

BEATRIZ LOURENÇO FRANCO

Licenciada em Ciências de Engenharia e Gestão Industrial

Benchmarking de modelos de previsão

APLICAÇÃO NO PLANEAMENTO DE CAPACIDADE DA MANU-
TENÇÃO AERONÁUTICA

MESTRADO INTEGRADO EM ENGENHARIA E GESTÃO INDUSTRIAL

Universidade NOVA de Lisboa
setembro, 2024

BENCHMARKING DE MODELOS DE PREVISÃO

APLICAÇÃO NO PLANEAMENTO DE CAPACIDADE DA MANUTENÇÃO AERO-NÁUTICA

BEATRIZ LOURENÇO FRANCO

Licenciada em Ciências da Engenharia e Gestão Industrial

Orientador: Duarte Nuno Caldeira Cordeiro Dinis,
Professor Auxiliar, Universidade NOVA de Lisboa

Coorientadores: Ana Paula Ferreira Barroso,
Professora Auxiliar, Universidade NOVA de Lisboa

Júri:

Presidente: Ana Teresa Martins Videira Gabriel,
Professora Auxiliar, Universidade NOVA de Lisboa

Arguente: Radu Godina,
Professor Auxiliar, Universidade NOVA de Lisboa

Orientador: Duarte Nuno Caldeira Cordeiro Dinis,
Professor Auxiliar, Universidade NOVA de Lisboa

Benchmarking de Modelos de Previsão: Aplicação no Planeamento de Capacidade da Manutenção Aeronáutica

Copyright © Beatriz Lourenço Franco, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Este documento foi criado com o processador de texto Microsoft Word e o template NOVATHESIS Word [11].

À minha família.

AGRADECIMENTOS

Agradeço à minha família por todo o carinho, palavras amigas e apoio incondicional, não só nesta última e extremamente difícil etapa, mas ao longo de todo o meu percurso universitário. Foram realmente o meu pilar e o meu porto de abrigo.

Agradeço ao meu orientador, o Professor Duarte Dinis, e à minha coorientadora, a Professora Ana Paula Barroso, por terem sido incansáveis e estarem sempre dispostos e disponíveis para me ajudar.

Agradeço às amigadas que fiz na faculdade e que espero levar para a vida: a Carolina Maurício, a Filipa Santos, a Inês Marques, a Rita Nunes e a Vanessa Coelho. Tornaram este percurso ainda mais especial, não podia ter pedido amigas melhores!

Finalmente, agradeço-me a mim própria por nunca ter desistido e ter enfrentado, de cabeça erguida, todas as adversidades com que me deparei ao longo destes 5 anos.

Aqui fica o meu "muito obrigada por tudo", pois sem vós nada disto teria sido possível!

"O sucesso é 1% inspiração e 99% transpiração." (Thomas Edison)

RESUMO

As técnicas de previsão têm sido aplicadas nas mais variadas áreas, desde a política à economia, da saúde à indústria, entre muitas outras. No entanto, todas as áreas apresentam uma característica comum: a necessidade de selecionar a técnica de previsão que melhor se adequa ao seu contexto e que vai permitir obter as previsões mais precisas. Por isto, inúmeros estudos têm vindo a ser realizados com o intuito de avaliar e comparar o desempenho de várias técnicas de previsão de séries temporais. A presente dissertação pretende contribuir para esta discussão ao aplicar modelos *Autoregressive Integrated Moving Average* (ARIMA) a um conjunto real de dados, constituído por 171 projetos de manutenção realizados num determinado modelo de aeronave, recolhidos através de uma organização de *Maintenance, Repair and Overhaul* (MRO), e comparar os resultados obtidos com os resultados alcançados por um estudo anterior, em que se aplicaram modelos de alisamento exponencial ao mesmo conjunto de dados. Apesar dos dados conterem 171 observações, a série temporal é constituída por 8 pontos, referentes a 8 inspeções de manutenção, fazendo desta uma série temporal curta. No que diz respeito ao planeamento da capacidade, diferentes técnicas de previsão têm vindo a ser empregues, com o objetivo de determinar a carga de trabalho associada a atividades de manutenção. Neste estudo, a manutenção aeronáutica será o principal foco. Esta engloba dois tipos de manutenção: a planeada, considerada essencialmente determinística, e a não-planeada, predominantemente estocástica. Visto que esta última pode representar mais de metade do trabalho realizado por uma organização de MRO, torna-se imperativo que estas possuam previsões precisas, de modo a aumentar a eficiência operacional e diminuir custos.

Após a realização do estudo, concluiu-se que os modelos ARIMA se ajustaram melhor aos dados, apresentando valores inferiores nas medidas de desempenho, ao passo que os modelos de alisamento exponencial, anteriormente estudados, se destacaram por terem valores inferiores no que toca às medidas de erro. Assim, independentemente do número de pontos da série considerados, 7 ou 8, o modelo ARIMA (1, 1, 0) foi o que apresentou menor erro.

Palavras chave: Previsão, ARIMA, Alisamento Exponencial, Manutenção, Planeamento da Capacidade

ABSTRACT

Forecasting techniques have been applied to a multitude of fields, from politics to economics, from health to manufacturing, to name some examples. In all these fields, it is of the utmost importance to choose the forecasting technique that will provide the most accurate estimates. Several studies, such as those reporting the M-Competitions, have been conducted to assess and compare the performance of various time series forecasting techniques.

This research work aims to contribute to this discussion by applying ARIMA models to a real dataset of 171 aircraft maintenance projects collected from a Portuguese Maintenance, Repair, and Overhaul (MRO) organization, and comparing the obtained results with a previous study, which applied Exponential Smoothing models to the same dataset, comprising 7 and 8 points. Although the data contains 171 observations, the time series consists of a maximum of 8 points, referring to 8 types of maintenance inspections, making this a short time series.

When it comes to maintenance capacity planning, different forecasting techniques have been used to determine the workload associated with the execution of maintenance tasks. In this study, aircraft maintenance will be the focus. Aircraft maintenance comprises scheduled maintenance, whose nature is essentially deterministic, and unscheduled maintenance, whose nature is predominantly stochastic. Since the latter can represent half of the maintenance work carried out in aircraft, reliable and accurate workload forecasts are paramount for MRO organizations to improve operational efficiency and, consequently, minimize operational costs.

After conducting the study, it was concluded that the ARIMA models fit the data better, presenting lower values in performance metrics, meanwhile the exponential smoothing models stood out for having lower values in terms of accuracy metrics. Therefore, regardless of the number of points considered, 7 or 8, the ARIMA (1, 1, 0) model was the one with the lowest error.

Keywords: Forecasting, ARIMA, Exponential Smoothing, Maintenance, Capacity Planning

ÍNDICE

1	INTRODUÇÃO.....	1
1.1	Contextualização	1
1.2	Evolução do planeamento da capacidade	2
1.3	Objetivos da dissertação	3
1.4	Estrutura da dissertação	4
2	CONCEITOS E DEFINIÇÕES.....	5
2.1	Manutenção	5
2.2	Manutenção aeronáutica.....	5
2.2.1	Manutenção preventiva (planeada).....	6
2.2.2	Manutenção corretiva (não-planeada).....	7
2.3	Planeamento da manutenção	8
2.3.1	Planeamento da manutenção no setor aeronáutico.....	8
2.4	Técnicas de previsão.....	10
2.4.1	Alisamento exponencial	11
2.4.2	Modelos ARIMA	12
2.4.3	Medidas de desempenho das técnicas de previsão.....	18
2.4.4	Critérios para seleção de modelos.....	18
2.5	Modelos ARIMA vs AE: relevância da discussão	20
3	METODOLOGIA CIENTÍFICA APLICADA.....	23
3.1	Resultados anteriores.....	23
3.2	Aplicação dos modelos ARIMA	26
4	APLICAÇÃO DOS MODELOS ARIMA.....	29

4.1	Aplicação dos modelos ARIMA considerando 7 pontos	29
4.1.1	Teste de estacionaridade	29
4.1.2	Identificação do modelo	31
4.1.3	Ajustamento do modelo	33
4.1.4	Diagnóstico do modelo	36
4.2	Aplicação dos modelos ARIMA considerando 8 pontos	37
4.2.1	Teste de estacionaridade	37
4.2.2	Identificação do modelo	38
4.2.3	Ajustamento do modelo	39
4.2.4	Diagnóstico do modelo	44
4.3	Resultados.....	45
4.3.1	Resultados obtidos com a aplicação do AE	45
4.3.2	Comparação dos resultados obtidos com a aplicação dos modelos de AE e ARIMA.....	47
4.3.3	Comparação dos resultados obtidos pelos modelos de AE com os modelos ARIMA equivalentes	48
5	CONCLUSÃO.....	49
5.1	Conclusões gerais	49
5.2	Limitações encontradas	50
5.3	Trabalhos futuros.....	50
	REFERÊNCIAS BIBLIOGRÁFICAS.....	51

ÍNDICE DE FIGURAS

Figura 2.1 - ACF de um modelo AR(2).....	14
Figura 2.2 - PACF de um modelo AR(2).....	14
Figura 2.3 - ACF de um modelo AR(1).....	15
Figura 2.4 - PACF de um modelo AR(1).....	15
Figura 2.5 - ACF de um modelo MA(1).....	16
Figura 2.6 - PACF de um modelo MA(1).....	16
Figura 3.1 -Distribuição dos projetos pelos diferentes <i>checks</i> e respectivas cargas de trabalho de manutenção	24
Figura 3.2 -Variabilidade da carga de trabalho de manutenção dos diferentes <i>checks</i> .	26
Figura 3.3 - Fluxograma do processo de aplicação de um modelo ARIMA	28
Figura 4.1 - Função de autocorrelação para amostra de 7 pontos	30
Figura 4.2 - Gráfico do valor da carga média de trabalho associada a cada <i>check</i> para amostra de 7 pontos.....	30
Figura 4.3 - ACF da amostra com 7 pontos	31
Figura 4.4 - PACF da amostra com 7 pontos.....	32
Figura 4.5 -Ajustamento do modelo (1, 1, 0)	35
Figura 4.6 - Previsões efetuadas pelo modelo (1, 1, 0)	35
Figura 4.7 - Ajustamento do modelo (1, 2, 0)	35
Figura 4.8 - Previsões efetuadas pelo modelo (1, 2, 0)	35
Figura 4.9 - Ajustamento do modelo (0, 2, 1)	35
Figura 4.10 - Previsões efetuadas pelo modelo (0, 2, 1)	35
Figura 4.11 - Ajustamento do modelo (1, 1, 1).....	36
Figura 4.12 - Previsões efetuadas pelo modelo (1, 1, 1).....	36
Figura 4.13 - Histograma dos resíduos do modelo (1, 1, 0)	36
Figura 4.14 - Função de autocorrelação para a amostra completa.....	37
Figura 4.15 - Gráfico do valor da carga média de trabalho associada a cada <i>check</i> para a amostra completa.....	37
Figura 4.16 - ACF da amostra completa	38

Figura 4.17 - PACF da amostra completa.....	39
Figura 4.18 - Ajustamento do modelo (1, 1, 0).....	42
Figura 4.19 - Previsões efetuadas pelo modelo (1, 1, 0).....	42
Figura 4.20 - Ajustamento do modelo (0, 2, 0).....	42
Figura 4.21 - Previsões efetuadas pelo modelo (0, 2, 0).....	42
Figura 4.22 - Ajustamento do modelo (1, 2, 0).....	42
Figura 4.23 - Previsões efetuadas pelo modelo (1, 2, 0).....	42
Figura 4.24 - Ajustamento do modelo (2, 2, 0).....	43
Figura 4.25 - Previsões efetuadas pelo modelo (2, 2, 0).....	43
Figura 4.26 - Ajustamento do modelo (1, 3, 0).....	43
Figura 4.27 - Previsões efetuadas pelo modelo (1, 3, 0).....	43
Figura 4.28 - Ajustamento do modelo (2, 3, 0).....	43
Figura 4.29 - Previsões efetuadas pelo modelo (2, 3, 0).....	43
Figura 4.30 - Ajustamento do modelo (0, 2, 1).....	44
Figura 4.31 - Previsões efetuadas pelo modelo (0, 2, 1).....	44
Figura 4.32 - Histograma dos resíduos do modelo (1, 1, 0).....	44

ÍNDICE DE TABELAS

Tabela 2.1 - Formulação para o AE utilizada por Dinis et al. (2022).....	12
Tabela 3.1 - Número de projetos associados a cada <i>check</i> , uso/limitação temporal de cada <i>check</i> e períodos de tempo e ciclos considerados para análise da série temporal	24
Tabela 3.2 - Resultados obtidos por Dinis et. al (2022) para o AICc, <i>log-likelihood</i> , DMA e EQM.....	25
Tabela 4.1- Valores médios da carga de trabalho associada a cada <i>check</i>	29
Tabela 4.2 -Valor da estatística do teste ADF e valor crítico obtido para amostra de 7 pontos	31
Tabela 4.3 - Possíveis parametrizações para a série temporal curta.....	32
Tabela 4.4 -Resultados obtidos para o AICc, <i>log-likelihood</i> , DMA e EQM considerando 7 pontos	33
Tabela 4.5 - Valores previstos da carga de trabalho associada a cada <i>check</i> e limites inferiores e superiores, considerando um intervalo de confiança de 95% e 7 pontos ...	34
Tabela 4.6 -Valor da estatística do teste ADF e valor crítico obtido para amostra completa.....	38
Tabela 4.7 - Resultados obtidos para o AICc, <i>log-likelihood</i> , DMA e EQM considerando a amostra completa.....	39
Tabela 4.8 -Valores previstos da carga de trabalho associada a cada <i>check</i> e limites inferiores e superiores, considerando um intervalo de confiança de 95% e a amostra completa.....	41
Tabela 4.9 - Resultados obtidos, para o AE, após remoção dos <i>outliers</i> para o AICc, <i>log-likelihood</i> , DMA e EQM, considerando 7 pontos de dados.....	45
Tabela 4.10 - Resultados obtidos, para o AE, após remoção dos <i>outliers</i> para o AICc, <i>log-likelihood</i> , DMA e EQM, considerando 8 pontos de dados (série completa).....	45
Tabela 4.11 - Carga de trabalho prevista, através da aplicação do modelo MHW, para os <i>checks</i> "8C" a "12C", considerando a série curta	46

Tabela 4.12 - Carga de trabalho prevista, através da aplicação do modelo MHW, para os <i>checks</i> "8C" a "12C", considerando a série completa.....	46
Tabela 4.13 - Valores das medidas de desempenho e erro para o modelo ARIMA (1, 1, 0) e MHW, considerando 7 pontos	47
Tabela 4.14 - Valores das medidas de desempenho e erro para o modelo ARIMA (1, 1, 0) e MHW, considerando 8 pontos (série completa)	47
Tabela 4.15 - Modelos de AE, utilizados por Dinis et al. (2022), e modelos ARIMA equivalentes	48

GLOSSÁRIO

<i>Augmented Dickey-Fuller test</i>	Teste estatístico que permite averiguar sobre a estacionaridade de uma série temporal
Manutenção planeada	Manutenção que ocorre em intervalos de tempo pré-determinados, cujas tarefas a realizar são definidas antecipadamente e a carga de trabalho é essencialmente determinística
Manutenção não-planeada	Manutenção cuja realização depende da natureza probabilística das falhas, o que confere um carácter estocástico à carga de trabalho associada às tarefas de manutenção a realizar
Planeamento da capacidade	Tem como objetivo determinar e atribuir o nível apropriado de carga de trabalho aos diferentes recursos de manutenção em cada período de planeamento

SIGLAS

AE	Alisamento Exponencial
ADF	<i>Augmented Dickey-Fuller</i>
AHW	<i>Additive Holt-Winters</i>
AIC	<i>Akaike Information Criterion</i>
AICc	<i>Akaike Information Criterion corrected</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
DMA	Desvio Médio Absoluto
HLM	<i>Holt's Linear Model</i>
MHW	<i>Multiplicative Holt-Winters</i>
MRO	<i>Maintenance, Repair and Overhaul</i>
EPAM	Erro Percentual Absoluto Médio
EPQM	Erro Percentual Quadrático Médio
EQM	Erro Quadrático Médio
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i>
SES	<i>Simple Exponential Smoothing</i>

INTRODUÇÃO

1.1 Contextualização

O mercado da aviação apresentava um crescimento rápido e contínuo até 2019, tendo gerado lucros de 750 mil milhões de euros com o transporte de 4,5 mil milhões de passageiros (ICAO, 2019). No entanto, no ano de 2020, tais valores sofreram uma diminuição acentuada, devido aos impactes causados pela pandemia de COVID-19 (ICAO, 2020). Desde então, o setor tem vindo a recuperar, acumulando 465 mil milhões de euros de receita, em 2021, e transportando 2,2 mil milhões de passageiros (Statista, 2022).

Dentro do setor da aviação, podem distinguir-se dois domínios de grande importância que podem influenciar largamente os valores mencionados acima: o custo de operação das aeronaves e a satisfação das necessidades dos clientes. A manutenção dos aviões desempenha um papel fundamental em ambos (Gu et al., 2015). Adicionalmente, e uma vez que esta indústria é estritamente regulada, as atividades de manutenção são também indispensáveis para garantir a segurança dos passageiros e a aeronavegabilidade dos aviões (Ertogral & Öztürk, 2019). A manutenção é realizada em várias indústrias, incluindo a aeronáutica, com o intuito de reduzir a probabilidade de falhas e maximizar a disponibilidade do sistema, mantendo os custos a um nível mínimo (Dinis et al., 2019). Na aviação comercial, tal permite ainda evitar atrasos e cancelamentos de voos, o que contribui positivamente para a satisfação dos clientes, um fator de extrema relevância, dada a intensa e crescente competitividade que se tem vindo a verificar no setor (Falatouri et al., 2023).

A manutenção, por sua vez, divide-se em manutenção preventiva e manutenção corretiva, conhecidas comumente no setor aeronáutico por manutenção planeada e manutenção não-planeada, respetivamente (Dinis et al., 2019). A primeira corresponde à manutenção que ocorre em intervalos de tempo pré-determinados, cujas tarefas a realizar são definidas antecipadamente e a carga de trabalho é essencialmente determinística. Já a segunda depende da natureza probabilística das falhas, o que confere um carácter estocástico à carga de trabalho

associada às tarefas de manutenção a realizar (Dinis et al., 2022). Depreende-se, assim, que o planeamento da manutenção é um processo extremamente complexo para as organizações de *Maintenance, Repair and Overhaul* (MRO), uma vez que conjuga o planeamento da capacidade requerida, a previsão da quantidade e tipo de peças sobresselentes necessárias e a calendarização das atividades a realizar (Márquez, 2007). As adversidades associadas ao planeamento são ainda agravadas pela incerteza inerente à manutenção não-planeada, que representa uma grande parte do trabalho de manutenção efetuado em aeronaves (Dinis et al., 2019; Georgiev & Vachev, 2022).

No que diz respeito ao planeamento da capacidade, o seu principal objetivo passa por determinar e atribuir o nível apropriado de carga de trabalho aos diferentes recursos de manutenção em cada período de planeamento. Para cada período, as decisões de planeamento de capacidade incluem: o número de funcionários, o nível de *backlog*, a carga horária extraordinária, a carga de trabalho subcontratada, entre outros. Com a elaboração de um planeamento da capacidade pretende-se maximizar a utilização da força de trabalho, bem como a disponibilidade do sistema, minimizando os custos associados (Duffuaa & Alfares, 2015).

1.2 Evolução do planeamento da capacidade

Ao longo do tempo, várias técnicas têm sido utilizadas para elaborar um planeamento da manutenção eficiente e um planeamento da capacidade preciso. Tipicamente, técnicas como o *Material Requirement Planning* (MRP I) (Stadtler, 2005) eram utilizadas para gerir e garantir a existência dos recursos necessários para assegurar o processo produtivo. Posteriormente, surgiu o modelo *Manufacturing Resources Planning* (MRP II) (Zijm & Regattieri, 2019a), uma extensão do MRP I, que, para além de considerar as necessidades materiais, tinha também em conta a mão-de-obra necessária, bem como os custos associados (Zijm & Regattieri, 2019b). Tais técnicas, aliadas a ferramentas de gestão de projeto, como o *Critical Path Method* (CPM), permitiam obter um planeamento muitas vezes ineficaz, devido à falta de sincronização e integração aquando da sua aplicação (Samaranayake & Kiridena, 2012). Adicionalmente, os modelos MRP I e MRP II não têm capacidade para computar variações na procura (Zijm & Schutten, 2019), o que se materializa numa grande limitação no que respeita a sua aplicação ao setor aeronáutico, face à grande incerteza associada à probabilidade de falha dos componentes de sistemas complexos, como é o caso das aeronaves (Ben-Daya et al., 2009). Por esta razão, diversas técnicas de previsão têm vindo a ser utilizadas, com o intuito de se obterem estimativas o mais preciso possível relativamente à carga de trabalho a realizar, na tentativa de se desenvolver um planeamento adequado.

A estimativa do volume de trabalho associado à manutenção de uma aeronave era tradicionalmente baseada no conhecimento e experiência de técnicos e engenheiros (Kala et al., 2019). Nesses casos, onde as previsões são baseadas nos julgamentos dos decisores, a

previsão pode denominar-se de qualitativa. Outras técnicas qualitativas incluem a realização de estudos, bem como o Método de Delphi (Duffuaa & Raouf, 2015), uma abordagem sistemática e iterativa, que envolve um painel de especialistas da área, cujo objetivo é alcançar um consenso sobre uma determinada questão, evitando opiniões tendenciosas (Nurcahyo et al., 2018). Contrariamente, se a técnica aplicada se baseia em modelos matemáticos, elaborados a partir de dados históricos, de modo a obter-se uma previsão, infere-se que esta corresponde a uma técnica de previsão quantitativa. Tais modelos podem basear-se em séries temporais, como médias móveis, alisamento exponencial (*Exponential Smoothing* em inglês) e modelos *Autoregressive Integrated Moving Average* (ARIMA), introduzidos por George E. P. Box e Gwilym M. Jenkins, em 1970, uma generalização dos modelos *Autoregressive Moving Average* (ARMA), ou de regressões. A eficácia das técnicas aplicadas pode ser medida através da sua precisão, simplicidade e facilidade dos cálculos efetuados, dados necessários e flexibilidade. De notar que a precisão do modelo está relacionada com a exatidão das suas previsões e é avaliada, em valor absoluto, pela diferença observada entre o valor real e o estimado. Já a flexibilidade prende-se com a capacidade do modelo se adaptar a mudanças nas condições, ou seja, mede a robustez do modelo (Duffuaa & Raouf, 2015).

Quando se trata da precisão das técnicas de previsão, vários estudos têm vindo a ser realizados, de modo a deduzir quais as que melhor se adequam a diferentes cenários. Os primeiros trabalhos realizados neste âmbito datam de 1969, contudo os resultados obtidos basearam-se num número relativamente pequeno de métodos. Assim sendo, mais tarde, em 1979, Makridakis e Hibon elaboraram um estudo onde foram analisadas, no total, 111 séries temporais. Posteriormente, em 1982, Makridakis desenvolveu a primeira *M-Competition*, onde foram estudadas 1001 séries temporais, através da aplicação de 15 métodos diferentes (Makridakis & Hibon, 2000). A *M-Competition* compreende, até aos dias de hoje, 4 estudos empíricos, tendo o último sido publicado em 2018. (Makridakis et al., 2018).

A realização destes estudos sublinha a importância de escolher a técnica de previsão que melhor se adequa e descreve o comportamento dos dados em análise. Tal justifica a realização da presente dissertação, que tem como objetivo complementar e contribuir para esta discussão.

1.3 Objetivos da dissertação

O objetivo central da dissertação passa pela comparação dos resultados obtidos através da aplicação de modelos de alisamento exponencial com aqueles obtidos pela utilização de modelos ARIMA, quando aplicados na previsão da carga de trabalho de manutenção a ser efetuada, ao longo de inspeções do tipo "C", a um determinado modelo de aeronave. Pretende-se saber se a utilização dos modelos ARIMA pode constituir uma mais-valia na previsão de carga de trabalho da manutenção aeronáutica, dada a incerteza associada a este processo.

Este tipo de modelos é frequentemente comparado com os modelos de alisamento exponencial, sendo apresentados como tendo uma maior flexibilidade, permitindo uma melhor modelação de séries temporais com padrões irregulares, incorporando de forma mais robusta a componente sazonal, e sendo relativamente fácil e rápido de computar (Sangwan & Herrmann, 2020; Zhang et al., 2020). Adicionalmente, visto tratar-se de uma série temporal constituída por apenas 8 pontos, pretende-se ainda estudar o comportamento dos modelos ARIMA, bem como a precisão das previsões por estes efetuadas, no contexto de séries temporais curtas.

1.4 Estrutura da dissertação

A presente dissertação encontra-se segmentada em seis capítulos, correspondendo o Capítulo 1 à Introdução.

No Capítulo 2 apresentar-se-ão alguns conceitos e definições, indispensáveis para uma melhor compreensão e entendimento do restante conteúdo do relatório, como “manutenção” e uma noção mais aprofundada daquilo que constitui o planeamento da manutenção, com especial ênfase no planeamento da capacidade, sobretudo no setor aeronáutico. Complementarmente, serão enunciadas lacunas observadas ao nível da literatura relacionada com o tema, algumas das quais a presente dissertação pretende esclarecer.

No Capítulo 3 será exposta a metodologia utilizada para realizar o estudo proposto. Neste capítulo, apresentar-se-ão também os resultados obtidos no estudo anterior, em que se aplicaram técnicas de alisamento exponencial, e que servirão como ponto de comparação com os resultados obtidos com a realização do presente estudo.

No Capítulo 4 será descrita detalhadamente a aplicação dos modelos ARIMA aos dados em estudo, bem como os resultados obtidos. Neste capítulo será ainda apresentada a comparação entre os resultados obtidos através da aplicação dos modelos ARIMA e dos modelos de alisamento exponencial. Adicionalmente, será ainda feita uma comparação entre os modelos de alisamento exponencial e os modelos ARIMA a estes equivalentes.

Por fim, o Capítulo 5 conterá as conclusões do trabalho de investigação realizado, as limitações identificadas e eventuais trabalhos de pesquisa futuros.

2 CONCEITOS E DEFINIÇÕES

Neste capítulo serão introduzidos conceitos e definições fundamentais para compreender os conteúdos expostos na dissertação, nomeadamente, noções como “manutenção” e “técnicas de previsão”. Apresentar-se-ão ainda as lacunas encontradas ao nível da literatura e a forma como o presente trabalho irá contribuir e complementar os estudos realizados.

2.1 Manutenção

Manutenção pode ser definida como o conjunto de ações técnicas, administrativas e de gestão levadas a cabo durante o ciclo de vida de um produto, de modo a mantê-lo, ou restaurá-lo, a um estado em que possa realizar a função projetada (Dinis & Barbosa-Póvoa, 2015). A principal responsabilidade da manutenção é providenciar serviços que permitam às empresas atingir os seus objetivos. Tais responsabilidades variam de organização para organização, contudo, geralmente incluem (Haroun & Duffuaa, 2015):

1. Manter os equipamentos em condições que lhes permitam desempenhar as funções devidas, em segurança;
2. Executar todas as atividades de manutenção, incluindo as preventivas, corretivas, *overhauls*, alterações ao design do equipamento e de emergência, de forma eficaz e eficiente;
3. Conservar e controlar a utilização de peças sobresselentes e materiais;
4. Gerir as *utilities* necessárias, com vista a manter os custos num valor mínimo, através, por exemplo, da conservação de energia.

Uma vez que a realização de tarefas e atividades de manutenção vai impactar diretamente o funcionamento das organizações, é de extrema importância que os fatores referidos estejam alinhados e concordantes com os objetivos estratégicos da empresa.

2.2 Manutenção aeronáutica

A realização de atividades de manutenção em aeronaves é um processo de extrema importância para o setor, já que é um dos maiores contribuidores para a garantia da segurança da aeronave, bem como daqueles que nela viajam, da sua operacionalidade e eficiência, quer financeira, quer ambiental. A execução destas atividades é ainda indispensável para assegurar a funcionalidade da aeronave e atingir os níveis de fiabilidade pretendidos, de modo a

desacelerar a sua deterioração física e, conseqüentemente, reduzir o número de falhas e os custos associados, cumprir as diretrizes impostas pelas autoridades regulatórias e gerar lucro (Mofokeng et al., 2020).

Atualmente, as inspeções levadas a cabo na manutenção aeronáutica são regidas pela filosofia *Maintenance Steering Group-3* (MSG-3), desenvolvida pela *Air Transport Association* (ATA), uma associação de companhias aéreas dos Estados Unidos, com os seguintes propósitos (Mofokeng, 2023; SKYbrary, n.d.):

1. Potenciar a segurança e a fiabilidade das aeronaves;
2. Restaurar os níveis de segurança e fiabilidade dos diversos componentes, quando ocorre deterioração dos mesmos;
3. Adquirir informação sobre o design de componentes, cujos níveis de fiabilidade sejam insuficientes;
4. Minimizar as falhas e o custo associado à manutenção.

No setor aeronáutico, os vários sistemas e subsistemas das aeronaves são organizados e categorizados de acordo com os Capítulos ATA 100, o que facilita a análise e identificação das suas funções e eventuais modos de falha. Por sua vez, no documento MSG-3, são ainda apresentados os requisitos de manutenção da aeronave, disponibilizados pelo fabricante, antes desta entrar em serviço, para posterior análise por parte das autoridades competentes. Paralelamente, a manutenção aeronáutica é dividida em manutenção planeada e não-planeada, correspondendo àquilo que noutras indústrias é conhecido por manutenção preventiva e corretiva, respetivamente (Bhagat et al., 1996).

2.2.1 Manutenção preventiva (planeada)

Manutenção preventiva inclui toda a manutenção realizada de modo a evitar a ocorrência de falhas. Esta pode ser realizada em função do tempo de uso ou da condição em que se encontra o equipamento, após uma análise ao seu estado físico e a alguns parâmetros a este associados, e é efetuada em intervalos de tempo pré-definidos, tendo em conta eventuais restrições de tempo e monetárias. A regularidade com que a manutenção é efetuada, geralmente, é definida com base na fiabilidade pretendida para o equipamento ou no conhecimento relativo à sua distribuição de falha. Para além de ser conhecida a frequência com que esta ocorre, são ainda discriminadas todas as tarefas que serão levadas a cabo, pelo que este tipo de manutenção carece de um planeamento rigoroso (Duffuaa & Raouf, 2015). A manutenção preventiva, ou planeada, uma denominação conotada ao setor aeronáutico, pode permitir uma redução nos custos relacionados com as tarefas de manutenção e aumentar a disponibilidade do sistema, que corresponde à capacidade de um item para executar a sua função requerida num instante de tempo específico ou ao longo de um período de tempo determinado (Ben-Daya et al., 2009a). Algumas das tarefas de manutenção preventiva realizadas em

aeronaves incluem: inspeções programadas, substituição de equipamentos, calibração de sistemas, etc. (Verhagen et al., 2023).

Os programas de manutenção planeada das aeronaves são compostos, sobretudo, por um conjunto de inspeções, com um crescente grau de exigência e diligência face ao número de horas de voo acumuladas pelo aparelho e/ou pelo número de ciclos descolagem-aterragem. As inspeções estão categorizadas, genérica e tradicionalmente, em quatro grupos, dependendo do modelo de aeronave: tipo A, realizadas quando a aeronave completa 450 a 650 horas de voo; tipo B, elaboradas a cada 1950 horas de voo; tipo C, levadas a cabo em intervalos de 15 a 18 meses, sendo que é executado um teste de voo após a inspeção; e tipo D, a intervenção mais intensiva, que se realiza a cada 6 a 8 anos e possui o maior pacote de trabalhos, ou seja, o maior número de tarefas de manutenção a concretizar e, consequentemente, necessitando também de uma maior quantidade de recursos. De notar que estas inspeções, ou *checks* em jargão aeronáutico, bem como os intervalos de tempo anteriormente apresentados, podem apresentar variações, dependendo da aeronave em questão. Ao conjunto que inclui as inspeções dos tipos A e B dá-se o nome de manutenção leve. A manutenção pesada, também conhecida como manutenção de base, engloba os restantes dois tipos de inspeção, C e D (Atli & Kahraman, 2012).

2.2.2 Manutenção corretiva (não-planeada)

Apesar da existência de um plano de manutenção preventiva, as falhas podem, por vezes, ocorrer de forma inesperada e inutilizar o equipamento. Nos casos em que ocorre este cenário, o tipo de manutenção a realizar designa-se de corretiva (Dinis et al., 2019). Dada a incerteza associada ao acontecimento destas falhas e, consequentemente, à impossibilidade de proceder ao seu planeamento, esta forma de manutenção é frequentemente apelidada de não-planeada, sobretudo no meio aeronáutico. Este tipo de manutenção é caracterizado pela ocorrência estocástica de atividades de manutenção não-planeada, o que pode dificultar alocação de mão de obra e outros recursos, levar a aumentos de custos, uma vez que pode ser necessária a contratação de mão de obra adicional e/ou a compra de materiais e peças necessários, e reduzir a disponibilidade do equipamento (Rosales et al., 2014).

Neste setor, a manutenção corretiva é levada a cabo, maioritariamente, com base em situações reportadas pelos pilotos, análise de dados, discrepâncias observadas durante a execução de tarefas de manutenção planeada e/ou ocorrência de imprevistos durante a operação normal (Dinis et al., 2019b).

2.3 Planeamento da manutenção

Planeamento corresponde ao processo de tomada de decisões e realização de ações futuras, necessárias para alcançar objetivos e metas pretendidos. O planeamento contribui ainda para que os objetivos definidos sejam atingidos da forma mais eficaz e eficiente possível. Este pretende, também, minimizar custos e reduzir riscos e perda de oportunidades, podendo, complementarmente, aumentar a vantagem competitiva da organização. O processo de planeamento pode ser dividido em três níveis, dependendo do horizonte de planeamento:

1. Planeamento de longo prazo (abrangendo um período de um até vários anos);
2. Planeamento de médio prazo (planos de um mês a um ano);
3. Planeamento de curto prazo (planos diários e semanais).

No que diz respeito à gestão da manutenção, o desenvolvimento de um planeamento eficaz contribui significativamente para a redução dos custos relacionados com as tarefas de manutenção, diminui a probabilidade de ocorrência de atrasos e interrupções desnecessárias e permite melhorar a qualidade dos trabalhos de manutenção realizados, através da adoção de métodos e procedimentos mais adequados, bem como da alocação dos trabalhadores necessários, consoante a sua área de formação. Os principais objetivos do planeamento da manutenção passam por (Ben-Daya et al., 2009b):

1. Reduzir o tempo de inatividade da força de trabalho encarregue da manutenção;
2. Maximizar o uso eficiente do tempo de trabalho, dos materiais e dos equipamentos;
3. Manter o equipamento operacional, de modo a que este possa dar resposta às necessidades.

2.3.1 Planeamento da manutenção no setor aeronáutico

No setor aeronáutico, o objetivo do planeamento da manutenção passa pelo agendamento da manutenção das aeronaves, com base numa avaliação prévia, e na disponibilidade dos recursos para realizar essa manutenção, de modo maximizar a disponibilidade das frotas. Ao elaborar-se o planeamento da manutenção, é fulcral definir antecipadamente quando e quais as tarefas a realizar, quais os equipamentos, peças e materiais necessários e a capacidade requerida, para que o processo de manutenção seja o mais eficiente possível, uma vez que vai impactar a disponibilidade do avião. Quando as aeronaves são mantidas e retornam ao serviço, o seu funcionamento sob variadas condições e ambientes permite a recolha de dados que são utilizados para monitorizar a sua condição e, posteriormente, proceder ao ajustamento do planeamento da manutenção (Verhagen et al., 2023).

2.3.1.1 Gestão das peças sobresselentes

No que diz respeito às peças sobresselentes, é imperativo garantir que estas estão disponíveis quando são necessárias. Contudo, um dos grandes problemas enfrentados pela indústria passa por garantir um equilíbrio entre as quantidades mantidas em stock e os custos associados, dada a intermitência e incerteza do seu consumo, causadas, sobretudo, pela ocorrência de atividades de manutenção não-planeada. Face a isto, torna-se imperativo recorrer a técnicas de previsão que permitam realizar uma estimativa rigorosa das eventuais necessidades (Pinçe et al., 2021). Este problema é abordado por modelos específicos, e não será considerado nesta dissertação.

2.3.1.2 Calendarização das atividades

A calendarização das atividades de manutenção corresponde ao processo de atribuir recursos, nomeadamente mão-de-obra, às tarefas a levar a cabo, bem como determinar o instante para as mesmas serem realizadas. Para que uma tarefa de manutenção possa ser calendarizada, é necessário garantir que todos os recursos necessários para a sua realização, quer humanos, quer materiais, estejam disponíveis (Ben-Daya et al., 2009b).

2.3.1.3 Planeamento da capacidade

O planeamento da capacidade tem como objetivo determinar o nível ótimo de recursos necessários para fazer face às atividades de manutenção a executar durante um determinado período, tendo em conta a sua disponibilidade. Os recursos incluem materiais, equipamentos, ferramentas, peças sobresselentes e o número de trabalhadores, bem como a sua qualificação e área de especialização. Prever a carga de trabalho, alocar recursos e monitorizar a sua performance são também tarefas incluídas no planeamento da capacidade.

Dado que nem todo o trabalho de manutenção é planeado, é ainda função do planeamento da capacidade garantir que consegue dar resposta aos eventos de manutenção não-planeada, de modo a maximizar a disponibilidade do sistema, segurança e utilização de recursos limitados (Duffuaa & Alfares, 2015). Contudo, assegurar que estes estão disponíveis quando e na quantidade necessária é um dos maiores problemas enfrentados pelo setor aeronáutico no que diz respeito a este tema. Por um lado, um excesso de recursos leva a um aumento nos custos, por outro, a falta de recursos pode representar falhas operacionais e uma redução na qualidade do serviço prestado ao cliente (Eickemeyer, Herde, et al., 2014).

Como foi referido, o planeamento da capacidade é efetuado para garantir a existência de um equilíbrio entre a capacidade disponível, mais concretamente, de mão-de-obra, e a capacidade necessária, isto é, a carga de trabalho. A sua elaboração é facilitada quando se trata de atividades de manutenção planeada, visto que são conhecidas, antecipadamente, as tarefas a realizar, a sua duração e os recursos necessários. Contudo, este cenário é transfigurado ao tratar-se de manutenção não-planeada, que representa grande parte do trabalho de

manutenção realizado em sistemas complexos, fazendo com que o planeamento da capacidade seja caracterizado pela incerteza (Dinis et al., 2022).

Várias técnicas, como as apresentadas por Márquez (2007), Duffuaa & Al-Shayea (2020) e Eickemeyer, Steinkamp, et al. (2014), por exemplo, têm vindo a ser desenvolvidas na tentativa de dar resposta a este problema. No entanto, a maioria das técnicas e modelos apresentados apenas conseguem prever o volume de trabalho associado a intervenções de manutenção que já tenham ocorrido, não integrando técnicas de previsão quantitativas, cuja definição será apresentada no próximo subcapítulo, que permitam prever a capacidade necessária para realizar intervenções de manutenção futuras e sem precedentes (Dinis et al., 2022).

2.4 Técnicas de previsão

Previsão corresponde a um prognóstico, efetuado através de estimativas, cálculos ou modelos conceituais, de um, ou mais, eventos futuros. A necessidade de se recorrer a previsões é observada nos mais variados campos, desde negócios e indústrias, economia, medicina, até à política e às ciências sociais. Quando se trata da realização de prognósticos, os seus horizontes temporais podem ser classificados como: curto prazo, médio prazo e longo prazo, seguindo os mesmos moldes do planeamento da manutenção.

Previsões efetuadas a curto e médio prazos são tipicamente baseadas na identificação, modelação e extrapolação de padrões observados nos dados recolhidos. De mencionar que, uma vez que estes padrões geralmente apresentam uma certa inércia quando se trata de mudança, métodos estatísticos são comumente utilizados para realizar estas previsões (Land, 2015).

Grande parte das situações em que são empregues técnicas de previsão envolve o uso de séries temporais. Uma série temporal corresponde a uma sequência temporal ou cronológica de observações relacionadas com uma determinada variável de interesse. A elaboração de prognósticos através do estudo e análise de séries temporais é deveras importante, pois a antevisão de possíveis eventos futuros fornece informações e dados críticos e indispensáveis para que possam ser tomadas decisões e efetuados planeamentos nas mais diversas áreas, incluindo a manutenção.

Existe uma grande variedade de problemas que podem ser solucionados com a utilização de técnicas de previsão, e estas dividem-se em dois grupos: técnicas de previsão qualitativas e técnicas de previsão quantitativas. As primeiras são consideradas subjetivas por natureza e são baseadas no julgamento de especialistas. Estas técnicas são usualmente aplicadas quando não existem dados históricos, ou a sua quantidade é insuficiente para elaborar uma previsão minimamente precisa. A técnica qualitativa mais conhecida corresponde ao Método de Delphi. Nesta técnica, é reunido um grupo de peritos, numa determinada área de conhecimento, que vão, de forma individual, responder a um questionário. As suas respostas são, posteriormente,

partilhadas, de modo que os vários indivíduos presentes possam repensar e reavaliar as suas próprias respostas. O processo repete-se até que seja atingido um consenso.

Contrariamente às técnicas qualitativas, as técnicas de previsão quantitativas recorrem a dados históricos e a modelos que a estes se ajustem, ou seja, que descrevam os padrões, se existirem, observados nos dados e evidenciem a relação estatística entre o valor anterior e o atual da variável em estudo. O modelo é então utilizado para estimar um valor futuro a partir de um ou mais valores passados (Lee et al., 2008). Dentro desta categoria de técnicas de previsão, distinguem-se dois grupos de modelos, largamente utilizados: modelos de regressão linear e análise de séries temporais. As regressões tiram partido da relação entre a variável de interesse e uma ou mais variáveis independentes. Já a análise de séries temporais emprega as propriedades estatísticas dos dados históricos e utilizam-nas para desenvolver um modelo e estimar os seus parâmetros desconhecidos (Duffuaa & Raouf, 2015). Os modelos ARIMA, desenvolvidos nos anos 70 do século passado por George Box e Gwilym Jenkins, o alisamento exponencial, introduzido pela primeira vez durante o período da Segunda Guerra Mundial por Robert Goodell Brown, e as médias móveis são algumas das técnicas englobadas na análise de séries temporais.

2.4.1 Alisamento exponencial

O alisamento exponencial foi desenvolvido, nos anos de 1940, por Robert G. Brown, que desempenhava o cargo de analista de investigação operacional na Marinha dos Estados Unidos. O método de alisamento exponencial simples era apenas aplicado a dados contínuos, sendo ainda utilizado nos dias de hoje. Nos anos subsequentes, o método sofreu alterações que permitiram que este recorresse a dados discretos para efetuar as previsões (Gardner, 2006). A juntar a isto, desenvolveram-se ainda métodos para determinar tendências, ou seja, o movimento evolutivo no valor da variável em estudo, e sazonalidades, que corresponde ao componente das séries temporais cujo comportamento se repete cíclica e regularmente (Yang et al., 2017). Na década de 1950, Charles C. Holt desenvolveu um método, semelhante ao proposto por Brown, que permitia aplicar o alisamento exponencial a tendências aditivas e um outro método, completamente diferente, para alisar dados sazonais. No entanto, as técnicas apresentadas por Holt apenas ganharam popularidade no ano de 1960, após terem sido testados, por Winters, com dados empíricos, tendo o sistema de previsão ficado conhecido como Holt-Winters (HW) (Gardner, 2006). Posteriormente, novas modificações foram introduzidas aos métodos de AE. Uma das modificações permitiu o desenvolvimento e robustecimento da base estatística destes métodos: a introdução de uma estrutura de espaço de estados, que permitiu que os métodos, agora denominados modelos, passassem a incluir erros aditivos e multiplicativos (Dinis et al., 2022; Hyndman et al., 2002).

Os modelos de alisamento exponencial são considerados intuitivos e de fácil compreensão, tornando a sua aplicação relativamente simples. Uma das formulações utilizada para descrever os modelos de alisamento exponencial está apresentada na Tabela 2.1, equações 2.1 a 2.13 (Dinis et al., 2022).

Tabela 2.1 - Formulação para o AE utilizada por Dinis et al. (2022)

Modelo de AE	Formulação	Equação
<i>Simple Exponential Smoothing</i> (SES)	$\mu_t = l_{t-1}$	2.1
	$l_t = l_{t-1}(1 + \alpha \varepsilon_t)$	2.2
<i>Holt's Linear Method</i> (HLM)	$\mu_t = l_{t-1} + b_{t-1}$	2.3
	$l_t = (l_{t-1} + b_{t-1})(1 + \alpha \varepsilon_t)$	2.4
	$b_t = b_{t-1} + \beta (l_{t-1} + b_{t-1}) \varepsilon_t$	2.5
<i>Additive Holt- Winters</i> (AHW)	$\mu_t = (l_{t-1} + b_{t-1})s_{t-m}$	2.6
	$l_t = l_{t-1} + b_{t-1} + \alpha(l_{t-1} + b_{t-1}) \varepsilon_t$	2.7
	$b_t = b_{t-1} + \beta(l_{t-1} + b_{t-1} + s_{t-m}) \varepsilon_t$	2.8
	$s_t = s_{t-m} + \gamma(l_{t-1} + b_{t-1} + s_{t-m}) \varepsilon_t$	2.9
<i>Multiplicative Holt- Winters</i> (MHW)	$\mu_t = (l_{t-1} + b_{t-1})s_{t-m}$	2.10
	$l_t = (l_{t-1} + b_{t-1})(1 + \alpha \varepsilon_t)$	2.11
	$b_t = b_{t-1} + \beta(l_{t-1} + b_{t-1}) \varepsilon_t$	2.12
	$s_t = s_{t-m} + (1 + \gamma \varepsilon_t)$	2.13

2.4.2 Modelos ARIMA

Os modelos ARIMA, introduzidos pela primeira vez em 1976, estão inseridos numa classe de modelos lineares que têm, historicamente, vindo a ser largamente utilizados para modelar e prever os valores associados a séries temporais. Estes derivam dos modelos *Auto-regressive Moving Average* (ARMA), que modelam séries temporais, e podem ser divididos em duas partes. Uma parte autorregressiva (AR), que demonstra a correlação existente entre o valor atual e os valores passados, denominada *lag*. E uma segunda parte correspondente à média móvel (*Moving Average* – MA), que corresponde à correlação existente entre os valores atuais e os resíduos resultantes de valores passados (Flores et al., 2012). Contudo, tais modelos apenas podem ser aplicados para modelar processos estacionários, ou seja, que exibem um “comportamento estatístico” estável ao longo do tempo (Jimenez-Cortadi et al., 2018). Complementarmente, os modelos ARIMA têm a capacidade de descrever séries temporais quer estacionárias, quer não-estacionárias, uma vez que possuem um componente de integração "I", que permite eliminar tendências presentes nas séries temporais, tornando-as estacionárias,

através do processo de diferenciação. Neste processo, subtraem-se valores passados aos dados (Lah et al., 2022; Yang et al., 2017). Graças às suas características, como a rapidez e quantidade relativamente pequena de cálculos a efetuar aquando da sua aplicação, os modelos ARIMA têm vindo a tornar-se extremamente utilizados em problemas que envolvem séries temporais, como a previsão dos preços da eletricidade, a procura de combustíveis fósseis e no desenvolvimento de estratégias de manutenção (Jimenez-Cortadi et al., 2018). Adicionalmente, vários estudos têm demonstrado a superioridade destes modelos quando comparados com outras técnicas de previsão, como o método de Holt-Winters (Zhang et al., 2020).

Os modelos ARIMA são geralmente denotados por ARIMA (p, d, q), onde p corresponde à ordem da parte autorregressiva (número de *lags*), d representa a ordem de diferenciação, ou seja, o número de vezes que valores passados foram subtraídos aos dados, e q diz respeito à ordem do processo de médias móveis (Yang et al., 2017).

Os modelos desenvolvidos por Box-Jenkins utilizam ainda duas ferramentas gráficas para obter um sumário estatístico da série temporal em estudo: a função de autocorrelação (ACF - *autocorrelation function*) e a função de autocorrelação parcial (PACF - *partial autocorrelation function*). Ambas as funções demonstram, de maneira diferente, a variação ao longo do tempo da intensidade da correlação. Um modelo considera-se bem ajustado quando a ACF e a PACF não demonstram uma correlação significativa.

A ACF é obtida através da correlação linear entre o valor da observação no momento t , representada por x_t , e os restantes valores da série com *lags* diferentes, ou seja, $x_{(t-1)}$, $x_{(t-2)}$, etc... Já a PACF devolve o mesmo resultado, removendo as interferências introduzidas por outros valores. Por exemplo, na ACF, a correlação entre x_t e $x_{(t-2)}$ é afetada pela interferência de $x_{(t-1)}$, que é removida pela PACF. Apesar de cada uma das funções ter a sua própria interpretação, estas podem ser interpretadas conjuntamente (Flores et al., 2012). Observem-se as Figuras 2.1 e 2.2, onde são apresentadas a ACF e a PACF de um modelo AR(2), respetivamente.

Na Figura 2.1 são visíveis duas correlações que ultrapassam os limites de significância, definidos pelas linhas a tracejado. De notar que a ACF mostra todas as correlações, incluindo, algumas vezes, a de *lag* 0, que não deve ser considerada. Na Figura 2.2 também é possível observar correlações significativas. Tal ocorre devido a eventuais variações amostrais e à possível interação entre o termo autorregressivo, AR, e o termo das médias móveis, MA.

Por definição, o valor do componente autorregressivo pode ser observado na PACF, nomeadamente, quando esta é estatisticamente diferente de 0 nos *lags* $m = 1, 2, \dots, p$ e zero no seguinte, acompanhada de uma diminuição acentuada nos valores da ACF. Assim, o parâmetro AR(p), de acordo com a equação 2.14, é utilizado para (Flores et al., 2012):

$$x_t = \Phi_1 x_{(t-1)} + \Phi_2 x_{(t-2)} + \dots + \Phi_p x_{(t-p)} + \varepsilon_t \quad 2.14$$

Onde:

x_t corresponde à observação no momento t .

Φ corresponde aos parâmetros autorregressivos.

ε_t corresponde ao erro aleatório, no momento t , assumido como independente e identicamente distribuído, com uma média igual a zero e uma variância constante correspondente a σ^2 (*white noise*).




Figura 2.1 - ACF de um modelo AR(2). Fonte: Flores et al. (2012).




Figura 2.2 - PACF de um modelo AR(2). Fonte: Flores et al. (2012).

Nas Figuras 2.3 e 2.4 estão representadas a ACF e a PACF de um modelo AR(1), respectivamente.




Figura 2.3 - ACF de um modelo AR(1). Fonte: Chen et al. (2008).




Figura 2.4 - PACF de um modelo AR(1). Fonte: Chen et al. (2008).

Como se pode verificar na Figura 2.3, a partir do *lag* 1 há uma diminuição nos valores de correlação, e na Figura 2.4 há um corte também no valor 1. Assim, pode concluir-se que se trata de um modelo AR(1) (Chen et al., 2008).

Relativamente ao parâmetro MA(q), este pode ser estimado através da ACF, nomeadamente, quando esta é estatisticamente diferente de 0 nos *lags* $m = 1, 2, \dots, q$ e zero no seguinte, acompanhada de uma diminuição acentuada nos valores da PACF. Este parâmetro é então empregue, como é descrito na equação 2.15, para:

$$x_t = \gamma_1 \varepsilon_{(t-1)} + \gamma_2 \varepsilon_{(t-2)} + \dots + \gamma_q \varepsilon_{(t-q)} + \varepsilon_t \quad 2.15$$

Onde:

γ_q corresponde aos parâmetros das médias móveis.

Nas Figuras 2.5 e 2.6 estão representadas a ACF e a PACF de um modelo MA(1), respectivamente.




Figura 2.5 - ACF de um modelo MA(1). Fonte: Yang et al. (2017)




Figura 2.6 - PACF de um modelo MA(1). Fonte: Yang et al. (2017).

Na Figura 2.5, após o *lag* 1, há uma queda abrupta nos valores da correlação, passando a estar dentro dos limites de significância, podendo ser considerado um corte. Na Figura 2.6

é visível uma diminuição nos valores da função depois do *lag* 1, o que indica que se está perante um modelo MA(1) (Yang et al., 2017).

Assim, considerando uma série temporal dependente $\{X_t: 1 \leq t \leq n\}$, o modelo ARIMA correspondente pode ser matematicamente descrito pelas equações 2.16 a 2.20 (Yang et al., 2017):

$$\nabla^d X_t = \frac{\theta(B)}{\phi(B)} \varepsilon_t \quad 2.16$$

B corresponde ao *backshift operator*:

$$BX_t = X_{t-1} \quad 2.17$$

$\phi(B)$ é o operador autorregressivo e é representado como um polinómio no *backshift operator*:

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad 2.18$$

$\theta(B)$ é o operador de médias móveis e é representado como um polinómio no *backshift operator*:

$$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad 2.19$$

∇^d descreve a operação de diferenciação realizada de modo a tornar a série temporal estacionária, onde d corresponde ao número de diferenciações.

$$\nabla^d = (1 - B)^d \quad 2.20$$

De acordo com os criadores do modelo, Box e Jenkins, o número ideal de observações a partir do qual se deve aplicar o modelo é 100, sendo 50 o número mínimo recomendado (Tseng et al., 2002).

2.4.2.1 Modelos SARIMA

Os modelos SARIMA (*Seasonal* ARIMA) são utilizados quando as séries temporais apresentam características que se repetem nos mesmos intervalos de tempo, ou seja, sazonalidade. Nestes casos, uma diferenciação sazonal é mais eficaz na remoção dos efeitos da sazonalidade sobre a série temporal (Yang et al., 2017).

Estes modelos são comumente denotados como SARIMA (p, d, q) (P, D, Q)_s, onde P corresponde à parte sazonal autorregressiva, D representa a ordem da diferenciação sazonal, Q diz respeito à ordem do processo de média móvel sazonal e s denomina o número de períodos do ciclo sazonal (Jain et al., 2021).

2.4.3 Medidas de desempenho das técnicas de previsão

Quando se trata da aplicação de técnicas de previsão, é de fundamental importância garantir que o modelo escolhido é o que melhor se adequa aos dados analisados. Nesta sequência, surge a análise do erro da previsão como forma de atestar a precisão da técnica escolhida, permitindo ainda aferir se foi selecionada a técnica mais indicada quando são aplicadas várias técnicas. O erro em relação a um determinado período t , $e(t)$, é calculado pela diferença entre o valor observado no período t , $R(t)$, e o valor previsto nesse mesmo período, $P(t)$, equação 2.21.

$$e(t) = R(t) - P(t) \quad 2.21$$

Os erros podem ser positivos, nulos e negativos. Ao efetuar-se a soma dos erros, valores dos erros positivos compensam valores dos erros negativos, pelo que não é possível concluir acerca da precisão da técnica de previsão adotada. Para contornar esta limitação, recorre-se frequentemente ao valor absoluto, ou ao quadrado dos erros. Assim, para determinar o erro associado à técnica de previsão pode ser usada uma das seguintes medidas do erro: desvio médio absoluto (equação 2.22) e erro quadrático médio (equação 2.23). Em termos percentuais, podem ser usados o erro percentual absoluto médio (equação 2.24) e o erro percentual quadrático médio (equação 2.25) (Hyndman & Koehler, 2006).

Desvio Médio Absoluto (DMA)	$DMA = \frac{\sum_{t=1}^N R(t) - P(t) }{N}$	2.22
--------------------------------	--	------

Erro Quadrático Médio (EQM)	$EQM = \frac{\sum_{t=1}^N (R(t) - P(t))^2}{N}$	2.23
--------------------------------	--	------

Erro Percentual Absoluto Médio (EPAM)	$EPAM = \frac{100}{N} * \sum_{t=1}^N \left \frac{R(t) - P(t)}{R(t)} \right $	2.24
--	---	------

Erro Percentual Quadrático Médio (EPQM)	$EPQM = \frac{100}{N} * \sum_{t=1}^N \left[\left(\frac{R(t) - P(t)}{R(t)} \right)^2 \right]$	2.25
--	--	------

2.4.4 Critérios para seleção de modelos

Um critério utilizado para avaliar o desempenho da aplicação de técnicas de previsão a dados denomina-se *Akaike Information Criterion* (AIC). Este critério penaliza a soma dos erros ao quadrado, devido à adição de parâmetros ao modelo. Considera-se que modelos que possuam um valor baixo de AIC representam mais corretamente os dados.

Uma das formulações comumente utilizadas para descrever o AIC é apresentada na equação 2.26 (Dinis et al., 2022).

$$AIC = -2 \log L(\theta, x_0) + 2p \quad 2.26$$

Onde:

θ representa os parâmetros do modelo,

x_0 inclui os parâmetros necessários para iniciar o modelo,

p corresponde à soma do número de parâmetros em θ com o número de parâmetros iniciais em x_0 e, por fim,

$\log L(\theta, x_0)$ corresponde à função *log-likelihood*, um valor que demonstra o quão bem o modelo escolhido se adequa aos dados em causa (Van Opheusden et al., 2020). A equação 2.27 permite obter tal valor:

$$\log L(\theta, x_0) = \sum_{t=1}^n \sum_{i=1}^{k_t} \log L(\lambda_t, \xi_t | y_{ti}) \quad 2.27$$

Onde λ_t e ξ_t correspondem aos parâmetros da distribuição lognormal. No contexto do trabalho a desenvolver, esta distribuição de probabilidade descreve mais adequadamente a carga de trabalho a prever do que a distribuição normal, uma vez que apenas assume valores positivos e está desviada para a direita (Dinis et al., 2022). Assim, λ_t e ξ_t são obtidos a partir das equações 2.28 e 2.29:

$$\xi_t = \sqrt{\ln(1 + \frac{\sigma^2}{\mu^2})} \quad 2.28$$

$$\lambda_t = \ln(\mu) - \frac{\xi_t^2}{2} \quad 2.29$$

De notar que os valores da média, μ , e do desvio padrão, σ , correspondem aos parâmetros das amostras estatísticas utilizadas para levar a cabo o estudo.

Caso as amostras de dados a analisar sejam relativamente pequenas, recorre-se ao *bias-corrected Akaike Information Criterion* (AICc), cujo valor é dado pela equação 2.30, onde K diz respeito ao número total de observações.

$$AICc = AIC + \frac{2p(p+1)}{K-p-1} \quad 2.30$$

Ao utilizar-se o AICc, pode concluir-se que, geralmente, a técnica de previsão que possui o menor valor vai adequar-se melhor e descrever de forma mais precisa os dados em questão.

2.5 Modelos ARIMA vs AE: relevância da discussão

A comparação entre os modelos de AE e os modelos ARIMA tem sido efetuada com o intuito de atestar a robustez de ambas as técnicas, principalmente quando se trata de previsões a curto prazo e com um volume de dados reduzido (Rubio et al., 2021). Algumas destas previsões incluem a previsão da procura e dos preços da eletricidade (Alsaedi & Tularam, 2021), possível número de infeções associadas à pandemia de COVID-19 (Jain et al., 2021), a procura de uma sala de colheita de sangue, com o intuito de se efetuar um planeamento da capacidade (Zhang et al., 2020), entre outros. Nos trabalhos mencionados, os modelos ARIMA demonstraram ser superiores e obtiveram melhores resultados comparativamente com os obtidos através da aplicação de modelos de alisamento exponencial. Estes últimos são utilizados para descrever eventuais tendências e sazonalidade, ao passo que os modelos ARIMA descrevem correlações observadas nos dados. Graças às componentes autorregressivas (AR), aliadas às componentes de médias móveis (MA), os modelos têm a capacidade de determinar mudanças observadas nos dados ao longo do tempo, bem como detetar tendências mais alisadas. A juntar a isto, a componente de integração, associada à letra "I" presente em ARIMA, indica o nível de diferenciação necessário para que os dados possam ser tratados como uma série temporal estacionária (Rubio et al., 2021; Yang et al., 2017). Assim, as principais características que distinguem e, em alguns casos, destacam os modelos ARIMA do alisamento exponencial são (Fomby, 2008; Montgomery, 2015):

1. Flexibilidade: os modelos ARIMA podem ser aplicados a uma ampla gama de séries temporais, com sazonalidades e tendências variadas, permitindo que detetem padrões mais complexos presentes nos dados. Adicionalmente, grande parte dos modelos de AE resultam de casos especiais dos modelos ARIMA, o que incita a utilização destes modelos precisamente por serem considerados mais flexíveis, podendo ajustar-se mais corretamente aos dados;
2. Estimativa dos parâmetros: os valores obtidos para as diferentes componentes, nomeadamente, as autorregressivas, as médias móveis e a de integração, permitem uma melhor interpretação da dinâmica associada à série temporal em estudo;
3. Inferência estatística: os modelos ARIMA baseiam-se numa rede estatística mais robusta e sólida, facilitando o teste de hipóteses e a estimação do intervalo de confiança dos parâmetros do modelo. Tal pode ainda ser benéfico no que toca à averiguação e avaliação da relação entre as diferentes variáveis;

4. Precisão: em determinadas situações, as características dos modelos ARIMA possibilitam a obtenção de estimativas mais precisas, quando comparadas com as obtidas pelos modelos de AE, uma vez que permitem a análise de padrões mais complexos e irregulares, que podem não ser modelados e calculados tão eficazmente pelos modelos de alisamento exponencial.

Dadas as características apresentadas e trabalhos mencionados, demonstra-se a forma como os modelos ARIMA se distinguem do AE e, em alguns casos, os superam ao efetuarem previsões mais precisas. Desta forma, justifica-se a realização do presente estudo, para testar se o mesmo se verifica no contexto da manutenção aeronáutica, mais concretamente, na previsão da carga de trabalho, de modo a que se possa efetuar um planeamento da capacidade mais rigoroso.

3 METODOLOGIA CIENTÍFICA APLICADA

No Capítulo 3 será apresentada a metodologia adotada para o desenvolvimento do trabalho da presente dissertação, bem como os resultados obtidos por Dinis et. al (2022), aquando da aplicação dos modelos de alisamento exponencial ao mesmo conjunto de dados e com o mesmo objetivo.

3.1 Resultados anteriores

Um dos objetivos desta dissertação passa por comparar a precisão dos resultados obtidos a partir da aplicação de modelos de alisamento exponencial e modelos ARIMA ao mesmo conjunto de dados. Para o efeito, foi utilizada uma amostra de dados reais, composta por 171 projetos de manutenção, levados a cabo por uma organização de MRO portuguesa. Tais projetos representam inspeções do tipo "C", que são cíclicos por natureza, repetindo-se sucessivamente ao longo do tempo de vida útil da aeronave, de acordo com o seu uso e eventuais limitações de tempo. Por esta razão, são considerados como "manutenção planeada" e vão introduzir, expectavelmente, uma componente sazonal na série temporal.

No caso do modelo da aeronave em estudo, quando esta atinge as 25000 horas de voo/ciclos de voo (HV/CV), ou 150 meses (MO), realiza-se a segunda inspeção do tipo "C", também denominada "5C". Ao atingir-se as 30000 horas de voo/ciclos de voo, ou 180 meses, realiza-se a segunda inspeção "2C", correspondente à inspeção "6C", e assim sucessivamente. Um ciclo de inspeções para a aeronave em causa é composto por 4 períodos, um por cada inspeção realizada, tendo início em "C" e terminando em "4C". Nesta amostra existem dois ciclos.

Na Tabela 3.1 estão sintetizadas as características de cada *check* associados ao modelo de aeronave em causa.

Na Figura 3.1 estão apresentadas as cargas de trabalho associadas a cada *check* dos projetos recolhidos.

Tabela 3.1 - Número de projetos associados a cada *check*, uso/limitação temporal de cada *check* e períodos de tempo e ciclos considerados para análise da série temporal. Adaptado de: Dinis et al. (2022).

<i>Check</i>	Número de Projetos	Uso/limitação temporal	Período de tempo t	Ciclo
C	14	5000 HV/CV ou 30 MO	1	1
2C	25	10000 HV/CV ou 60 MO	2	
3C	28	15000 HV/CV ou 90 MO	3	
4C	41	20000 HV/CV ou 120 MO	4	
C (5C)	28	25000 HV/CV ou 150 MO	5	2
2C (6C)	16	30000 HV/CV ou 180 MO	6	
3C (7C)	16	35000 HV/CV ou 210 MO	7	
4C (8C)	3	40000 HV/CV ou 240 MO	8	




Figura 3.1 - Distribuição dos projetos pelos diferentes *checks* e respectivas cargas de trabalho de manutenção (valores dados em percentagem, por motivos de confidencialidade, sendo o 100% representado pela carga média do *check* "C"). Fonte: Dinis et. al (2022)

Apesar da realização de manutenção planeada, vários sistemas da aeronave deterioram-se com o avançar do tempo, o que faz com que a carga de trabalho associada a cada projeto de manutenção aumente com a idade da aeronave, aumentando a probabilidade da necessidade de realizar manutenção não-planeada. De notar que este tipo de manutenção pode introduzir uma tendência crescente na série temporal que descreve a carga de trabalho.

No trabalho que serve de comparação e também ponto de partida para a presente dissertação, foram utilizados quatro modelos de alisamento exponencial, mais concretamente: SES, HLM, AHW e MHW.

Para a aplicação dos modelos, utilizaram-se os dados das inspeções "C" até "7C", correspondendo a um total de 168 intervenções de manutenção, e recorreu-se à última inspeção existente nos dados, "8C", para validar os modelos, tendo sido adotado o que apresentava um menor valor de AICc. De notar que, de modo a que os dados representassem as várias atividades de manutenção realizadas em cada tipo de inspeção, foi aplicada a função *log-likelihood* ou *log-verossimilhança*. Assim, cada ponto de dados passou a descrever e a representar todas as atividades de manutenção associadas a um determinado tipo de *check*, permitindo aumentar a informação extraída dos a partir dos dados. Tal função foi aplicada dado tratar-se de uma série temporal curta, com o intuito de se utilizarem todas as observações na aplicação dos modelos.

Para inicializar os vários modelos, dado existirem apenas 7 pontos na série, recorreu-se à técnica explorada em Rasmussen (2004), que permitiu obter os parâmetros de inicialização. Seguidamente, aplicaram-se os métodos de alisamento exponencial e calculou-se o AICc e a *log-likelihood* para cada um dos modelos, bem como o valor das medidas de erro escolhidas, nomeadamente, o DMA e o EQM. Tais valores podem ser observados na Tabela 3.2.

Tabela 3.2 - Resultados obtidos por Dinis et. al (2022) para o AICc, *log-likelihood*, DMA e EQM. Nota: melhores valores a negrito.

Modelo	AICc	logL (θ , x0)	DMA	EQM
SES	1067,99	-531,95	2836,49	9927028,10
HLM	1067,89	-529,81	2036,92	5754686,77
AHW	1070,88	-525,81	2176,33	6365964,72
MHW	1067,02	-523,88	1502,34	3456492,68

A partir dos valores apresentados na Tabela 3.2, concluiu-se que o método que melhor descreveu os dados foi o MHW, uma vez que obteve o menor valor de AICc (1067,02) e o maior valor de *log-likelihood* (-523,88). Com este modelo, obtiveram-se ainda os menores valores associados às medidas de erro, 1502,34 e 3456492,68 para o DMA e EQM, respetivamente. Adicionalmente, constatou-se que o HLM teve um desempenho superior ao do AHW, apresentado os segundos valores mais baixos de AICc (1067,89), DMA (2036,92) e EQM (5754686,77). Apesar do método de MHW possuir mais valores iniciais e parâmetros para calcular, comparativamente com o SES e o HLM, exibe, contudo, um menor valor do AICc, demonstrando que o seu ajuste aos dados compensa a sua complexidade acrescida. Através da análise dos vários valores da *log-likelihood*, é ainda evidente que métodos que tenham capacidade para determinar componentes sazonais e de tendência têm um melhor desempenho

do que aqueles que não o fazem. Tal comportamento seria esperado, dadas as componentes sazonais e de tendência introduzidas pela manutenção planeada e não-planeada, respetivamente, na carga total de trabalho. Finalmente, a performance superior do método MHW, relativamente ao AHW, sugere que a amplitude da componente sazonal, presente na série temporal da carga de trabalho, é proporcional à quantidade da carga, ao invés de independente.

3.2 Aplicação dos modelos ARIMA

Para proceder à aplicação dos modelos ARIMA, começou-se por retirar os *outliers* presentes no conjunto de dados, dada a elevada variabilidade observada e que está representada na Figura 3.2. Um *outlier* corresponde a uma observação que se desvia marcadamente das restantes e a sua deteção é de extrema importância quando se trata de análise de dados. Estes descrevem um comportamento anómalo dos dados, ou seja, quando estes se desviam da sua variabilidade natural (Bagheri Garmarudi et al., 2015).




Figura 3.2 -Variabilidade da carga de trabalho de manutenção dos diferentes checks (valores dados como percentagens da carga de trabalho média do check "C"). Fonte: Dinis et al. (2022).

O método adotado foi a padronização das variáveis, tal como é descrito por Muhammad Ali & Faraj (2014), um método amplamente utilizado para facilitar a deteção de *outliers* (e.g.: Owen et al. (2022)). De notar que, uma vez que no trabalho de Dinis et. al (2022) não se retiraram *outliers*, tendo-se usado todo o conjunto dos dados para aplicar o AE, foi necessário refazer toda essa modelação, desconsiderando os valores determinados como *outliers*. Neste processo, considerou-se um intervalo de confiança de 95%.

Após a remoção dos *outliers*, iniciou-se a aplicação dos modelos ARIMA. Os modelos foram aplicados e identificados de acordo com um processo dividido em quatro etapas (Yang et al., 2017):

1. Teste de estacionaridade: realiza-se com o objetivo de determinar os valores de d . O método mais intuitivo corresponde à análise do gráfico de autocorrelação, em que se o coeficiente de autocorrelação se aproximar rapidamente de zero, então conclui-se que a série temporal é estacionária. Outra forma de analisar a estacionariedade da série passa pela realização do teste *Augmented Dickey-Fuller* (ADF). De acordo com este teste, toma-se como hipótese nula a não estacionariedade da série temporal. Se o valor do teste for superior aos valores críticos, então não se rejeita a hipótese nula e conclui-se que a série não é estacionária (Nyabwanga, 2016);
2. Identificação do modelo: permite estimar os valores dos parâmetros p e q . Tal é conseguido através do cálculo da função de autocorrelação e da função de autocorrelação parcial. A partir dos valores obtidos, pode ser escolhida a ordem do modelo que melhor se adequa, por meio da adoção de critérios de seleção de modelos;
3. Ajustamento do modelo: são escolhidos os parâmetros a utilizar, com base nas medidas de desempenho adotadas;
4. Diagnóstico do modelo: realiza-se uma análise aos resíduos (ou erros) obtidos, de modo a concluir se o modelo e os parâmetros escolhidos captaram de forma correta a dinâmica da série temporal.

Na Figura 3.3 está representado um fluxograma deste processo.

Assim, foi necessário, primeiramente, verificar a estacionariedade dos dados, uma propriedade imperativa para a aplicação de tais modelos, que determinaria se o valor do parâmetro d seria igual ou diferente de zero, caso a série fosse estacionária ou não, respetivamente. Para tal, realizou-se o teste de ADF. Seguidamente, com o intuito de fazer uma primeira identificação do modelo e determinar possíveis valores de p e q , estudaram-se a ACF e a PACF. Deste passo resultaram diversas combinações de parâmetros, que foram posteriormente estudadas com recurso à linguagem de programação *Python*, mais concretamente, recorreu-se à biblioteca *statsmodels.tsa.arima.model*. Esta biblioteca foi utilizada com o intuito de testar individualmente as várias combinações e descartar aquelas cujos parâmetros não permitissem ao *Python* ajustar um modelo aos dados em estudo. Na etapa seguinte, avaliaram-se as medidas de erro e de desempenho das parametrizações que poderiam eventualmente descrever e prever o comportamento das séries temporais em causa. Na quarta e última etapa, procedeu-se à análise de resíduos da combinação que melhor se ajustou.

Posteriormente, enunciaram-se os resultados obtidos e, tratando-se de um dos principais objetivos da presente dissertação, compararam-se os resultados obtidos através da aplicação do AE com aqueles obtidos pelos modelos ARIMA. Adicionalmente, efetuou-se também uma comparação entre os modelos de AE utilizados e os seus modelos ARIMA equivalentes.




Figura 3.3 - Fluxograma do processo de aplicação de um modelo ARIMA. Adaptado de: Yang et al. (2017)

4 APLICAÇÃO DOS MODELOS ARIMA

Neste capítulo serão descritas, pormenorizadamente, as etapas do processo de aplicação dos modelos ARIMA aos dados em causa.

De notar que os modelos foram aplicados à mesma série temporal, considerando, numa das iterações, 7 pontos de dados, à semelhança do que foi realizado por Dinis et. al (2022), por motivos de comparação, e, numa segunda iteração, consideraram-se os 8 pontos de dados, na tentativa de obter um modelo mais ajustado. Cada ponto de dados corresponde à média da carga de trabalho, em percentagem, das várias observações recolhidas para cada *check*. Na Tabela 4.1 podem observar-se os valores a utilizar.

Tabela 4.1- Valores médios da carga de trabalho associada a cada *check* (valores dados em percentagem, por motivos de confidencialidade, sendo o 100% representado pela carga média do *check* "C")

<i>Check</i>	Carga de trabalho média
C	100%
2C	149,09%
3C	147,62%
4C	166,11%
5C	150,32%
6C	239,19%
7C	299,02%
8C	404,37%

4.1 Aplicação dos modelos ARIMA considerando 7 pontos

4.1.1 Teste de estacionaridade

O primeiro passo para aplicar um modelo ARIMA passa por garantir que a série temporal não apresenta componentes sazonais ou tendências, ou seja, que é estacionária. Ao utilizar-se o mesmo número de pontos que Dinis et. al (2022), obtém-se o gráfico de autocorrelação

apresentado na Figura 4.1. Através da análise do gráfico de autocorrelação, não é evidente a presença de sazonalidade na série, uma vez que em nenhum *lag* o valor da autocorrelação ultrapassa os limites, nem se repete de forma cíclica. Ao observar-se a Figura 4.2 também não é evidente a presença de tendência. Assim sendo, para analisar a estacionaridade da série temporal, realizou-se o teste de ADF. Este teste é realizado com o intuito de aferir se a série temporal possui, ou não, uma tendência estocástica, também denominada raiz unitária. Ao verificar-se a sua presença, conclui-se que a série não é estacionária, o que pode afetar a precisão das previsões efetuadas (Silveira et al., 2022). Neste teste, assume-se como hipótese nula a não estacionaridade da série. Se valor da estatística do teste de ADF for superior aos valores críticos, considerando um determinado nível de significância, então não se rejeita a hipótese nula, confirmando a não estacionaridade da série em estudo (Nyabwanga, 2016).




Figura 4.1 - Função de autocorrelação para amostra de 7 pontos




Figura 4.2 - Gráfico do valor da carga média de trabalho associada a cada *check* para amostra de 7 pontos (valores dados em percentagem, por motivos de confidencialidade, sendo o 100% representado pela carga média do *check* "C")

Na Tabela 4.2 estão presentes o valor da estatística do teste e os valores críticos associados a vários níveis de significância. Considerando um nível de significância de 5%, constata-se que o valor do teste (1,15) é superior ao valor crítico (-3,93), não se rejeitando a hipótese nula, o que indica a não estacionaridade da série. Desta forma, deduz-se que é necessário diferenciar a série, indicando que o valor do parâmetro d é diferente de zero

Tabela 4.2 -Valor da estatística do teste ADF e valor crítico obtido para amostra de 7 pontos

Estatística do teste ADF	Valor crítico	
1,15	$\alpha=0,05$	-3,93

4.1.2 Identificação do modelo

A segunda etapa da elaboração de um modelo ARIMA corresponde à identificação do modelo, ou seja, à estimativa dos possíveis valores de p e q . Para tal, recorre-se também às funções de autocorrelação (ACF) e de autocorrelação parcial (PACF). Para determinar o parâmetro p , observa-se o valor a partir do qual a ACF começa a diminuir e a PACF corta. No caso do parâmetro q , este toma o valor a partir do qual a PACF começa a diminuir e onde a ACF corta (Chen et al., 2008). Os restantes parâmetros foram estimados através da linguagem de programação *Python*.

Tendo em conta a série temporal utilizada por Dinis et. al (2022), começou-se, novamente, por analisar a ACF, observando também o comportamento da PACF. As funções encontram-se representadas as Figuras 4.3 e 4.4:




Figura 4.3 - ACF da amostra com 7 pontos




Figura 4.4 - PACF da amostra com 7 pontos

Ao analisarem-se a ACF e a PACF, infere-se que o valor do parâmetro p , que representa a parte autorregressiva, pode ser 1, uma vez que a PACF assume o valor 0 após esse *lag*, havendo um corte, e os valores da ACF também sofrem um decréscimo após esse *lag* 1. Relativamente ao parâmetro q , que representa o termo das médias móveis, infere-se que este pode tomar o valor 0 ou 1, uma vez que não é claro que a ACF tome o valor 0 entre dois *lags* consecutivos, verificando-se apenas uma diminuição nos valores.

Após esta primeira análise, testaram-se várias combinações de parâmetros, considerando que cada um destes poderia tomar valores entre 0 e 3, excetuando d , que não poderia tomar o valor 0, pois demonstrou-se a necessidade de diferenciar a série. Desta forma, obtiveram-se 48 possibilidades, apresentadas na Tabela 4.3.:

Tabela 4.3 - Possíveis parametrizações para a série temporal curta

(0, 1, 0)	(0, 1, 1)	(1, 1, 2)	(3, 2, 1)
(1, 1, 0)	(0, 1, 2)	(1, 1, 3)	(3, 2, 2)
(2, 1, 0)	(0, 1, 3)	(2, 1, 2)	(3, 2, 3)
(3, 1, 0)	(0, 2, 1)	(3, 1, 2)	(1, 3, 1)
(0, 2, 0)	(0, 2, 2)	(2, 1, 3)	(1, 3, 2)
(1, 2, 0)	(0, 2, 3)	(3, 1, 3)	(1, 3, 3)
(2, 2, 0)	(0, 3, 1)	(1, 2, 1)	(2, 3, 1)
(3, 2, 0)	(0, 3, 2)	(1, 2, 2)	(2, 3, 2)
(0, 3, 0)	(0, 3, 3)	(1, 2, 3)	(2, 3, 3)
(1, 3, 0)	(1, 1, 1)	(2, 2, 1)	(3, 3, 1)
(2, 3, 0)	(2, 1, 1)	(2, 2, 2)	(3, 3, 2)
(3, 3, 0)	(3, 3, 1)	(2, 2, 3)	(3, 3, 3)

4.1.3 Ajustamento do modelo

Para proceder ao ajustamento do modelo, que consiste em determinar os parâmetros que melhor o descrevem, recorreu-se, à semelhança do que foi feito em Dinis et al. (2022), a medidas de desempenho, nomeadamente, o AICc e a maximização da função de *log-likelihood*, e a medidas de erro, DMA e EQM.

De entre as 48 possibilidades, apenas 4 produziram resultados satisfatórios, sendo que a parametrização das restantes 44 se mostrou desajustada para a série em causa uma vez que a linguagem de programação utilizada não teve capacidade para ajustar um modelo aos dados em estudo, com base nos parâmetros fornecidos.

Na Tabela 4.4 encontram-se os valores obtidos para as duas medidas de desempenho e os dois tipos de erro, para as 4 melhores combinações:

Tabela 4.4 -Resultados obtidos para o AICc, *log-likelihood*, DMA e EQM considerando 7 pontos. Nota: melhores valores a negrito.

ARIMA (p, d, q)	AICc	$\log L(\theta, x_0)$	DMA	EQM
(1, 1, 0)	99,29	-47,57	888,08	922877,42
(1, 2, 0)	84,19	-40,02	2035,56	4146390,83
(0, 2, 1)	83,64	-39,75	1210,07	1499320,85
(1, 1, 1)	100,47	-47,16	1079,35	1218296,39

Como se pode constatar através da análise da Tabela 4.4, o modelo ARIMA (0, 2, 1) é aquele que apresenta melhores valores nas medidas de desempenho, tendo o menor valor de AICc (83,64) e o valor mais alto para a *log-likelihood* (-39,75). No entanto, não possui os menores valores no que diz respeito às medidas de erro. Quando se trata do DMA e do EQM, observa-se que o modelo ARIMA (1, 1, 0) é o que apresenta menores valores, 888,08 e 922877,42, respetivamente. Possui, contudo, um valor mais elevado do AICc e da *log-likelihood*. Pode então afirmar-se que este é o modelo mais adequado, uma vez que é aquele que permite obter previsões mais precisas, por apresentar menores valores nas medidas de erro. Adicionalmente, o facto de apresentar um valor mais elevado de AICc indica que é um modelo mais complexo e, por isso, se ajusta mais corretamente aos dados.

Na Tabela 4.5 estão discriminados os valores previstos para a carga de trabalho (em percentagem), até ao *check* 12C, tal como foi feito em Dinis et al. (2022), considerando um intervalo de confiança de 95%:

Ao observar-se a Tabela 4.5, é notória uma tendência crescente na carga de trabalho ao longo dos *checks*, em todos os modelos.

Tabela 4.5 - Valores previstos da carga de trabalho associada a cada *check* e limites inferiores e superiores, considerando um intervalo de confiança de 95% e 7 pontos (valores dados em percentagem, por motivos de confidencialidade, sendo o 100% representado pela carga média do *check* "C")

ARIMA (p, d, q)	Check	Previsão	Limite inferior	Limite superior
(1, 1, 0)	8C	323,90%	232,25%	415,55%
	9C	334,25%	175,38%	493,12%
	10C	338,56%	123,04%	554,07%
	11C	340,35%	76,49%	604,20%
	12C	341,09%	35,10%	647,09%
(1, 2, 0)	8C	440,11%	273,65%	606,57%
	9C	510,57%	244,38%	776,77%
	10C	579,39%	203,12%	955,65%
	11C	649,01%	148,96%	1149,05%
	12C	718,23%	83,95%	1352,52%
(0, 2, 1)	8C	333,55%	248,17%	418,93%
	9C	368,09%	239,57%	496,60%
	10C	402,62%	236,25%	568,99%
	11C	437,16%	235,23%	639,09%
	12C	471,70%	235,45%	707,94%
(1, 1, 1)	8C	327,67%	247,18%	408,16%
	9C	356,32%	236,15%	476,48%
	10C	384,95%	239,36%	539,49%
	11C	413,58%	227,00%	600,16%
	12C	442,20%	224,88%	659,53%

Tal seria de esperar, pois com o avançar do tempo e utilização da aeronave, esta irá necessitar progressivamente de mais horas de manutenção, o que demonstra que os modelos seleccionados conseguiram captar a dinâmica da série e prever, de forma mais ou menos satisfatória, a carga de trabalho associada a *checks* futuros.

Nas Figuras 4.5 a 4.12 podem observar-se os gráficos quer do ajustamento, quer das previsões efetuadas pelos 4 modelos ARIMA. O eixo das abcissas representa os vários *checks* e o eixo das ordenadas representa a carga de trabalho prevista, em percentagem, por motivos de confidencialidade, sendo o 100% representado pela carga média do *check* "C".




Figura 4.5 - Ajustamento do modelo (1, 1, 0)




Figura 4.6 - Previsões efetuadas pelo modelo (1, 1, 0)




Figura 4.7 - Ajustamento do modelo (1, 2, 0)




Figura 4.8 - Previsões efetuadas pelo modelo (1, 2, 0)




Figura 4.9 - Ajustamento do modelo (0, 2, 1)




Figura 4.10 - Previsões efetuadas pelo modelo (0, 2, 1)




Figura 4.11 - Ajustamento do modelo (1, 1, 1)




Figura 4.12 - Previsões efetuadas pelo modelo (1, 1, 1)

4.1.4 Diagnóstico do modelo

Para proceder ao diagnóstico do modelo, ou seja, para garantir que a informação foi corretamente extraída e que o modelo é válido, foram analisados os resíduos ou erros de previsão.

Elaborou-se então o histograma dos resíduos, onde também está representada a curva da distribuição normal. Na Figura 4.14 pode observar-se o histograma feito a partir dos valores dos resíduos obtidos para o modelo (1, 1, 0), que foi o considerado mais adequado.




Figura 4.13 - Histograma dos resíduos do modelo (1, 1, 0)

Através da análise da Figura 4.13, é evidente que os resíduos não se encontram normalmente distribuídos. Contudo, um fator que pode ter contribuído grandemente para esta ocorrência é o reduzido número de observações, tal como é demonstrado em Behnken & Draper (1972), que pode causar um comportamento anormal dos resíduos por se utilizarem poucas observações para estimar os parâmetros do modelo.

4.2 Aplicação dos modelos ARIMA considerando 8 pontos

Para realizar a análise considerando 8 pontos de dados, adotou-se um procedimento semelhante ao apresentado anteriormente.

4.2.1 Teste de estacionaridade

Novamente, começou-se por averiguar a estacionaridade da série, utilizando 8 pontos. Na Figura 4.14 está representada a ACF da série temporal completa. À semelhança do que se verificou na série temporal mais curta, não existem sazonalidade nem tendência evidentes.

Averiguou-se também a presença de tendência na série completa. Como se pode observar na Figura 4.15, esta não é evidente, verificando-se apenas uma ligeira tendência positiva a partir do *check* "5C".




Figura 4.14 - Função de autocorrelação para a amostra completa




Figura 4.15 - Gráfico do valor da carga média de trabalho associada a cada *check* para a amostra completa

Desta forma, realizou-se o teste de ADF para examinar a estacionaridade da série. Considerou-se um nível de significância de 5% e na Tabela 4.6 estão expostos o valor da estatística do teste ADF e o valor crítico.

Tabela 4.6 -Valor da estatística do teste ADF e valor crítico obtido para amostra completa

Estatística do teste ADF	Valor crítico	
1,37	$\alpha=0,05$	-3,48

De acordo com o nível de significância adotado, o valor da estatística do teste ADF (1,37) é superior ao valor crítico (-3,48). Posto isto, não se rejeita a hipótese nula, provando-se a não estacionaridade da série. Conclui-se também que o valor do parâmetro d irá ser diferente de zero, pois será necessário diferenciar a série para a tornar estacionária e viabilizar a aplicação dos modelos ARIMA.

4.2.2 Identificação do modelo

Para identificar possíveis valores para p e q , analisou-se, novamente, a ACF e estudou-se a PACF. Tais funções podem ser observadas nas Figuras 4.16 e 4.17.

Ao estudarem-se a ACF e a PACF, infere-se que o parâmetro p pode assumir o valor 1, uma vez que a PACF toma o valor 0 após o *lag* 1, havendo um corte, e os valores da ACF também diminuem após esse *lag*. No que diz respeito ao parâmetro q , deduz-se que este pode tomar o valor 2, uma vez que a ACF assume o valor 0 entre o *lag* 2 e 3. Seguidamente, testaram-se diferentes possibilidades para os valores dos parâmetros. Tal como foi considerado no caso da série temporal curta, ponderou-se que cada um destes poderia tomar valores entre 0 e 3, já que, apesar do facto de a série temporal ter mais um ponto, estes continuam a ser relativamente poucos, o que faria com que um modelo com valores de parametrização mais elevados fosse desajustado. Apenas d continua a não poder assumir o valor 0, pois é necessário diferenciar a série, de modo a torná-la estacionária.




Figura 4.16 - ACF da amostra completa




Figura 4.17 - PACF da amostra completa

Assim, obtiveram-se as mesmas 48 possibilidades, correspondentes às apresentadas na Tabela 4.3.

4.2.3 Ajustamento do modelo

Para realizar o ajustamento do modelo, utilizaram-se as mesmas medidas de desempenho (AICc e a maximização da função de *log-likelihood*) e de erro (DMA e EQM).

Das 48 possibilidades averiguadas, 7 destacaram-se, atingindo resultados positivos, contrastando com as restantes 41, cujo ajustamento foi impossível.

Na Tabela 4.7 encontram-se os valores obtidos para as duas medidas de desempenho e os dois tipos de erro, para as 7 melhores combinações:

Tabela 4.7 - Resultados obtidos para o AICc, *log-likelihood*, DMA e EQM considerando a amostra completa. Nota: melhores valores a negrito.

ARIMA (p, d, q)	AICc	$\log L(\theta, x_0)$	DMA	EQM
(1, 1, 0)	116,53	-56,19	2144,49	4794425,64
(0, 2, 0)	99,56	-48,70	3120,18	9735523,23
(1, 2, 0)	99,51	-47,68	2666,89	7119269,25
(2, 2, 0)	100,82	-47,34	2723,06	7415184,85
(1, 3, 0)	84,14	-39,10	2936,08	8637049,80
(2, 3, 0)	86,13	-39,99	3035,66	9239295,97
(0, 2, 1)	100,26	-48,05	2612,65	6854537,54

Através da análise da Tabela 4.7, verifica-se que o modelo com o menor valor de AICc é o (1, 3, 0), correspondendo a 84,14, e apresenta também o valor mais elevado de *log-likelihood*, -39,10. No que toca às medidas de erro, constata-se que o modelo (1, 1, 0) possui os menores valores de ambas as medidas, apresentando, no entanto, valores mais elevados nas medidas de desempenho. Adotando a mesma lógica aplicada aquando da análise da série temporal

mais curta, isto é, dando mais ênfase aos valores das medidas de erro, pode afirmar-se que o melhor modelo é o (1, 1, 0).

Na Tabela 4.8 estão expostos os valores previstos para a carga de trabalho, em percentagem, por motivos de confidencialidade, sendo o 100% representado pela carga média do *check* "C". As previsões foram efetuadas até ao *check* 12C, tal como foi feito em Dinis et al. (2022), considerando um intervalo de confiança de 95%:

Analogamente ao que se verificou nas previsões efetuadas tendo em conta a série temporal com 7 pontos, observa-se uma tendência crescente, ao longo dos *checks*, na carga de trabalho. Este facto demonstra, mais uma vez, que os modelos descritos pelas parametrizações apresentadas na Tabela 4.8 tiveram a capacidade de captar a dinâmica dos dados e realizar previsões que vão de encontro ao que seria expectável, no que diz respeito à evolução da carga de trabalho associada às várias intervenções de manutenção.

Nas Figuras 4.18 a 4.31 podem observar-se os gráficos de ajustamento das várias combinações de parâmetros, bem como as previsões realizadas. O eixo das abcissas representa os vários *checks* e o eixo das ordenadas representa os valores da carga de trabalho, em percentagem, por motivos de confidencialidade, sendo o 100% representado pela carga média do *check* "C".

Tabela 4.8 -Valores previstos da carga de trabalho associada a cada *check* e limites inferiores e superiores, considerando um intervalo de confiança de 95% e a amostra completa

ARIMA (p, d, q)	Check	Previsão	Limite inferior	Limite superior
(1, 1, 0)	9C	473,70%	375,91%	571,49%
	10C	519,33%	329,98%	708,67%
	11C	549,35%	270,66%	828,04%
	12C	569,10%	206,26%	931,95%
(0, 2, 0)	9C	509,72%	402,43%	617,02%
	10C	615,08%	375,17%	854,99%
	11C	720,42%	318,99%	1221,88%
	12C	825,77%	238,13%	1413,45%
(1, 2, 0)	9C	484,75%	398,84%	570,66%
	10C	578,83%	427,40%	730,26%
	11C	665,40%	422,95%	907,83%
	12C	756,08%	415,09%	1097,07%
(2, 2, 0)	9C	483,66%	404,59%	555,36%
	10C	587,51%	435,61%	739,41%
	11C	673,83%	408,99%	938,00%
	12C	774,65%	388,12%	1161,19%
(1, 3, 0)	9C	488,63%	395,85%	581,41%
	10C	611,31%	394,96%	827,66%
	11C	719,27%	280,18%	1158,31%
	12C	859,94%	127,32%	1592,54%
(2, 3, 0)	9C	493,54%	643,48%	586,72%
	10C	619,85%	406,39%	833,29%
	11C	737,03%	307,35%	1166,76%
	12C	885,26%	171,73%	1598,78%
(0, 2, 1)	9C	486,87%	391,70%	582,05%
	10C	569,38%	393,97%	744,79%
	11C	651,88%	386,23%	917,54%
	12C	734,40%	368,45%	1100,33%




Figura 4.18 - Ajustamento do modelo (1, 1, 0)




Figura 4.19 - Previsões efetuadas pelo modelo (1, 1, 0)




Figura 4.20 - Ajustamento do modelo (0, 2, 0)




Figura 4.21 - Previsões efetuadas pelo modelo (0, 2, 0)




Figura 4.22 - Ajustamento do modelo (1, 2, 0)




Figura 4.23 - Previsões efetuadas pelo modelo (1, 2, 0)




Figura 4.24 - Ajustamento do modelo (2, 2, 0)




Figura 4.25 - Previsões efetuadas pelo modelo (2, 2, 0)




Figura 4.26 - Ajustamento do modelo (1, 3, 0)




Figura 4.27 - Previsões efetuadas pelo modelo (1, 3, 0)




Figura 4.28 - Ajustamento do modelo (2, 3, 0)




Figura 4.29 - Previsões efetuadas pelo modelo (2, 3, 0)




Figura 4.30 - Ajustamento do modelo (0, 2, 1)




Figura 4.31 - Previsões efetuadas pelo modelo (0, 2, 1)

4.2.4 Diagnóstico do modelo

Para se efetuar o diagnóstico do modelo, adotou-se a mesma abordagem aplicada à série temporal curta: a análise do histograma dos resíduos. Na Figura 4.32 pode observar-se o histograma dos resíduos, feito a partir dos valores obtidos para o modelo (1, 1, 0), considerado o modelo que providenciou os resultados mais satisfatórios.




Figura 4.32 - Histograma dos resíduos do modelo (1, 1, 0)

Tal como se observou anteriormente, constata-se que os resíduos não estão normalmente distribuídos. Novamente, esta ocorrência pode ser justificada pelo número insuficiente de observações.

4.3 Resultados

Neste subcapítulo serão evidenciados os resultados obtidos através da realização do estudo descrito ao longo dos capítulos anteriores. Será, paralelamente, efetuada uma apreciação e comparação entre os resultados obtidos com a aplicação dos modelos de AE e os resultados providenciados pelos modelos ARIMA escolhido.

4.3.1 Resultados obtidos com a aplicação do AE

No que diz respeito aos modelos de AE, estes foram aplicados considerando 7 pontos de dados, como foi feito no trabalho realizado por Dinis et al. (2022), e utilizando a série completa, composta por 8 pontos. Em ambos os casos foram desconsiderados os valores identificados como *outliers*. Nas Tabelas 4.9 e 4.10 podem ser observados os resultados obtidos com a aplicação dos vários modelos de AE.

Tabela 4.9 - Resultados obtidos, para o AE, após remoção dos *outliers* para o AICc, *log-likelihood*, DMA e EQM, considerando 7 pontos de dados. Nota: melhores valores a negrito.

Modelo	AICc	$\log L(\theta, x_0)$	DMA	EQM
SES	1153,04	-574,48	803,77	1259998,59
HLM	1137,35	-564,55	755,08	1041670,45
AHW	1134,94	-558,47	713,99	915718,40
MHW	1131,01	-555,91	689,99	851687,68

Tabela 4.10 - Resultados obtidos, para o AE, após remoção dos *outliers* para o AICc, *log-likelihood*, DMA e EQM, considerando 8 pontos de dados (série completa). Nota: melhores valores a negrito.

Modelo	AICc	$\log L(\theta, x_0)$	DMA	EQM
SES	1177,16	-586,54	898,31	1439005,03
HLM	1162,60	-577,18	921,42	1479844,02
AHW	1158,66	-569,75	708,24	880192,80
MHW	1154,23	-567,53	682,46	808294,53

Após a remoção dos *outliers*, constatou-se um incremento nos valores do AICc e *log-likelihood*, tendo os valores de ambas as medidas de erro diminuído nos modelos AHW e MHW e aumentado no SES e HLM. Apesar disto, e tal como ocorreu no trabalho de Dinis et. al (2022), o modelo de AE que melhor modela e descreve o comportamento dos dados continua a ser o MHW, possuindo o menor valor, quer das medidas de desempenho, quer das medidas de erro.

Na Tabela 4.11 são apresentadas as previsões da carga de trabalho, em percentagem, por motivos de confidencialidade, sendo o 100% representado pela carga média do *check* "C", associadas aos *checks* "8C" a "12C, obtidas pela aplicação do modelo de AE que teve o melhor desempenho (MHW), considerando a série temporal curta.

Tabela 4.11 - Carga de trabalho prevista, através da aplicação do modelo MHW, para os *checks* "8C" a "12C", considerando a série curta

<i>Check</i>	Previsão
8C	374,11%
9C	414,92%
10C	666,83%
11C	744,85%
12C	867,24%

Na Tabela 4.12 estão presentes as previsões da carga de trabalho, também em percentagem, à semelhança do processo adotado para a Tabela 4.11, associadas aos *checks* "9C" a "12C, obtidas pela aplicação do modelo de AE que teve o melhor desempenho (MHW), considerando a série temporal completa.

Tabela 4.12 - Carga de trabalho prevista, através da aplicação do modelo MHW, para os *checks* "8C" a "12C", considerando a série completa

<i>Check</i>	Previsão
9C	415,57%
10C	672,09%
11C	753,23%
12C	881,49%

Como seria de esperar, com o avançar da idade da aeronave e com o seu uso, é esperado que com o passar do tempo a carga de trabalho associada aos vários *checks* vá aumentando (Mofokeng, 2023). Tal facto pode ser verificado ao observarem-se os valores das Tabelas 4.11 e 4.12, demonstrando que estes modelos conseguem captar e descrever o comportamento da série, ao efetuarem previsões que seguem o padrão esperado.

4.3.2 Comparação dos resultados obtidos com a aplicação dos modelos de AE e ARIMA

Nas Tabelas 4.13 e 4.14 podem observar-se os valores das medidas de desempenho e de erro dos modelos ARIMA e de AE que providenciaram os melhores resultados, considerando, quer a série temporal curta, quer série temporal completa, respetivamente.

Tabela 4.13 - Valores das medidas de desempenho e erro para o modelo ARIMA (1, 1, 0) e MHW, considerando 7 pontos. Nota: melhores valores a negrito.

Modelo	AICc	$\log L(\theta, x_0)$	DMA	EQM
ARIMA (1, 1, 0)	99,29	-47,57	888,08	922877,42
MHW	1131,01	-555,91	689,99	851687,68

Tabela 4.14 - Valores das medidas de desempenho e erro para o modelo ARIMA (1, 1, 0) e MHW, considerando 8 pontos (série completa). Nota: melhores valores a negrito.

Modelo	AICc	$\log L(\theta, x_0)$	DMA	EQM
ARIMA (1, 1, 0)	116,53	-56,19	2144,49	4794425,64
MHW	1154,23	-567,53	682,46	808294,53

Atentando na Tabela 4.13, observa-se que o modelo ARIMA (1, 1, 0) apresenta melhores valores nas medidas de desempenho, tendo um valor de 99,29, para o AICc, enquanto que o MHW possui um valor de 1131,01, demonstrando que o primeiro modelo representa mais corretamente os dados. Adicionalmente, o modelo ARIMA (1, 1, 0) tem também um maior valor da *log-likelihood* (-47,57) do que o modelo MHW (-555,91), mostrando que o modelo ARIMA se adequa melhor aos dados. Todavia, o modelo ARIMA possui valores mais elevados no que diz respeito às medidas de erro, 888,08 para o DMA e 922877,42 para o EQM, ao passo que o modelo MHW apresenta um valor de 689,99 para o DMA e 851687,68 para o EQM.

Observando agora a Tabela 4.14, tal como ocorreu no caso da série temporal de 7 pontos, o modelo ARIMA (1, 1, 0) destaca-se do modelo MHW no que toca às medidas de desempenho, uma vez que estas possuem valores relativamente melhores. Enquanto que o modelo MHW tem um valor de AICc de 1154,23, o modelo ARIMA apenas toma o valor de 116,53. O mesmo acontece no caso da *log-likelihood*, em que no modelo ARIMA (1, 1, 0) assume o valor de -59,19 enquanto que no MHW esta assume o valor de -567,53. No que toca às medidas de erro, o modelo ARIMA (1, 1, 0) apresenta um valor de 2144,49, para o DMA, e 4794425,64, para o EQM.

4.3.3 Comparação dos resultados obtidos pelos modelos de AE com os modelos ARIMA equivalentes

Para complementar a análise feita em 4.3.2, considerou-se que seria também pertinente comparar os resultados obtidos com a aplicação dos modelos de AE, se possível, com aqueles obtidos através da aplicação dos modelos ARIMA homólogos.

Como é descrito em Gardner (2006) é possível estabelecer uma equivalência entre os modelos de AE e o modelos ARIMA. Na Tabela 4.15 estão expressos os modelos de AE, empregues por Dinis et al. (2022), e os respetivos modelos ARIMA equivalentes.

Tabela 4.15 - Modelos de AE, utilizados por Dinis et al. (2022), e modelos ARIMA equivalentes

Modelo de AE	Modelo ARIMA
SES	(0, 1, 1)
HLM	(0, 2, 2)
AHW	SARIMA (p, d, q)(P, D, Q) _s
MHW	SARIMA (p, d, q)(P, D, Q) _s

Ao analisar-se a Tabela 4.15, infere-se que nenhum dos modelos ARIMA selecionados, quer para a série temporal de 7 pontos, quer para a série temporal de 8 pontos, corresponde aos modelos ARIMA equivalentes aos modelos de AE utilizados. Em ambas as séries temporais, verificou-se que o modelo (0, 1, 1) não se ajustava, uma vez que as previsões efetuadas tomavam todas o mesmo valor. Relativamente ao modelo (0, 2, 2), observou-se que, após a diferenciação, os valores restantes não eram suficientes para permitir o ajuste do modelo, dado o valor do parâmetro q. Finalmente, também não foi possível comparar os modelos ARIMA equivalentes aos modelos AHW e MHW, uma vez que não há uma sazonalidade clara na série temporal em estudo.

5 CONCLUSÃO

Neste capítulo serão enunciadas as principais conclusões obtidas por meio da realização do estudo descrito ao longo dos capítulos anteriores. Enumerar-se-ão também as limitações encontradas aquando da aplicação dos modelos ARIMA, na tentativa de solucionar o problema associado ao planeamento da capacidade no setor aeronáutico. Será também discutida a aplicabilidade destes modelos para séries temporais curtas e qual dos modelos, ARIMA ou AE, melhor se adequa. Finalmente, apresentar-se-ão eventuais possíveis trabalhos de pesquisa.

5.1 Conclusões gerais

O objetivo principal desta dissertação passou por averiguar qual das técnicas de previsão, modelos de AE ou modelos ARIMA, descreve e prevê mais corretamente o comportamento de uma série temporal, composta pelas cargas de trabalho médias associadas a várias intervenções de manutenção, nomeadamente, *checks* do tipo "C".

No que diz respeito aos modelos de AE, o MHW foi superior a qualquer uma das outras variações deste tipo de modelos, tanto considerando a série temporal curta, como a completa. Já nos modelos ARIMA, concluiu-se que o modelo (1, 1, 0) foi aquele que melhor descreveu a série composta por 7 pontos e a série composta por 8 pontos. Verificou-se que estes modelos efetuaram previsões que foram de encontro ao que seria de esperar na prática, ou seja, houve, com o passar do tempo, um aumento da carga de trabalho de manutenção associada aos diversos *checks*. Contudo, apesar dos modelos ARIMA possuírem melhores valores nas medidas de desempenho, obtiveram valores mais elevados nas medidas de erro comparativamente ao modelo MHW, o que demonstra que, embora os modelos ARIMA se tenham ajustado de forma mais correta à série temporal em causa, as previsões efetuadas são menos precisas. Desta forma, ainda que forneçam resultados satisfatórios, efetuam previsões acompanhadas de um erro maior, mostrando que os modelos de AE têm um desempenho superior quando se trata da previsão da carga de trabalho.

5.2 Limitações encontradas

A principal limitação encontrada prendeu-se no reduzido número de pontos, apesar de a série possuir 171 observações. Este facto limitou a quantidade de possibilidades de parâmetros que puderam ser testadas, uma vez que os parâmetros se tornavam rapidamente desajustados, principalmente após a diferenciação da série, pois por cada diferenciação efetuada era perdido um grau de liberdade, correspondente a um ponto na série temporal. Adicionalmente, tal dificultou ainda o ajustamento do modelo, uma vez que, para grande parte das parametrizações analisadas, a linguagem de programação *Python* era incapaz de convergir para um único valor para a *log-likelihood*.

5.3 Trabalhos futuros

Com a realização da presente dissertação, pretendeu-se contribuir para a discussão que existe na comunidade científica sobre qual das técnicas de previsão, modelos de alisamento exponencial ou modelos ARIMA, melhor se adequa a determinadas situações. Neste caso, o objetivo passou por apurar qual dos modelos melhor se aplica ao problema do planeamento da capacidade na manutenção aeronáutica, causado, maioritariamente, pela incerteza associada à manutenção não planeada.

Durante a sua elaboração, identificaram-se algumas lacunas que poderão vir a servir de oportunidades para trabalhos de investigação futuros. A primeira oportunidade passa por tentar aumentar o volume de dados disponíveis, quer seja através da recolha de mais observações, quer seja tornando a série temporal mais longa. De notar que esta última seria conseguida caso se utilizasse outro modelo de aeronave, uma vez que os 8 pontos já cobrem toda a vida útil do tipo de aeronave em causa. Caso tal se consiga, constituiria ainda um trabalho futuro a aplicação de transformações aos dados, como a logarítmica, por exemplo, de modo a tentar garantir a normalidade dos resíduos. De notar que tal não foi implementado, derivado do reduzido número de resíduos. Finalmente, a aplicação e experimentação com outras técnicas de previsão também pode constituir um trabalho interessante e uma contribuição significativa. Estas podem incluir as analogias históricas e o julgamento de especialistas.

REFERÊNCIAS BIBLIOGRÁFICAS

- Alsaedi, Y., & Tularam, G. (2021, December 16). The use of exponential smoothing (ES), Holts and Winter (HW) and ARIMA models in electricity price analysis. *MODSIM2021, 24th International Congress on Modelling and Simulation*. 24th International Congress on Modelling and Simulation. <https://doi.org/10.36334/modsim.2021.A1.alsaedi>
- Atli, O., & Kahraman, C. (2012). Aircraft Maintenance Planning Using Fuzzy Critical Path Analysis: *International Journal of Computational Intelligence Systems*, 5(3), 553. <https://doi.org/10.1080/18756891.2012.696920>
- Bagheri Garmarudi, A., Ghasemi, K., Mozaffari, F., Khorani, M., & Khanmohammadi, M. (2015). *Most common techniques of outlier detection* (pp. 253–274).
- Behnken, D. W., & Draper, N. R. (1972). Residuals and Their Variance Patterns. *Technometrics*, 14(1) (pp. 101–111). <https://doi.org/10.1080/00401706.1972.10488887>
- Ben-Daya, M., Duffuaa, S. O., Raouf, A., Knezevic, J., & Ait-Kadi, D. (Eds.). (2009). *Handbook of Maintenance Management and Engineering*. Springer London. <https://doi.org/10.1007/978-1-84882-472-0>
- Chen, P., Yuan, H., & Shu, X. (2008). Forecasting Crime Using the ARIMA Model. *2008 Fifth International Conference on Fuzzy Systems and Knowledge Discovery*, (pp. 627–630). <https://doi.org/10.1109/FSKD.2008.222>
- Dinis, D., Barbosa-Póvoa, A., & Teixeira, Â. P. (2019). A supporting framework for maintenance capacity planning and scheduling: Development and application in the aircraft MRO industry. *International Journal of Production Economics*, 218, (pp. 1–15). <https://doi.org/10.1016/j.ijpe.2019.04.029>
- Dinis, D., Barbosa-Póvoa, A., & Teixeira, Â. P. (2022). Enhancing capacity planning through forecasting: An integrated tool for maintenance of complex product systems. *International Journal of Forecasting*, 38(1), (pp. 178–192). <https://doi.org/10.1016/j.ijforecast.2021.05.003>
- Duffuaa, S. O., & Alfares, H. K. (2015). *Methods and Approaches for Maintenance Capacity Planning*. 2015 International Conference on Industrial Engineering and Operations Management (pp. 1674-1677)
- Duffuaa, S. O., & Raouf, A. (2015). *Planning and Control of Maintenance Systems: Modelling and Analysis*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-19803-3>

- Ertogral, K., & Öztürk, F. S. (2019). An integrated production scheduling and workforce capacity planning model for the maintenance and repair operations in airline industry. *Computers & Industrial Engineering*, 127, (pp. 832–840). <https://doi.org/10.1016/j.cie.2018.11.022>
- Falatouri, T., Brandtner, P., Nasser, M., & Darbanian, F. (2023). Maintenance Forecasting Model for Geographically Distributed Home Appliances Using Spatial-Temporal Networks. *Procedia Computer Science*, 219, (pp. 495–503). <https://doi.org/10.1016/j.procs.2023.01.317>
- Flores, J. H. F., Engel, P. M., & Pinto, R. C. (2012). Autocorrelation and partial autocorrelation functions to improve neural networks models on univariate time series forecasting. *The 2012 International Joint Conference on Neural Networks (IJCNN)*, (pp. 1–8). <https://doi.org/10.1109/IJCNN.2012.6252470>
- Fomby, T. (2008). *SMOOTHING MODELS*.
- Gardner, E. S. (2006). Exponential smoothing: The state of the art—Part II. *International Journal of Forecasting*, 22(4), (pp. 637–666). <https://doi.org/10.1016/j.ijforecast.2006.03.005>
- Georgiev, K., & Vachev, N. (2022). *Predicting the unscheduled workload for an aircraft maintenance work package*. 020001. <https://doi.org/10.1063/5.0104651>
- Gu, J., Zhang, G., & Li, K. W. (2015). Efficient aircraft spare parts inventory management under demand uncertainty. *Journal of Air Transport Management*, 42, (pp. 101–109). <https://doi.org/10.1016/j.jairtraman.2014.09.006>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), (pp. 679–688). <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Hyndman, R. J., Koehler, A. B., Snyder, R. D., & Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, 18(3), (pp. 439–454). [https://doi.org/10.1016/S0169-2070\(01\)00110-8](https://doi.org/10.1016/S0169-2070(01)00110-8)
- ICAO. (2019). The World of Air Transport in 2019. *Consultado Em: 08/02/2024*. <https://www.icao.int/annual-report-2019/Pages/the-world-of-air-transport-in-2019.aspx#:~:text=Accord%20to%20ICAO%E2%80%99s%20preliminary%20compilation%20of%20annual%20global,million%20in%202019%2C%20a%201.7%20per%20cent%20increase>
- ICAO. (2020). The World of Air Transport in 2020. *Consultado em: 08/02/2024*. <https://www.icao.int/annual-report-2020/Pages/the-world-of-air-transport-in-2020.aspx>
- Jain, A., Sukhdeve, T., Gadia, H., Sahu, S. P., & Verma, S. (2021). COVID19 Prediction using Time Series Analysis. *2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS)*, (pp. 1599–1606). <https://doi.org/10.1109/ICAIS50930.2021.9395877>
- Jimenez-Cortadi, A., Boto, F., Irigoien, I., Sierra, B., & Rodriguez, G. (2018). Time Series Forecasting in Turning Processes Using ARIMA Model. In J. Del Ser, E. Osaba, M. N. Bilbao, J. J. Sanchez-Medina, M. Vecchio, & X.-S. Yang (Eds.), *Intelligent Distributed Computing XII* (Vol. 798, (pp. 157–166). Springer International Publishing. https://doi.org/10.1007/978-3-319-99626-4_14
- Kala, M., Lalis, A., & Vittek, P. (2019). Optimizing Calculation of Maintenance Revision Times in Maintenance Repair Organizations. *2019 International Conference on Military Technologies (ICMT)*, (pp. 1–6). <https://doi.org/10.1109/MILTECHS.2019.8870132>
- Lah, M. S. C., Arbaiy, N., & Lin, P.-C. (2022). *An improved ARIMA fitting procedure*. 040005. <https://doi.org/10.1063/5.0104053>

- Land, K. C. (2015). Forecasting. In J. D. Wright (Ed.), *International Encyclopedia of the Social & Behavioral Sciences (Second Edition)* (Second Edition, pp. 316–323). Elsevier. <https://doi.org/10.1016/B978-0-08-097086-8.10544-6>
- Lee, C.-K., Song, H.-J., & Mjelde, J. W. (2008). The forecasting of International Expo tourism using quantitative and qualitative techniques. *Tourism Management*, 29(6), (pp. 1084–1098). <https://doi.org/10.1016/j.tourman.2008.02.007>
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: Results, conclusions and implications. *International Journal of Forecasting*, 16(4), (pp. 451–476). [https://doi.org/10.1016/S0169-2070\(00\)00057-1](https://doi.org/10.1016/S0169-2070(00)00057-1)
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). The M4 Competition: Results, findings, conclusion and way forward. *International Journal of Forecasting*, 34(4), (pp. 802–808). <https://doi.org/10.1016/j.ijforecast.2018.06.001>
- Márquez, A. C. (Ed.). (2007). Models to Deal with Maintenance Capacity Planning. In *The Maintenance Management Framework: Models and Methods for Complex Systems Maintenance* (pp. 157–184). Springer. https://doi.org/10.1007/978-1-84628-821-0_12
- Mofokeng, T. (2023). Analysis of aircraft maintenance processes and cost. *Procedia CIRP*. <https://doi.org/10.1016/j.procir.2020.01.115>
- Montgomery, D. C. (2015). *Introduction to Time Series Analysis and Forecasting*.
- Muhammad Ali, P., & Faraj, R. (2014). Data Normalization and Standardization: A Technical Report. *Mach Learn Tech Rep*, 1(1), (pp. 1–6). <https://doi.org/10.13140/RG.2.2.28948.04489>
- Nurchahyo, R., Darmawan, D., Jannis, Y., Kurniati, A., & Habiburrahman, M. (2018). Maintenance Planning Key Process Area: Case Study at Oil Gas Industry in Indonesia. *2018 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, (pp. 1704–1708). <https://doi.org/10.1109/IEEM.2018.8607527>
- Nyabwanga, R. (2016). Application of Seasonal Autoregressive Integrated MOving Average (SARIMA) to model and Forecast Water Demand in Kisumu City, Kenya. *International Journal of Ecological Economics and Statistics*, 37.
- Owen, C. A., Dick, G., & Whigham, P. A. (2022). Standardization and Data Augmentation in Genetic Programming. *IEEE Transactions on Evolutionary Computation*, 26(6), (pp. 1596–1608). <https://doi.org/10.1109/TEVC.2022.3160414>
- Rosales, L. J. S., Yang, J.-B., & Chen, Y.-W. (2014). *Analysing delays and disruptions in Aircraft Heavy Maintenance*.
- Rubio, L., Gutiérrez-Rodríguez, A. J., & Forero, M. G. (2021). EBITDA Index Prediction Using Exponential Smoothing and ARIMA Model. *Mathematics*, 9(20), (p. 2538). <https://doi.org/10.3390/math9202538>
- Samaranayake, P., & Kiridena, S. (2012). Aircraft maintenance planning and scheduling: An integrated framework. *Journal of Quality in Maintenance Engineering*, 18(4), (pp. 432–453). <https://doi.org/10.1108/13552511211281598>
- Sangwan, K. S., & Herrmann, C. (Eds.). (2020). *Enhancing Future Skills and Entrepreneurship: 3rd Indo-German Conference on Sustainability in Engineering*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-44248-4>

- Silveira, A. G., De Mattos, V. L. D., Nakamura, L. R., Amaral, M. C., & Konrath, A. C. (2022). Seleção de defasagens em testes de raiz unitária: Uma revisão de literatura. *Exacta*. <https://doi.org/10.5585/exactaep.2022.22061>
- SKYbrary. (n.d.). Maintenance Steering Group-3 (MSG-3). *SKYbrary*. Retrieved March 17, 2024, from <https://skybrary.aero/articles/maintenance-steering-group-3-msg-3>
- Stadtler, H. (2005). *11 Purchasing and Material Requirements Planning* (pp. 215–227). https://doi.org/10.1007/3-540-24814-5_12
- Statista. (2022). Number of scheduled passengers boarded by the global airline industry from 2004 to 2022. *Consultado em: 08/02/2024*. <https://www.statista.com/statistics/564717/airline-industry-passenger-traffic-globally/#:~:text=In%202021%2C%20due%20to%20the%20coronavi-rus%20pandemic%2C%20the,industry%20amounted%20to%20just%20over%202.2%20bil-lion%20people.>
- Tseng, F.-M., Yu, H.-C., & Tzeng, G.-H. (2002). Combining neural network model with seasonal time series ARIMA model. *Technological Forecasting and Social Change*, 69(1) (pp. 71–87). [https://doi.org/10.1016/S0040-1625\(00\)00113-X](https://doi.org/10.1016/S0040-1625(00)00113-X)
- Van Opheusden, B., Acerbi, L., & Ma, W. J. (2020). Unbiased and efficient log-likelihood estimation with inverse binomial sampling. *PLOS Computational Biology*, 16(12). <https://doi.org/10.1371/journal.pcbi.1008483>
- Yang, Y., Zheng, H., & Zhang, R. (2017). Prediction and analysis of aircraft failure rate based on SARIMA model. *2017 2nd IEEE International Conference on Computational Intelligence and Applications (ICCI)* (pp. 567–571). <https://doi.org/10.1109/CIAPP.2017.8167281>
- Zhang, X., Yu, Y., Xiong, F., & Luo, L. (2020). Prediction of Daily Blood Sampling Room Visits Based on ARIMA and SES Model. *Computational and Mathematical Methods in Medicine*, 2020 (pp. 1–11). <https://doi.org/10.1155/2020/1720134>
- Zijm, H., & Regattieri, A. (2019a). Manufacturing Planning and Control Systems. In H. Zijm, M. Klumpp, A. Regattieri, & S. Heragu (Eds.), *Operations, Logistics and Supply Chain Management* (pp. 251–271). Springer International Publishing. https://doi.org/10.1007/978-3-319-92447-2_12
- Zijm, H., & Regattieri, A. (2019b). Manufacturing Planning and Control Systems. In H. Zijm, M. Klumpp, A. Regattieri, & S. Heragu (Eds.), *Operations, Logistics and Supply Chain Management* (pp. 251–271). Springer International Publishing. https://doi.org/10.1007/978-3-319-92447-2_12
- Zijm, H., & Schutten, M. (2019). Advanced Production Planning and Scheduling Systems. In H. Zijm, M. Klumpp, A. Regattieri, & S. Heragu (Eds.), *Operations, Logistics and Supply Chain Management* (pp. 417–439). Springer International Publishing. https://doi.org/10.1007/978-3-319-92447-2_19



