos modelos de negócio, mostrou-se, em certa medida, sustentada pelos dados operacionais, uma vez que os algoritmos conseguiram identificar padrões com acurácia superior a 90%. Isso sugere que, historicamente, os rótulos tradicionais corresponderam a arquétipos operacionais discerníveis.

Contudo, as classificações propostas, construídas a partir de métricas objetivas de eficiência — como horas voadas, decolagens diárias, utilização da frota e consumo de combustível — não apenas alcançaram níveis de desempenho preditivo comparáveis ou superiores, como também trouxeram ganhos significativos em termos de interpretabilidade. A capacidade de identificar as variáveis operacionais específicas que mais contribuem para a categorização de uma companhia como de alta, média ou baixa eficiência (PF ou IOA) confere a essa abordagem um valor diagnóstico considerável. Essa clareza sobre os direcionadores de eficiência é fundamental para análises comparativas mais fundamentadas e para a formulação de estratégias de otimização operacional.

Do ponto de vista prático, os achados deste estudo reforçam o potencial de abordagens orientadas por dados para subsidiar decisões de investimento, planejamento estratégico e *benchmarking* no setor aéreo. A utilização de classificações baseadas em eficiência pode tornar as comparações entre empresas mais transparentes, tecnicamente embasadas e menos suscetíveis a rótulos históricos que podem não refletir a complexidade operacional atual. Isso representa uma ferramenta valiosa para gestores, analistas e reguladores que buscam compreender e fomentar o desempenho no setor. Adicionalmente, este trabalho contribui para consolidar a tendência de aplicação de técnicas de *machine learning* na análise de características específicas de empresas aéreas,

promovendo uma tomada de decisão mais fundamentada em evidências quantitativas.

Pesquisas futuras poderiam expandir essa análise para outros contextos geográficos e regulatórios, incorporar múltiplas dimensões de desempenho (financeiro, ambiental, satisfação do cliente), e refinar os critérios de classificação, possivelmente desenvolvendo métricas de eficiência mais abrangentes ou específicas para nichos de mercado.

REFERÊNCIAS

- [1] R. Doganis, *Flying off Course: Airline Economics and Marketing*, 4th ed. London: Routledge, 2010.
- [2] I. Iatrou and A. Oretti, *Airline Choices for the Future: From Alliances to Mergers*. Burlington, VT: Ashgate, 2007.
- [3] A. Magdalina and M. Bouzaima, "An empirical investigation of European airline business models: Classification and hybridisation," *J. Air Transp. Manag.*, vol. 93, 2021. doi: 10.1016/j.jairtraman.2021.102059.
- [4] K. J. Mason and W. G. Morrison, "Towards a means of consistently comparing airline business models with an application to the 'low cost' airline sector," *Res. Transp. Econ.*, vol. 24, pp. 75–84, 2009. doi: 10.1016/j.retrec.2009.01.006.
- [5] M. Wojahn, *Aviation Economics: The Management of Costs and Revenues*. Hamburg: Avinus Press, 2002.
- [6] L. Tomová and K. Ramajová, "Full-service vs. low-cost carriers: Network structure and pricing strategies," *Transp. Pol.*, vol. 35, pp. 71–79, 2014.
- [7] J. Pachon, M. Erkoc, and E. Iakovou, "Contract optimization with front-end fare discounts for airline corporate deals," *Transp. Res. Part E Logist. Transp. Rev.*, vol. 43, no. 4, pp. 425–441, 2007.
- [8] X. Fageda, P. Suaui-Sanchez, and K. J. Mason, "The evolving low-cost business model: Network implications of fare bundling and connecting flights in Europe," *J. Air Transp. Manag.*, vol. 42, pp. 289–296, 2015.
- [9] A. Saini, D. Truong, and J. Y. Pan, "Airline efficiency and environmental impacts – Data envelopment analysis," *Int. J. Transp. Sci. Technol.*, vol. 12, pp. 335–353, 2023. doi: 10.1016/j.ijtst.2022.02.005.
- [10] K. Kiraci and M. Yasar, "The determinants of airline operational performance: An empirical study on major world airlines," *Sosyoekonomi*, vol. 28, no. 43, pp. 107–117, 2020. doi: 10.17233/sosyoekonomi.2020.01.06.
- [11] O. Mhlanga, "Factors impacting airline efficiency in Southern Africa: A data envelopment analysis," *GeoJournal*, vol. 84, pp. 759–770, 2019. doi: 10.1007/s10708-018-9889-9.
- [12] C.-M. Feng and R.-T. Wang, "Performance evaluation for airlines including the consideration of financial ratios," *J. Air Transp. Manag.*, vol. 6, no. 3, pp. 133–142, 2000.
- [13] M. Wang, J. Liu, and Q. Zhang, "Fuel consumption modeling using machine learning for aircraft performance optimization," *Alexandria Eng. J.*, vol. 126, pp. 300–312, 2025. doi: 10.1016/j.aej.2025.03.017.
- [14] Y. Tang, "Airline flight delay prediction using machine learning models," in *Proc. Int. Conf. E-Business Internet (ICEBI)*, Singapore, 2021, p. 4. doi: 10.1145/3497701.3497725.
- [15] M. A. Rahman, T. Bhuiyan, and M. A. Ali, "Enhancing aviation safety: Machine learning for real-time ADS-B injection detection through advanced data analysis," *Alexandria Eng. J.*, vol. 126, pp. 262–276, 2025. doi: 10.1016/j.aej.2025.04.045.