

# **A INFLUÊNCIA DOS *DEPARTURE PROCEDURES-66B* NOS ATRASOS DA COMPANHIA AÉREA PORTUGÁLIA**

Uma análise exploratória

---

**DAVID DANIEL ALJUSTREL SERRANO**

Provas destinadas à obtenção de grau de:

Mestre em Operações de Transporte Aéreo

Junho de 2025

**VERSÃO FINAL**



ISEC LISBOA | INSTITUTO SUPERIOR DE EDUCAÇÃO E CIÊNCIAS

Escola de Gestão, Engenharia e Aeronáutica

Provas para obtenção do grau de Mestre em Operações de Transporte Aéreo

**A influência dos *Departure Procedures* – 66b nos atrasos dos voos da companhia aérea Portugália**

Uma análise exploratória

Autor: David Daniel Aljustrel Serrano

Orientador: Professor Especialista Eurico Pimenta de Brito

Co - Orientador: Professora Doutora Ana Cristina Cabrita Freitas

Junho de 2025



## **AGRADECIMENTOS**

Este estudo marca a conclusão do meu Mestrado, motivo pelo qual expresso o meu profundo agradecimento à minha família.

Aos meus filhos, Ana Carolina e Miguel, agradeço por me darem a oportunidade de ser, através do seu olhar, um exemplo de compromisso, ambição e vontade de evoluir, nomeadamente no que respeita à formação e à aquisição de conhecimento de acordo com os seus interesses.

À minha esposa, Catarina, deixo um agradecimento especial pela compreensão, apoio incondicional e por me permitir ser quem sou, muitas vezes abdicando do tempo na minha companhia e assumindo responsabilidades decorrentes da minha ausência, exigida por este percurso académico.

À restante família, em especial aos meus irmãos, o meu sincero agradecimento por serem, desde sempre, um exemplo a seguir e a acompanhar.

Agradeço igualmente à companhia de aviação Portugália, na pessoa do Diretor de Operações de Voo, bem como a todos os colegas do Departamento de Análise e Engenharia de Dados, cujo envolvimento foi decisivo na coordenação e definição do tema para a defesa da presente tese. Este apoio revelou-se fundamental por me motivar através de desafios reais e por me permitir adquirir uma nova perspetiva sobre uma indústria na qual, apesar de já possuir experiência profissional, nunca tinha aprofundado conhecimentos nas matérias abordadas neste estudo, possibilitando ainda a aplicação prática de grande parte dos conhecimentos académicos adquiridos ao longo do curso de mestrado.

Não menos importante, expresso um especial agradecimento aos meus orientadores, Professor Especialista Eurico de Brito e Professora Doutora Ana Cristina Freitas, por toda a disponibilidade, resiliência e conhecimento que me transmitiram ao longo de todo o processo de desenvolvimento deste trabalho.

Por fim, agradeço a todos os Professores, aos serviços académicos e aos colegas de Mestrado, pela partilha de experiências, conhecimentos e momentos que levarei comigo para sempre.

[esta página foi deixada em branco deliberadamente]

## RESUMO

A pontualidade constitui um dos principais indicadores de desempenho na aviação comercial, com impacto direto na reputação e eficiência das companhias aéreas. O código 66 (IATA) é usado para identificar atrasos relacionados com a tripulação de cabine nos procedimentos de partida. A TAP/PGA acrescenta o B quando estão em causa procedimentos sob responsabilidade da cabine que impedem o embarque no horário previsto ou causam um atraso na saída do voo. Este estudo analisa o atraso 66B - *Departure Procedures* (DP) numa amostra com 14.127 registos (efetuados entre set.–dez. 2022), 19,6% dos quais (N=2765) suscetíveis de intervenção pela companhia e 80,4% não controláveis, ocorrendo de forma isolada (10,8%) e combinada (89,2%) com outros tipos de atraso. Pretendeu-se compreender a especificidade do atraso 66B nos voos da PGA quanto à sua frequência, impacto temporal e relação com outros tipos de atraso, visando propostas de melhoria. Os resultados mostraram que, quanto à sua frequência, o 66B ocupa a 12ª posição na amostra global e o 4º lugar no grupo dos atrasos controláveis. Quanto à sua duração, o 66B ocupa o 26º lugar no *ranking* da duração total, o 160º lugar quanto à duração média ( $M= 8,08$ ) por ocorrência, em geral. No grupo dos controláveis, o 66B situa-se no 57º nos *rankings*. Verificaram-se diferenças significativas entre os dois tipos de atraso, controláveis (onde se insere o 66B) e não controláveis, através do teste  $t$  de Welch ( $F_{(1,14126)}=131.23$ ,  $p<. 001$ ) e do teste de  $U$  de Mann-Whitney ( $U=12312897.0$ ,  $z=-17,65$ ,  $p<.001$ ). Quanto aos atrasos compostos com o envolvimento do 66B, o teste Kruskal-Wallis revelou diferenças significativas entre grupos de complexidade distinta até um máximo de 2 atrasos compostos, a duração média do atraso global cresce de forma significativa ( $H=95,06$   $p<.001$ ). Conclui-se que o comportamento do atraso do 66B na amostra revela (1) frequência expressiva dentro dos atrasos controláveis, (2) tendência clara para a inserção em cadeias de atraso compostas, com impacto amplificado; (3) articulação com falhas em planeamento, cockpit e embarque. Propõem-se medidas concretas, como a padronização de procedimentos e melhoria da coordenação entre equipas, para reforçar a eficiência da operação.

Palavras-chave:

Atrasos operacionais, código 66B, pontualidade, Portugália Airlines, aviação regional, análise de atrasos, gestão de desempenho

[esta página foi deixada em branco deliberadamente]

## ABSTRACT

*Punctuality is one of the main performance indicators in commercial aviation, with a direct impact on airline reputation and operational efficiency. IATA code 66 is used to identify delays related to cabin crew during departure procedures. TAP/PGA adds the suffix “B” when the delay is caused by processes under the cabin crew’s responsibility that prevent timely boarding or delay the aircraft’s departure. This study analyses delay code 66B – Departure Procedures (DP) – based on a sample of 14,127 records (collected between September and December 2022), of which 19.6% (N=2,765) were controllable by the airline and 80.4% were not. These occurred either in isolation (10.8%) or in combination with other delay codes (89.2%). The aim was to understand the specific behaviour of delay 66B on PGA flights in terms of frequency, duration, and its relationship with other delay types, to support operational improvements. Results show that 66B ranked 12th in the overall frequency and 4th among controllable delays. In terms of duration, it ranked 26th in total delay time and 160th in average delay per occurrence (M=8.08). Within the controllable group, 66B ranked 57th. Significant differences between controllable (including 66B) and non-controllable delays were confirmed using Welch’s t-test ( $F_{(1,14126)}=131.23, p<.001$ ) and the Mann-Whitney U test ( $U=12312897.0, z=-17.65, p<.001$ ). Regarding compound delays involving 66B, the Kruskal-Wallis test revealed significant differences between levels of complexity: up to two combined delays, the overall average duration increases significantly ( $H=95.06, p<.001$ ). It is concluded that 66B delays in the sample demonstrate: (1) high frequency within controllable delays, (2) a clear tendency to form part of compound delay chains with amplified impact, and (3) strong association with planning, cockpit, and boarding failures. Concrete measures are proposed, such as the standardisation of procedures and improved coordination between teams, to enhance operational efficiency.*

### *Keywords:*

*Operational delays, code 66B, punctuality, Portugália Airlines, regional aviation, delay analysis, performance management*

[esta página foi deixada em branco deliberadamente]

## ÍNDICE

<b>1. INTRODUÇÃO.....</b>	<b>19</b>
1.1. Generalidades .....	19
1.2. Âmbito.....	21
1.3. Motivação.....	23
1.4. Objetivos .....	24
1.5. Metodologia .....	25
1.6. Estrutura do Trabalho.....	25
<b>2. ENQUADRAMENTO TEÓRICO .....</b>	<b>27</b>
2.1. A pontualidade como fator estratégico.....	27
2.2. Impactos económicos e reputacionais dos atrasos .....	28
2.3. Codificação dos atrasos e fatores causadores.....	30
2.3.1. Classificação e codificação dos atrasos IATA.....	32
2.3.2. Fatores não controláveis .....	36
2.3.3. Fatores controláveis .....	38
2.4. Adaptações operacionais: o caso do grupo TAP.....	39
2.4.1. <i>Departure Procedures</i> .....	41
<b>3. DESENVOLVIMENTO DO TEMA.....</b>	<b>45</b>
3.1. A amostra analisada .....	45
3.1.1. Estrutura dos registos e registos compostos .....	46
3.1.2. Catalogação preliminar dos códigos de atraso .....	46
3.1.3. Limitações da amostra.....	47
3.2. Estratégia de análise .....	47
<b>4. RESULTADOS.....</b>	<b>50</b>
4.1. Atrasos com maior frequência e duração .....	50

<b>4.2. Controláveis vs. Não Controláveis.....</b>	<b>55</b>
4.2.1. Medidas descritivas e distribuições.....	55
<b>4.3. Comportamento do atraso 66B em frequência, duração e na relação com outros atrasos .....</b>	<b>58</b>
4.3.1. A frequência do 66B .....	59
4.3.2. A duração do 66B .....	62
4.3.3. Relação com outros atrasos .....	63
<b>5. DISCUSSÃO .....</b>	<b>70</b>
<b>6. CONCLUSÕES .....</b>	<b>80</b>
<b>REFERÊNCIAS.....</b>	<b>84</b>
<b>ANEXOS.....</b>	<b>92</b>

## ÍNDICE DE FIGURAS

Figura 1: CODA Delay groupings (EUROCONTROL, 2019, p:26) .....	35
Figura 2: Ordenação dos atrasos por frequência .....	50
Figura 3: Ordenação dos atrasos por duração .....	<b>Erro! Marcador não definido.</b>
Figura 4: Relação frequência e duração, por código de atraso .....	55
Figura 5: contagem de voos por atraso (Total da amostra) .....	56
Figura 6: Distribuição dos atrasos (0 a <175) .....	56
Figura 7: O atraso 66B nos Top 20 da mostra, quanto à frequência .....	59
Figura 8: O atraso 66B nos top 20 da amostra, quanto à frequência no grupo C.....	60
Figura 9: O atraso 66B nos top 20 da amostra, quanto à duração .....	62
Figura 10: O atraso 66B nos top 20 da amostra, quanto à duração no grupo C.....	62
Figura 11: Top 20 Combinações de Códigos com 66B .....	64
Figura 12: Atraso médio total por nível de complexidade, no grupo C .....	66

## ÍNDICE DE TABELAS

Tabela 1: Campos da amostra .....	45
Tabela 2: Enquadramento dos códigos .....	52
Tabela 3: Medidas descritivas dos atrasos Controláveis e Não Controláveis .....	55
Tabela 4: Comparação entre os atrasos C e NC quanto à duração .....	58
Tabela 5: Enquadramento dos códigos controláveis, quanto à sua frequência .....	61
Tabela 6: Posição do 66B no conjunto total de atrasos .....	63
Tabela 7: Posição do 66B no conjunto dos atrasos C.....	63
Tabela 8: Distribuição dos voos por grau de complexidade .....	65
Tabela 9: Duração por nível de complexidade .....	65
Tabela 10: Teste post-hoc Dunn-Bonferroni .....	66
Tabela 11: Classificação dos códigos por controlabilidade .....	68



## ABREVIATURAS E SIGLAS

<b>AHM</b>	Airport Handling Manual
<b>ATC</b>	Air Traffic Control (Controlo de Tráfego Aéreo)
<b>ATFM</b>	Air Traffic Flow Management
<b>CODA</b>	Central Office for Delay Analysis (EUROCONTROL)
<b>DP</b>	Departure Procedures (Procedimentos de Partida)
<b>EASA</b>	European Union Aviation Safety Agency
<b>ETA</b>	Estimated Time of Arrival
<b>GMC</b>	Ground Movement Control
<b>GPU</b>	Ground Power Unit
<b>IATA</b>	International Air Transport Association
<b>ICAO</b>	International Civil Aviation Organization
<b>IGOM</b>	IATA Ground Operations Manual
<b>IQR</b>	Interquartile Range (Intervalo Interquartil)
<b>ISEC</b>	Instituto Superior de Educação e Ciências
<b>KLM</b>	Koninklijke Luchtvaart Maatschappij (Royal Dutch Airlines)
<b>KPI</b>	Key Performance Indicator
<b>NC</b>	Não Controlável
<b>OCC</b>	Operations Control Center
<b>ORO</b>	Operations Requirements Organisation (EASA Part ORO)
<b>PGA</b>	Portugália Airlines
<b>TAP</b>	Transportes Aéreos Portugueses

**TAP/PGA** TAP e Portugália Airlines (em conjunto)



# 1. INTRODUÇÃO

## 1.1. Generalidades

No setor da aviação, entre os principais indicadores de desempenho operacional salienta-se a pontualidade, um elemento fundamental para a reputação, fidelização de clientes e otimização de custos. Os atrasos, por sua vez, constituem uma das principais fragilidades operacionais, com impacto financeiro significativo e consequências ao nível da experiência do passageiro, da conectividade e da cadeia logística da aviação (Fujun et al. 2022; Peterson et al., 2011). Os custos económicos dos atrasos aéreos são substanciais, abrangendo desde a perda de produtividade até à reprogramação de operações e compensações aos passageiros. Lin, (2023) estima que, no contexto europeu, os atrasos podem representar perdas anuais superiores a milhares de milhões de euros, salientando a importância do controlo rigoroso das causas internas evitáveis.

Segundo Singh et al. (2024), a pontualidade tem-se tornado uma prioridade estratégica, uma vez que os atrasos afetam diretamente o desempenho financeiro e a perceção do serviço prestado. A análise operacional demonstra que os fatores causadores de atrasos são muitas vezes interdependentes, o que agrava o desafio da mitigação em tempo real. Esta complexidade exige não apenas sistemas de previsão mais precisos, mas também um reforço na coordenação entre departamentos internos da companhia aérea.

Britto et al., (2012) reforçam que o impacto dos atrasos não se limita à operação de um único voo, estendendo-se à rotação de aeronaves, escalas de tripulação e conexões em rede. Esta propagação é particularmente sensível em companhias regionais, como a Portugália Airlines, que operam com intervalos reduzidos entre voos e estruturas de planeamento pouco flexíveis.

Além disso, o estudo de Wang et al., (2020) aponta para a importância dos processos em terra como fator crítico para a pontualidade, sublinhando que falhas nesta fase tendem a desencadear atrasos sucessivos ao longo do dia operativo. Assim, é essencial estudar os procedimentos de partida em maior detalhe, com enfoque específico na sua contribuição para a propagação de atrasos sistémicos.

De acordo com Sternberg et al. (2020), a análise e a previsão de atrasos nos voos tornaram-se uma prioridade estratégica para as companhias aéreas, nomeadamente pela crescente saturação da infraestrutura aeroportuária e do espaço aéreo.

Para melhor interpretação das vicissitudes operacionais, existem códigos para rotular os atrasos sentidos pelas companhias aéreas e restantes *players* do setor da aviação. Essa codificação obedece a boas práticas defendidas e implementadas pela *International Air Transport Association*. Por exemplo, designação “66” tem origem na tabela internacional de códigos de atraso da IATA, estabelecida no manual AHM 730 (*Airport Handling Manual*), que padroniza as causas de atraso utilizadas globalmente pela indústria da aviação. O código 66 refere-se de forma genérica a atrasos provocados por questões relacionadas com a tripulação de cabine.

No caso da TAP Air Portugal, esta categoria foi subdividida em 66A e 66B, como forma de obter maior precisão analítica. O subcódigo 66A é utilizado quando o atraso decorre da chegada tardia da tripulação de cabine a bordo (*Cabin Crew Late on Board*), enquanto o 66B é aplicado quando processos associados à atuação da tripulação impedem o embarque atempado ou contribuem para o atraso na partida (*Departure Procedures*). Esta segmentação interna, embora não esteja formalmente prevista na estrutura do AHM 730, é compatível com a lógica do sistema IATA e representa uma prática comum em companhias com operações complexas. Ao permitir distinguir diferentes causas sob a mesma categoria-base, reforça a rastreabilidade dos eventos e apoia intervenções operacionais mais dirigidas (Ionescu et al., 2016; Y. Wang et al., 2020; Zámková et al., 2017).

Adicionalmente, estudos recentes têm vindo a reforçar a importância de se entender os atrasos como um fenómeno dinâmico, cuja origem pode estar em fatores iniciais de pequena magnitude, mas com elevada capacidade de propagação ao longo da rede. Li e Yao, (2025) sublinham que, em companhias regionais, esta propagação é particularmente acentuada pela ausência de *buffers* temporais e pela elevada dependência entre segmentos operacionais consecutivos. O fenómeno torna-se ainda mais preocupante quando se verificam falhas nos processos associados entre voos, um aspeto especialmente sensível em *hubs* congestionados como o de Lisboa.

De igual modo, Zhou et al., (2022) demonstram que a variabilidade no desempenho dos procedimentos em terra está diretamente relacionada com padrões de atraso registados em aeroportos com elevado volume de tráfego, onde atrasos de partida originam efeitos em cascata sobre a rede. Este argumento é reforçado por Singh et al., (2024), ao destacar que a eficiência da fase pré-descolagem é decisiva para evitar o efeito dominó de atrasos em companhias com alta frequência de voos por aeronave.

Por outro lado, a gestão dos procedimentos de partida, de forma geral, carece frequentemente de abordagens sistematizadas que integrem fatores operacionais, humanos e tecnológicos. O estudo de Zhang et al., (2024) também alerta para a necessidade de ferramentas de diagnóstico em tempo real e de estratégias de coordenação interdepartamental mais eficazes, de modo a mitigar os atrasos atribuíveis à fase de preparação do voo.

A análise detalhada do impacto destes procedimentos pode contribuir para uma compreensão mais robusta das causas internas de atrasos e para o desenvolvimento de propostas de intervenção que melhorem o desempenho global da operação aérea. Assim, ao analisar a realidade da Portugália Airlines — caracterizada por elevada intensidade de rotação e utilização contínua da frota —, torna-se evidente que qualquer ineficiência nos Departure Procedures não apenas compromete a pontualidade imediata, mas também a estabilidade do sistema operacional ao longo do dia. Tal realidade justifica a escolha do código 66B como objeto central de estudo, numa tentativa de esclarecer as causas estruturais e operacionais que o tornam um dos mais prevalentes na operação da companhia

## **1.2. Âmbito**

O presente estudo centra-se na análise dos atrasos classificados com o código 66B (*66-Late Cabin Crew Boarding or Departure Procedures other than Connection and Standby B) Departure Procedures - Used when the Cabin Crew processes prevent boarding on time or cause a departure delay*). na Portugália Airlines (PGA), uma companhia aérea regional portuguesa que integra o grupo TAP Air Portugal. O foco recai sobre o período

compreendido entre setembro e dezembro de 2022, durante o qual foram registadas elevadas taxas de atrasos associados a procedimentos de partida. A delimitação do âmbito do trabalho, justifica-se através de vários aspetos relacionados com o interesse da própria companhia aérea Portugal: uma visão analítica e académica dos dados disponibilizados pela mesma; uma compreensão e resolução de um problema específico pois a PGA opera com tempos de rotação curtos e elevada reutilização das suas aeronaves, o que torna qualquer atraso inicial num fator crítico com potencial de propagação ao longo do dia operativo (Britto, Dresner, & Voltes 2012). A operação a partir do Aeroporto Humberto Delgado, frequentemente condicionado por limitações de infraestrutura e tráfego, agrava a vulnerabilidade da companhia aos efeitos dos atrasos. Estudos anteriores sugerem que atrasos iniciais associados a processos em terra tendem a propagar-se com maior frequência em companhias regionais (Y. Wang et al., 2020).

Singh et al., (2024) defendem que, em contextos operacionais restritos, como os observados em companhias subsidiárias com elevado número de rotações diárias, pequenas falhas na fase de partida podem comprometer a pontualidade global da rede. Lin (2023) acrescenta que, no espaço aéreo europeu, atrasos locais amplificam-se rapidamente devido à elevada conectividade entre aeroportos, criando uma cadeia de impacto em voos posteriores. Wang et al., (2020) e Evler, et al., (2022) sublinham ainda a importância da gestão eficaz do *turnaround* para mitigar o risco de disrupção generalizada da rede.

A análise específica do atraso 66B permite ainda compreender melhor os pontos críticos do fluxo de coordenação entre os diferentes intervenientes no processo inicial de toda a operação. Segundo Peterson et al., (2013), a maioria dos atrasos neste segmento pode ser reduzida com a padronização dos procedimentos e melhorias na comunicação entre equipas, sobretudo em ambientes de pressão temporal elevada. A literatura destaca também que companhias com estruturas hierárquicas claras e ferramentas digitais de monitorização apresentam menores índices de atraso em fases críticas do ciclo de voo (Singh et al., 2024).

Finalmente, estudos como os de Brueckner et al., (2021) e Sternberg et al., (2020) sublinham os impactos económicos diretos e indiretos dos atrasos nas companhias

aéreas, particularmente em operações regionais com margens apertadas. Estes custos operacionais e reputacionais reforçam a necessidade de intervenções estratégicas nos procedimentos de partida.

Este estudo visa, assim, analisar os atrasos 66B no contexto real da PGA, identificar padrões operacionais críticos e propor medidas concretas de mitigação que contribuam para melhorar a eficiência e a pontualidade operacional da companhia.

### **1.3. Motivação**

A escolha deste tema prende-se com a necessidade de compreender melhor as causas internas de atrasos nas operações aéreas e com o interesse em contribuir de forma prática para a melhoria dos processos da PGA, uma companhia com tradição de pontualidade. Nos últimos anos, fatores como o aumento do tráfego aéreo e as limitações operacionais no aeroporto de Lisboa tornaram este desafio ainda mais evidente.

A motivação para o desenvolvimento deste estudo surge também da constatação, em ambiente profissional, da frequência com que os atrasos classificados com o código 66B ocorrem na operação da Portugália Airlines. São atrasos que, embora muitas vezes de curta duração, têm implicações diretas no desempenho operacional e na qualidade do serviço prestado, especialmente num contexto de operação regional, com múltiplos voos diários por aeronave.

A experiência acumulada no acompanhamento direto de voos e na análise de dados operacionais despertou o interesse em investigar as causas específicas destes atrasos e compreender de que forma os procedimentos de partida contribuem para a propagação de perturbações ao longo do dia. De acordo com estudos recentes, atrasos operacionais em fases iniciais da operação são particularmente prejudiciais em redes com baixa resiliência temporal (Lin, 2023; Sternberg et al., 2020).

A investigação ganha especial relevância considerando que, atrasos em companhias regionais tendem a ter um impacto mais severo em cascata, devido à reutilização intensiva das aeronaves e à escassez de margens temporais (Brueckner et al., 2022). Além disso, atrasos recorrentes não afetam apenas a eficiência operacional, mas

também a percepção de fiabilidade por parte dos passageiros, como referido por Wang et al., (2020), que evidenciam a correlação entre pontualidade e fidelização do cliente.

Do ponto de vista económico, o estudo de Fujun et al. (2022) demonstra que os custos associados a atrasos em voos de curta distância não se limitam ao tempo perdido em solo, mas incluem também penalizações contratuais, aumentos nos custos de tripulação e prejuízos reputacionais. Assim, a motivação para compreender melhor os atrasos 66B também se relaciona com a otimização de recursos num setor fortemente pressionado por margens operacionais reduzidas.

A gestão estratégica das operações aéreas exige uma visão sistémica das causas de atraso, integrando fatores humanos, técnicos, meteorológicos e regulatórios. Li & Yao, (2025) defendem que apenas através da integração transversal entre departamentos é possível alcançar uma melhoria sustentada na performance operacional.

Este trabalho nasce, portanto, não só de uma inquietação profissional, mas também de um desejo académico de propor soluções concretas e contextualizadas. Ao investigar o impacto específico dos atrasos classificados como 66B, pretende-se contribuir para um conhecimento mais sistematizado das causas e consequências destes eventos, promovendo recomendações aplicáveis à realidade concreta da PGA e, possivelmente, transferíveis para outras companhias com características semelhantes.

#### **1.4. Objetivos**

O presente trabalho tem como objetivo geral estudar os atrasos associados ao código 66B nos voos da PGA, compreendendo a sua relevância dentro do universo de atrasos da companhia e propondo medidas de intervenção específicas.

Para concretizar este propósito, foram definidos os seguintes objetivos específicos:

1. Analisar os atrasos sob o ponto de vista teórico, com foco nas implicações para as companhias aéreas.

2. Caracterizar a presença dos atrasos controláveis e não controláveis que influenciam a pontualidade, com especial atenção aos procedimentos de partida do código 66B.
3. Analisar o comportamento do atraso 66B no que respeita a sua frequência, duração, coocorrências com outros atrasos na PGA.
4. Com base nos resultados, apresentar recomendações para reduzir a ocorrência e o impacto do atraso 66B.

### **1.5. Metodologia**

O estudo adotou uma metodologia descritiva e exploratória, com recurso a análise quantitativa de dados e análise documental. Esta abordagem segue princípios defendidos por autores como Buddhadev, (2025) e Ogunsina et al., (2021) que destacam a importância da compreensão contextual dos dados em estudo operacionais, permitindo interpretar os registos com maior profundidade, respeitando a sua natureza complexa e o ambiente específico onde foram recolhidos.

As técnicas de análise quantitativa incluíram medidas descritivas e análises comparativas com recurso a testes não paramétricos que permitiram concretizar os objetivos definidos e efetuar uma leitura crítica da origem, natureza e impacto dos atrasos na operação da Portugália Airlines. A base empírica foi composta por dados operacionais da PGA sobre os registos dos atrasos, recolhidos entre setembro e dezembro de 2022, analisados com o auxílio da ferramenta de visualização Julius.ai.

### **1.6. Estrutura do Trabalho**

A dissertação está organizada em seis capítulos principais. O Capítulo 1 – Introdução apresenta a contextualização do problema, os objetivos do estudo e a descrição da metodologia adotada. O Capítulo 2 – Enquadramento Teórico faz uma revisão da literatura sobre atrasos aéreos, códigos de atraso e desempenho operacional. No Capítulo 3 – Desenvolvimento do Tema, é feita uma análise da operação da Portugália Airlines (PGA) e uma caracterização detalhada do atraso 66B com base em dados reais

da companhia. O Capítulo 4 – Resultados apresenta os principais resultados obtidos a partir da análise estatística. O Capítulo 5 – Discussão interpreta esses resultados, estabelecendo ligações à revisão teórica previamente exposta. Por fim, o Capítulo 6 – Conclusões sintetiza o trabalho, apresenta as considerações finais e propõe medidas de intervenção

## 2. ENQUADRAMENTO TEÓRICO

### 2.1. A pontualidade como fator estratégico

A pontualidade dos voos é um dos principais indicadores de desempenho na aviação comercial. Representa não só a capacidade técnica e operacional de uma companhia aérea, como também reflete diretamente a qualidade da operação e tem impacto significativo na perceção dos passageiros, na reputação da empresa e na sua capacidade de competir num mercado altamente regulado e competitivo. Além disso, é um fator determinante na escolha dos passageiros, principalmente daqueles que viajam frequentemente (Y. Wang et al., 2020).

A pontualidade está diretamente relacionada com a gestão eficiente de recursos, incluindo aeronaves, tripulações e infraestruturas aeroportuárias. Atrasos recorrentes podem originar um efeito dominó em cadeia, afetando outros voos e comprometendo a estabilidade da operação (Jatavallabha et al., 2024; Zámková et al., 2017). Este fenómeno é particularmente sensível em companhias com elevados níveis de reutilização das suas aeronaves e tempos de rotação curtos (Zámková et al., 2022) , como é o caso da Portugália Airlines.

Em declarações públicas, várias companhias aéreas reconheceram o peso estratégico da pontualidade. O CEO da Iberia, Javier Sánchez-Prieto, afirmou em 2023 que liderar o *ranking* mundial de pontualidade “é um ótimo sinal de que a equipa está a trabalhar na mesma direção”. A Ryanair, em 2020, revelou uma taxa de 98% de voos no horário, contribuindo para níveis elevados de satisfação dos clientes (Publituris, 2020).

Neste contexto, vários estudos reforçam que a pontualidade se tornou um dos mais importantes indicadores de desempenho no setor da aviação, assumindo uma dimensão estratégica que vai além da mera eficiência operacional (Britto et al., 2012; Peterson et al., 2013; Sugishita et al., 2024) . O impacto económico dos atrasos é expressivo: afeta diretamente os custos operacionais, provoca reacomodação de passageiros, necessidade de gestão de tripulações, penalizações contratuais e, em muitos casos, perda de confiança do cliente.

Estudos como o de Wang et al., (2020) demonstram que os atrasos tendem a propagar-se mais facilmente em aeroportos congestionados, criando uma cadeia de perturbações

que se estende ao longo de toda a rede. Para companhias regionais como a Portugália Airlines, esta vulnerabilidade é amplificada pela estrutura da sua operação, onde atrasos iniciais têm maior dificuldade de recuperação ao longo do dia (Fleurquin et al., 2013; Lin, 2023; Jetzki M et al., 2009) .

De acordo com Li e Yao, (2025), a crescente interdependência entre aeroportos e companhias aéreas torna a pontualidade um pilar central da resiliência operacional. Os autores sublinham que estratégias preventivas — como margens operacionais de tempo, reprogramações dinâmicas e monitorização em tempo real — são agora decisivas para garantir a fiabilidade das operações. Neste mesmo sentido, Zhang et al., (2024) analisam como a coordenação entre *stakeholders* (companhias aéreas, handling, controlo de tráfego e aeroportos) afeta diretamente a capacidade de resposta a perturbações e, conseqüentemente, a manutenção de horários.

Zhou et al., (2022) acrescentam que as avaliações de desempenho da pontualidade devem considerar não apenas métricas de hora de descolagem e aterragem, mas também indicadores de eficiência nos procedimentos em solo. Essas variáveis operacionais têm ganho relevo nas auditorias internas e nas exigências regulatórias da EASA e da IATA.

A crescente exigência do mercado tem levado várias companhias a investir em mecanismos avançados de controlo e mitigação de atrasos, incluindo o uso de ferramentas preditivas, integração de dados operacionais e uma maior coordenação entre departamentos internos (Singh et al., 2024). Nesse sentido, a análise de causas internas de atrasos, como os *Departure Procedures*, assume um papel fundamental na construção de uma operação mais robusta e eficiente (Lin, 2023) .

Compreender estas dinâmicas permite desenhar estratégias adaptadas à realidade operacional da companhia, melhorando a pontualidade e reforçando a sua competitividade.

## 2.2. Impactos económicos e reputacionais dos atrasos

A investigação recente (eg. Santana et al., 2023; Zámková et al., 2017) tem procurado evidências cada vez mais consistentes sobre os efeitos dos atrasos na aviação comercial, não apenas ao nível da operação em si, mas também quanto às suas consequências económicas e reputacionais. Estes impactos, muitas vezes interligados, assumem especial relevância num contexto em que a competitividade entre companhias aéreas está fortemente associada à eficiência, pontualidade e fiabilidade percebida pelos passageiros e parceiros comerciais.

### *Impactos económicos*

Para além do desconforto gerado nos passageiros, os atrasos afetam diretamente os custos operacionais das companhias aéreas e constituem um dos principais desafios operacionais das transportadoras e dos aeroportos. As suas implicações estendem-se a várias dimensões da atividade, desde o aumento de custos diretos até ao prejuízo na capacidade produtiva da operação (Peterson et al., 2013; Zámková et al., 2017). De forma geral, os atrasos provocam um desequilíbrio na programação dos recursos, obrigando à reorganização de tripulações, ao pagamento de indemnizações e à prestação de serviços adicionais aos passageiros afetados (Hassan et al., 2021; Santana et al., 2023). As penalizações financeiras, os reembolsos, a necessidade de reprogramar voos e o impacto nos segmentos seguintes da operação aumentam significativamente os encargos (Jatavallabha et al., 2024).

A TAP, por exemplo, registou um aumento de 40 milhões de euros em custos relacionados com atrasos no ano de 2018 (Jornal de Negócios, 2018). Segundo Peterson et al., (2013) , os atrasos de voos representam um custo anual de milhares de milhões de euros a nível global, afetando companhias aéreas, infraestruturas aeroportuárias e passageiros. Os custos são agravados quando os atrasos se tornam sistemáticos, afetando a estabilidade do sistema e conduzindo à perda de competitividade.

Do ponto de vista operacional, os atrasos podem ainda desencadear penalizações contratuais com empresas de *handling*, *catering* e assistência, além de gerar efeitos em cadeia com atrasos subsequentes na rede (Li & Yao, 2025) . Tal como apontado por Wang et al., (2020) , a sucessão dos atrasos pode afetar todo o sistema de transporte aéreo, criando desequilíbrios generalizados que afetam não só a transportadora de origem, mas também parceiros e infraestruturas interligadas.

Zhou et al., (2022) acrescenta que mesmo os atrasos de curta duração representam encargos financeiros relevantes, pois exigem medidas corretivas como rearranjos de frota, reprogramações, renegociação de *slots* e reacomodação de passageiros. A existência de contratos com SLAs (*Service Level Agreements*), entre companhias aéreas e prestadores de serviços, acentua o peso financeiro de cada evento disruptivo.

Por fim, Santana et al., (2023) defendem que as companhias com menor capacidade de recuperação operacional após eventos disruptivos tendem a perder quota de mercado no médio prazo. Este fenómeno é mais evidente em contextos de forte concorrência e em segmentos de elevado valor, como o mercado corporativo ou intercontinental.

#### *Impactos reputacionais*

Do ponto de vista reputacional, os atrasos afetam negativamente a experiência do passageiro e a perceção da qualidade do serviço, contribuindo para avaliações negativas, perda de fidelização e redução da procura (Peterson et al., 2013). Em companhias de bandeira ou operadores regionais com forte presença num mercado específico, o impacto reputacional tende a ser ainda mais significativo, dada a maior exposição mediática e o posicionamento de proximidade com o cliente (Santana et al., 2023; Singh et al., 2024).

A pontualidade, quando elevada, é frequentemente utilizada como argumento de *marketing* e fator de diferenciação. Quando sistematicamente baixa, torna-se num elemento de risco reputacional com impacto direto na perceção pública da fiabilidade da companhia (Efthymiou et al., 2019; Zámková & Martin Prokop, 2015). Além disso, a visibilidade acrescida em plataformas digitais — como sites de avaliação, redes sociais e fóruns de consumidores — amplifica a exposição reputacional associada a atrasos. Um incidente isolado pode rapidamente escalar, afetando a imagem institucional de forma desproporcional ao seu impacto operacional imediato.

### **2.3. Codificação dos atrasos e fatores causadores**

As causas dos atrasos na aviação comercial podem ser, de forma geral, agrupadas em dois grandes domínios: fatores controláveis e fatores não controláveis. Esta distinção é fundamental para a análise de desempenho operacional, pois permite às companhias

aéreas identificar quais as áreas sob sua alçada direta de atuação e quais as que dependem de entidades externas ou de variáveis imprevisíveis (Mitsokapas et al., 2021).

Os fatores controláveis dizem respeito a todas as variáveis operacionais que podem ser planeadas, monitorizadas ou ajustadas pela companhia aérea e seus parceiros diretos, como atrasos na alocação de tripulações, falhas na coordenação em terra, atrasos na preparação da aeronave ou processos internos administrativos. Já os fatores não controláveis incluem aspetos externos como meteorologia adversa, restrições de tráfego aéreo, greves externas, incidentes de segurança ou limitações estruturais dos aeroportos (Fleurquin et al., 2013; Li & Yao, 2025; Lin, 2023).

Os estudos (Mitsokapas et al., 2021; Santana et al., 2023) demonstram que atrasos de origem interna — ainda que de curta duração — tendem a gerar efeitos de propagação mais acentuados em companhias regionais com estruturas operacionais compactas e tempos de rotação reduzidos. No caso da Portugália Airlines, cuja operação é altamente sincronizada com a malha da TAP, atrasos classificados como 66B podem comprometer não apenas o voo isolado, mas toda a cadeia de conexões da aeronave ao longo do dia.

Além disso, estudos recentes indicam que há uma relação direta entre a frequência dos atrasos atribuídos a determinadas categorias de código IATA e a capacidade de resposta da companhia aérea (Beltman et al., 2025; Zhou et al., 2022). Assim, a identificação e categorização rigorosa das causas operacionais dos atrasos não só permite mitigar eventos futuros, como também contribui para a transparência da gestão e para a robustez do planeamento tático e estratégico.

A análise dos padrões de atraso na aviação moderna deve, por isso, incorporar abordagens combinadas — tanto quantitativas como qualitativas — que explorem as causas operacionais subjacentes e a forma como estas interagem com os contextos específicos de cada companhia e aeroporto. A crescente digitalização dos sistemas de reporte e monitorização torna possível, hoje, uma análise muito mais fina e acionável dos dados, com benefícios claros para a mitigação de atrasos recorrentes (Falque et al., 2024; Gondara & Wang, 2018; Muzellec et al., 2020).

A identificação e categorização rigorosa das causas operacionais dos atrasos é um passo essencial para a sua mitigação. Apenas com base numa análise detalhada dos padrões de ocorrência e dos processos envolvidos será possível desenhar estratégias eficazes de prevenção e resposta.

### **2.3.1. Classificação e codificação dos atrasos IATA**

A correta identificação e classificação dos atrasos constitui uma ferramenta essencial para garantir a fiabilidade da análise de desempenho operacional nas companhias aéreas. Sem um sistema coerente e padronizado, seria praticamente impossível comparar dados entre operadores, identificar causas sistémicas ou implementar medidas eficazes de mitigação. Neste contexto, destaca-se a IATA (International Air Transport Association) como a principal entidade responsável pela criação e manutenção do Delay Code System. É importante sublinhar que, apesar da IATA ser uma associação de companhias aéreas e não um regulador oficial, o seu sistema é aceite de forma quase universal como referência técnica. Segundo Singh et al., (2024), a adoção transversal da tabela IATA contribui para uniformizar as práticas de reporte operacional, o que se revela particularmente útil em companhias que operam a partir de hubs internacionais e em contextos de elevada densidade de tráfego, como é o caso do Aeroporto Humberto Delgado, em Lisboa.

O sistema IATA organiza os atrasos em grupos numéricos de dois dígitos, sendo cada grupo associado a uma categoria operacional específica — por exemplo, operações com passageiros (11–19), manutenção técnica (30–39), assistência em terra como bagagem, catering e limpeza (40–49), documentação e processos administrativos da companhia (50–59), tripulação (60–69) ou restrições externas como meteorologia ou controlo de tráfego aéreo (80–89).

A tabela de códigos de atraso da IATA foi concebida não apenas para fins estatísticos, mas também para facilitar a comunicação operacional entre companhias aéreas, operadores de handling, aeroportos e autoridades reguladoras. A sua padronização permite que todos os agentes envolvidos na cadeia de operações partilhem um vocabulário comum, essencial para garantir transparência, rastreabilidade e capacidade

de resposta. Jetzki, et al. (2009) também reforça a importância dos códigos IATA como base essencial para distinguir entre atrasos primários e reacionários, permitindo análises mais detalhadas sobre propagação de atrasos e eficácia de mitigação

Paralelamente, a ICAO (International Civil Aviation Organization) e outras entidades de supervisão como a EASA (European Union Aviation Safety Agency) e a Eurocontrol não dispõem de um sistema próprio de codificação operacional de atrasos, mas reconhecem a estrutura da IATA como referência válida e, muitas vezes, recomendada para análise e compilação de dados. Esta articulação será explorada com maior detalhe na seção seguinte.

Importa ainda destacar que muitas companhias aéreas (eg. American Airlines, British Airways, KLS), especialmente aquelas com operações complexas ou estruturas multinacionais, optam por adaptar a tabela IATA às suas realidades específicas (Singh et al., 2024). Estas adaptações mantêm a lógica estrutural original, mas introduzem distinções adicionais — como é o caso da TAP Air Portugal com o código 66B — que permitem segmentar atrasos de forma mais precisa. Tais adaptações, desde que bem documentadas, são compatíveis com os requisitos regulatórios e podem inclusive facilitar auditorias internas e certificações de qualidade operacional (Peterson et al., 2013).

É, acima de tudo, uma ferramenta estratégica que permite às companhias aéreas analisar o seu desempenho com profundidade, identificar áreas críticas de intervenção e comunicar com clareza entre departamentos e com entidades externas. O seu uso eficiente traduz-se em ganhos concretos em termos de pontualidade, satisfação do cliente e otimização de recursos — objetivos fundamentais num setor altamente competitivo e regulado.

Embora a IATA mantenha o sistema de codificação de atrasos mais amplamente adotado a nível global, é importante compreender o papel das principais organizações reguladoras — ICAO (International Civil Aviation Organization), EASA (European Union Aviation Safety Agency) e Eurocontrol — no contexto da análise e reporte de atrasos.

Estas entidades não criaram sistemas próprios de codificação detalhada de atrasos, mas utilizam e reconhecem amplamente a estrutura da IATA como padrão de referência para efeitos estatísticos, regulamentares e operacionais.

A ICAO, agência especializada das Nações Unidas responsável pela padronização da aviação civil internacional, foca-se principalmente em aspetos relacionados com segurança, navegação aérea e interoperabilidade entre estados-membros. Embora não disponha de um sistema específico de codificação de atrasos ao nível operacional, reconhece a utilidade da codificação da IATA no suporte à compilação de dados globais sobre atrasos, especialmente no contexto dos Key Performance Indicators (KPIs) definidos nos seus documentos técnicos, como o Manual on Global Performance of the Air Navigation System (ICAO Doc 9883). A ICAO utiliza também dados consolidados com base na estrutura IATA para os seus relatórios de performance, como forma de monitorizar tendências globais (ICAO, 2021).

A EASA, enquanto autoridade reguladora da aviação civil europeia, também não define um sistema próprio de codificação de atrasos. No entanto, os relatórios de conformidade e segurança operacional que supervisiona — nomeadamente os Annual Safety Review Reports — incorporam dados operacionais submetidos pelas companhias aéreas europeias, geralmente com base na codificação IATA. Este alinhamento prático permite à EASA uniformizar os dados recolhidos sem duplicar sistemas, beneficiando da granularidade e padronização já existentes (EASA, 2023).

Já a Eurocontrol, organização intergovernamental europeia responsável pela coordenação do tráfego aéreo na região, desempenha um papel mais direto na análise de atrasos. Através do CODA (Central Office for Delay Analysis), publica trimestralmente os relatórios CODA Digest, que consolidam os dados de atrasos reportados por companhias aéreas e aeroportos da Europa.

Figura 1: CODA Delay groupings (EUROCONTROL, 2019, p:26)

	CODA CAUSE	Description	IATA Code
Primary Delay Causes	Airline	Passenger and Baggage	11-19
		Cargo and Mail	21-29
		Aircraft and Ramp Handling	31-39
		Technical and Aircraft Equipment	41-48
		Damage to Aircraft & EDP Automated Equipment Failure	51-58
		Flight Operations and Crewing	61-69
		Other Airline Related Causes	Others
	Airport	ATFM due to Restriction at Destination Airport	83
		Airport Facilities	87
		Restrictions at Airport of Destination	88
		Restrictions at Airport of Departure	89
	En-Route	ATFM due to ATC En-Route Demand Capacity	81
		ATFM due to ATC Staff Equipment En-Route	82
	Governmental	Security and Immigration	85-86
	Weather	Weather (other than ATFM)	71-77
		ATFM due to Weather at Destination	84
Miscellaneous	Miscellaneous	97-99	
Reactionary	Late Arrival of Aircraft, Crew, Passengers or Load	91-96	

Fonte: CODA Digest Q2 2019

A imagem 123 representa a estrutura de causas de atraso segundo o CODA (EUROCONTROL), baseada nos códigos IATA AHM 730, mas adaptada e agrupada de forma funcional para fins estatísticos europeus.

São reconhecidos agrupamentos funcionais por causa operacional de forma a agrupar os códigos por grandes áreas de responsabilidade: Airline, Airport, En-Route, Weather, entre outros.

Esta estrutura é mais flexível do que a numeração da IATA pois a numeração CODA junta códigos de faixas não contínuas num só grupo funcional.

Desta forma, existem códigos atribuídos a diferentes categorias do que na IATA oficial.

31–39 é usado no CODA como "Aircraft and Ramp Handling", enquanto no AHM 730, 31–36 é manutenção técnica, e 37–39 é handling. 41–48 aparece como "Technical and Aircraft Equipment", mas o AHM 730 trata 41–44 como bagagem/catering e 45–49 como carga.

A coexistência entre estas entidades e a IATA revela-se, portanto, sinérgica. A padronização da IATA fornece uma base sólida para o reporte e análise de atrasos, enquanto os organismos reguladores utilizam essa mesma base para construir métricas agregadas, definir políticas de mitigação e avaliar a eficiência do sistema europeu de transporte aéreo. Esta interoperabilidade é crucial para a análise integrada de desempenho, tal como sublinhado por (EUROCONTROL, 2022), que reforçam a importância de uma linguagem comum para a gestão colaborativa de operações aéreas. Esta divisão é fundamental para o planeamento estratégico das companhias: permite focar os recursos na mitigação dos atrasos onde é possível intervir. Estudos como os de (Y. Wang et al., 2020; Zámková & Martin Prokop, 2015) destacam que os atrasos controláveis representam uma oportunidade significativa de melhoria operacional, ao passo que os não controláveis requerem planeamento alternativo e margens operacionais de tempo.

### **2.3.2. Fatores não controláveis**

Os fatores não controláveis representam um desafio permanente para as companhias aéreas, uma vez que escapam à sua esfera direta de atuação. Condições meteorológicas adversas, congestionamento do espaço aéreo e limitações estruturais dos aeroportos estão entre os principais elementos que interferem na pontualidade dos voos. Nestes casos, mesmo as operações mais bem preparadas podem ver-se comprometidas. Atrasos provocados por nevoeiros densos, tempestades, ventos cruzados ou greves de controladores de tráfego aéreo são fenómenos recorrentes em aeroportos de elevada densidade operacional, como Lisboa, Madrid ou Heathrow, particularmente durante os períodos de maior tráfego diário ou em épocas de maior pressão sazonal. Este tipo de perturbações tem impacto direto na capacidade dos aeroportos e dos centros de controlo de tráfego aéreo, e surge como uma das principais causas de atrasos na aviação

européia, como evidenciado por análises recentes da EUROCONTROL e por estudos sobre a propagação dos atrasos em rede (EUROCONTROL, 2022; Lin, 2023; Evler, Schultz, et al., 2022).

O recurso a técnicas de inteligência artificial, nomeadamente redes neuronais profundas, tem vindo a ganhar espaço na identificação automática de padrões de propagação de atrasos (Z. Wang et al., 2023) demonstram que a classificação das funções de cada aeroporto dentro da rede pode antecipar com elevada precisão os efeitos em cascata provocados por atrasos iniciais.

A imprevisibilidade destas condições coloca pressão adicional sobre companhias regionais como a Portugália Airlines, cuja operação depende de intervalos curtos entre voos e de uma elevada taxa de reutilização das suas aeronaves. Uma perturbação num único voo pode facilmente afetar toda a rede ao longo do dia. Este efeito dominó é reconhecido na literatura e observado em diversos estudos empíricos. A título de exemplo, (Y. Wang et al., 2020) descrevem como uma simples restrição de *slot* num aeroporto europeu pode resultar em atrasos em cadeia que se estendem a dezenas de voos interligados. Já (Lin, 2023) alerta que companhias com menor acesso prioritário a faixas horárias e recursos aeroportuários são particularmente vulneráveis a este tipo de interrupção.

Mesmo quando a gestão interna funciona com eficácia, a influência do contexto externo pode anular grande parte dos esforços. Em situações de adversidade — como tempestades de verão, episódios de gelo em pista ou ruturas na coordenação do controlo de tráfego aéreo — torna-se fundamental dispor de estratégias de contingência robustas e sistemas de previsão fiáveis (Z. Wang et al., 2023). Estudos como o de Z. Wang et al., (2023) sublinham a importância de antecipar estas ocorrências e ajustar dinamicamente os planos de operação. A experiência recente de várias companhias durante as ondas de calor extremo em 2023, com pistas inoperacionais em horários críticos, veio reforçar essa necessidade.

A utilização estratégica de *buffers* nos horários das companhias aéreas tem-se revelado eficaz na mitigação da propagação de atrasos. Segundo Falque et al., (2024) mostra que a alocação de maiores margens temporais operacionais nos pontos críticos da rede (como voos *hub-feeder*) pode reduzir significativamente o impacto dos atrasos

reacionários. Nestes momentos, a capacidade de resposta rápida pode fazer a diferença entre um pequeno atraso e uma interrupção prolongada com impacto operacional e financeiro significativo.

### 2.3.3. Fatores controláveis

Os fatores controláveis dizem respeito a todas as variáveis operacionais internas cuja gestão está ao alcance da companhia aérea. Entre estes, destacam-se a coordenação das tripulações, o cumprimento de horários nos procedimentos de rampa, o fluxo de comunicação entre departamentos e a gestão eficiente dos processos e de *turnaround* (Hassan et al., 2021). Sobre este último, existe evidencia que a integração entre processos de *turnaround* e recuperação de aeronaves é recomendada para reduzir o tempo de reação face a interrupções (Santana et al., 2023). Os autores sugerem modelos integrados que otimizam simultaneamente a alocação de recursos em terra e as decisões de substituição de aeronaves, com resultados positivos na *performance* de pontualidade.

De acordo com Peterson et al., (2013), grande parte dos atrasos em companhias regionais decorre de falhas logísticas internas, nomeadamente a disponibilização tardia de documentação, a má coordenação entre operações e *handling* e a duplicação de funções não padronizadas. Singh et al., (2024) reforçam que as falhas de coordenação durante a fase de preparação da aeronave são responsáveis por uma percentagem significativa de atrasos com impacto em cascata.

Beltman et al., (2025) & Muzellec et al., (2020) defendem que o investimento em tecnologias de integração de processos e em sistemas preditivos pode reduzir significativamente a frequência e duração dos atrasos operacionais controláveis. A utilização de dashboards operacionais em tempo real permite à supervisão antecipar conflitos de alocação e otimizar a tomada de decisão nas fases críticas de partida.

A rotatividade elevada das tripulações, associada à escassez de recursos humanos qualificados, é também um fator crítico (Zámková & Martin Prokop, 2015). Quando não há margem temporal para reprogramações, a ausência ou indisponibilidade de tripulantes pode atrasar o início do embarque ou mesmo inviabilizar o voo. A

manutenção não planeada, embora tecnicamente distinta, também se insere nesta categoria, pois pode ser reduzida com programas de manutenção preditiva e otimização de ciclos operacionais (Lin, 2023).

Além disso, falhas nos procedimentos de briefing da tripulação, erros no carregamento da bagagem ou problemas com a distribuição de peso e balanceamento da aeronave são atrasos recorrentes causados por lapsos em processos internos. Exemplos práticos incluem a indisponibilidade de GPU (*Ground Power Unit*) no tempo correto, atrasos no abastecimento de combustível por falhas de comunicação, ou ausência de documentação digital validada nos sistemas da companhia no momento previsto de *pushback* (Ogunsina et al., 2021).

A recuperação de horários após eventos disruptivos requer não apenas ferramentas preditivas, mas também a capacidade de otimização em tempo real com recursos limitados. Como demonstrado por (Hassan et al., 2021; Santana et al., 2023), o sucesso de uma recuperação eficaz nas operações em terra depende da modelação conjunta dos recursos de rampa, das janelas de *slot* e das prioridades operacionais da companhia, com impacto direto na redução do tempo entre voos.

Recentemente, estudos como o de (Zhou et al., 2022) destacam que atrasos originados na coordenação entre equipas de solo e cockpit representam até 18% dos atrasos classificados como técnicos, mas que na verdade derivam de falhas processuais. Neste contexto, a utilização de sistemas automatizados de planeamento de turnaround, como os usados em *hubs* europeus de elevada performance, tem permitido reduzir estes atrasos em até 12% (Li & Yao, 2025).

A categorização de atrasos atribuídos a fatores controláveis é essencial para a sua mitigação. Estudos como os de (atavallabha et al., (2024) sugerem que classificações imprecisas dificultam a resposta tática e amplificam o impacto operacional de falhas internas.

#### **2.4. Adaptações operacionais: o caso do grupo TAP**

A análise dos atrasos na aviação comercial exige, para efeitos de registo e monitorização, uma estrutura de codificação estandardizada, que permita identificar com precisão a

origem e a natureza de cada ocorrência. No caso do grupo TAP, a codificação segue uma lógica funcional organizada por áreas operacionais temáticas, em que cada grupo representa um domínio específico do processo de transporte aéreo. A estrutura baseia-se na atribuição de códigos de dois dígitos, frequentemente complementados por sufixos alfabéticos que detalham a razão concreta do atraso registado.

Cada grupo temático é identificado por um intervalo numérico específico, e está associado a uma designação genérica que traduz a sua área de influência operacional. Por exemplo, os códigos 11 a 19 dizem respeito a fatores ligados a passageiros e bagagem, enquanto os 21 a 29 estão associados a carga e correio, e os 31 a 39 correspondem à área de manuseamento em escala e operações de rampa. Esta lógica mantém-se ao longo de todo o sistema, cobrindo domínios tão diversos como operações de voo, condições meteorológicas, limitações do controlo de tráfego aéreo, ações de autoridades aeroportuárias, eventos técnicos ou atrasos de reação de outros voos.

No interior de cada grupo, os códigos principais (aqueles compostos exclusivamente por dois dígitos numéricos, como 11, 14 ou 66) funcionam como identificadores de categorias amplas de atraso, refletindo a tipologia geral do evento registado. Estes códigos são utilizados sempre que a origem do atraso se encontra claramente associada a uma categoria específica, mas sem necessidade de detalhamento adicional. Contudo, na maioria das situações operacionais, o sistema exige a utilização de subcódigos complementares com sufixo alfabético (ex: 15A, 18D, 66B), os quais oferecem um nível superior de discriminação, permitindo identificar com exatidão o motivo particular do atraso. Companhias aéreas como a TAP, optam por introduzir subcódigos alfanuméricos, como sufixos com letras (ex: 66A, 66B), com o objetivo de aumentar a possibilidade de análise interna e identificar de forma mais precisa as causas específicas de cada atraso. Esta prática é reconhecida como legítima pela própria IATA, desde que os subcódigos sejam derivados de um código standard do AHM 730 e usados apenas para fins internos de gestão (IATA, 2020; IATA, 2016).

A introdução dos subcódigos permite uma atribuição rigorosa das responsabilidades operacionais e uma análise estatística mais precisa e segmentada. Por exemplo, no grupo dos atrasos relacionados com passageiros (códigos 11 a 19), o código 13 corresponde genericamente a "*Check-in Errors*", mas só com os subcódigos 13A (erro de

assento), 13B (erro de *self-check-in*), entre outros, é possível perceber a falha concreta e, conseqüentemente, intervir na sua correção. Esta lógica é igualmente aplicada noutras categorias operacionais. O código 93, refere-se a atrasos causados pela rotação da aeronave proveniente de um voo anterior, designando genericamente que o atraso se deveu à chegada tardia do aparelho. No entanto, os subcódigos 93A a 93R permitem identificar com maior precisão qual foi o motivo do atraso na etapa precedente, seja ele o embarque lento de passageiros (93A), a demora na carga e/ou descarga de bagagem (93C), a indisponibilidade de tripulação (93L), ou até condições meteorológicas adversas no voo anterior (93L). O subcódigo 93R, por sua vez, está reservado a situações que não se enquadram nos casos anteriores.

#### *O código 66B*

A TAP Air Portugal, à semelhança de outras grandes companhias, faz adaptações internas à tabela da IATA, acrescentando sufixos alfabéticos para maior granularidade no controlo interno. É neste contexto que surge o código 66B, uma subdivisão do código IATA 66, o qual corresponde a “problemas na preparação da aeronave para partida” (IATA, 2023). O sufixo “B” permite à companhia distinguir atrasos relacionados com os *Departure Procedures* sob responsabilidade da tripulação de cabine, como a não preparação atempada da cabine, atrasos na conclusão dos checks de segurança, falhas na comunicação de “*cabin ready*”, ou demora no fecho das portas. Estas situações impedem que o embarque se conclua no horário previsto.

Em síntese, a adoção de subcódigos internos, como o 66B, está alinhada com práticas comuns no setor da aviação, conforme descrito por (Singh et al., 2024), permitindo às companhias uma melhor monitorização dos seus indicadores de desempenho e facilitando a identificação de padrões recorrentes que carecem de intervenção. Esta abordagem também reforça a capacidade de resposta estratégica, ao permitir análises mais detalhadas dos atrasos e ações corretivas mais específicas.

#### **2.4.1. *Departure Procedures***

Os *Departure Procedures* (DP) representam um dos momentos mais sensíveis da operação aérea, especialmente em companhias regionais como a Portugália Airlines,

cuja estrutura se baseia em voos de curta duração, tempos de rotação reduzidos e elevado número de escalas por aeronave. Pequenos desvios ou atrasos nesta fase inicial do ciclo de voo tendem a desencadear efeitos de propagação que comprometem toda a operação subsequente (Lin, 2023; Sternberg et al., 2017;.Schultz, 2018).

No sistema oficial da IATA, conforme descrito no manual AHM 730, o código 66 refere-se genericamente a atrasos causados por "Late Cabin Crew Boarding or Departure Procedures", ou seja, situações em que a atuação da tripulação de cabine afeta o embarque ou a partida da aeronave, excluindo casos de ligação ou *standby*. Trata-se de um código abrangente, que pode esconder causas distintas dentro da operação (IATA, 2023).

Para aumentar a capacidade analítica, a TAP – e, por extensão, a Portugália Airlines – adotou uma subdivisão interna deste código em dois subcódigos: 66A e 66B. O código 66A refere-se a *Cabin Crew Late on Board*, aplicado quando a tripulação de cabine chega tardiamente ao avião. Já o código 66B é utilizado quando *Departure Procedures* executados pela tripulação de cabine impedem o embarque atempado ou causam atrasos na partida. Esta segmentação permite distinguir entre atrasos causados por ausência física da tripulação e atrasos decorrentes dos procedimentos sob responsabilidade direta da tripulação de cabine.

A tripulação de cabine, muitas vezes conhecida como assistentes ou comissários de bordo, desempenha um papel essencial na segurança, conforto e preparação de um voo. Para além de atender os passageiros durante a viagem, esta equipa tem um conjunto de tarefas críticas que precisam de ser executadas antes de o avião poder descolar. Quando tais tarefas são atrasadas ou não são concluídas a tempo, podem afetar todo o processo de embarque e provocar atrasos na partida da aeronave.

Antes de os passageiros começarem a embarcar, a tripulação de cabine deve garantir que o interior do avião está totalmente preparado. Isso inclui verificar se todos os equipamentos de segurança estão disponíveis e funcionais — como extintores, coletes salva-vidas, lanternas de emergência e máscaras de oxigénio. A cabine também precisa de estar limpa, organizada e com as saídas desobstruídas. Nenhum passageiro pode embarcar até que estas tarefas estejam concluídas e a tripulação confirme que a cabine está pronta.

Durante o embarque, a tripulação acompanha a entrada dos passageiros, ajudando-os a encontrar os seus lugares e a guardar a bagagem de mão de forma segura. Este processo pode ser mais demorado quando há passageiros com mobilidade reduzida, famílias com crianças ou pessoas que precisam de assistência especial. Os assistentes de bordo também resolvem questões comuns, como lugares trocados ou excesso de bagagem de cabine. Toda esta gestão requer atenção e coordenação.

Depois de todos os passageiros estarem a bordo, a tripulação ainda tem de realizar uma série de verificações obrigatórias. É necessário confirmar que todos os cintos estão apertados, os compartimentos de bagagem estão fechados, as cortinas estão abertas e que não há objetos a bloquear as saídas de emergência. Em seguida, é feita a demonstração de segurança — instruções que explicam o uso do cinto, máscaras de oxigénio, colete salva-vidas e saídas de emergência. Só depois de todas estas etapas é que as portas da aeronave podem ser fechadas. Por fim, a tripulação comunica ao comandante que a cabine está pronta.

O código 66B visa, assim, representar todos os atrasos que resultam de ineficiências ou falhas na atuação da tripulação de cabine na fase final de preparação antes do avião começar a se movimentar. A segmentação adotada, entre 66<sup>a</sup> e 66B, embora não formalmente prevista no AHM 730, segue uma prática comum entre companhias com operação complexa e elevada exposição internacional. Permite identificar padrões recorrentes e áreas críticas com maior precisão (Singh et al., 2024). Falhas nesta fase representam uma “janela de vulnerabilidade operacional”, com elevado potencial de repercussão sistémica. O congestionamento do Aeroporto Humberto Delgado, por exemplo, agrava a dificuldade de recuperação, limitando a flexibilidade da operação (Wang et al., 2020).

A gestão eficaz dos DP exige elevado nível de coordenação entre áreas. A literatura aponta falhas de comunicação e de padronização como causas frequentes de atraso nesta fase (Lin, 2023; Muecklich et al., 2023; Singh et al., 2024). Como resposta, companhias como a Lufthansa e a KLM têm implementado checklists digitais intersetoriais e sistemas de alerta antecipado baseados em inteligência operacional (Singh et al., 2024). Além disso, a propagação de atrasos está correlacionada com a presença de nós críticos na rede. Ivanoska et al. (2022) identificam que determinados

hubs funcionam como amplificadores de disrupção, exigindo monitorização contínua e estratégias proativas de contenção.

A adoção de boas práticas de padronização e digitalização pode reduzir significativamente a frequência dos atrasos classificados como 66B, contribuindo para a recuperação da performance operacional da PGA e para o reforço da sua imagem de fiabilidade.

### 3. DESENVOLVIMENTO DO TEMA

Nesta secção do trabalho centramo-nos no contexto organizacional sob estudo, a companhia Portugália Airlines que, como outras, pretende fortalecer a sua performance operacional através da análise sistemática dos atrasos registados. Assim, descrevemos abordagens sustentadas por literatura científica recente, com enfoque particular em estudos sobre o tratamento e análise de dados operacionais no setor do transporte aéreo (Shang et al., 2024; Z. Wang et al., 2023).

#### 3.1. A amostra analisada

A Portugália Airlines (PGA) disponibilizou uma amostra composta por 14.561 registos operacionais de voos com atrasos registados entre setembro e dezembro de 2022, extraídos diretamente da aplicação digital utilizada pelas equipas operacionais da PGA. A amostra inclui os seguintes campos:

Tabela 1: Campos da amostra

leg_no	day_of_origin	ac_registration	dep_ap_sched	dep_sched_dt	delay_code	delay
--------	---------------	-----------------	--------------	--------------	------------	-------

Optou-se por manter a integridade estrutural dos registos originais, respeitando a complexidade natural da operação da companhia. Esta abordagem inclui a preservação de múltiplos códigos de atraso por voo e estruturas compostas, estando alinhada com práticas metodológicas reconhecidas na investigação científica. Autores como Gondara & Wang, (2018) & Muzellec et al., (2020) apresentam soluções para imputação de dados em falta que sustentam esta opção. Optou-se apenas por eliminar registos que, eventualmente por lapso de registo, de erro de exportação ou outros desconhecidos, não apresentavam código e/ou tempo de duração.

Ao preservar a estrutura original dos dados, este estudo adere a recomendações presentes na literatura que valorizam a fidelidade ao *dataset* e a sua capacidade explicativa (Fleurquin et al., 2013; Ionescu et al., 2016; Pineda-Jaramillo et al., 2024). Esta decisão permite explorar de forma mais rigorosa as interações entre causas de atraso e os padrões compostos que ocorrem na prática.

### **3.1.1. Estrutura dos registos e registos compostos**

O modelo de inserção de dados utilizado pela PGA permite o registo de múltiplos atrasos associados a um mesmo voo, no mesmo dia. Assim, a estrutura da base de dados do estudo admite até quatro códigos de atraso distintos por voo, cada um com a sua duração específica. Esta flexibilidade resulta num conjunto significativo de registos compostos, com múltiplos códigos de atraso para a mesma referência de voo e data (Buddhadev, 2025).

A distinção entre os dois grupos permitiu estruturar as análises de forma segmentada, reconhecendo-se a complexidade dos fatores operacionais que podem, em simultâneo, contribuir para o atraso de um mesmo voo. Registos compostos representam frequentemente situações multifatoriais, como atrasos técnicos seguidos de constrangimentos operacionais ou meteorológicos, o que lhes confere uma relevância analítica significativa. A manutenção destes registos compostos na base de dados original foi uma decisão metodológica fundamentada, permitindo captar não apenas a ocorrência de atrasos, mas também a interação entre causas múltiplas.

A opção de manter tanto os registos simples como os compostos, mostra-se particularmente relevante na análise detalhada dos atrasos simples vs. compostos no Capítulo 4, permitindo explorar, entre outros aspetos, a sua distribuição temporal e o impacto combinado de múltiplos fatores.

### **3.1.2. Catalogação preliminar dos códigos de atraso**

A codificação dos atrasos na amostra segue a tabela interna de códigos da Portugália Airlines, baseada na estrutura da IATA, mas com adaptações específicas à realidade operacional da companhia. Inclui subtipos (como o 66B), que representam causas de atraso com maior detalhe do que os códigos *standard* da IATA. No presente capítulo, optou-se por manter os códigos originais da companhia (ex.: 66B, 93, 83, 12), sem conversão direta para a nomenclatura IATA, garantindo assim a preservação da riqueza descritiva e da fidelidade à fonte dos dados.

Como defendido por Gondara e Wang, (2018), manter a codificação original é essencial quando ao nível de detalhe dos dados, reflete práticas operacionais específicas que

seriam perdidas com normalizações excessivas. Liang et al., (2021) e Muzellec et al., (2020) também sublinham que a transformação ou abstração prematura da informação pode comprometer a modelação de padrões reais em bases de dados complexas.

A catalogação preliminar dos códigos teve como base o documento interno que inclui uma descrição detalhada das causas atribuídas a cada código. Esta estrutura servirá de suporte para a segmentação analítica no Capítulo 4, onde os códigos serão agrupados por categorias, avaliados quanto à sua tipologia (controlável vs. não controlável) e posicionados em relação à sua frequência e impacto.

### **3.1.3. Limitações da amostra**

Apesar da robustez da base de dados analisada, foram identificadas algumas limitações que condicionam a profundidade de determinadas análises. O principal constrangimento identificado prende-se com a ausência de um campo que indique os atrasos de forma cronológica. Esta limitação na estrutura da amostra dos dados obtidos, impede uma análise segmentada por fase operacional, o que poderia ser relevante, sobretudo na avaliação dos Departure Procedures. Trata-se de uma característica do modelo de recolha que compromete parcialmente a capacidade de associar causas específicas a fases críticas da operação (Ogunsina et al., 2021; Shao et al., 2019). Contudo, a amostra disponibilizada permitiu identificar importantes padrões de frequência, duração e complexidade envolvendo um tipo de atraso dentro do universo controlável pela companhia.

### **3.2. Estratégia de análise**

A abordagem analítica definida para este estudo procura responder aos objetivos centrais delineados no Capítulo 1, ou seja, a caracterização, segmentação e interpretação dos atrasos registados na operação da Portugália Airlines, com destaque para o código 66B (*Departure Procedures*). Iniciou-se o tratamento dos dados com um conjunto de análises preliminares exploratórias, que incluíram o cálculo de medidas descritivas, a produção de gráficos e o diagnóstico de *outliers* para compreender melhor a natureza das distribuições e decidir sobre a natureza da estatística a utilizar.

A identificação da presença de *outliers* em cada grupo foi efetuada com recurso à Regra do Intervalo Interquartil (IQR) (Tukey, 1977) que corresponde à diferença entre o 3º e 1º quartis (Q3 e Q1), correspondendo o primeiro a  $Q3+1.5*IQR$  e o segundo a  $Q1-1.5*IQR$ . Por se situarem abaixo dos 10%, considerou-se que as percentagens de *outliers* por grupo não iriam comprometer os resultados pois, como salientado por Hubert e Van der Veeken (2008), percentagens entre 5 e 10% são comuns em fenómenos assimétricos, não traduzindo erros de medição, nem comprometendo a integridade do conjunto de dados, muito embora requeiram a utilização de estatísticas robustas (anexoff). Em síntese, os *outliers* não representam uma preocupação na amostra do estudo.

Tomaram-se também decisões em relação aos dados em falta, optando-se por excluir os casos com código de atraso omissos e os casos com duração igual a 0 minutos, num total de 434 (3%) registos excluídos. Assim, obteve-se uma amostra viável de 14 127 registos.

A análise assenta numa lógica de segmentação progressiva. Em primeiro lugar, os códigos de atraso foram tratados de forma isolada, avaliando-se a sua frequência e o tempo total associado. Posteriormente, foram agrupados por tipologia (ex: atrasos controláveis vs. não controláveis), estrutura (registos simples vs. compostos) e complexidade (número de códigos por registo), permitindo uma leitura multifacetada da amostra. Esta segmentação reforça a importância de modelos baseados em seleções de atributos relevantes para diferenciar causas e tipologias de atraso com base em tipologias de atraso Ding et al., (2024) e segue orientações metodológicas de estudos (Ogunsina et al. 2021), que reforçam a importância de estruturar os dados em múltiplas camadas analíticas para compreender fenómenos operacionais complexos.

Os resultados da estratégia analítica são apresentados no Capítulo 4, onde cada eixo de segmentação (frequência, duração, tipologia, estrutura e complexidade) é desenvolvido com suporte visual e estatístico adequados. Este encadeamento metodológico visa garantir que os resultados obtidos são não só fiéis à realidade da operação observada, como também relevantes para futuras intervenções na gestão de atrasos.

As análises dos dados foram efetuadas com o apoio da ferramenta Julius (anexos).  
[www.julius.ai](http://www.julius.ai)

## **A Influência dos Departure Procedures – 66b nos atrasos dos voos da companhia aérea Portugália**

Trata-se de uma ferramenta de inteligência artificial que usa a linguagem Python, o Excel e o ChatGPT para criar código e gráficos, em interação com o utilizador. Este processo permitiu identificar e analisar fatores associados aos atrasos 66B e a forma como se relacionam com outros atrasos, de forma interativa.

## 4. RESULTADOS


Nesta seção, apresentamos a concretização da estratégia de análise e apresentamos os resultados dos cálculos levados a cabo, adotando uma sequência e organização dos mesmos coerente com a lista de objetivos específicos (seção 1.4, capítulo 1).

Antes de prosseguir para a análise focalizada dos resultados, importa referir que a amostra analisada inclui ocorrências simples e combinadas até um máximo de 4 níveis de complexidade. No segmento de ocorrências simples, resultaram um total de 3766 ocorrências, no campo das ocorrências com dois níveis de atrasos compostos, resultaram 6452 ocorrências. Para três níveis de atrasos compostos, o resultado foi de 3018 ocorrências e por fim, com 4 atrasos conjugados, 891 resultados.

### 4.1. Atrasos com maior frequência e duração

A figura 2 apresenta os 30 códigos de atraso com maior número de ocorrências na amostra analisada. Há três códigos dominantes na amostra em termos de frequências.

Figura 2: Ordenação dos atrasos por frequência



O atraso mais recorrente é o **89** (*Restrictions at Airport of Departure, With or Without ATFM Restrictions, including Air Traffic Services, start-up and pushback, airport and/or runway closed due to obstruction or weather or industrial action*), com mais de 2600 registos, seguido pelo **93R** (*Others*), da categoria "*Aircraft Rotation, Late Arrival of A/C from another Flight or previous Sector, due to:*", com cerca de 1950 ocorrências. O terceiro código mais frequente totalizou aproximadamente 1500 registos que é o código genérico de todo o universo do código **93** que conta com 18 sufixos existentes, vai desde o *A) Slow Boarding on Previous Flight* até ao *R) Others*, pertencente ao segundo lugar do pódio.

Ainda dentro do top 10 encontram-se os códigos: **83** (*ATFM due to Restriction at Destination Airport, airport and/or runway closed due to obstruction, industrial action, staff shortage, political unrest, noise abatement, night curfew, special flights*); **81** (*ATFM due to ATC en-route demand /capacity, standard demand / capacity problems*); **82** (*ATFM due to ATC staff/Equipment en-route, reduced capacity caused by industrial action or staff shortage, equipment failure, military exercise or a extraordinary demand due to capacity reduction in neighbouring area*); **32A** (*Lack of Loading Staff, Error*); **41A** (*Aircraft Defects at Home Base*); **84** (*ATFM due to Weather at Destination*) e **35A** (*Cabin Cleaning*). Estes códigos pertencem às categorias internas da TAP, conforme indicado na tabela 2.

Tabela 2: Enquadramento dos códigos

Categoria principal	Código geral	Significado geral	Código visado no Top 10
<i>Aircraft and Ramp Handling (31 to 39)</i>	32	<i>Loading / Unloading, bulky, special, excessive Load, Cabin Load, Lack of Loading Staff, Volume Difficulties, Stretcher</i>	32A
	35	<i>Aircraft Cleaning</i>	35A
<i>Technical and Aircraft Equipment (41 to 49)</i>	41	<i>Aircraft Defects at Home Base</i>	41A
<i>Air Traffic Flow Management Restrictions (81 to 84)</i>	NA	NA	81; 82; 83; 84
<i>Airport and Governmental Authorities (85 to 89)</i>	89	<i>Restrictions at Airport of Departure, With or Without ATFM Restrictions, including Air Traffic Services, start-up and pushback, airport and/or runway closed due to obstruction or weather or industrial action</i>	89
<i>Reactionary (91 to 96)</i>	93	<i>Aircraft Rotation, Late Arrival of A/C from another Flight or previous Sector, due to:</i>	93; 93R

Fonte: Documento Interno: Delay Codes

O código **66B**, foco desta investigação, aparece em posição intermédia da lista, com 223 ocorrências, enquadrando-se na categoria *Departure Procedures*. O número absoluto de vezes que este código surge é indicativo da sua relevância operacional, embora não seja um dos códigos mais prevalentes no topo da amostra.

Em síntese, a análise das frequências absolutas revela um predomínio de atrasos relacionados com problemas de rotação de aeronaves e voos anteriores (respetivamente, 93R e 93), bem como situações de difícil classificação (89). O facto de o código 66B surgir nesta lista já demonstra uma presença significativa, embora não dominante, o que reforça a necessidade de estudar o seu impacto noutros indicadores como a duração total do atraso.


A figura 3 apresenta os 30 códigos com maior impacto em termos duração dos atrasos. O código **93R** lidera destacadamente com mais de 84 mil minutos perdidos, seguido do código **93** com cerca de 65 mil minutos. Ambos pertencem à categoria de atrasos por

rotação ou proveniência de outros voos e refletem disrupções sistémicas na malha de voos.

O terceiro código com maior tempo de atraso é o **89**, tal como observado na vertente de frequência de atrasos, confirmando a sua importância também do ponto de vista temporal. Seguem-se os códigos **41A** (*Aircraft Defects at Home Base*), **83** (*ATFM due to Restriction at Destination Airport, airport and/or runway closed due to obstruction, industrial action, staff shortage, political unrest, noise abatement, night curfew, special flights*), **81** (*ATFM due to ATC en-route demand /capacity, standard demand / capacity problems*), **82** (*ATFM due to ATC staff/Equipment en-route, reduced capacity caused by industrial action or staff shortage, equipment failure, military exercise or a extraordinary demand due to capacity reduction in neighbouring area*) e **32A** (*Lack of Loading Staff, Error*), todos com tempos totais de atraso superiores a 10 mil minutos.

O código **66B**, embora não se destaque entre os primeiros 10 códigos, surge na parte final desta lista, em 26º lugar, com um tempo total de atraso de 1802 minutos totais, correspondente a 0,49% de toda a amostra o que poderá indicar que, apesar da sua presença regular, os atrasos associados a este código tendem a ser de menor duração. Este aspeto será explorado na comparação direta do ponto seguinte.

Figura 3: Ordenação dos atrasos por duração



Em suma, os resultados sugerem que os códigos associados a atrasos herdados de segmentos anteriores (93R, 93 - *Aircraft Rotation, Late Arrival of A/C from another Flight or previous Sector*) e problemas técnicos ou operacionais têm impacto muito elevado no tempo total perdido.

Tanto no Top 10 de atrasos por ocorrência como no Top 10 de atrasos por duração, têm em comum 9 códigos. A exceção está no 10º lugar ocupado pelo 35A (*Cabin Cleaning*) e na análise da duração, e pelo código geral 64 (*Flight Deck Crew Shortage, Illness, awaiting Standby, Flight Time Limitations, Crew Meals, etc*).


Embora presente, o 66B revela um impacto mais contido nesta métrica, reforçando a necessidade de uma análise cruzada entre frequência e duração para compreender o seu peso relativo.

Estas duas dimensões, frequência e duração de atrasos, anteriormente analisadas, representam 39 códigos de atraso classificados em três grupos distintos: (1) os que figuram simultaneamente nos rankings de frequência e duração (barras azuis com pontos), (2) os que surgem apenas por frequência (barras verdes), e (3) os que surgem apenas por duração (pontos vermelhos). Esta abordagem permite identificar códigos com impacto estrutural (muito frequentes e demorados) e códigos com impacto específico (muito frequentes mas curtos, ou raros mas demorados).

Os códigos **93R**, **93**, **89**, **83**, **81**, **82**, **41A**, **32A** e **66B** são exemplos de códigos com dupla presença nas métricas, destacando-se como estruturalmente relevantes. O código **66B**, em particular, está entre os casos que, embora com frequência moderada, apresentam também impacto temporal suficiente para justificar atenção operacional.

Por outro lado, observa-se a existência de códigos como **64**, **94**, **41B** ou **42**, que não figuram entre os mais frequentes mas apresentam tempos totais de atraso elevados, o que poderá indicar eventos pontuais mas com consequências operacionais sérias. Em contraste, códigos como **15A**, **34B** ou **31A** são muito recorrentes mas com impacto temporal reduzido, sugerindo atrasos de curta duração, possivelmente mitigáveis com maior facilidade.

Figura 4: Relação frequência e duração, por código de atraso



A análise cruzada revela que um subconjunto restrito de códigos acumula simultaneamente elevada frequência e impacto em tempo, constituindo prioridades claras para intervenção operacional. O código 66B, embora não esteja entre os extremos de nenhuma das métricas, revela-se relevante por figurar em ambas, confirmando o seu estatuto de atraso estrutural de média intensidade e justificando a sua análise aprofundada nos pontos seguintes desta investigação.

#### 4.2. Controláveis vs. Não Controláveis

Nesta secção apresentamos os resultados da análise comparativa entre os atrasos controláveis e não controláveis quanto á sua frequência e duração.

##### 4.2.1. Medidas descritivas e distribuições

A tabela 3 apresenta o conjunto de medidas descritivas por tipo de atraso, Controláveis (C) e Não Controláveis (NC), e nas figuras 5 e 6, constam a representação gráfica das distribuições dos atrasos.

Tabela 3: Medidas descritivas dos atrasos Controláveis e Não Controláveis

Tipo de atraso	Fa (%)	Duração(minutos)						
		M	Dp	Md	Máx	Min	Curt.	Assi.
Controláveis(C) [nº de voos: 2 765]	2 765 (19,6%)	18,33	33,99	9	750	1	113,73	8,17
Não controláveis (NC) [nº de voos: 11 362]	11 362 (80,4%)	28,16	37,70	15	491	1	19,07	3,47

Nota. N= 14 127

Figura 5: contagem de voos por atraso (Total da amostra)





Figura 6: Distribuição dos atrasos (0 a <175)



Os atrasos NC são mais frequentes ( $N=11\ 362$ ) que os C ( $N=2\ 765$ ) e, em média, duram mais tempo (respetivamente,  $M = 28,16$  e  $M= 18,33$ ), embora com variabilidade aproximada.

A figura 5 permite visualizar o que as medidas de curtose e assimetria (tabela 3) sugerem: ambos os grupos apresentam uma distribuição dos atrasos com forte assimetria positiva, ou seja, com caudas longas à direita (distribuições leptocúrticas), mais extensas no grupo C que vai até aos 750 minutos e com picos nos 5-10 minutos. Para tornar a assimetria mais visível, produziu-se um segundo gráfico (figura 6) limitando-se o eixo x a 200 min. As linhas tracejadas marcam os atrasos médios dos grupos (no caso dos C,  $M=18,33$  min; no caso dos NC,  $M=28,16$  min). Os atrasos NC apresentam um pico nos 10-20 minutos e assimetria positiva, embora mais distribuída que nos atrasos C.

Em síntese, tanto a concentração de atrasos curtos como a presença de atrasos longos — sobretudo entre ocorrências não controláveis — elevam as médias dos atrasos e conferem elevada assimetria às distribuições. Assim, como ambas se afastam claramente da distribuição gaussiana, antecipou-se a utilização de uma estatística não paramétrica nas análises a realizar.

### ***Análise comparativa dos atrasos C e NC quanto à sua duração***

Procurou-se compreender se as diferenças na amostra entre os dois tipos de atrasos, controláveis (C) e não controláveis (NC), seriam ou não significativas para a variável 'duração'. Para o efeito, e para direcionar a análise, tendo a não normalidade das distribuições já sido apurada, testou-se a homogeneidade de variâncias através do teste de Levene. O resultado indicou a presença de variâncias significativamente diferentes,  $F_{(1,14126)}=131.23$ ,  $p<.001$ . Decidiu-se por isso usar o teste  $t$  de Welch (para variâncias heterogéneas) e um teste não paramétrico complementar: o teste  $U$  de Mann-Whitney para duas amostras independentes, duas variáveis categóricas, e que usa as medianas para comparar as posições das observações em dois grupos. A tabela mm mostra os resultados obtidos.

Tabela 4: Comparação entre os atrasos C e NC quanto à duração

Teste	Coef.	Sign.	Md C	Md NC
<i>t</i> de Welch	-13,351	.000	--	--
<i>U</i> Mann-Whitney	12312897	.000	9.0	15.0

Nota. C –atrasos controláveis (n=2 765); NC –atrasos não controláveis (n=11 362); Md – mediana.

Os resultados sugerem que a duração média dos atrasos difere significativamente entre voos controláveis ( $M=18.33$ ,  $DP=33.99$ ,  $n=2765$ ) e não-controláveis ( $M= 28.16$ ,  $DP = 37.70$ ,  $n =11 362$ ). O teste *t* de Welch aponta para uma diferença estatisticamente significativa,  $t_{(4567.08)}=-13.35$ ,  $p<.001$ . Mediu-se o tamanho do efeito através do teste de Cohen (*d*) e constatou-se ter sido pequeno-médio,  $d=0.27$ , sugerindo que os atrasos NC são, em média, cerca de um quarto de um desvio-padrão superiores aos C. O teste *U* de Mann Whitney corroborou os resultados anteriores. A mediana dos atrasos foi de 9 minutos para os C e 15 minutos para os NC. Confirmou-se assim uma diferença significativa entre os grupos,  $U=12312897.0$ ,  $z=-17.65$ ,  $p<.001$ .

Em síntese, ambos os testes rejeitam a hipótese nula de igualdade das distribuições e médias. Os atrasos NC são significativamente mais longos que os C.

#### 4.3. Comportamento do atraso 66B em frequência, duração e na relação com outros atrasos


A análise do comportamento do código de atraso 66B revela-se essencial para compreender a sua frequência, duração e em associação com outros códigos numa lógica de acumulação. A presença do 66B em registos compostos, muitas vezes em articulação com fatores operacionais exógenos, exige uma abordagem analítica detalhada. Este subponto propõe uma leitura sistematizada desses padrões, considerando tanto a incidência isolada do 66B como o seu papel em cadeias de atraso, com base numa amostra de 223 voos. O objetivo é identificar tendências de associação,

perfis médios de duração e enquadramento operacional, de forma a posicionar este código dentro da amostra da Portugalia Airlines.

#### 4.3.1. A frequência do 66B

A Figura X apresenta os vinte códigos de atraso com maior número de ocorrências na amostra total, discriminando-os de acordo com a tipologia **controlável** (em azul), **não controlável** (em cinzento) e com destaque para o **código 66B** (em vermelho). Esta representação permite uma leitura imediata da distribuição dos principais atrasos consoante o grau de influência direta da companhia aérea, evidenciando padrões relevantes para a gestão operacional. Entre os códigos mais frequentes destacam-se sobretudo atrasos classificados como não controláveis, nomeadamente os códigos 89, 93R e 93, cuja génese está frequentemente associada a fatores externos ou à propagação de atrasos de segmentos anteriores. Contudo, observa-se também a presença de vários códigos associados a causas controláveis, como é o caso do 32A, 41A, 35A e, com especial relevância, o 66B. A sua inclusão neste conjunto restrito de códigos com maior frequência total reforça a pertinência de uma análise mais detalhada sobre o seu impacto na operação.

Figura 7: O atraso 66B nos Top 20 da mostra, quanto à frequência




Quando considerado o universo total dos atrasos (figura 7), verifica-se que o 66B surge em 12.º lugar (n=223), entre os 20 com mais ocorrências, correspondendo a 1,6% do total da amostra (14 127 registos), com uma frequência acumulada de 74,3%.

Contudo, no grupo dos atrasos C (figura 8), o 66B ocupa a 4.ª posição, acompanhado do atraso 34B (Fa=223), correspondendo a 8,1% dos atrasos e com uma frequência acumulada de 51,8%.

Representa, portanto, um dos principais atrasos dentro do universo controlável pela companhia.

Figura 8: O atraso 66B nos top 20 da amostra, quanto à frequência no grupo C



A Influência dos Departure Procedures – 66b nos atrasos dos voos da companhia aérea Portugaláia

Tabela 5: Enquadramento dos códigos controláveis, quanto à sua frequência

Categoria principal	Código geral	Significado geral	Código visado no Top 20
<i>Passenger and Baggage (11 to 19)</i>	15	<i>Slow Boarding, Discrepancies and Paging, Missing Checked-in Passenger without baggage</i>	15A; 15D
	16	<i>Commercial Reasons, Publicity, Passenger's Convenience, VIP, Press, Unscheduled Ground, Meals, Missing Pers. Items</i>	16H
<i>Aircraft and Ramp Handling (31 to 39)</i>	31	<i>Aircraft Documentation Late / Inaccurate, Weight and Balance, General Declaration, Passenger Manifest, etc.</i>	31A; 31B
	32	<i>Loading / Unloading, bulky, special, excessive Load, Cabin Load, Lack of Loading Staff, Volume Difficulties, Stretcher</i>	32A
	34	<i>Servicing Equipment, Lack of or Breakdown Lack of Staff</i>	34A; 34B
	35	<i>Cabin Cleaning</i>	35A
<i>EDP/Automated Equipment Failure (55 to 58)</i>	55	<i>Departure Control System</i>	55B
	58	<i>Other Automated Systems</i>	58A; 28B
<i>Flight Operations and Crewing (61 to 69)</i>	63	<i>Late Crew Boarding or Departure Procedures other than Connection and Standby (Flight Deck or entire Crew)</i>	63A; 63D
	64	<i>Flight Deck Crew Shortage, Illness, awaiting Standby, Flight Time Limitations, Crew Meals, etc.</i>	64; 64A
	65	<i>Flight Deck Crew Special Request, not within Operational Requirements</i>	65
	66	<i>Late Cabin Crew Boarding or Departure Procedures other than Connection and Standby</i>	66B
	67	<i>Cabin Crew Shortage, Illness, awaiting Standby, Flight Time Limitations, Crew Meals, etc.</i>	67
<i>Reactionary</i>	96	<i>Operation Control, Rerouting, Diversion, Consolidation, A/C change for reason other than technical</i>	96C

### 4.3.2. A duração do 66B

Para se obter um retrato mais completo da relação entre o 66B e os outros atrasos, em termos de duração, optou-se por analisá-lo tanto no contexto geral da amostra como dentro dos grupos controláveis. Assim, foram ordenados e contabilizados todos os atrasos de acordo com a sua duração e calculadas medidas descritivas.

Figura 9: O atraso 66B nos top 20 da amostra, quanto à duração





Figura 10: O atraso 66B nos top 20 da amostra, quanto à duração no grupo C



Apurou-se que (tabela 6) o atraso 66B surge em 223 ocorrências, ocupando a 12.<sup>a</sup> posição no *ranking* geral de causas de atraso (no conjunto total 14 127 registos), o 160.<sup>o</sup> valor médio de atraso e o 149.<sup>o</sup> mediana de atraso. No grupo dos atrasos C (tabela 7), apresenta a mesma magnitude que no total da amostra, com  $M=8.08$  min e  $Md=7$  min, melhorando para a 57.<sup>a</sup> e 52.<sup>a</sup> posições, respetivamente.

Tabela 6: Posição do 66B no conjunto total de atrasos

<i>Fa</i>	<i>M</i> atraso (min)	<i>Md</i> atraso (min)	<i>Rank. M</i> Atraso	<i>Rank Md</i> atraso
223	8.08	7.0	160. <sup>o</sup>	152. <sup>o</sup>

Tabela 7: Posição do 66B no conjunto dos atrasos C

<i>Fa</i>	<i>M</i> atraso (min)	<i>Md</i> atraso (min)	<i>Rank. M</i> Atraso	<i>Rank Md</i> atraso
223	8.08	7.0	57. <sup>o</sup>	52. <sup>o</sup>

Em síntese, na amostra a duração dos atrasos associados ao código 66B é modesta. Estes valores sugerem que o 66B não está entre os principais responsáveis por atrasos prolongados, especialmente quando se considera o universo completo de voos.


#### 4.3.3. Relação com outros atrasos

De forma a posicionar o 66B no mapa de interações que moldam os atrasos da companhia, procurou-se identificar padrões de associação e categorias operacionais associadas. A primeira etapa consistiu na agregação dos registos de atraso por voo. Para tal, todos os movimentos com o mesmo número de voo, no mesmo dia e com o mesmo número de sector de voo, foram considerados como um único voo. Esta consolidação permitiu observar de forma robusta a estrutura composta dos atrasos.

Foi então realizada uma filtragem dos voos com a presença do código 66B. Esta seleção implicou: conversão dos campos de códigos por voo em conjuntos únicos e retenção apenas dos voos onde o conjunto incluía o 66B, um processo que resultou em 223 voos com atraso 66B presente.

*Associação do 66B com outros atrasos no total da amostra*

**Figura 11: Top 20 Combinações de Códigos com 66B**



A complexidade foi definida pelo número de outros códigos de atraso diferentes do 66B registados no mesmo voo. Assim, um voo com apenas o 66B foi classificado com complexidade 0; um voo com o 66B e mais um código, com complexidade 1; e assim sucessivamente (tabela 8).

Tabela 8: Distribuição dos voos por grau de complexidade

Grau de Complexidade 66	Nº de Voos	Percentagem (%)
0 (66B isolado)	24	10,8%
1 código adicional	82	36,8%
2 códigos adicionais	77	34,5%
3 códigos adicionais	40	17,9%
Total	223	100%

Para cada nível, foram calculadas três métricas: (1) duração média dos minutos imputados ao 66B, (2) duração média dos minutos atribuídos aos restantes códigos, (3) soma total média dos minutos de atraso por voo.

Tabela 9: Duração por nível de complexidade


Grau de Complexidade	<i>M</i> 66B (min)	<i>DP</i> do 66B (min)	<i>M</i> Outros (min)	<i>DP</i> outros (min)	Total <i>M</i> (min)	Total <i>DP</i> (min)
0 (66B isolado)	8,46	13,77	0	0	8,46	13,77
1 código adicional	7,94	5,68	22,66	27,91	30,61	30,35
2 códigos adicionais	8,41	6,19	53,44	44,80	61,83	44,91
3 códigos adicionais	7,55	4,68	66,63	46,17	74,18	46,71

Nota. *M* – média; *DP* – Desvio padrão

Há 24 voos com apenas o atraso 66B ( $M= 8,46$  min,  $DP= 5,7$ ). Com um código extra ( $n = 82$ ) o atraso médio total elevou-se para 30,60 min; com dois códigos ( $n = 77$ ) subiu para 61,83 min; e com três códigos ( $n = 40$ ) alcançou 74,18 min. A análise conduzida permite afirmar que o código 66B raramente ocorre em isolamento e, quando associado a outros atrasos, configura um perfil de complexidade operacional crescente. Assim, o seu contributo médio para o atraso total é constante e modesto (cerca de 8 minutos) independentemente da complexidade, indicando que o acréscimo de minutos advém

dos códigos acompanhantes. A figura 12 representa o atraso médio total para cada nível de complexidade (de 0 a 3 códigos adicionais).

Figura 12: Atraso médio total por nível de complexidade, no grupo C



Para verificar se as diferenças entre os grupos eram estatisticamente significativas, e tratando-se de distribuições assimétricas e de grupos com tamanhos diferentes, recorreu-se ao teste não paramétrico Kruskal–Wallis que compara as medianas (de atraso total) entre os quatro níveis de complexidade. Obteve-se um resultado significativo,  $H = 95,06$ ,  $p < .001$ , o que sugere diferenças sistemáticas entre os grupos.

Dada a significância das diferenças encontradas, decidiu-se identificar o tamanho do efeito, o que foi feito através do teste post-hoc de Dunn-Bonferroni.

Tabela 10: Teste post-hoc Dunn-Bonferroni

Grupos de atrasos	0	1	2	3
0	1			
1	.000	1		
2	.000	.000	1	1
3	.000	.000	1	1

## **A Influência dos Departure Procedures – 66b nos atrasos dos voos da companhia aérea Portugal**

Os resultados sugerem que o atraso total nos voos exclusivamente com 66B é significativamente menor ( $p < .001$ ) que em qualquer nível com atrasos extra (tabela 9). Se se adicionar um segundo ou terceiro atraso controlável, aumenta substancialmente o atraso médio em relação ao cenário de apenas um parceiro. Entre dois e três atrasos adicionais não há diferença estatística ( $p = 1.00$ ). Embora o atraso médio suba de 61,83 para 74,18 minutos, essa variação não supera o limiar após Bonferroni.

Em síntese, cada incremento de complexidade até dois códigos agravam significativamente o atraso total. O acréscimo do segundo para o terceiro código, parece não ser relevante.

### ***A controlabilidade dos atrasos com o envolvimento do 66B***

O envolvimento do 66B em cadeias de atraso com códigos como o 89 – *Restrictions at Airport of Departure, With or Without ATFM Restrictions* – ou o 93R – *Aircraft Rotation, Late Arrival of A/C from another Flight or previous Sector, due to: Others* –, ambos classificados como não controláveis, revela um padrão crítico: o 66B atua muitas vezes como elo inicial ou complementar de contextos operacionais complexos e fora da esfera de intervenção direta da companhia. Esta constatação é particularmente relevante para estratégias de mitigação, pois exige abordagens interdepartamentais e cooperação com *stakeholders* externos (como aeroportos e outros prestadores de serviços) para que se possa reduzir o impacto sistémico dos atrasos em que o 66B participa.

Contudo, para além da quantidade de códigos presentes por voo, importa agora compreender a natureza dos mesmos — ou seja, se representam causas controláveis pela companhia aérea ou fatores externos ao seu domínio de atuação. Trata-se de uma distinção relevante para avaliar o grau de governabilidade dos atrasos em que o 66B se insere e para identificar eventuais margens de melhoria operacional.

Com base na classificação da TAP, os voos com 66B foram agrupados em três categorias operacionais distintas:

- voos em que todos os códigos associados são controláveis,
- voos com apenas causas não controláveis,

- voos com composição mista entre causas controláveis e não controláveis.

A tabela 10 apresenta a distribuição da amostra segundo esta segmentação, que servirá de base para a análise aprofundada dos diferentes contextos operacionais do 66B.

**Tabela 11: Classificação dos códigos por controlabilidade**

Tipo de Código	Nº de Ocorrências	Porcentagem (%)
Apenas controláveis	36	16,1%
Apenas não controláveis	123	55,2%
Mistos	64	28,7%
Total (voos com 66B)	223	100%

Mais de 83% dos voos com 66B parecem ocorrer em contextos que envolvem influências não inteiramente controláveis, o que reforça a complexidade sistémica do fenómeno. Contudo, a identificação de um subconjunto de 36 voos onde o 66B surge exclusivamente associado a códigos controláveis representa uma oportunidade analítica distinta: a de investigar em detalhe as situações em que a responsabilidade operacional se concentra integralmente na esfera de atuação da companhia aérea.

Este conjunto de ocorrências evidencia, por um lado, o real potencial de intervenção por parte da transportadora, e por outro, a necessidade de reforçar a articulação entre as áreas operacionais diretamente envolvidas na preparação do voo. A análise destes contextos exclusivamente controláveis fornece uma base sólida para a definição de medidas internas de mitigação, com vista à melhoria da eficiência dos procedimentos de partida e à redução da propagação de atrasos.

[esta página foi deixada em branco deliberadamente]

## 5. DISCUSSÃO

O presente trabalho teve como finalidade compreender os atrasos operacionais associados ao código 66B na operação da Portugália Airlines (PGA), explorando a sua relevância no conjunto dos atrasos registados e avaliando o seu potencial impacto na *performance* da companhia. Trata-se de uma área especialmente crítica para as companhias aéreas regionais, como a PGA, dado que os atrasos não representam apenas disfunções pontuais, mas são também indicadores de fragilidades sistémicas, com implicações diretas na reputação, nos custos operacionais e na capacidade de resiliência da operação (Peterson et al., 2013; Santana et al., 2023; Y. Wang et al., 2020).

Para concretizar o objetivo geral do estudo, recorreu-se a uma análise descritiva e exploratória de uma base empírica composta por 14.127 registos operacionais com atrasos, recolhidos entre setembro e dezembro de 2022. Esta amostra permitiu estudar o comportamento dos códigos de atraso na operação real da PGA, com especial atenção ao código 66B, que se inclui aos *Departure Procedures* — uma fase operacional frequentemente sub-representado na literatura, mas que se revelou estruturante no contexto analisado.

Neste capítulo, interpretam-se e discutem-se os principais resultados obtidos, tendo por referência o quadro teórico apresentado no Capítulo 2. A discussão organiza-se em torno dos quatro objetivos específicos definidos no início do trabalho. Sempre que oportuno, destacam-se tensões, lacunas ou confirmações face à literatura consultada, no sentido de se interpretar os resultados de forma crítica e orientada para a melhoria operacional. Serão ainda sublinhadas as implicações dos resultados, bem como eventuais limitações que condicionam o seu alcance.

### ***Tipologia dos atrasos: controláveis, não controláveis e as fronteiras da governabilidade operacional*** (objetivo 2)

Este estudo estabelece a distinção entre atrasos controláveis (C) e não controláveis (NC) na operação da Portugália Airlines, articulando esta tipologia com os resultados efetivos da amostra e com os desafios reais da gestão da pontualidade. A distribuição da amostra revelou desde logo um desequilíbrio marcante: 80,4% dos atrasos registados foram classificados como NC, enquanto apenas 19,6% foram considerados C. Esta

predominância de causas externas parece, à primeira vista, validar os argumentos da literatura que apontam para a crescente vulnerabilidade das companhias a fatores exógenos — como congestionamentos aeroportuários, limitações estruturais ou atrasos herdados (Lin, 2023; Sternberg et al., 2020). No entanto, uma leitura mais detalhada dos resultados levanta dúvidas sobre até que ponto tais causas estão verdadeiramente fora da esfera de intervenção da companhia. Por exemplo, os atrasos do tipo 93 e 93R, que lideram tanto em frequência como em tempo total perdido (figuras 2 e 3 Sec. 4.1.), são tecnicamente não controláveis, mas ocorrem muitas vezes associados a outros atrasos, inclusive de origem interna. Este efeito de retroalimentação operacional é descrito por autores como Fleurquin et al., (2013) e Y. Wang et al., (2020), que alertam para o risco de “transferência passiva de responsabilidade” nos processos de classificação de atrasos.

Do ponto de vista estatístico, a análise descritiva mostrou diferenças claras e significativas entre os dois grupos, C e NC, em termos de duração média (os NC, com  $M=28,16$  min,  $DP=37,70$ ,  $Md=15$ min os C,  $M=18,33$ ,  $DP=33,99$ ,  $Md=9$ ) (tabela 4, figuras 5 e 6, Sec. 4.2). São resultados consistentes com as previsões da literatura (Mitsokapas et al., 2021; Zámková et al., 2017), mas também revelam um ponto crítico: mesmo os atrasos classificados como C apresentam uma cauda longa de duração, com valores máximos que, em alguns casos, ultrapassam os 700 minutos. Este aspeto é particularmente relevante para companhias como a PGA cuja operação é caracterizada por rotação intensiva de aeronaves, curtos períodos de *turnaround* e alta dependência de recursos partilhados. Em tais contextos, como referem Li e Yao, (2025), atrasos controláveis curtos, mas frequentes, podem ter um impacto acumulado superior ao dos atrasos esporádicos, mas prolongados. No caso da amostra analisada, os atrasos do grupo C representam apenas cerca de 20% ( $n=2765$  em 11 363) dos casos, mas têm um potencial de mitigação muito superior, dado que decorrem de causas diretamente relacionadas com a operação da companhia.

Um exemplo concreto desta margem de atuação encontra-se no código 66B. Classificado como atraso controlável e diretamente ligado ao foco central deste trabalho, o 66B apresentou 223 ocorrências (figuras 7 e 8, Sec. 4.3.1), surgindo como o

4.º código mais frequente dentro da categoria dos C. No entanto, e este é um ponto essencial, a análise da estrutura dos registos (Sec. 4.3.3) revelou que em mais de 83% dos voos com atraso 66B, este surgia combinado com outros códigos — muitos dos quais não controláveis (ex: 93R, 89, 84). Esta constatação desafia uma leitura simplista da tipologia C/NC e aponta para a necessidade de analisar os atrasos em rede, como já propuseram Fleurquin et al., (2013) & Liang et al., (2021).

Outro aspeto a destacar é o padrão de complexidade crescente observado à medida que aumenta o número de códigos associados a cada voo (Cap. 4.3.3.1). Nos voos com apenas atraso 66B, a duração média foi de 8,46 minutos; com um código adicional, esse valor subiu para 30,6 minutos; com dois, para 61,8 minutos; e com três, para 74,2 minutos. O teste de Kruskal–Wallis indicou diferenças estatisticamente significativas entre os grupos ( $H = 95,06$ ,  $p < 0,001$ ), e o *post-hoc* de Dunn-Bonferroni mostrou que o impacto cresce substancialmente com cada código adicional — sobretudo entre o primeiro e o segundo. Esta progressão confirma que a governabilidade de um atraso não depende apenas da sua classificação formal, mas também do contexto operacional em que ocorre.

É interessante notar, neste ponto, que os próprios atrasos exclusivamente controláveis associados ao 66B ( $N=36$ , tabela 10 e 11, Sec. 4.3.3) mostraram padrões específicos de coocorrência. Os códigos mais frequentes nesse subconjunto foram o 63D (*Departure Procedures – cockpit*), o 05 (*Planning and Management*) e o 15A (*Slow Boarding*). Todos representam falhas internas previsíveis e, em teoria, corrigíveis. Isto significa que existe um núcleo identificável de causas que poderiam ser alvo de medidas operacionais, como a melhoria da comunicação entre tripulações e supervisores ou a redefinição de prazos para entrega de documentação e autorização de *pushback*, medidas também sugeridas por Singh et al., (2024).

Apesar da larga consistência com a literatura, a interpretação dos resultados permitiu constatar um vazio. Designadamente, não se conseguiu encontrar produção científica que aborde a articulação entre atrasos C e NC num mesmo registo de voo. Esta lacuna torna-se evidente quando se analisam os atrasos compostos, um fenómeno que aparece com frequência na amostra (10.361 registos compostos, Sec. 4), mas que não tem tido merecido a atenção devida por parte da investigação. Tal facto limita o enquadramento

teórico e aponta para um potencial contributo deste estudo: ao se analisar a distribuição e interação entre tipos de atraso num mesmo evento operacional, contribui-se para uma leitura mais realista da complexidade das operações.

Por outro lado, identificam-se também oportunidades de intervenção clara, sobretudo em cadeias de atraso iniciadas por códigos do tipo C. A implicação prática parece ser clara: melhorar a pontualidade exige atuar não apenas sobre o que se pode controlar diretamente, mas também sobre as interfaces entre aquilo que é interno e externo, simples e composto, previsível e inesperado.

***O atraso 66B: comportamento estatístico, inserção operacional e impacto sistémico*** (objetivo 3)

O código 66B constitui o núcleo de análise deste estudo. Os resultados obtidos permitem caracterizar este atraso com detalhe, com base numa amostra da operação da Portugália Airlines. O objetivo foi compreender a sua expressão quantitativa — em termos de frequência e duração —, mas também a que outros códigos está associado. Os dados revelam um perfil de atraso que, embora discreto à primeira vista, apresenta implicações significativas para a estabilidade da operação.

Começando pela sua frequência, o atraso 66B surgiu em 223 registos de atraso ao longo da amostra (figura 7, Sec. 4.3.1), o que o coloca na 12.<sup>a</sup> posição entre todos os códigos analisados. Ainda que não figure entre os mais prevalentes, destaca-se no grupo dos atrasos classificados como controláveis, ocupando aí a 4.<sup>a</sup> posição (figura 8, Sec. 4.3.1). Este posicionamento evidencia que, dentro das causas atribuídas à esfera da companhia, o 66B tem uma expressão relevante, representando cerca de 8,1% dos atrasos controláveis e 1,6% do total da amostra.

Estes valores, se considerados isoladamente, poderiam sugerir um atraso de importância secundária. No entanto, esta leitura é desmentida quando se observa a sua capacidade de associação a outros atrasos. Apenas 10,8% dos registos com 66B foram ocorrências isoladas (tabela 7, Cap. 4.3.3); ou seja, em quase 90% dos casos, o 66B surge em combinação com um ou mais outros códigos de atraso. Trata-se de uma característica crítica, pois remete diretamente para o conceito de propagação de atrasos

descrito por autores como (Fleurquin et al., 2013; Zhang et al., 2024), que defendem que certos atrasos, apesar da sua curta duração individual, funcionam como catalisadores de disrupção ao longo da rede.

Do ponto de vista da duração, o 66B apresentou uma média de 8,08 minutos por ocorrência e uma mediana de 7 minutos (tabelas 5 e 6, Sec. 4.3.2). No contexto global da amostra, estas posições correspondem ao 160.º lugar em média e ao 152.º em mediana, o que lhe atribui um perfil de “atraso curto”. Contudo, no subconjunto dos atrasos controláveis, o 66B melhora significativamente a sua posição: sobe para o 57.º lugar em média e o 52.º em mediana (tabela 6, Cap. 4.3.2). Esta constatação reforça a ideia de que, dentro dos atrasos imputáveis à companhia, o 66B é relativamente frequente e operacionalmente sensível.

Uma das análises mais reveladoras foi a avaliação da complexidade dos voos com 66B, baseada no número de códigos adicionais por registo (tabela 7 e 8 Sec. 4.3.3.). Observou-se que, à medida que o número de códigos aumentava, a duração média do atraso total crescia de forma significativa:

- 8,46 minutos nos registos com apenas 66B,
- 30,61 minutos com um código adicional,
- 61,83 minutos com dois códigos adicionais,
- e 74,18 minutos com três códigos adicionais.

As diferenças encontradas são estatisticamente significativas ( $p < .05$ ) e cada nível (i.e. transição de 0 para 1 e de 1 para 2 códigos ) representa um agravamento real.

Curiosamente, o aumento de complexidade de dois para três códigos adicionais já não se afigurou estatisticamente relevante, sugerindo a existência de um limiar de saturação na propagação do impacto. Este fenómeno é coerente com os modelos de resiliência de rede discutidos por De Bruin et al., (2025) & Fleurquin et al., (2013), segundo os quais existe um ponto a partir do qual a acumulação de disrupções deixa de amplificar o atraso, entrando numa fase de saturação operacional.

Um dado particularmente relevante foi a identificação dos códigos mais frequentemente associados ao 66B nos voos com causas exclusivamente controláveis

(tabela 10 Sec. 4.3.3.). Destacaram-se o 63D (*Departure Procedures – cockpit crew*), o 05 (*Planning and Management*) e o 15A (embarque lento ou erro de *gate*) (tabela 12 Sec. 4.3.3.). Esta tríade revela que apesar do 66B poder ser um incidente isolado, ocorre também em contexto de falhas de planeamento, de comunicação entre equipas ou de sincronização entre operações em terra e tripulação. A literatura já sugeriu esta interdependência (Santana et al., 2023; Singh et al., 2024), mas os resultados da PGA oferecem agora evidência empírica concreta que corrobora esse padrão.

Do ponto de vista conceptual, são resultados que reforçam a leitura do atraso 66B como um marcador de ineficiência sistémica. Embora a sua duração média seja baixa, a sua repetição, frequência e articulação com outras falhas transformam-no num vetor estratégico de disrupção. Em termos operacionais, a sua mitigação poderá não ter impacto direto em minutos poupados por evento, mas terá impacto acumulado significativo ao reduzir a formação de cadeias compostas.

Por outro lado, não foram encontrados estudos dedicados ao comportamento específico do código 66B, quer na literatura nacional, quer em fontes internacionais com densidade semelhante. A maior parte dos estudos concentra-se em categorias amplas, mas raramente se debruça sobre subcódigos como o 66B, adotado internamente pela TAP/PGA. Esta ausência de comparabilidade limita o potencial de generalização dos resultados, mas também abre espaço para um contributo original deste estudo: ao caracterizar o 66B com base em dados operacionais reais e em contexto nacional, a presente investigação fornece um ponto de partida empírico para futuras abordagens dedicadas a atrasos específicos por segmento de operação.

Em síntese, o comportamento do atraso 66B na amostra analisada revela três características fundamentais: (1) uma frequência expressiva dentro dos atrasos controláveis; (2) uma tendência clara para inserção em cadeias de atraso compostas, com impacto amplificado; e (3) uma articulação recorrente com falhas em planeamento, cockpit e embarque. Apesar da sua duração média modesta, justifica-se a análise específica do 66B e a formulação de medidas direcionadas de mitigação.

***Propostas de intervenção para reduzir a ocorrência e o impacto do atraso 66B***  
(objetivo 4)

O presente estudo revelou que o atraso 66B, embora com duração média individual relativamente curta (aprox. 8 minutos), apresenta um impacto operacional significativo pela forma como se insere em cadeias complexas de interrupção. O atraso não deve ser interpretado apenas como um evento isolado, mas como um marcador de fragilidade nos processos de partida — frequentemente conjugado com atrasos controláveis de elevada duração como 05, 63D ou 15A. Além disso, o 66B destaca-se por ocorrer quase sempre em contexto composto e controlável, o que reforça a importância de uma abordagem sistémica.

Com base nos resultados do estudo, nas evidências operacionais observadas e na revisão teórica dos capítulos anteriores, apresentam-se as seguintes seis propostas de intervenção. Cada uma está alinhada com os dados da amostra e priorizada com base no seu impacto esperado no comportamento do 66B e da operação global.

***1. Resposta operacional reforçada em voos com atrasos múltiplos***

Cerca de 89% dos registos com 66B envolvem dois ou mais códigos de atraso, elevando a duração total média para valores superiores a 60 minutos. Este padrão demonstra que o impacto do 66B depende sobretudo da sua inserção em contextos operacionais frágeis, onde o encadeamento de causas amplifica a interrupção (Zhou et al., 2022). Propõe-se a criação de mecanismos de resposta diferenciada para voos com múltiplos atrasos antes do *off-block*, como alertas automáticos no OCC, supervisão reforçada, coordenação prioritária com *handling* ou *pushback* acelerado. A literatura especializada reforça que medidas de antecipação e atuação tática nos momentos críticos da operação podem mitigar significativamente os efeitos dominó associados a atrasos compostos (Evler et al., 2021a, 2021b; Hassan et al., 2021; Zhou et al., 2022). Ao atuar sobre a complexidade e não apenas sobre a ocorrência, a PGA pode conter a acumulação dos atrasos e proteger a rotação seguinte.

***2. Programa de priorização preventiva para os atrasos controláveis mais frequentes e duradouros***

A amostra revelou que os atrasos 32A, 15A, 34B, 64 e 64A não só são controláveis, como superam o 66B em frequência e/ou tempo total de atraso. Esta concentração em poucos códigos sugere padrões operacionais críticos que podem ser detetados e mitigados com ações dirigidas. Propõe-se, por isso, a implementação de um programa interno de monitorização contínua destes atrasos — com alertas semanais, análise de tendências e medidas operacionais direcionadas por área funcional. Estudos como os de Ogunsina et al., (2021) e Shao et al., (2019) demonstram que programas de gestão por prioridades operacionais, baseados em dados reais de atraso, permitem ganhos relevantes na previsibilidade e na alocação de recursos em fases críticas do *turnaround*. Atuar diretamente nestes atrasos permitirá reduzir o contexto que alimenta o surgimento e agravamento do 66B, reforçando a robustez dos processos de partida e contribuindo para uma melhoria estrutural da pontualidade.

### ***3. Redefinição do tempo de referência para atrasos e previsão ativa do impacto do 66B***

A lógica atual de contagem de atraso parte da hora prevista de partida. No entanto, há voos em que o atraso já está garantido à partida, por exemplo devido à chegada tardia da aeronave, sem que a tripulação tenha iniciado qualquer ação. Nestes casos, manter o tempo de referência original artificializa o problema, inflacionando o total de minutos registados e atribuindo atraso a operações ainda não iniciadas. Propõe-se redefinir o tempo de referência operacional, ajustando o momento zero ao *Estimate Time of Arrival* real da aeronave ou à assunção da operação pela tripulação. Esta abordagem está em linha com o que defendem autores como Falque et al. (2024), ao sugerirem que uma modelação mais realista do tempo *off-block ready* permite uma avaliação mais justa do desempenho da operação. Além disso, ferramentas de previsão ativa, como as exploradas por Lin, (2023), mostram que a introdução de margens de atuação realistas nos modelos de atraso contribui para decisões táticas mais eficientes. Esta mudança permitirá distinguir entre atrasos herdados e efetivos, prevenir imputações imprecisas (como o 93) e antecipar decisões em voos com risco real de propagação do 66B.

#### **4. Plataforma colaborativa e interligada para reporte de atrasos**

O sistema atual de reporte de atrasos atribui à tripulação a responsabilidade exclusiva pelo reporte dos atrasos, mesmo em contextos de elevada pressão operacional. Isto pode comprometer a qualidade do registo e penalizar a operação ao adicionar carga cognitiva em momentos críticos. Propõe-se a criação de uma plataforma colaborativa digital, que integre contributos de diferentes atores (OCC, handling, supervisores), recolhendo múltiplas perspetivas sem depender exclusivamente do piloto. Esta abordagem encontra eco em recomendações da IATA (2023), que sublinham a importância de uma comunicação interfuncional eficaz para melhorar o desempenho em solo e reduzir os tempos de turnaround. Além disso, estudos como os de Ogunsina et al., (2021) e Shang et al., (2024) reforçam que a partilha de informação em tempo real entre equipas reduz falhas de coordenação e melhora a perceção situacional dos eventos disruptivos. Esta medida contribuiria para uma melhor representação do atraso real e reforçaria a inteligência coletiva no tratamento das disrupções.

#### **5. Redução do uso de códigos genéricos e reforço da precisão na codificação**

O uso de códigos como 93 (*late arrival*), 89 (restrições de destino) ou 66 sem sufixo retira clareza à análise e impossibilita intervenções específicas. Estes códigos podem ser utilizados por desconhecimento das causas reais ou por falta de formação sobre os critérios de codificação. A amostra revelou, por exemplo, 13 registos com “66” simples, que comprometem a análise da complexidade do 66B. Propõe-se reforçar a formação dos responsáveis pelo registo e estabelecer critérios mais claros para imputação, criando condições para análises mais profundas e melhorias operacionais mais eficazes. Esta necessidade é também destacada pelo estudo de Falque et al. (2024), que sublinha que a falta de densidade e especificidade nos dados de atraso dificulta a identificação de causas sistémicas e limita a eficácia das intervenções corretivas. De forma complementar, Lin (2023) defende a revisão periódica das categorias e a implementação de mecanismos que promovam a *accountability* na atribuição dos códigos, como parte de uma cultura organizacional orientada para a precisão

## **6. Integração do 66B como Key Performance Indicator (KPI) e revisão sistemática dos seus registos**

O comportamento do 66B justifica a sua inclusão como um indicador estruturante de *performance* operacional. Sugere-se que o código passe a integrar os painéis de controlo internos da companhia, com acompanhamento trimestral e visibilidade entre áreas. Recomenda-se ainda a realização de revisões sistemáticas dos registos com 66B — especialmente os isolados e controláveis — de forma a identificar padrões e promover a aprendizagem organizacional. Esta abordagem é consistente com o que é proposto por Fujun et al., (2022) e Sugishita et al., (2024), que defendem que a utilização de indicadores operacionais específicos e rastreáveis contribui para a maturidade organizacional na gestão de atrasos. A IATA (2023), no seu *Manual de Ground Operations*, também sublinha a importância de *KPIs* específicos, adaptados à realidade de cada operador, como meio de estimular melhorias contínuas e reforçar a responsabilização entre áreas funcionais. Transformar o 66B em métrica visível e auditável pode, assim, potenciar tanto a eficácia operacional como a cultura interna de prevenção.

Em síntese, a discussão apresentada neste capítulo permitiu demonstrar que o atraso 66B, embora modesto na sua duração média, desempenha um papel relevante na complexidade e instabilidade da operação da Portugália Airlines. A sua análise revelou padrões de coocorrência com outros atrasos controláveis e não controláveis e também sugeriu, com base nos dados disponibilizados pela companhia, eventuais lacunas nos sistemas de reporte. As propostas de intervenção delineadas respondem diretamente a estes desafios, com base em evidências empíricas e enquadramento teórico, oferecendo caminhos realistas e adaptáveis para a mitigação do 66B e, por extensão, para a melhoria da *performance* operacional da companhia. No capítulo seguinte, serão apresentadas as conclusões gerais deste estudo, respondendo diretamente aos objetivos definidos e refletindo sobre os contributos, limitações e perspetivas futuras da investigação.

## 6. CONCLUSÕES

Este trabalho teve como finalidade compreender de forma aprofundada os atrasos operacionais associados ao código 66B na operação da Portugália Airlines, avaliando a sua relevância no universo de atrasos registados, bem como o seu impacto real na pontualidade da companhia. Importa recordar que o estudo surgiu da constatação de que os *Departure Procedures*, frequentemente tratados de forma genérica na literatura e nos sistemas de reporte, podem assumir um papel estrutural na cadeia de eventos que compõe a disrupção operacional. Ao centrar o olhar num único código — o 66B —, procurou-se desenvolver uma análise detalhada e multidimensional que permitisse revelar os padrões de comportamento e as dinâmicas sistémicas subjacentes.

Para o efeito, definiram-se quatro objetivos específicos, que definiram o percurso metodológico, orientaram a análise crítica dos dados e as interpretações dos resultados.

O primeiro objetivo consistia em analisar os atrasos sob o ponto de vista teórico, com foco nas implicações para as companhias aéreas. A revisão da literatura permitiu a concretização deste objetivo e a identificação de diferentes dimensões do fenómeno que em muito contribuíram para a sua compreensão e interpretação dos resultados do estudo. Os resultados mostraram que os atrasos, para além de eventos isolados, são manifestações de fragilidades operacionais profundas, com impacto direto na eficiência, na imagem e na sustentabilidade da operação aérea. A conclusão deste trabalho abre caminho para uma interpretação que a pontualidade não depende apenas da resolução pontual de problemas, mas da existência de processos robustos, coordenados e preparados para antecipar a disrupção.

Para se concretizar o segundo objetivo, segmentaram-se os atrasos controláveis e não controláveis, com especial atenção aos associados ao 66B. A análise permitiu identificar que atrasos formalmente controláveis, como o 66B, surgem frequentemente em contextos mistos, refletindo interdependências complexas e exigindo uma leitura mais sistémica da tipologia operacional.

O terceiro objetivo, visou detalhar o comportamento do código 66B na operação da PGA. Os resultados demonstraram que, embora não seja um dos atrasos mais longos, o 66B apresenta elevada frequência relativa dentro da categoria dos atrasos controláveis

e uma forte tendência para integrar cadeias compostas. Esta capacidade de amplificação do impacto operacional, mesmo em atrasos de curta duração, posiciona o 66B como um fator crítico na estabilidade da operação, particularmente em voos com tempos de rotação reduzidos e alta sensibilidade à descoordenação.

Por fim, o quarto objetivo visava apresentar recomendações para reduzir a ocorrência e o impacto do 66B. A investigação permitiu ir além de sugestões genéricas, construindo um conjunto de seis propostas de intervenção robustas, diretamente fundamentadas nos dados da amostra e articuladas com a realidade operacional da PGA. Estas medidas incidem sobre diferentes dimensões — desde a redefinição do tempo de referência para o início do atraso, à antecipação de riscos operacionais, passando pelo reforço da resposta em voos com atrasos múltiplos, até à criação de plataformas colaborativas e ao uso do 66B como indicador estruturante. Cada proposta foi desenhada com base em evidência concreta, acompanhada de visão estratégica e operacional, e formulada com potencial real de implementação. Mais do que soluções isoladas, estas recomendações propõem um modelo de atuação articulado que permite não só mitigar o impacto do 66B, mas também elevar o grau de maturidade da gestão de atrasos na companhia. Trata-se, assim, de um contributo prático e analítico relevante, com aplicabilidade imediata e margem clara para evolução futura.

Em síntese, este trabalho permitiu compreender de forma detalhada o comportamento do atraso 66B, identificar os seus padrões de coocorrência e impacto, e propor intervenções sustentadas na evidência. Foi também possível evidenciar as limitações das tipologias tradicionais de atraso e desafiar a separação rígida entre causas controláveis e não controláveis. Este posicionamento analítico oferece uma nova perspetiva sobre a governabilidade dos atrasos e contribui para o debate sobre a resiliência operacional em companhias aéreas regionais.

Entre os principais contributos do estudo, destaca-se a possibilidade de oferecer uma caracterização não muito frequente de um código de atraso específico num contexto operacional real. Ao focar-se no 66B, o presente trabalho aprofundou um ponto crítico do processo de partida. É um contributo que poderá servir de base para outros estudos que procurem analisar causas específicas de atraso e as suas interações dentro do sistema.

Naturalmente, como em qualquer estudo, este apresenta limitações. A mais evidente prende-se com a ausência de variáveis temporais detalhadas por fase de voo, o que dificultou a distinção rigorosa entre momentos operacionais. Também a dependência de dados secundários e de um sistema de classificação sujeito a interpretações limita, em certa medida, a precisão da análise. No entanto, a metodologia adotada permitiu mitigar parte dessas limitações e assegurar a robustez das conclusões.

Acresce uma limitação de natureza estrutural associada ao próprio sistema de codificação de atrasos utilizado. Constatou-se que vários atrasos amplamente utilizados na amostra — como o 93 (*late arrival of aircraft*), 93R (*reactionary delay*) e 89 (restrições no aeroporto de destino ou na rota) — apresentam um nível de generalidade excessivo, o que retira profundidade à análise de associação. Estes códigos funcionam como categorias “abrangentes”, frequentemente utilizadas de forma rápida ou automática, mas que ocultam a origem concreta da disrupção. É uma prática que compromete a capacidade de apuramento analítico e rouba protagonismo a atrasos específicos que poderiam, se identificados corretamente, ser alvo de medidas de mitigação mais precisas. Tal fragilidade é visível tanto na análise macro dos códigos mais relevantes, como na vertente micro, nomeadamente no caso do código 66 sem sufixo, cuja utilização impede a distinção de causas operacionais concretas, como as atribuídas ao 66B.

É ainda importante referir que a escassez de estudos centrados em códigos específicos, como o 66B, limitou a possibilidade de comparações externas aprofundadas. No entanto, esta ausência de evidência não enfraquece os resultados aqui apresentados; pelo contrário, reforça o valor exploratório desta abordagem, ao lançar bases para futuras investigações no mesmo campo.

Se houvesse oportunidade de dar continuidade a este estudo, seria relevante desenvolver investigações que incluam a análise temporal dos atrasos por fase de voo, a integração de dados qualitativos recolhidos junto das equipas operacionais e a comparação entre o comportamento do 66B em diferentes bases operacionais. Além disso, futuras investigações poderiam expandir o foco para outros códigos da família dos *DP*, avaliando o seu papel conjunto na robustez do processo de partida.

[esta página foi deixada em branco deliberadamente]

## REFERÊNCIAS

- Beltman, M., Ribeiro, M., de Wilde, J., & Sun, J. (2025). Dynamically forecasting airline departure delay probability distributions for individual flights using supervised learning. *Journal of Air Transport Management*, 126. <https://doi.org/10.1016/j.jairtraman.2025.102788>
- Britto, R., Dresner, M., & Voltes, A. (2012). The impact of flight delays on passenger demand and societal welfare. *Transportation Research Part E: Logistics and Transportation Review*, 48(2), 460–469. <https://doi.org/10.1016/j.tre.2011.10.009>
- Brueckner, J. K., Czerny, A. I., & Gaggero, A. A. (2021). Airline mitigation of propagated delays via schedule buffers: Theory and empirics. *Transportation Research Part E: Logistics and Transportation Review*, 150. <https://doi.org/10.1016/j.tre.2021.102333>
- Brueckner, J. K., Czerny, A. I., & Gaggero, A. A. (2022). Airline delay propagation: A simple method for measuring its extent and determinants. *Transportation Research Part B: Methodological*, 162, 55–71. <https://doi.org/10.1016/j.trb.2022.05.003>
- Buddhadev, M. (2025). Data preparation for predictive analytics: Cleaning and balancing airline datasets for flight diversion prediction. *International Journal of Computing and Artificial Intelligence*, 6(1), 141–148. <https://doi.org/10.33545/27076571.2025.v6.i1b.144>
- Custos da TAP com atrasos aumentam 40 milhões em 2018 - Aviação - Jornal de Negócios.* (2018). <https://www.jornaldenegocios.pt/empresas/transportes/aviacao/detalhe/custos-da-tap-com-atrasos-dobram-para-40-milhoes-em-2018>
- De Bruin, P., Van Den Akker, M., Kumar, K., Heuseveldt, L., & Paelinck, M. (2025). *Integrated Airline Fleet and Crew Recovery through Local Search.*
- Ding, Q., Ma, L., Cui, Y., Cheng, B., & He, X. (2024). Identification and Analysis of Flight Delay Based on Process Relevance. *Aerospace*, 11(6). <https://doi.org/10.3390/aerospace11060445>

- Efthymiou, M., Njoya, E. T., Lo, P. L., Papatheodorou, A., & Randall, D. (2019). The impact of delays on customers' satisfaction: An empirical analysis of the british airways on-time performance at heathrow airport. *Journal of Aerospace Technology and Management*, 11. <https://doi.org/10.5028/jatm.v11.977>
- EUROCONTROL. (2022). EUROCONTROL. (2023). CODA Digest Annual Report 2022: All-causes delay and cancellations to air transport in Europe. Brussels: EUROCONTROL Performance Review Unit. [www.eurocontrol.int](http://www.eurocontrol.int)
- Evler, J., Asadi, E., Preis, H., & Fricke, H. (2021a). Airline ground operations: Optimal schedule recovery with uncertain arrival times. *Journal of Air Transport Management*, 92. <https://doi.org/10.1016/j.jairtraman.2021.102021>
- Evler, J., Asadi, E., Preis, H., & Fricke, H. (2021b). Airline ground operations: Schedule recovery optimization approach with constrained resources. *Transportation Research Part C: Emerging Technologies*, 128. <https://doi.org/10.1016/j.trc.2021.103129>
- Evler, J., Lindner, M., Fricke, H., & Schultz, M. (2022). Integration of turnaround and aircraft recovery to mitigate delay propagation in airline networks. *Computers and Operations Research*, 138. <https://doi.org/10.1016/j.cor.2021.105602>
- Evler, J., Schultz, M., Fricke, H., & Cook, A. (2022). Stochastic Delay Cost Functions to Estimate Delay Propagation Under Uncertainty. *IEEE Access*, 10, 21424–21442. <https://doi.org/10.1109/ACCESS.2022.3152570>
- Falque, T., Mazure, B., & Tabia, K. (2024). Machine learning for predicting off-block delays: A case study at Paris — Charles de Gaulle International Airport. *Data and Knowledge Engineering*, 152. <https://doi.org/10.1016/j.datak.2024.102303>
- Fe, S., Allan, S. S., Beesley, J. A., Evans, J. E., & Gaddy, S. G. (2001). 4<sup>th</sup> USA/Europe Air Traffic Management R&D Seminar Analysis of Delay Causality at Newark International Airport\*. <http://www.ll.mit.edu/AviationWeather>
- Fleurquin, P., Ramasco, J. J., & Eguiluz, V. M. (2013). Systemic delay propagation in the US airport network.

Fujun, W., Jun, B., Dongfan, X., & Xiaomei, Z. (2022). *Flight delay forecasting and analysis of direct and indirect factors*.

Gondara, L., & Wang, K. (2018). *MIDA: Multiple Imputation using Denoising Autoencoders*. <http://arxiv.org/abs/1705.02737>

Hassan, L. K., Santos, B. F., & Vink, J. (2021). Airline disruption management: A literature review and practical challenges. In *Computers and Operations Research* (Vol. 127). Elsevier Ltd. <https://doi.org/10.1016/j.cor.2020.105137>

Hubert, M., & Van der Veeken, S. (2008). Outlier detection for skewed data. *Journal of Chemometrics*, 22(3-4), 235–246. doi:10.1002/cem.1123

Ionescu, L., Gwiggner, C., & Kliewer, N. (2016). Data Analysis of Delays in Airline Networks. *Business and Information Systems Engineering*, 58(2), 119–133. <https://doi.org/10.1007/s12599-015-0391-3>

Jatavallabha, A., Gerlach, J., & Naresh, A. (2024). Deciphering Air Travel Disruptions: A Machine Learning Approach \*. In *Proceedings of ACM Conference (Conference'17)* (Vol. 1). [https://github.com/jwgerlach00/flight\\_delay\\_predictio](https://github.com/jwgerlach00/flight_delay_predictio)

W. Tukey (1979) Exploratory Data Analysis. *Journal of the Royal Statistical Society. Series C (Applied Statistics)* Vol. 28, No. 1 (1979), pp. 79-83 (5 pages)

Published By: Oxford University Press

Li, N., & Yao, H. G. (2025). A Review of Research on Flight Delay Propagation: Current Situation and Prospect. In *Journal of Advanced Transportation* (Vol. 2025, Issue 1). John Wiley and Sons Ltd. <https://doi.org/10.1155/atr/4851103>

Liang, Y., Zhao, Z., & Sun, L. (2021). *Dynamic Spatiotemporal Graph Convolutional Neural Networks for Traffic Data Imputation with Complex Missing Patterns*. <https://doi.org/10.1016/j.trc.2022.103826>

Lin, P. C. (2023). The propagation of European airports' on-time performance and on-time flights via air connectivity prior to the Covid-19 pandemic. *Journal of Air Transport Management*, 109. <https://doi.org/10.1016/j.jairtraman.2023.102382>

Martina Jetzki, by, & rer nat Johannes Reichmuth Dipl-Wi-Ing Sebastian Kellner, U.-P. (2009). *The propagation of air transport delays in Europe Thesis*.

- Mitsokapas, E., Schäfer, B., Harris, R. J., & Beck, C. (2021). Statistical characterization of airplane delays. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-021-87279-8>
- Muzellec, B., Josse, J., Boyer, C., & Cuturi, M. (2020). *Missing Data Imputation using Optimal Transport*. <https://github>.
- Ogunsina, K., Bilionis, I., & DeLaurentis, D. (2021). *Exploratory Data Analysis for Airline Disruption Management*. <https://doi.org/10.1016/j.mlwa.2021.100102>
- Peterson, E. B., Neels, K., Barczi, N., & Graham, T. (2011). *The Economic Cost of Airline Flight Delay*.
- Peterson, E. B., Neels, K., Barczi, N., & Graham, T. (2013). The Economic Cost of Airline Flight Delay. *Journal of Transport Economics and Policy*, 47, 107–121.
- Pineda-Jaramillo, J., Munoz, C., Mesa-Arango, R., Gonzalez-Calderon, C., & Lange, A. (2024). Integrating multiple data sources for improved flight delay prediction using explainable machine learning. *Research in Transportation Business and Management*, 56. <https://doi.org/10.1016/j.rtbm.2024.101161>
- Ryanair com 98% dos voos no horário e clientes satisfeitos em setembro | Publituris*. (2020). <https://www.publituris.pt/2020/10/06/ryanair-com-98-dos-voos-no-horario-e-clientes-satisfeitos-em-setembro>
- Santana, M., De La Vega, J., Morabito, R., & Pureza, V. (2023). The aircraft recovery problem: A systematic literature review. In *EURO Journal on Transportation and Logistics* (Vol. 12). Elsevier B.V. <https://doi.org/10.1016/j.ejtl.2023.100117>
- Schultz, M. (2018). Fast aircraft turnaround enabled by reliable passenger boarding. *Aerospace*, 5(1). <https://doi.org/10.3390/aerospace5010008>
- Shang, Q., Tang, Y., & Yin, L. (2024). A hybrid model for missing traffic flow data imputation based on clustering and attention mechanism optimizing LSTM and AdaBoost. *Scientific Reports*, 14(1), 26473. <https://doi.org/10.1038/s41598-024-77748-1>
- Shao, W., Prabowo, A., Zhao, S., Tan, S., Koniusz, P., Chan, J., Hei, X., Feest, B., & Salim, F. D. (2019). Flight delay prediction using airport situational awareness map. *GIS:*

- Proceedings of the ACM International Symposium on Advances in Geographic Information Systems*, 432–435. <https://doi.org/10.1145/3347146.3359079>
- Singh, K. U., Singh, S., Sajjan, S., Singh, T., & Kumari, N. (2024). Strategic Management of Airline Operations: A Comprehensive Analysis of Flight Delay Causes and Mitigation Strategies. *2024 International Conference on Automation and Computation, AUTOCOM 2024*, 669–674. <https://doi.org/10.1109/AUTOCOM60220.2024.10486117>
- Sternberg, A., Soares, J., Carvalho, D., & Ogasawara, E. (2017). *A Review on Flight Delay Prediction*. <https://doi.org/10.1080/01441647.2020.1861123>
- Sternberg, A., Soares, J., Carvalho, D., & Ogasawara, E. (2020). *A Review on Flight Delay Prediction*. <https://doi.org/10.1080/01441647.2020.1861123>
- Sugishita, K., Arisawa, K., & Hanaoka, S. (2024). *Delay propagation patterns in Japan's domestic air transport network*.
- Wang, Y., Cao, Y., Zhu, C., Wu, F., Hu, M., Duong, V., Watkins, M., Barzel, B., & Stanley, H. E. (2020). Universal patterns in passenger flight departure delays. *Scientific Reports*, 10(1). <https://doi.org/10.1038/s41598-020-62871-6>
- Wang, Z., Zhuang, D., Li, Y., Zhao, J., Sun, P., Wang, S., & Hu, Y. (2023). *ST-GIN: An Uncertainty Quantification Approach in Traffic Data Imputation with Spatio-temporal Graph Attention and Bidirectional Recurrent United Neural Networks*. <http://arxiv.org/abs/2305.06480>
- Zámková, M., & Martin Prokop, M. (2015). *The evaluation of factors influencing flights delay at czech international airports*. [https://www.researchgate.net/publication/288178705\\_The\\_Evaluation\\_of\\_Factors\\_Influencing\\_Flights\\_Delay\\_at\\_Czech\\_International\\_Airports](https://www.researchgate.net/publication/288178705_The_Evaluation_of_Factors_Influencing_Flights_Delay_at_Czech_International_Airports)
- Zámková, M., Prokop, M., & Stolín, R. (2017). *Factors Influencing Flight Delays Of An European Airline*. [https://acta.mendelu.cz/artkey/acu-201705-0037\\_factors-influencing-flight-delays-of-a-european-airline.php](https://acta.mendelu.cz/artkey/acu-201705-0037_factors-influencing-flight-delays-of-a-european-airline.php)
- Zámková, M., Rojík, S., Prokop, M., & Stolín, R. (2022). Factors Affecting the International Flight Delays and Their Impact on Airline Operation and Management and

Passenger Compensations Fees in Air Transport Industry: Case Study of a Selected Airlines in Europe. *Sustainability (Switzerland)*, 14(22).  
<https://doi.org/10.3390/su142214763>

Zhang, M., Wen, X., Wu, M., & Xie, H. (2024). Identification of Critical Nodes for Delay Propagation in Susceptible-Exposed-Infected-Recovered (SEIR) and Genetic Algorithm (GA) Route Networks. *Aerospace*, 11(11).  
<https://doi.org/10.3390/aerospace11110878>

Zhou, F., Jiang, G., Lu, Z., & Wang, Q. (2022). Evaluation and Analysis of the Impact of Airport Delays. *Scientific Programming*, 2022.  
<https://doi.org/10.1155/2022/7102267>

## 8. ANEXO – Utilização da ferramenta julius.ai: *prompts* e *outputs*

## 2.1. User

I uploaded the file: `Delays\_codificados\_CLASSIFICADOS\_FINAL`

Considera os dois tipos de atrasos, controláveis e não controláveis. Calcula para cada um, o número de voos associados, as frequências absolutas e para os atrasos as médias e desvios-padrão, as medianas, o mínimo e o máximo, a curtose e a assimetria. Fornece um file Excel.

## 2.2. Julius

### 2.2.1. run\_code

```
# Load the excel file and compute summary stats by Controlabilidade
import pandas as pd
from scipy.stats import kurtosis, skew

# Read file
file_path = 'Delays_codificados_CLASSIFICADOS_FINAL_para_ACF.xlsx'

df = pd.read_excel(file_path, engine='calamine')

# Assuming Controlabilidade column 1=controlavel, 0=nao controlavel
# Clean: drop NaNs in Atraso (minutos)
df_clean = df.dropna(subset=['Atraso (minutos)', 'Controlabilidade'])

# convert delay to numeric
df_clean['Atraso (minutos)'] = pd.to_numeric(df_clean['Atraso (minutos)'], errors='coerce')

summary_list = []
for tipo, group in df_clean.groupby('Controlabilidade'):
    count = group.shape[0]
    mean_ = group['Atraso (minutos)'].mean()
    std_ = group['Atraso (minutos)'].std(ddof=1)
    median_ = group['Atraso (minutos)'].median()
    min_ = group['Atraso (minutos)'].min()
    max_ = group['Atraso (minutos)'].max()
    kurt = kurtosis(group['Atraso (minutos)'], bias=False)
    skewness = skew(group['Atraso (minutos)'], bias=False)
    summary_list.append({'Tipo': 'Controlável' if tipo==1 else 'Não controlável',
                        'N_voos': count,
                        'Média': mean_,
                        'Desvio-padrão': std_,
                        'Mediana': median_,
                        'Mínimo': min_,
                        'Máximo': max_,
                        'Curtose': kurt,
                        'Assimetria': skewness})

summary_df = pd.DataFrame(summary_list)
```

```
# Save to excel
output_file = 'estatisticas_atrasos.xlsx'
summary_df.to_excel(output_file, index=False)

print(summary_df.head())
print('Arquivo gerado:', output_file)
```

## 2.3. User

mostra a distribuição dos atrasos de ambos os grupos para visualizarmos a natureza das distribuições. Usa o azul para os controláveis e o vermelho para os não controláveis. Insere tracejados verticais relativos aos valores médios dos atrasos de cada grupo

## 2.4. Julius

### 2.4.1. run\_code

```
# Plot histograms for the two groups
import matplotlib.pyplot as plt
import seaborn as sns

# Data
controlavel = filtered[filtered['Controlabilidade']==1]['Atraso (minutos)']
nao = filtered[filtered['Controlabilidade']==2]['Atraso (minutos)']

fig, ax = plt.subplots(figsize=(9,6))
plt.subplots_adjust(left=0.15, right=0.85, top=0.85, bottom=0.15)
ax.set_axisbelow(True)


bins = range(0, int(filtered['Atraso (minutos)'].max()+10, 10)

sns.histplot(controlavel, bins=bins, color='#1f77b4', alpha=0.6, kde=False, stat='density', ax=ax, label='Controlável')
sns.histplot(nao, bins=bins, color='#d62728', alpha=0.6, kde=False, stat='density', ax=ax, label='Não controlável')

# means
mean_control = controlavel.mean()
mean_nao = nao.mean()
ax.axvline(mean_control, color='#1f77b4', linestyle='--', linewidth=2)
ax.axvline(mean_nao, color='#d62728', linestyle='--', linewidth=2)

ax.set_title('Distribuição dos atrasos por tipo de controlo', pad=15,
fontsize=20, weight='semibold', color='#222222')
ax.set_xlabel('Atraso (minutos)', labelpad=10, fontsize=16, weight='medium', color='#333333')
ax.set_ylabel('Densidade', labelpad=10, fontsize=16, weight='medium',
```

```
color='#333333')
ax.tick_params(axis='both', labels=14, colors='#555555')
ax.grid(color='#E0E0E0')
ax.legend(loc='upper right', frameon=False, fontsize=12)
plt.show()
```



## 2.5. User

Faz um novo gráfico, mas agora limitando a cauda até aos 200 minutos para se ver melhor a assimetria das distribuições

## 2.6. Julius

### 2.6.1. run\_code

```
# Plot truncated histogram 0-200 min
fig, ax = plt.subplots(figsize=(9,6))
plt.subplots_adjust(left=0.15, right=0.85, top=0.85, bottom=0.15)
ax.set_axisbelow(True)

bins = range(0, 201, 10)

sns.histplot(controlavel[controlavel<=200], bins=bins, color='#1f77b4',
             alpha=0.6, stat='density', ax=ax, label='Controlável')
sns.histplot(nao[nao<=200], bins=bins, color='#d62728', alpha=0.6, stat='density',
             ax=ax, label='Não controlável')


# vertical means remain at full mean but limit axis 200
ax.axvline(mean_control, color='#1f77b4', linestyle='--', linewidth=2)
ax.axvline(mean_nao, color='#d62728', linestyle='--', linewidth=2)
```

```

ax.set_title('Distribuição dos atrasos (0-200 min)', pad=15, fontsize=
20, weight='semibold', color='#222222')
ax.set_xlabel('Atraso (minutos)', labelpad=10, fontsize=16, weight='me
dium', color='#333333')
ax.set_ylabel('Densidade', labelpad=10, fontsize=16, weight='medium',
color='#333333')
ax.set_xlim(0,200)
ax.tick_params(axis='both', labelsize=14, colors='#555555')
ax.grid(color='#E0E0E0')
ax.legend(loc='upper right', frameon=False, fontsize=12)

plt.show()

```



Com o eixo limitado a 0-200 min, a assimetria positiva fica mais nítida:

- Controláveis (azul):
  - Pico robusto nos 5-10 min, queda acentuada, depois uma cauda suave até cerca de 120 min; poucos eventos acima disso dentro deste intervalo.
  - A média (linha tracejada) permanece nos 18 min, claramente puxada pela cauda apesar de a maioria concentrar-se abaixo dos 15 min.
- Não controláveis (vermelho):
  - Pico nos 10-20 min e distribuição mais “espalmada” até 200 min; densidade residual maior a partir dos 60 min em comparação com os controláveis, ilustrando atrasos longos mais frequentes.

- A média ( $\approx 28$  min) também se desloca para a direita por influência da cauda.

Assim, mesmo sem os extremos ( $>200$  min), ambas mantêm forte assimetria à direita, mas os atrasos não controláveis revelam-se globalmente mais longos e dispersos.

## 2.7. User

Volta a emitir os dois gráficos, mas desta vez com a duração dos atrasos.

## 2.8. Julius

### 2.8.1. run\_code

```
# Two histograms: full range and 0-200 min, y-axis counts
import matplotlib.pyplot as plt
import seaborn as sns


# Full range
fig, ax = plt.subplots(figsize=(9,6))
plt.subplots_adjust(left=0.15, right=0.85, top=0.85, bottom=0.15)
ax.set_axisbelow(True)


bins_full = range(0, int(filtered['Atraso (minutos)'].max()+10, 10)
sns.histplot(controlavel, bins=bins_full, color='#1f77b4', alpha=0.6,
stat='count', label='Controlável', ax=ax)
sns.histplot(nao, bins=bins_full, color='#d62728', alpha=0.6, stat='count',
label='Não controlável', ax=ax)
ax.axvline(mean_control, color='#1f77b4', linestyle='--', linewidth=2)
ax.axvline(mean_nao, color='#d62728', linestyle='--', linewidth=2)
ax.set_title('Contagem de voos por atraso (toda a gama)', pad=15, font
size=20, weight='semibold', color='#222222')
ax.set_xlabel('Atraso (minutos)', labelpad=10, fontsize=16, weight='medium',
color='#333333')
ax.set_ylabel('Número de voos', labelpad=10, fontsize=16, weight='medium',
color='#333333')
ax.tick_params(axis='both', labelsize=14, colors='#555555')
ax.grid(color='#E0E0E0')
ax.legend(loc='upper right', frameon=False, fontsize=12)
plt.show()

# Truncated 0-200 min
fig2, ax2 = plt.subplots(figsize=(9,6))
plt.subplots_adjust(left=0.15, right=0.85, top=0.85, bottom=0.15)
ax2.set_axisbelow(True)

bins_trunc = range(0, 201, 10)
sns.histplot(controlavel[controlavel<=200], bins=bins_trunc, color='#1f77b4',
alpha=0.6, stat='count', label='Controlável', ax=ax2)
sns.histplot(nao[nao<=200], bins=bins_trunc, color='#d62728', alpha=0.6,
stat='count', label='Não controlável', ax=ax2)
ax2.axvline(mean_control, color='#1f77b4', linestyle='--', linewidth=2)
)
```

```
ax2.axvline(mean_ao, color='#d62728', linestyle='--', linewidth=2)
ax2.set_title('Contagem de voos por atraso (0-200 min)', pad=15, fontsize=20, weight='semibold', color='#222222')
ax2.set_xlabel('Atraso (minutos)', labelpad=10, fontsize=16, weight='medium', color='#333333')
ax2.set_ylabel('Número de voos', labelpad=10, fontsize=16, weight='medium', color='#333333')
ax2.set_xlim(0,200)
ax2.tick_params(axis='both', labelsize=14, colors='#555555')
ax2.grid(color='#E0E0E0')
ax2.legend(loc='upper right', frameon=False, fontsize=12)
plt.show()
```





## 2.9. User

Efetua o diagnóstico de outliers nas distribuições dos atrasos com recurso à Regra do Intervalo Interquartil

### 2.10. Julius

#### 2.10.1. run\_code

```
# Diagnose outliers using IQR rule for each group in 'filtered'
results=[]
for tipo, grp in filtered.groupby('Controlabilidade'):
    delays=grp['Atraso (minutos)']
    q1=delays.quantile(0.25)
    q3=delays.quantile(0.75)
    iqr=q3-q1
    lower=q1-1.5*iqr
    upper=q3+1.5*iqr
    outliers=delays[(delays<lower)|(delays>upper)]
    results.append({'Tipo':'Controlável' if tipo==1 else 'Não controlável', 'Q1':q1, 'Q3':q3, 'IQR':iqr, 'Limite inferior':lower, 'Limite superior':upper, 'Outliers':outliers.count(), 'Percentual_outliers':100*outliers.count()/delays.count()})
summary_out=pd.DataFrame(results)
print(summary_out)
```

	Tipo	Q1	Q3	IQR	Limite inferior	Limite superior	Outliers	Percentual_outliers
0	Controlu00e1vel	5.0	17.0	12.0	-13.0	35.0	288	10.415913200723327

Tipo	Q1	Q3	IQR	Limite inferior	Limite superior	Outliers	Percentual_outliers
1 Nu00e3o controllu00e1vel	7.0	33.0	26.0	-32.0	72.0	1042	9.17092061256821

### Diagnóstico com a Regra do Intervalo Interquartil (IQR)

- Para cada grupo calculou-se:

$Q1$  (1.º quartil)

$Q3$  (3.º quartil)

$IQR = Q3 - Q1$

Limites de detecção:

- inferior:  $Q1 - 1.5 \cdot IQR$
- superior:  $Q3 + 1.5 \cdot IQR$

### Resultados

- Controláveis
  - Limites: -13 min a 35 min  
288 voos excedem estes limites ( $\approx 10.4\%$  do total).  
Todos os outliers estão acima do limite superior (não há atrasos negativos), confirmando a cauda longa.
- Não controláveis
  - Limites: -32 min a 72 min  
1 042 voos identificados ( $\approx 9.2\%$ ).  
Também só ocorrem acima do limite superior, mas o limiar é bem mais alto (72 min), reflectindo atrasos tipicamente maiores neste grupo.

#### 2.11. User

Testa se as diferenças entre os dois grupos, controláveis e não controláveis, são ou não estatisticamente significativas quanto à duração dos atrasos. Explica quais os testes usados, justifica a opção e descreve as etapas. Exporta os resultados para um file excel.

## 2.12. Julius

### 2.12.1. run\_code

```
# Statistical tests comparing delay durations between controlável (1)
and não controlável (2)
import pandas as pd
from scipy.stats import ttest_ind, mannwhitneyu, normaltest, levene

# Data already: filtered, controlavel, nao

# normality tests (D'Agostino-Pearson)
norm_control = normaltest(controlavel)
norm_nao = normaltest(nao)

# variance equality
lev = levene(controlavel, nao)

# Welch t-test (unequal var)
welch = ttest_ind(controlavel, nao, equal_var=False)

# Mann-Whitney U (non-parametric)
mann_u = mannwhitneyu(controlavel, nao, alternative='two-sided')

# effect size (Cohen d)
import numpy as np
def cohen_d(a,b):
    n1=len(a); n2=len(b)
    s1=np.var(a, ddof=1); s2=np.var(b, ddof=1)
    s_pooled = ((n1-1)*s1 + (n2-1)*s2) / (n1+n2-2)
    return (np.mean(a)-np.mean(b)) / np.sqrt(s_pooled)

d = cohen_d(controlavel, nao)

results = pd.DataFrame({
    'Teste':['Normalidade controlável', 'Normalidade não controlável',
    'Levene variâncias', 'Welch t', 'Mann-Whitney U', 'Cohen d'],
    'Estatística':[norm_control.statistic, norm_nao.statistic, lev.sta
tistic, welch.statistic, mann_u.statistic, d],
    'p-valor':[norm_control.pvalue, norm_nao.pvalue, lev.pvalue, welch
.pvalue, mann_u.pvalue, '']
})

results_file='testes_diferencas_atrasos.xlsx'
results.to_excel(results_file, index=False)

print(results)
```

	Teste	Estatística	p-valor
0	Normalidade controlável	3925.946588341812	0.0
1	Normalidade não controlável	8578.132216222433	0.0

Teste	Estatu00edstica	p-valor
2 Levene variu00e2ncias	131.22539019281544	3.006091310477667e-30
3 Welch t	-13.351018025544532	6.488326253864316e-40
4 Mann-Whitney U	12312897.0	8.156560877621261e-70
5 Cohen d	-0.26585650794875676	

### Etapas e justificações

1. Preparação dos dados
  - Mantiveram-se apenas os voos com atraso > 0 min e eliminaram-se os 32 registos com código 0.  
Ficaram 2 765 atrasos controláveis e 11 362 não-controláveis.
2. Verificação de pressupostos
  - Normalidade (teste de D’Agostino-Pearson):  $p < 0.001$
  - para ambos os grupos  $\Rightarrow$  distribuições claramente não-normais.  
Homogeneidade de variâncias (Levene):  $p < 0.001$   
 $\Rightarrow$  variâncias diferentes.
3. Testes de diferença de médias
  - Welch’s t-test (robusto a variâncias desiguais) .  $t = -13.35$ ,  $p < 10^{-38}$
  - .Mann-Whitney U (não-paramétrico, dispensa normalidade)  $\rightarrow$   
 $\$U = 1.23 \times 10^7, \; p < 10^{-69}\$$   
 .Ambos rejeitam a hipótese nula de igualdade das distribuições/médias.
4. Tamanho do efeito
  - Cohen’s,  $d = -0.27$
  - (valor negativo porque o grupo não-controlável tem média maior).  
Efeito pequeno-médio – a diferença é estatisticamente forte mas, em termos práticos, uma média 10 min superior não é enorme para operações, embora relevante.

Resultados exportados

Arquivo: testes\_diferencas\_atrasos.xlsx

Download em [https://julius.ai/files/testes\\_diferencas\\_atrasos.xlsx](https://julius.ai/files/testes_diferencas_atrasos.xlsx)

### 2.13. User

Apresenta os resultados do teste t de Welch com o tamanho do efeito para se poder apreciar a magnitude prática. Exporta os resultados para um file excel.

### 2.14. Julius

#### 2.14.1. run\_code

```
# Recompute Welch t with df attribute
from scipy.stats import ttest_ind
res = ttest_ind(controlavel, nao, equal_var=False)

stat = res.statistic
pval = res.pvalue
```

```

try:
    df_dof = res.df
except AttributeError:
    # compute Welch-Satterthwaite df manually
    import numpy as np
    n1=len(controlavel); n2=len(nao)
    s1=np.var(controlavel, ddof=1); s2=np.var(nao, ddof=1)
    df_dof = (s1/n1 + s2/n2)**2 / ((s1/n1)**2/(n1-1) + (s2/n2)**2/(n2-
1))

# Means SDs
import numpy as np
mean1=controlavel.mean(); sd1=controlavel.std(ddof=1); n1=len(controla
vel)
mean2=nao.mean(); sd2=nao.std(ddof=1); n2=len(nao)

# Cohen d computed earlier

d

# Table
apa_table = pd.DataFrame({
    'Grupo': ['Controlável', 'Não controlável'],
    'N': [n1, n2],
    'Média': [mean1, mean2],
    'Desvio-padrão': [sd1, sd2]
})

# stats row
summary_stats = pd.DataFrame({
    't': [stat],
    'df': [df_dof],
    'p valor': [pval],
    "Cohen's d": [d]
})

excel_file='welch_t_apresentacao.xlsx'
with pd.ExcelWriter(excel_file) as writer:
    apa_table.to_excel(writer, sheet_name='Descritivas', index=False)
    summary_stats.to_excel(writer, sheet_name='Teste', index=False)

print(apa_table)
print(summary_stats)
print('Arquivo salvo:', excel_file)

```

	Grupo	N	Mu00e9dia	Desvio-padru00e3o
0	Controlu00e1vel	2765	18.326582278481013	33.988665942031496
1	Nu00e3o controlu00e1vel	11362	28.163703573314557	37.69823467218747

. O tamanho do efeito foi pequeno-médio,  $d = 0.27$

, indicando que os atrasos não-controláveis são, em média, cerca de um quarto de um desvio-padrão superiores aos controláveis.

O ficheiro Excel com as estatísticas descritivas e o teste encontra-se disponível para download em [https://julius.ai/files/welch\\_t\\_apresentacao.xlsx](https://julius.ai/files/welch_t_apresentacao.xlsx)

## 2.15. User

Vamos analisar agora o comportamento do 66B primeiro na amostra total quanto à sua frequência. Indica que posição ocupa na amostra global e no grupo dos controláveis. Explica os cálculos. Produz gráficos.

## 2.16. Julius

### 2.16.1. run\_code

```
# reload dataframe quickly
import pandas as pd
file_path='Delays_codificados_CLASSIFICADOS_FINAL_para_ACF.xlsx'
df_full=pd.read_excel(file_path, engine='calamine')

print(df_full.columns)
```

### 2.16.2. run\_code

```
# Prepare and analyze frequency of delay_code focusing on 66B
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

file_path='Delays_codificados_CLASSIFICADOS_FINAL_para_ACF.xlsx'
df=pd.read_excel(file_path, engine='calamine')

# filter out controlabilidade 0 and delays 0
filtered=df[(df['Controlabilidade']!=0) & (df['Atraso (minutos)']!=0)]

# frequency overall
freq_overall=filtered['delay_code'].value_counts().reset_index()
freq_overall.columns=['delay_code', 'N']
freq_overall['Rank']=freq_overall['N'].rank(method='min', ascending=False).astype(int)

# frequency within controláveis
ctrl=filtered[filtered['Controlabilidade']==1]
freq_ctrl=ctrl['delay_code'].value_counts().reset_index()
freq_ctrl.columns=['delay_code', 'N_ctrl']
freq_ctrl['Rank_ctrl']=freq_ctrl['N_ctrl'].rank(method='min', ascending=False).astype(int)

# extract 66B info
code='66B'
info_overall=freq_overall[freq_overall['delay_code']==code]
info_ctrl=freq_ctrl[freq_ctrl['delay_code']==code]
```

```

print(info_overall)
print(info_ctrl)

# merge for table
summary=pd.concat([info_overall.reset_index(drop=True), info_ctrl[['N_
ctrl', 'Rank_ctrl']]], axis=1)

# Plot bar overall top 20 highlight 66B
sns.set(style='white')
fig, ax = plt.subplots(figsize=(9,6))
plt.subplots_adjust(left=0.15, right=0.85, top=0.85, bottom=0.2)
ax.set_axisbelow(True)

top20=freq_overall.head(20)
colors=['#766CDB' if dc==code else '#D9CC8B' for dc in top20['delay_co
de']]
ax.bar(top20['delay_code'], top20['N'], color=colors)
ax.set_title('Top 20 códigos de atraso - frequência total', pad=15, fo
ntsize=20, weight='semibold', color='#222222')
ax.set_xlabel('Código', labelpad=10, fontsize=16, weight='medium', col
or='#333333')
ax.set_ylabel('Número de voos', labelpad=10, fontsize=16, weight='medi
um', color='#333333')
ax.tick_params(axis='x', rotation=45, labels=12, colors='#555555')
ax.tick_params(axis='y', labels=14, colors='#555555')
ax.grid(axis='y', color='#E0E0E0')
plt.show()

# Plot controlável top 20
fig2, ax2 = plt.subplots(figsize=(9,6))
plt.subplots_adjust(left=0.15, right=0.85, top=0.85, bottom=0.2)
ax2.set_axisbelow(True)

top20c=freq_ctrl.head(20)
colors2=['#766CDB' if dc==code else '#7CD9A5' for dc in top20c['delay_
code']]
ax2.bar(top20c['delay_code'], top20c['N_ctrl'], color=colors2)
ax2.set_title('Top 20 códigos de atraso - grupo controlável', pad=15,
fontsize=20, weight='semibold', color='#222222')
ax2.set_xlabel('Código', labelpad=10, fontsize=16, weight='medium', co
lor='#333333')
ax2.set_ylabel('Número de voos', labelpad=10, fontsize=16, weight='med
ium', color='#333333')
ax2.tick_params(axis='x', rotation=45, labels=12, colors='#555555')
ax2.tick_params(axis='y', labels=14, colors='#555555')
ax2.grid(axis='y', color='#E0E0E0')
plt.show()

# export summary & full counts
excel_file='frequencia_66B.xlsx'
with pd.ExcelWriter(excel_file) as writer:
    summary.to_excel(writer, sheet_name='66B_resumo', index=False)
    freq_overall.to_excel(writer, sheet_name='Frequencia_total', index


```

```
=False)  
    freq_ctrl.to_excel(writer, sheet_name='Frequencia_controlavel', in  
dex=False)  
  
print('Resumo 66B')  
print(summary)  
print('Arquivo salvo:', excel_file)
```


delay_code	N	Rank
11 66B	223	12

delay_code	N_ctrl	Rank_ctrl
4 66B	223	4

**Top 20 códigos de atraso - frequência total**



## Top 20 códigos de atraso - grupo controlável



Na amostra depurada (sem código 0 e sem atrasos 0 min):

- Código 66B surge 223 vezes, ocupando a 12.ª posição no ranking global de causas de atraso (top-20 ilustrado a azul-púrpura no primeiro gráfico).
- Entre os atrasos controláveis, esses mesmos 223 registos colocam o 66B na 4.ª posição, destacado a roxo no segundo gráfico; é, portanto, um dos principais motivos de atraso dentro do universo controlável.

Explicação dos cálculos

1. Filtrou-se a base para excluir Controlabilidade 0 e atrasos 0 min.
2. Contou-se a frequência de cada delay\_code (value\_counts).
3. Ordenou-se em ordem decrescente e atribuiu-se a posição (Rank).
4. Repetiu-se o procedimento dentro do sub-dataframe controlável.
5. Os gráficos mostram os 20 códigos mais comuns: barras neutras para os demais e cor de destaque para o 66B.

- Eixo vertical: número de voos; eixo horizontal: códigos de atraso.

O ficheiro detalhado com as tabelas completas encontra-se em

[https://julius.ai/files/frequencia\\_66B.xlsx](https://julius.ai/files/frequencia_66B.xlsx)

### 2.16.3. run\_code

```
# Create duration analysis plots - Top 20 by mean duration
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np

# Calculate mean duration by delay code
duration_overall = filtered.groupby('delay_code')['Atraso (minutos)'].
```

```

agg(['mean', 'count']).reset_index()
duration_overall.columns = ['delay_code', 'mean_duration', 'count']
duration_overall = duration_overall[duration_overall['count'] >= 5] #
filter codes with at least 5 occurrences
duration_overall = duration_overall.sort_values('mean_duration', ascen
ding=False)
duration_overall['Rank_duration'] = range(1, len(duration_overall) + 1
)

# Add controlability info
duration_overall['Controlabilidade'] = duration_overall['delay_code'].
map(controlability_map)

# Top 20 by mean duration
fig3, ax3 = plt.subplots(figsize=(12,7))
plt.subplots_adjust(left=0.1, right=0.95, top=0.85, bottom=0.25)
ax3.set_axisbelow(True)

top20_dur = duration_overall.head(20)
colors3 = []
for i, row in top20_dur.iterrows():
    if row['delay_code'] == '66B':
        colors3.append('#d62728') # red for 66B
    elif row['Controlabilidade'] == 1:
        colors3.append('#1f77b4') # blue for controlable
    else:
        colors3.append('#7f7f7f') # grey for non-controlable

bars3 = ax3.bar(range(len(top20_dur)), top20_dur['mean_duration'], col
or=colors3)

# Add duration labels on top of bars
for i, (bar, duration) in enumerate(zip(bars3, top20_dur['mean_duratio
n'])):
    ax3.text(bar.get_x() + bar.get_width()/2, bar.get_height() + 1,
             f'{duration:.1f}', ha='center', va='bottom', fontsize=10,
             color='#333333')

ax3.set_title('Top 20 códigos de atraso - duração média', pad=15, font
size=20, weight='semibold', color='#222222')
ax3.set_xlabel('Código de atraso', labelpad=10, fontsize=16, weight='m
edium', color='#333333')
ax3.set_ylabel('Duração média (minutos)', labelpad=10, fontsize=16, we
ight='medium', color='#333333')
ax3.set_xticks(range(len(top20_dur)))
ax3.set_xticklabels(top20_dur['delay_code'], rotation=45, ha='right')
ax3.tick_params(axis='both', labelsize=12, colors='#555555')
ax3.grid(axis='y', color='#E0E0E0')

# Legend
legend_elements3 = [Patch(facecolor='#1f77b4', label='Controlável'),
                    Patch(facecolor='#7f7f7f', label='Não controlável'
),
                    Patch(facecolor='#d62728', label='66B')]

```

```

ax3.legend(handles=legend_elements3, loc='upper right', frameon=False,
           fontsize=12)

plt.tight_layout()
plt.show()

# Duration for controlable codes only
ctrl_duration = ctrl.groupby('delay_code')['Atraso (minutos)'].agg(['mean', 'count']).reset_index()
ctrl_duration.columns = ['delay_code', 'mean_duration_ctrl', 'count_ctrl']
ctrl_duration = ctrl_duration[ctrl_duration['count_ctrl'] >= 5]
ctrl_duration = ctrl_duration.sort_values('mean_duration_ctrl', ascending=False)
ctrl_duration['Rank_duration_ctrl'] = range(1, len(ctrl_duration) + 1)

fig4, ax4 = plt.subplots(figsize=(12,7))
plt.subplots_adjust(left=0.1, right=0.95, top=0.85, bottom=0.25)
ax4.set_axisbelow(True)

top20_dur_ctrl = ctrl_duration.head(20)
colors4 = ['#d62728' if dc == '66B' else '#1f77b4' for dc in top20_dur_ctrl['delay_code']]

bars4 = ax4.bar(range(len(top20_dur_ctrl)), top20_dur_ctrl['mean_duration_ctrl'], color=colors4)

# Add duration labels
for i, (bar, duration) in enumerate(zip(bars4, top20_dur_ctrl['mean_duration_ctrl'])):
    ax4.text(bar.get_x() + bar.get_width()/2, bar.get_height() + 1,
            f'{duration:.1f}', ha='center', va='bottom', fontsize=10,
            color='#333333')

ax4.set_title('Top 20 códigos de atraso - duração média (grupo controlável)', pad=15, fontsize=20, weight='semibold', color='#222222')
ax4.set_xlabel('Código de atraso', labelpad=10, fontsize=16, weight='medium', color='#333333')
ax4.set_ylabel('Duração média (minutos)', labelpad=10, fontsize=16, weight='medium', color='#333333')
ax4.set_xticks(range(len(top20_dur_ctrl)))
ax4.set_xticklabels(top20_dur_ctrl['delay_code'], rotation=45, ha='right')
ax4.tick_params(axis='both', labelsize=12, colors='#555555')
ax4.grid(axis='y', color='#E0E0E0')

# Legend for controlable duration
legend_elements4 = [Patch(facecolor='#1f77b4', label='Controlável'),
                   Patch(facecolor='#d62728', label='66B')]
ax4.legend(handles=legend_elements4, loc='upper right', frameon=False,
           fontsize=12)

plt.tight_layout()
plt.show()

```

```

# Find 66B position in duration rankings
pos_66B_overall = duration_overall[duration_overall['delay_code'] == '66B']['Rank_duration'].iloc[0] if '66B' in duration_overall['delay_code'].values else 'N/A'
pos_66B_ctrl = ctrl_duration[ctrl_duration['delay_code'] == '66B']['Rank_duration_ctrl'].iloc[0] if '66B' in ctrl_duration['delay_code'].values else 'N/A'

print(f"Posição do 66B no ranking de duração média (geral): {pos_66B_overall}")
print(f"Posição do 66B no ranking de duração média (controlável): {pos_66B_ctrl}")

# Export duration analysis
excel_file_dur = 'duracao_66B.xlsx'
with pd.ExcelWriter(excel_file_dur) as writer:
    duration_overall.to_excel(writer, sheet_name='Duracao_geral', index=False)
    ctrl_duration.to_excel(writer, sheet_name='Duracao_controlavel', index=False)

print(f"Arquivo de duração salvo: {excel_file_dur}")

```

## 2.17. User

Os gráficos devem ter legendas, e as barras dos gráficos devem ser azuis para os códigos controláveis, cinzentas para os não controláveis. No topo de cada barra, colocar a frequência absoluta. Produz outros gráficos Top 20, mas desta vez para a duração dos atrasos.

## 2.18. Julius

### 2.18.1. run\_code

```

# Now create duration analysis - Top 20 by mean delay duration
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np

# Calculate mean delay duration by code
duration_stats = filtered.groupby('delay_code').agg({
    'Atraso (minutos)': ['mean', 'count', 'std']
}).round(2)

duration_stats.columns = ['Mean_duration', 'Count', 'Std_duration']
duration_stats = duration_stats.reset_index()

# Filter codes with at least 10 occurrences for reliability
duration_stats_filtered = duration_stats[duration_stats['Count'] >= 10]
duration_stats_filtered = duration_stats_filtered.sort_values('Mean_duration', ascending=False)

```

```

# Add controlability info
duration_stats_filtered['Controlabilidade'] = duration_stats_filtered[
'delay_code'].map(controlability_map)

# Top 20 by mean duration
fig3, ax3 = plt.subplots(figsize=(12,7))
plt.subplots_adjust(left=0.1, right=0.95, top=0.85, bottom=0.25)
ax3.set_axisbelow(True)

top20_dur = duration_stats_filtered.head(20)
colors3 = []
for i, row in top20_dur.iterrows():
    if row['delay_code'] == '66B':
        colors3.append('#d62728') # red for 66B
    elif row['Controlabilidade'] == 1:
        colors3.append('#1f77b4') # blue for controlable
    else:
        colors3.append('#7f7f7f') # grey for non-controlable

bars3 = ax3.bar(range(len(top20_dur)), top20_dur['Mean_duration'], col
or=colors3)

# Add duration labels on top of bars
for i, (bar, duration) in enumerate(zip(bars3, top20_dur['Mean_duratio
n'])):
    ax3.text(bar.get_x() + bar.get_width()/2, bar.get_height() + 1,
            f'{duration:.1f}', ha='center', va='bottom', fontsize=10,
            color='#333333')

ax3.set_title('Top 20 códigos por duração média do atraso', pad=15, fo
ntsize=20, weight='semibold', color='#222222')
ax3.set_xlabel('Código de atraso', labelpad=10, fontsize=16, weight='m
edium', color='#333333')
ax3.set_ylabel('Duração média (minutos)', labelpad=10, fontsize=16, we
ight='medium', color='#333333')
ax3.set_xticks(range(len(top20_dur)))
ax3.set_xticklabels(top20_dur['delay_code'], rotation=45, ha='right')
ax3.tick_params(axis='both', labelsize=12, colors='#555555')
ax3.grid(axis='y', color='#E0E0E0')

# Legend
from matplotlib.patches import Patch
legend_elements3 = [Patch(facecolor='#1f77b4', label='Controlável'),
                    Patch(facecolor='#7f7f7f', label='Não controlável'
),
                    Patch(facecolor='#d62728', label='66B')]
ax3.legend(handles=legend_elements3, loc='upper right', frameon=False,
fontsize=12)

plt.tight_layout()
plt.show()

# Top 20 controlable codes by duration

```

```

ctrl_duration = filtered[filtered['Controlabilidade']==1].groupby('delay_code').agg({
    'Atraso (minutos)': ['mean', 'count', 'std']
}).round(2)

ctrl_duration.columns = ['Mean_duration', 'Count', 'Std_duration']
ctrl_duration = ctrl_duration.reset_index()
ctrl_duration_filtered = ctrl_duration[ctrl_duration['Count'] >= 10]
ctrl_duration_filtered = ctrl_duration_filtered.sort_values('Mean_duration', ascending=False)

fig4, ax4 = plt.subplots(figsize=(12,7))
plt.subplots_adjust(left=0.1, right=0.95, top=0.85, bottom=0.25)
ax4.set_axisbelow(True)

top20_ctrl_dur = ctrl_duration_filtered.head(20)
colors4 = ['#d62728' if dc=='66B' else '#1f77b4' for dc in top20_ctrl_dur['delay_code']]

bars4 = ax4.bar(range(len(top20_ctrl_dur)), top20_ctrl_dur['Mean_duration'], color=colors4)

# Add duration labels
for i, (bar, duration) in enumerate(zip(bars4, top20_ctrl_dur['Mean_duration'])):
    ax4.text(bar.get_x() + bar.get_width()/2, bar.get_height() + 1,
            f'{duration:.1f}', ha='center', va='bottom', fontsize=10,
            color='#333333')

ax4.set_title('Top 20 códigos controláveis por duração média do atraso', pad=15,
              fontsize=20, weight='semibold', color='#222222')
ax4.set_xlabel('Código de atraso', labelpad=10, fontsize=16, weight='medium',
              color='#333333')
ax4.set_ylabel('Duração média (minutos)', labelpad=10, fontsize=16, weight='medium',
              color='#333333')
ax4.set_xticks(range(len(top20_ctrl_dur)))
ax4.set_xticklabels(top20_ctrl_dur['delay_code'], rotation=45, ha='right')
ax4.tick_params(axis='both', labelsize=12, colors='#555555')
ax4.grid(axis='y', color='#E0E0E0')

# Legend for controllable duration
legend_elements4 = [Patch(facecolor='#1f77b4', label='Controlável'),
                    Patch(facecolor='#d62728', label='66B')]
ax4.legend(handles=legend_elements4, loc='upper right', frameon=False,
          fontsize=12)

plt.tight_layout()
plt.show()

# Find 66B position in duration rankings
pos_66B_overall = duration_stats_filtered[duration_stats_filtered['delay_code']=='66B'].index[0] + 1
if '66B' in duration_stats_filtered['delay_code'].values else 'N/A'

```

```
pos_66B_ctrl = ctrl_duration_filtered[ctrl_duration_filtered['delay_code']=='66B'].index[0] + 1 if '66B' in ctrl_duration_filtered['delay_code'].values else 'N/A'

# Get 66B duration stats
stats_66B = duration_stats_filtered[duration_stats_filtered['delay_code']=='66B']
stats_66B_ctrl = ctrl_duration_filtered[ctrl_duration_filtered['delay_code']=='66B']


print("Posição do 66B no ranking de duração média:")
print(f"Global: {pos_66B_overall}")
print(f"Controláveis: {pos_66B_ctrl}")
print("\nEstatísticas 66B:")
print(stats_66B)
print(stats_66B_ctrl)
```


## 2.19. Análise de Frequência do Código 66B

{image\_urls\_dict['41ff1765']}

{image\_urls\_dict['a43b3f6c']}

## 2.20. Análise de Duração Média do Código 66B





Posição do 66B no ranking de duração média (geral): 120

Posição do 66B no ranking de duração média (controlável): 43

### 2.20.1. Resumo dos Resultados

**Frequência:** - O código 66B ocupa a 12.<sup>a</sup> posição no ranking geral de frequência (223 ocorrências) - No grupo controlável, sobe para a 4.<sup>a</sup> posição, sendo uma das principais causas

**Duração Média:** - No ranking geral de duração média, o 66B está na 120.<sup>a</sup> posição - Entre os códigos controláveis, ocupa a 43.<sup>a</sup> posição em duração média

Os gráficos mostram: - **Azul:** códigos controláveis - **Cinzeno:** códigos não-controláveis - **Vermelho:** código 66B (destacado) - Valores absolutos no topo de cada barra

Ficheiros disponíveis: - frecuencia\_66B.xlsx - duracao\_66B.xlsx

{outputs\_dict['5c5f9e9a']}

{outputs\_dict['d3641fed']}

<Figure size 2400x1400 with 1 Axes>

<Figure size 2400x1400 with 1 Axes>

Análise da frequência e duração do código 66B:

**Frequência (primeiros dois gráficos):** - Na amostra global: 66B ocupa a 12.<sup>a</sup> posição com 223 ocorrências - Entre controláveis: sobe para a 4.<sup>a</sup> posição (mesmo número absoluto, mas denominador menor)

**Duração média (últimos dois gráficos):** Posição do 66B no ranking de duração média:


Global: 115

Controláveis: 65

	delay_code	Mean_duration	Count	Std_duration	Controlabilidade
114	66B	8.08	223	6.96	1

	delay_code	Mean_duration	Count	Std_duration
64	66B	8.08	223	6.96

O código 66B apresenta uma duração média de apenas 8.08 minutos (DP = 6.96), colocando-o: - Na 115.ª posição globalmente por duração média - Na 65.ª posição entre códigos controláveis



## 2.21. User

Agora gráficos para a duração dos atrasos, no total da amostra e no grupo dos atrasos controláveis

## 2.22. Julius

### 2.22.1. run\_code



### 2.22.2. run\_code



### 2.22.3. run\_code

```

# Create duration analysis plots - Top 20 by mean duration
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np
from matplotlib.patches import Patch

# Calculate mean duration by delay code for overall sample
duration_overall = filtered.groupby('delay_code')['Atraso (minutos)'].
agg(['mean', 'count']).reset_index()
duration_overall.columns = ['delay_code', 'mean_duration', 'count']
duration_overall = duration_overall[duration_overall['count'] >= 10]
# filter codes with at least 10 occurrences
duration_overall = duration_overall.sort_values('mean_duration', ascen
ding=False)

# Add controlability info
duration_overall['Controlabilidade'] = duration_overall['delay_code'].
map(controlability_map)

# Plot 3: Top 20 by mean duration - overall sample
fig3, ax3 = plt.subplots(figsize=(12,7))
plt.subplots_adjust(left=0.1, right=0.95, top=0.85, bottom=0.25)
ax3.set_axisbelow(True)

top20_dur = duration_overall.head(20)
colors3 = []
for i, row in top20_dur.iterrows():
    if row['delay_code'] == '66B':
        colors3.append('#d62728') # red for 66B
    elif row['Controlabilidade'] == 1:
        colors3.append('#1f77b4') # blue for controlable
    else:
        colors3.append('#7f7f7f') # grey for non-controlable

bars3 = ax3.bar(range(len(top20_dur)), top20_dur['mean_duration'], col
or=colors3)

# Add duration labels on top of bars
for i, (bar, duration) in enumerate(zip(bars3, top20_dur['mean_duratio
n'])):
    ax3.text(bar.get_x() + bar.get_width()/2, bar.get_height() + 2,
             f'{duration:.1f}', ha='center', va='bottom', fontsize=10,
             color='#333333')

ax3.set_title('Top 20 códigos por duração média do atraso - amostra to
tal', pad=15, fontsize=20, weight='semibold', color='#222222')
ax3.set_xlabel('Código de atraso', labelpad=10, fontsize=16, weight='m
edium', color='#333333')
ax3.set_ylabel('Duração média (minutos)', labelpad=10, fontsize=16, we
ight='medium', color='#333333')
ax3.set_xticks(range(len(top20_dur)))
ax3.set_xticklabels(top20_dur['delay_code'], rotation=45, ha='right')
ax3.tick_params(axis='both', labelsize=12, colors='#555555')
ax3.grid(axis='y', color='#E0E0E0')

```

```

# Legend
legend_elements3 = [Patch(facecolor='#1f77b4', label='Controlável'),
                    Patch(facecolor='#7f77f7', label='Não controlável')],
                    Patch(facecolor='#d62728', label='66B')]
ax3.legend(handles=legend_elements3, loc='upper right', frameon=False,
           fontsize=12)

plt.tight_layout()
plt.show()

# Calculate duration for controlable codes only
ctrl_duration = ctrl.groupby('delay_code')['Atraso (minutos)'].agg(['mean', 'count']).reset_index()
ctrl_duration.columns = ['delay_code', 'mean_duration_ctrl', 'count_ctrl']
ctrl_duration = ctrl_duration[ctrl_duration['count_ctrl'] >= 10]
ctrl_duration = ctrl_duration.sort_values('mean_duration_ctrl', ascending=False)

# Plot 4: Top 20 controlable codes by duration
fig4, ax4 = plt.subplots(figsize=(12,7))
plt.subplots_adjust(left=0.1, right=0.95, top=0.85, bottom=0.25)
ax4.set_axisbelow(True)

top20_dur_ctrl = ctrl_duration.head(20)
colors4 = ['#d62728' if dc == '66B' else '#1f77b4' for dc in top20_dur_ctrl['delay_code']]

bars4 = ax4.bar(range(len(top20_dur_ctrl)), top20_dur_ctrl['mean_duration_ctrl'], color=colors4)

# Add duration labels
for i, (bar, duration) in enumerate(zip(bars4, top20_dur_ctrl['mean_duration_ctrl'])):
    ax4.text(bar.get_x() + bar.get_width()/2, bar.get_height() + 1,
            f'{duration:.1f}', ha='center', va='bottom', fontsize=10,
            color='#333333')

ax4.set_title('Top 20 códigos por duração média do atraso - grupo controlável', pad=15, fontsize=20, weight='semibold', color='#222222')
ax4.set_xlabel('Código de atraso', labelpad=10, fontsize=16, weight='medium', color='#333333')
ax4.set_ylabel('Duração média (minutos)', labelpad=10, fontsize=16, weight='medium', color='#333333')
ax4.set_xticks(range(len(top20_dur_ctrl)))
ax4.set_xticklabels(top20_dur_ctrl['delay_code'], rotation=45, ha='right')
ax4.tick_params(axis='both', labelsize=12, colors='#555555')
ax4.grid(axis='y', color='#E0E0E0')

# Legend for controlable duration
legend_elements4 = [Patch(facecolor='#1f77b4', label='Controlável'),

```

```

        Patch(facecolor='#d62728', label='66B')]
ax4.legend(handles=legend_elements4, loc='upper right', frameon=False,
           fontsize=12)

plt.tight_layout()
plt.show()

# Find 66B position in duration rankings
pos_66B_overall_dur = None
pos_66B_ctrl_dur = None

for i, code in enumerate(duration_overall['delay_code']):
    if code == '66B':
        pos_66B_overall_dur = i + 1
        break

for i, code in enumerate(ctrl_duration['delay_code']):
    if code == '66B':
        pos_66B_ctrl_dur = i + 1
        break

# Get 66B duration stats
stats_66B_overall = duration_overall[duration_overall['delay_code'] ==
                                     '66B']
stats_66B_ctrl = ctrl_duration[ctrl_duration['delay_code'] == '66B']

print("Posição do 66B no ranking de duração média:")
print(f"Amostra total: {pos_66B_overall_dur if pos_66B_overall_dur else 'Não encontrado no top'}")
print(f"Grupo controlável: {pos_66B_ctrl_dur if pos_66B_ctrl_dur else 'Não encontrado no top'}")


if not stats_66B_overall.empty:
    print(f"\n66B - Duração média (amostra total): {stats_66B_overall['mean_duration'].iloc[0]:.2f} min")
if not stats_66B_ctrl.empty:
    print(f"66B - Duração média (controláveis): {stats_66B_ctrl['mean_duration_ctrl'].iloc[0]:.2f} min")

print("\nGráficos de duração criados com legendas e valores no topo das barras")


```

## A Influência dos Departure Procedures – 66b nos atrasos dos voos da companhia aérea Portugaláia

### Top 20 códigos por duração média do atraso - amostra total



### Top 20 códigos por duração média do atraso - grupo controlável



Agora temos os gráficos de duração média dos atrasos:

Posição do 66B no ranking de duração média:

Amostra total: 83

Grupo controlável: 27

66B - Duração média (amostra total): 8.08 min

66B - Duração média (controláveis): 8.08 min

#### Análise da duração do código 66B:

- Na amostra total: 66B ocupa a 83.ª posição em duração média (8.08 minutos)

- No grupo controlável: sobe para a 27.<sup>a</sup> posição (mesma duração média)
- 

## 2.23. User

Agora filtra os voos com o código 66B, isolado ou associado a outros. Considera todos os movimentos com o mesmo número de voo, no mesmo dia e com o mesmo número de setor de voo como um único voo. Pretende-se observar a estrutura composta dos atrasos. Apresenta uma tabela com os diferentes graus de complexidade dos atrasos, o número dos voos para cada nível, percentagens, média do 66B, média dos outros atrasos e a duração média total dos atrasos de cada nível de complexidade e desvio-padrão.

## 2.24. Julius

### 2.24.1. run\_code

```
# Recalculate complexity based on number of additional codes beyond 66
B
print("Recalculando complexidade baseada no número de códigos adicionais...")
print()

# Count additional codes for each flight (excluding 66B)
def count_additional_codes(all_codes):
    codes_list = [code.strip() for code in all_codes.split(',')]
    # Remove 66B and count remaining codes
    additional_codes = [code for code in codes_list if code != '66B']
    return len(additional_codes)

flights_with_66B_composite['num_additional_codes'] = flights_with_66B_composite['all_codes'].apply(count_additional_codes)

# Create complexity levels based on number of additional codes
def assign_complexity_by_codes(num_additional):
    if num_additional == 0:
        return "0 (66B isolado)"
    elif num_additional == 1:
        return "1 código adicional"
    elif num_additional == 2:
        return "2 códigos adicionais"
    elif num_additional == 3:
        return "3 códigos adicionais"
    else:
        return f"{num_additional} códigos adicionais"

flights_with_66B_composite['Grau_Complexidade'] = flights_with_66B_composite['num_additional_codes'].apply(assign_complexity_by_codes)

# Check distribution
print("Distribuição por número de códigos adicionais:")
print(flights_with_66B_composite['num_additional_codes'].value_counts().sort_index())
```

```

print()

# Create new comprehensive summary table
complexity_by_codes = flights_with_66B_composite.groupby('Grau_Complexidade').agg({
    'flight_id': 'count',
    'delay_66B': ['mean', 'std'],
    'delay_others': ['mean', 'std'],
    'total_delay': ['mean', 'std']
}).round(2)

# Flatten column names
complexity_by_codes.columns = ['Número_Voos', 'Média_66B', 'DP_66B', 'Média_Outros', 'DP_Outros', 'Média_Total', 'DP_Total']
complexity_by_codes = complexity_by_codes.reset_index()

# Calculate percentages
complexity_by_codes['Percentagem'] = (complexity_by_codes['Número_Voos'] / len(flights_with_66B_composite) * 100).round(2)

# Reorder columns
complexity_by_codes = complexity_by_codes[['Grau_Complexidade', 'Número_Voos', 'Percentagem',
                                           'Média_66B', 'Média_Outros', 'Média_Total',
                                           'DP_66B', 'DP_Outros', 'DP_Total']]

# Sort by complexity level (0, 1, 2, 3, etc.)
complexity_order_new = ["0 (66B isolado)", "1 código adicional", "2 códigos adicionais", "3 códigos adicionais"]
# Add any additional levels if they exist
for level in complexity_by_codes['Grau_Complexidade'].unique():
    if level not in complexity_order_new:
        complexity_order_new.append(level)

complexity_by_codes['Order'] = complexity_by_codes['Grau_Complexidade'].map({level: i for i, level in enumerate(complexity_order_new)})
complexity_by_codes = complexity_by_codes.sort_values('Order').drop('Order', axis=1)

print("Tabela de complexidade por número de códigos adicionais:")
print(complexity_by_codes)

```

#### 2.24.2. run\_code

```

# Create detailed analysis of code combinations for each complexity level
print("Análise detalhada das combinações de códigos por nível...")
print()

# Most common combinations for each complexity level
for level in complexity_by_codes['Grau_Complexidade']:
    level_data = flights_with_66B_composite[flights_with_66B_composite

```

```

['Grau_Complexidade'] == level]
    print(f"\n{level} ({len(level_data)} voos):")

    if level == "0 (66B isolado)":
        print(" - Apenas código 66B")
    else:
        # Show most common combinations
        combinations = level_data['all_codes'].value_counts().head(5)
        for combo, count in combinations.items():
            print(f" - {combo}: {count} voos")

# Export updated analysis
output_file_by_codes = 'analise_complexidade_por_codigos_66B.xlsx'

# Create summary by complexity level
summary_by_level = []
for level in complexity_by_codes['Grau_Complexidade']:
    level_data = flights_with_66B_composite[flights_with_66B_composite
['Grau_Complexidade'] == level]

    # Get most common combinations
    if level == "0 (66B isolado)":
        top_combinations = ["66B"]
    else:
        top_combinations = level_data['all_codes'].value_counts().head
(3).index.tolist()

    summary_by_level.append({
        'Grau_Complexidade': level,
        'Combinações_Mais_Comuns': '; '.join(top_combinations[:3])
    })

combinations_summary = pd.DataFrame(summary_by_level)

# Merge with main analysis
complexity_final = complexity_by_codes.merge(combinations_summary, on=
'Grau_Complexidade')

print("\nTabela final com combinações mais comuns:")
print(complexity_final[['Grau_Complexidade', 'Número_Voos', 'Percentag
em', 'Combinações_Mais_Comuns']])

```

### 2.24.3. run\_code

```

# Export final comprehensive analysis
output_file_final = 'analise_complexidade_por_codigos_66B_final.xlsx'

# Create detailed breakdown for export
detailed_breakdown = []
for level in complexity_by_codes['Grau_Complexidade']:
    level_data = flights_with_66B_composite[flights_with_66B_composite
['Grau_Complexidade'] == level]

    for _, flight in level_data.iterrows():

```

```

detailed_breakdown.append({
    'flight_id': flight['flight_id'],
    'leg_no': flight['leg_no'],
    'day_of_origin': flight['day_of_origin'],
    'Grau_Complexidade': flight['Grau_Complexidade'],
    'Todos_Códigos': flight['all_codes'],
    'Atraso_66B': flight['delay_66B'],
    'Atraso_Outros': flight['delay_others'],
    'Atraso_Total': flight['total_delay'],
    'Num_Códigos_Adicionais': flight['num_additional_codes']
})

detailed_df = pd.DataFrame(detailed_breakdown)

# Write comprehensive analysis to Excel
with pd.ExcelWriter(output_file_final, engine='openpyxl') as writer:
    # Main complexity analysis
    complexity_by_codes.to_excel(writer, sheet_name='Análise por Compl
exidade', index=False)

    # Summary with combinations
    complexity_final.to_excel(writer, sheet_name='Resumo com Combinaçõ
es', index=False)

    # Detailed flight data
    detailed_df.to_excel(writer, sheet_name='Dados Detalhados', index=
False)

    # Statistics by level
    stats_by_level = flights_with_66B_composite.groupby('Grau_Complexi
dade').agg({
        'delay_66B': ['count', 'mean', 'median', 'std', 'min', 'max'],
        'delay_others': ['mean', 'median', 'std', 'min', 'max'],
        'total_delay': ['mean', 'median', 'std', 'min', 'max']
    }).round(2)

    stats_by_level.to_excel(writer, sheet_name='Estatísticas Detalhada
s')

print('Análise final exportada:', output_file_final)
print()
print("Resumo final da estrutura composta dos atrasos 66B:")
print("=" * 60)
print("Total de voos analisados:", len(flights_with_66B_composite))
print()
for _, row in complexity_by_codes.iterrows():
    print(f"{row['Grau_Complexidade']}: {row['Número_Voos']} voos ({ro
w['Porcentagem']}%)")
    print(f" - Atraso médio 66B: {row['Média_66B']} min")
    print(f" - Atraso médio outros: {row['Média_Outros']} min")
    print(f" - Atraso total médio: {row['Média_Total']} min")
    print()

```

## 2.25. Análise da Estrutura Composta dos Atrasos - Voos com Código 66B

	Grau_Complexidade	Nu00fame ro_Voos	Percentagem	Mu00e9 dia_66B	Mu00e9 dia_Outros	Mu00e9 dia_Total	DP_66B	DP_Outros	DP_Total
0	0 (66B isolado)	24	10.76	8.46	0.0	8.46	13.77	0.0	13.77
1	1 código adicional	82	36.77	7.94	22.66	30.6	5.68	27.91	30.35
2	2 códigos adicionais	77	34.53	8.39	53.44	61.83	6.19	44.8	44.91
3	3 códigos adicionais	40	17.94	7.55	66.62	74.18	4.68	46.17	46.71

### 2.25.1. Principais Descobertas

#### Distribuição por Grau de Complexidade:

**0 (66B isolado):** 24 voos (10,76%) - Apenas o código 66B, sem códigos adicionais - Atraso médio: 8,46 minutos - Desvio-padrão: 13,77 minutos

**1 código adicional:** 82 voos (36,77%) - Combinações mais comuns: 66B+89, 66B+93R, 63A+66B - Atraso médio 66B: 7,94 min | Outros: 22,66 min - Atraso total médio: 30,60 minutos

**2 códigos adicionais:** 77 voos (34,53%) - Combinação dominante: 66B+89+93R (33 voos) - Atraso médio 66B: 8,39 min | Outros: 53,44 min - Atraso total médio: 61,83 minutos

**3 códigos adicionais:** 40 voos (17,94%) - Combinações típicas: 35A+66B+89+93R, 15A+66B+89+93R - Atraso médio 66B: 7,55 min | Outros: 66,62 min - Atraso total médio: 74,18 minutos

A análise completa está disponível em [https://julius.ai/files/analise\\_complexidade\\_por\\_codigos\\_66B\\_final.xlsx](https://julius.ai/files/analise_complexidade_por_codigos_66B_final.xlsx)