



Lisbon School
of Economics
& Management
Universidade de Lisboa

MESTRADO
CONTABILIDADE, FISCALIDADE E FINANÇAS
EMPRESARIAIS

TRABALHO FINAL DE MESTRADO
DISSERTAÇÃO

APLICAÇÃO DE MACHINE LEARNING NA PREVISÃO DE DESVIOS
E CONTROLO ORÇAMENTAL NA FORÇA AÉREA PORTUGUESA

PEDRO DE OLIVEIRA PALMAS

OUTUBRO – 2023



Lisbon School
of Economics
& Management
Universidade de Lisboa

MESTRADO
CONTABILIDADE, FISCALIDADE E FINANÇAS
EMPRESARIAIS

TRABALHO FINAL DE MESTRADO
DISSERTAÇÃO

**APLICAÇÃO DE MACHINE LEARNING NA PREVISÃO DE DESVIOS
E CONTROLO ORÇAMENTAL NA FORÇA AÉREA PORTUGUESA**

PEDRO DE OLIVEIRA PALMAS

ORIENTAÇÃO:

PROFESSOR DOUTOR ANTÓNIO CARLOS DE OLIVEIRA SAMAGAIO
MAJOR ELSA DE BRITO ALVES PEREIRA EVANGELISTA

OUTUBRO – 2023

*“The difficulty lies not so
much in developing new
ideas as in escaping from old
ones.”*

- John Maynard Keynes

LISTA DE ABREVIATURAS E ACRÓNIMOS

- AP – Administração Pública.
- CAPO – Ciclo Anual de Planeamento Orçamental.
- CEMFA – Chefe do Estado-Maior da Força Aérea.
- CIO – *Chief Information Officer*.
- DARPA – *Defense Advanced Research Projects Agency*.
- DFFA – Direção de Finanças da Força Aérea.
- DIVPLAN – Divisão de Planeamento.
- DL – *Deep Learning*.
- DNN – *Deep Neural Networks*.
- EA – Elemento de Ação.
- EMGFA – Estado-Maior General das Forças Armadas.
- ES – *Expert System*.
- EY – *Ernst & Young*.
- FAP – Força Aérea Portuguesa.
- FN – Negativo Falso.
- FND – Forças Nacionais Destacadas.
- FP – Positivo Falso.
- IA – Inteligência Artificial.
- IDC – *International Data Corporation*.
- KPMG – *Klynveld Peat Mrwick Goerdeler*.
- LBCP – Lei de Bases da Contabilidade Pública.
- LOFA – Lei Orgânica da Força Aérea.
- MDN – Ministério da Defesa Nacional.
- ML – *Machine Learning*.

NN – *Neural Network*.

NPD – Número de Processo de Despesa.

OE – Orçamento de Estado.

PAA – Plano Anual de Atividades.

PCME – Plano de Cursos e Missões no Estrangeiro.

PNL – Programação Neurolinguística.

PWC – *PricewaterhouseCoopers*.

RAA – Relatório Anual de Atividades.

RPA – *Robotic Process Automation*.

RFA – Regulamento da Força Aérea.

SIAFP – Serviço de Inspeção e Auditoria Financeira e Patrimonial.

SIG – Sistema Integrado de Gestão.

TC – Tribunal de Contas.

TN – Negativo Verdadeiro.

TP – Positivo Verdadeiro.

UOS – Unidades/Órgãos/Serviços.

XAI – Inteligência Artificial Explicável.

ABSTRACT

The world has been experiencing paradigm shifts, with emerging technologies becoming an ever more formidable reality. Nowadays, organizations worldwide must stay current and aligned with this evolution in terms of their processes, harnessing artificial intelligence (AI) techniques as a resource. Only by doing so can they hope to maintain a competitive edge. Auditing plays a crucial role in comprehending and scrutinizing companies' processes to identify any inconsistencies or irregularities in their financial records. In this regard, the convergence of auditing and AI has been gaining prominence, particularly within major auditing firms.

The Portuguese Air Force (PAF), recognizing the impact of emerging trends, needs to determine the most effective ways where to apply AI, and one of those areas is internal control. As an integral part of Central Administration, it bears the responsibility of being accountable and therefore necessitates stringent, cohesive, and transparent internal control. With this objective in mind, the utilization of AI, particularly in budgetary control, offers an enticing opportunity for exploring the implementation of new technologies to address or enhance certain existing deficiencies. The results of the study show the usefulness of machine learning algorithms in predicting the occurrence of deviations and their contribution to budgetary control.

KEYWORDS: Artificial Intelligence; Machine Learning; Supervised Learning; Internal Audit; Portuguese Armed Forces; and Budget.

JEL CODES: C38; C53; C61; H61; H83; and M42.

RESUMO

O mundo tem vindo a sofrer alterações de paradigmas, sendo as tecnologias emergentes uma realidade cada vez mais desafiante. Atualmente, as organizações em todo o mundo devem manter-se atualizadas e alinhadas com essa evolução, a nível dos seus processos e utilizando técnicas de inteligência artificial (IA) como recurso, pois só assim poderão continuar a ambicionar ter vantagem competitiva. A função da auditoria passa por perceber e analisar os processos das entidades, por forma a detetar se existem inconformidades ou irregularidades nas suas contas. Nesse sentido, a conjugação entre auditoria e IA tem vindo a ganhar significância, sobretudo, nas principais firmas de auditoria.

A Força Aérea Portuguesa (FAP), sentindo a repercussão das tendências emergentes, deverá perceber em que pontos se poderá potenciar na IA, sendo o controlo interno uma delas. Inserida nos órgãos da Administração Central, tem o dever de prestar contas, e por isso, deverá ter um controlo interno rigoroso, coerente e transparente. Nessa senda, a implementação de IA, especificamente, no controlo orçamental, torna-se um terreno convidativo ao estudo da aplicação das novas tecnologias, na tentativa de resolver ou melhorar algumas lacunas existentes. Os resultados do estudo evidenciam a utilidade dos algoritmos de *machine learning* na previsão da ocorrência de desvios e no seu contributo ao controlo orçamental.

PALAVRAS-CHAVE: Inteligência Artificial; *Machine Learning*; Aprendizagem Supervisionada; Auditoria Interna; Forças Armadas Portuguesas; e Orçamento.

CÓDIGOS JEL: C38; C53; C61; H61; H83; e M42.

Índice

Lista de Abreviaturas e Acrónimos	i
Abstract.....	iii
Resumo	iv
Índice	v
Lista de Figuras	vii
Lista de Tabelas	vii
Lista de Anexos	vii
Agradecimentos	viii
1. Introdução	1
2. Revisão de Literatura	3
2.1. Conceito de Inteligência Artificial.....	3
2.2. Inteligência Artificial em Auditoria.....	5
2.3. Tipologias de Inteligência Artificial.....	8
2.4. Machine Learning	10
2.5. Aprendizagem Supervisionada	13
2.5.1. Algoritmos de Aprendizagem Supervisionada	14
3. Contexto de Investigação.....	15
3.1. Quadro Normativo Geral	15
3.2. Envolvente da Gestão Orçamental.....	18
3.2. Objeto de Estudo	19
4. Metodologia e Amostra	21
4.1. Método de Recolha de Dados.....	21
4.2. Descrição da Amostra.....	22
4.3. Método de Análise.....	23

5. Análise de Resultados.....	25
5.1. Cenário 1 da Previsão	25
5.2. Cenário 2 da Previsão	27
5.3. Implicações na Gestão	30
6. Conclusões, Limitações e Pistas de Investigação Futura.....	31
6.1. Conclusões.....	31
6.2. Limitações	34
6.3. Pistas de Investigação Futura.....	35
Referências	36
Anexos	45

LISTA DE FIGURAS

FIGURA 1 – Relação entre os três níveis de IA	10
FIGURA 2 – Representação <i>Confusion Matrix</i>	24

LISTA DE TABELAS

TABELA I – Resultados de Performance Cenário 1	25
TABELA II – Resultados de Performance Cenário 2.....	27
TABELA III – Peso Explicativo dos EA.....	29

LISTA DE ANEXOS

Anexo 1 – Plataformas/ferramentas desenvolvidas pelas <i>Big4</i>	45
Anexo 2 – Ciclo Anual de Planeamento Orçamental	45
Anexo 3 – Descrição das variáveis categóricas.....	46
Anexo 4 – Descrição variáveis numéricas e observações ausentes.....	46
Anexo 5 – Pesos (%) das 20 variáveis explicativas no cenário 1	46
Anexo 6 – Pesos (%) das 20 variáveis explicativas no cenário 2.....	47

AGRADECIMENTOS

O que parece hoje ser o trabalho de uma pessoa, foi na verdade, a soma de um esforço conjunto e acumular de aprendizagens e capacidades adquiridas ao longo de toda a minha formação. Daí que considere pertinente começar estes agradecimentos com uma nota de apreço por todos os docentes que tive na minha vida e me ajudaram a ser quem sou hoje, académica e pessoalmente.

Agradeço à Academia da Força Aérea, na pessoa de todos os docentes, instrutores e diretores de curso, dos quais destaco o Major Artur Guerreiro e o Major João Pina, pelas ferramentas que me deram ao longo destes seis anos, e pela oportunidade de ter um ensino de qualidade, que tanto me orgulha, ensino esse aliado a uma experiência fantástica no Instituto Superior de Economia e Gestão, que tanto me deu.

Agradeço ao Professor Doutor António Samagaio (orientador), antes de tudo, por ter aceitado embarcar neste desafio e me por me ter ajudado a encontrar a rota certa, sempre que algum tipo de dúvida ou questão aparecesse no caminho.

Agradeço ao Professor Jorge Caiado, pela ajuda e contributo fundamental na aplicação prática deste trabalho, pelo seu conhecimento e ajuda incansável.

Agradeço à Major Elsa Evangelista (coorientadora), por me encaminhar e permitir ter acesso a todos os militares que me poderiam melhor ajudar em cada fase do processo.

Agradeço assim a todos os militares que colaboraram, direta e indiretamente, na construção desta dissertação, entre os quais me sinto no dever de destacar a ajuda sempre pronta e relevante do Tenente-Coronel Ivo Alves, que pela sua mestria e conhecimento me ajudou a encontrar soluções numa fase crítica da formulação do trabalho. Realço também a ajuda e disponibilidade constante do Capitão João Malico, fundamental na fase final deste trabalho.

Agradeço aos KAISERS por seis anos de crescimento, momentos bons e outros nem tão bons, mas que tanto ensinaram. Para trás ficam boas memórias, noites de estudo, viagens, convívios, discussões, um quotidiano ao vosso lado, e acima de tudo um curso que levaremos para sempre. Sem vós, certamente, não teria sido igual. Para a frente, permanecerão os laços de amizade criados.

Agradeço de forma especial aos meus amigos, Jorge, que além de me ter marcado de forma tão “vincada” desde cedo, se tornou família e um exemplo gigante, e ao Pedro que mais que um exemplo, foi um porto a quem recorrer sempre que precisei. Por último, mas não menos importante, ao João, que conviveu comigo diariamente nos últimos anos e a quem estarei sempre agradecido pelo companheirismo.

A toda a minha família: Mãe e Pai, um enorme obrigado por todas as oportunidades, ensinamentos, conselhos e puxões de orelhas. Mais que ninguém vocês sabem como foi o caminho. Se aqui estou hoje, em muitos dias, mais do que por mim, foi por vocês. Sei que nunca me faltaram, e que nunca faltarão. À minha irmã, agradeço por me ter feito ser uma pessoa melhor, pois mesmo sem saber, sempre tentei ser um exemplo que pudesse seguir.

A ti, Inês, agradeço por ouvires os meus desabafos e confissões durante a realização desta dissertação, pois sei que não é fácil lidar comigo quando estou focado em algo e na forma como isso te tirou a minha atenção.

A vocês, que já não estão fisicamente, mas que me guiam todos os dias da minha vida, mesmos os que nem sequer sonharam que seria este o meu caminho, obrigado por estarem aí a olhar por mim.

1. INTRODUÇÃO

A Inteligência Artificial (IA) é, atualmente, uma das áreas de crescimento global mais acelerado. De acordo com o estudo *CIO Survey* de 2019, o número de empresas a adotar IA cresceu cerca de 270% entre 2015 e 2019 (Gartner, 2019). Segundo o inquérito *Deep Shift: Technology tipping points and societal impact*, até 2025, aproximadamente 30% das auditorias empresariais utilizarão IA (Shift, 2015). O aumento da adoção da IA pode ser atribuído à crescente procura por melhorias na produtividade em economias avançadas, pois as empresas veem nas tecnologias cognitivas uma forma de impulsionar esse crescimento. Além disso, a tomada de decisões com base em grandes volumes de dados, em tempo limitado, torna-se desafiadora para os humanos. No que toca à oferta, há disponibilidade de *software* e *hardware* com capacidades cognitivas para realizar tarefas anteriormente feitas manualmente. Os dados e a capacidade de processamento são elementos cruciais neste domínio (Kokina & Davenport, 2017), sendo que este fenómeno se reflete nas firmas de auditoria, especialmente nas *Big4*¹.

Em 2019, a KPMG tencionava investir 5 mil milhões de dólares em parceria com a *Microsoft* para desenvolver tecnologias de IA precisas, com capacidade de tomada de decisão (Wright, 2019). A EY também fez um investimento significativo no *EY Blockchain Analyzer* (EY, 2019), continuado até a uma quarta geração em 2023, com um investimento na ordem dos mil milhões de dólares (EY, 2022; EY, 2023). A PWC, por sua vez, tem planos de investir em IA na mesma ordem, num projeto plurianual até 2026, colaborando com a *Microsoft*, e formando as suas equipas nessa área (Loten, 2023). A *Deloitte* criou o *Deloitte Ominia*, um sistema impulsionado pela IA, com um investimento estimado em mil milhões de dólares (Deloitte, 2022).

Em Portugal, no ano de 2021, cerca de 17,3% das empresas usavam tecnologias de IA, mais concretamente análise textual, identificação de imagens, automatização de fluxos de trabalho e apoio à tomada de decisões (INE, 2021). Segundo a *Internacional Data Corporation* (IDC) (2023), o desenvolvimento de produtos e serviços relacionados com IA, atingia no final de 2022, 300 milhões de euros, prevendo-se um investimento superior a 500 milhões de euros até final de 2025. Gabriel Coimbra, vice-presidente do grupo e *country manager* da IDC Portugal, destaca na conferência *IDC Future of*

¹ Por *Big4*, entendam-se as maiores firmas de auditoria: KPMG, *Deloitte*, EY e PWC.

Intelligence (2023) que a combinação de soluções de *business analytics* e IA impulsiona a transformação dos negócios, promovendo inovação, eficiência e vantagem competitiva. O sucesso empresarial poderá, então, depender da capacidade de criar ciclos contínuos de *insights* e ações para aumentar a resiliência e a agilidade nas empresas (IDC, 2023).

O *machine learning* (ML) é um subcampo da IA com capacidade de automatizar a análise de dados, identificando padrões, e elaborando previsões para novos casos. Esta ferramenta poderá ser altamente benéfica ao nível de uma auditoria devido à mitigação de erros e aceleração das mesmas (Dickey et al., 2019).

A Força Aérea Portuguesa (FAP), como ramo das Forças Armadas inserido nos órgãos da Administração Central, tem à sua disposição créditos inscritos no Orçamento de Estado (OE) e, portanto, deve prestar contas a entidades específicas. O seu controlo envolve duas perspetivas: interna e externa. Internamente, a FAP possui militares com funções de auditoria que aplicam a legislação vigente e normas internacionais. Alinhado com a Diretiva Estratégica da FAP 2022-2025, as tendências emergentes da tecnologia têm crescido com elevado ritmo, o que se faz sentir a nível da Governança e Tomada de Decisão. Assim, a transição digital sentida na instituição sustenta a ideia de que aplicar tecnologias de IA, poderá contribuir na prossecução da eficiência e produtividade dos recursos existentes. As auditorias e o controlo interno são fundamentais na gestão organizacional, com auditores, internos ou externos à mesma, seguindo normas estabelecidas para analisar dados e detetar alguma possível irregularidade ou inconformidade. Nesse sentido, a análise digital ganha relevância no que ao campo da auditoria diz respeito (Taborda, 2017), ajudando os auditores na análise de dados de múltiplos ficheiros, auxiliando na tomada de decisão, e libertando-os para outras tarefas de maior valor acrescentado.

Do cruzamento entre as possibilidades de aplicação desta temática, e aquilo que os dados disponíveis permitiam analisar, surgiu a hipótese de aplicar a aprendizagem supervisionada na previsão de desvios no âmbito da gestão e controlo orçamental, especificamente ao nível dos elementos de ação. Ter um orçamento flexível é essencial, mas o objetivo será o de melhorar a capacidade de a instituição prever, com cada vez mais precisão, as despesas e a forma de alocação (pelos elementos de ação) dos seus recursos.

Este trabalho está estruturado em seis capítulos. No segundo capítulo é feito um apanhado do estado da arte sobre o tema central do trabalho – a inteligência artificial – tocando nos pontos mais relevantes em campos das diferentes técnicas e camadas da IA, na sua aplicação em auditoria, focando-se por fim, na aprendizagem supervisionada, pedra basilar na análise prática deste trabalho. No terceiro capítulo é feita uma breve apresentação da FAP, contextualizando a auditoria e controlo interno na mesma e explorando as possibilidades de aplicação da IA. Seguidamente, no quarto capítulo, é explicado o processo de recolha de dados, é feita a descrição da amostra e detalhado o método de análise. No capítulo cinco, é feita uma análise de resultados, seguida de conclusões, limitações e sugestões de investigações futuras, no sexto capítulo.

2. REVISÃO DE LITERATURA

Nesta secção será feita uma revisão abrangente do estado da arte da IA, começando pela sua origem, explorando as várias tipologias, campos de aplicação, diferentes camadas e, finalmente, abordando a aprendizagem supervisionada e respetivos algoritmos.

2.1. Conceito de Inteligência Artificial

A génese da IA está associada ao trabalho desenvolvido por John McCarthy, Marvin Minsky, Claude Shannon e Nathaniel Rochester, para a Conferência de Dartmouth, que partia da ideia de que "todos os aspetos da aprendizagem ou qualquer outra característica da inteligência podem, em princípio, ser descritos com tanta precisão que uma máquina pode ser programada para a simular" (McCarthy et al., 1955, p.1), onde se focaram em aspetos específicos da IA, como a automação, a linguagem utilizada por computadores e a sua capacidade de autoaperfeiçoamento (Cordeschi, 2007). A IA tem a capacidade de conseguir desempenhar tarefas que, à partida, necessitariam de inteligência humana (IEEE, 2019; Russell & Norvig, 2002), sendo por isso uma simulação do pensamento humano e da obtenção de informação (Afeng et al., 2017). Esta simulação tem duas formas de se efetuar: imitando o mecanismo estrutural do cérebro humano, construindo uma máquina semelhante ao cérebro; ou através da simulação funcional, isto é, colocando de parte a estrutura do cérebro humano, e simulando o seu funcionamento. Desta feita, os computadores modernos, serão uma simulação da função de pensamento do cérebro e do processo de informação (Li, 2018).

A IA pode então ser definida como "a habilidade de um sistema interpretar dados externos, aprendendo com esses dados, e utilizando essas aprendizagens para atingir objetivos e tarefas específicas através de uma adaptação flexível" (Kaplan & Haenlein, 2019, p.17). Sendo a IA um instrumento de ajuda à tomada de decisão nas organizações (Abdolmohammadi, 1991), Carlson (1983) refere que esse processo de decisão deverá conter, tipicamente, três fases iterativas básicas: i) inteligência - recolha de dados, identificação de objetivos, diagnóstico de problemas, dados de validação e estruturação de problemas; ii) conceção - manipulação dos dados, quantificação dos objetivos, geração de alternativas e atribuição de riscos ou valores às alternativas; e iii) escolha - envolve gerar estatísticas sobre alternativas, explicar as alternativas, escolher entre elas, explicando e justificando a escolha.

A IA pode ser distinguida e separada em dois conceitos diferentes: IA fraca e IA forte. A IA fraca é respeitante à capacidade que sistemas de computação têm de utilizar algoritmos destinados exclusivamente para uma tarefa, desenhados para casos muito específicos, oferecendo a possibilidade de executar a maioria das tarefas operacionais das empresas (Iansiti & Lakhani, 2020). As máquinas são programadas para realização de tarefas específicas, não tendo, por isso, a capacidade de desenvolver inteligência própria (Violante & Andrade, 2022). Por sua vez, a IA forte corresponde a sistemas com capacidade de realizar qualquer atividade lógica, desde a simulação do processo de tomada decisão, aprendendo e resolvendo problemas de qualquer domínio, até ao desenvolvimento de inteligência própria, como se tentou mostrar no Teste de *Turing* (IBM Cloud Education, 2020; Sabouret, 2020).

Ainda não existem tecnologias com capacidade de simular inteligência auto consciente, porém existem previsões de que serão os próximos passos da IA (Bostrom, 2014). Prevê-se que no futuro, através da IA forte, poderá existir um vasto manancial de máquinas e sistemas capazes de funcionar totalmente como seres humanos e com o seu nível de inteligência (Borana, 2016). A IA forte, até hoje, não conseguiu alcançar o seu potencial, muito em parte, devido à falta de dados disponíveis. Este obstáculo será contornado quando se alargarem as investigações nos campos de IA, ML e *Deep Learning* (DL), outra camada mais "refinada" e atual da IA. Nesse ponto, a IA forte conseguirá alcançar o seu elevado potencial (Butz, 2021). Através deste tipo de inteligência, poderiam ser emitidas e recomendadas linhas de ação flexíveis e adaptáveis na

prossecução de alguns objetivos (Butz, 2021). A relação mais próxima com IA forte, poderá ser o tipo de inteligência capaz de desenvolver linhas e pensamentos de senso comum (Davis & Marcus, 2015; Lake et al., 2017; Levesque, 2017; Minsky, 2007; Zhu et al., 2020). A IA forte terá a capacidade de raciocinar acerca do ambiente em volta, podendo identificar, pensar e explicar relações causais (Butz, 2021). A este nível de inteligência, com um elevado grau de sentimento e razão, chama-se “singularidade” (Kurzweil, 2014), que implica a inclusão de atributos como definir metas, usar a imaginação, ter uma vasta cultura geral, e principalmente, conseguir ser crítico em relação ao seu próprio desempenho (Goertzel, 2007). No futuro, para que este nível de singularidade seja obtido, as diferentes técnicas e algoritmos de IA tenderão a convergir (Davenport & Kirby, 2016).

2.2. Inteligência Artificial em Auditoria

A capacidade de fazer previsões por parte das técnicas de IA, tem vindo a ser melhorada ao longo do tempo como consequência do foco no desenvolvimento e aplicação de modelos de IA na contabilidade e auditoria (Bao et al., 2020; Perols, 2011; Perols et al., 2017). A auditoria é um terreno fértil para a aplicação de análise de dados e IA, uma vez que se tornou cada vez mais desafiante combinar grandes quantidades de dados estruturados e não estruturados com o fim de extrair informações acerca do desempenho financeiro e não financeiro das empresas. Além disso, muitas das tarefas de auditoria são estruturadas e repetitivas, podendo ser automatizadas (Kokina & Davenport, 2017). A natureza da auditoria, por si só, já é, então, um campo convidativo ao uso da IA, sendo que esta envolve a avaliação de risco de decisões estruturadas, de decisões não estruturadas e semiestruturadas, mas regularmente repetitivas (Baldwin et al., 2006). De entre os tipos de decisões (estruturadas, semiestruturadas ou não estruturadas), a auditoria foca-se bastante nas decisões e análises menos estruturadas, que apresentam muita incerteza devido aos riscos e falta de informação (Baldwin et al., 2006). Porém, a aplicação de IA tem sido mais bem-sucedida em tarefas de auditoria mais estruturadas, programáveis e repetitivas, para as quais a recolha de dados vindos do ser humano não é uma dificuldade (Baldwin et al., 2006). Atualmente, a utilização da IA é fortemente notória no campo da aquisição de dados (extração, comparação e validação), sendo que através das diversas tecnologias existentes, podem-se localizar e extrair informações relevantes de documentos, tornando-as válidas e utilizáveis para os auditores, que livres

deste tipo de tarefas, podem dedicar o seu tempo a outras que criem maior valor acrescentado e que requerem um nível de julgamento mais elevado (Brennan et al., 2017).

O processo de auditoria financeira pode beneficiar da utilização de IA, essencialmente, em três dimensões (Elliot et al., 2020; Law & Shen, 2020): i) melhorar a compreensão das operações dos clientes e dos seus riscos associados; ii) melhorar a deteção de distorções materiais; e iii) evoluir as técnicas de comunicação com os cargos de chefia. A tomada de boas decisões em auditoria podem ter um impacto no que toca à responsabilidade legal dos auditores, visto que uma boa ajuda à decisão poderá levar a que sejam tomadas melhores decisões, evitando assim a responsabilidade resultante de eventuais falhas decorrentes da auditoria (Baldwin et al., 2006). Assim, através da utilização de IA, pode permitir-se que sejam reduzidas as três componentes do risco: o risco inerente, o risco de controlo e o risco de deteção (Zemánková, 2019). Na prática, conseguem-se ultrapassar os problemas adjacentes aos métodos de auditoria tradicionais (Zhou, 2021), melhorando a sua capacidade, a qualidade e eficiência da mesma (Chen, 2020), solucionando problemas de forma mais célere e precisa, reduzindo a carga de trabalho dos auditores, melhorando o sistema de controlo interno e reduzindo o risco de auditoria, alcançando uma gestão efetiva e sustentável. Por exemplo, o ML, uma camada da IA, permite estabelecer um modelo de controlo de riscos inteligente com resposta ativa e em tempo real, substituindo o processamento e análise de manuais por parte dos auditores (Zhou, 2021).

Um dos principais desafios na introdução de IA na contabilidade e auditoria consiste na explicabilidade dos seus modelos (AICPA, 2020; CPAB, 2021). Quanto maior é o desempenho preditivo de um modelo de IA, a explicabilidade desse mesmo modelo, tendencialmente, diminui (Baryannis et al., 2019; DARPA, 2016; Virág & Nyitrai, 2014). Por consequência do desenvolvimento dos métodos convencionais, e surgimento de métodos de auditoria baseados em IA e ML, verificou-se que, através de análises comparativas, os desempenhos de classificação obtidos por parte destas técnicas, eram muito superiores aos resultados obtidos através de métodos convencionais (Kennedy et al., 2013).

Porém, consideram-se como métodos que podem levantar algumas questões, visto que não existem orientações objetivas quanto a qual será a estrutura ótima da rede, ou devido

a problemas de *black-box* (Martens et al., 2010), ou seja, do ponto de vista de quem analisa não é possível ver quais os parâmetros utilizados e como podem influenciar o *output* extraído através dos dados (Virág & Nyitrai, 2014). A introdução de IA na auditoria deve, então, ser feita com cautela, uma vez que existem alguns entraves, tais como: falta de competências transversais para utilizar e gerir técnicas de IA, algumas incertezas relativamente a Normas Internacionais de Auditoria e falta de confiança generalizada na capacidade de utilizar a IA num ambiente e contexto mais incerto (Raphael, 2017). Adicionalmente, é fundamental que as firmas de auditoria garantam que as suas equipas de trabalho colaborem e estejam empenhadas no processo de adoção de IA (Newmark et al., 2018). No tocante à documentação e provas de auditoria (por exemplo, PCAOB AS 1105) as normas em vigor implicam que caso os auditores não consigam explicar e documentar o funcionamento interno ou os resultados de um modelo de IA, a confiança nas ferramentas utilizadas fica limitada (AICPA, 2020; CPAB, 2021).

Nesse sentido, para colmatar a necessidade global de uma melhor interpretação dos processos e resultados, desenvolveu-se um fluxo de investigação dedicado à Inteligência Artificial Explicável (XAI), que é definido pela *Defense Advanced Research Projects Agency* (DARPA) como sendo um conjunto de técnicas que produzem modelos explicativos para algoritmos de *black-box* ML que, “quando conjugados, permitem uma melhor compreensão, e oferecem maior confiança e capacidade de gestão dos sistemas de IA aos utilizadores finais” (DARPA, 2016, p. 5). Reforçando esta corrente, considera-se que tecnologias como as *Neural Network* (NN) são úteis devido ao seu poder preditivo e não à sua interpretabilidade (Breiman 2001a; Lipton, 2018), e que os auditores através de *deep neural network* (DNN) podem aprender que fatores desempenham papéis importantes no modelo preditivo para um determinado objetivo de auditoria, o que faz com que o DL, não seja, exatamente, um campo de *black-box* (Sun, 2019).

A aplicação da IA no contexto da auditoria implica igualmente ameaças à qualidade dos trabalhos produzidos. A IA é construída baseada em códigos elaborados por seres humanos e fica sujeita a ser um reflexo das crenças do programador (Janvrin et al., 2008; Solaimani et al., 2020). Segundo Ucoglu (2020a), a utilização de IA em auditoria pode acarretar novos riscos na qualidade da mesma. Segundo o *CIO Survey* (Gartner, 2019), cerca de 85% dos projetos poderão transmitir erros devido a enviesamentos dos dados ou de erros de cálculo. Com a introdução da IA na auditoria, existe o risco de serem

introduzidos dados considerados irrelevantes, o que poderia levar a um efeito de diluição (Greenman, 2017; Raphael, 2017; Schmidt et al., 2020). A inclusão deste tipo de informação, isto é, de dados irrelevantes, por consequência, influenciaria o processo de auditoria, e por isso, a qualidade da mesma (Abdelraheema et al., 2021).

2.3. Tipologias de Inteligência Artificial

O termo *Robotic Process Automation* (RPA), é utilizado para fazer alusão a um sistema programado para realizar o trabalho que seria feito por uma pessoa (Lacity et al., 2016), e tem capacidade de processar transações, manipular dados, dar respostas e comunicar com outros sistemas digitais (*Institute for Robotic Automation and Artificial Intelligence*, s.d.). Apesar de muitas organizações terem adotado este tipo de técnica, por norma, os utilizadores não têm orientação correta sobre que tipologia de tarefas são apropriadas para a sua aplicação (Eulerich et al., 2022). A diferença entre RPA e a IA prende-se no facto de que, enquanto a RPA é orientada por processos que automatizam tarefas baseadas em regras, a IA, por sua vez, é orientada por dados, entendendo padrões para que consiga simular as decisões do ser humano (Gotthardt et al., 2020). A razão para que as tecnologias de RPA surjam em primeiro lugar, na auditoria, deve-se à tipologia de tarefas que ocupavam os auditores, entre as quais a preparação dos dados de auditoria, organização de ficheiros, integração de dados de múltiplos ficheiros, realização de testes de auditoria básicos em *Excel*, ou simplesmente anotações manuais (Cohen et al., 2019). São dois conceitos estreitamente ligados, que não são mutuamente exclusivos, mas que se podem complementar (EY, 2018).

Daí surge o conceito de *Expert Systems* (ES), que se diferenciam de RPA por serem concebidos para darem soluções inteligentes e apoio à tomada de decisão numa área específica. Um ES é um sistema concebido para simular e replicar o julgamento de um perito, destacando-se de outros tipos de sistemas pelo seu foco e aplicação (Baldwin & Stone, 1995). Dito de outra forma, é um sistema de *software* intensivo que conjuga a experiência de um ou mais peritos numa determinada área de decisão, com o objetivo de elaborar uma recomendação específica para certas questões, auxiliando assim a tomada de decisão (Arnold et al., 2004). Segundo Eining et al. (1997, p.5), “os ES diferem de mecanismos tradicionais de ajuda à decisão, de duas formas: colocam ênfase no conhecimento (...) em vez de em soluções algorítmicas e melhoram o diálogo entre o

utilizador e o sistema”. Observou-se que, embora todo o investimento e desenvolvimento no campo dos ES, estes não corresponderam ao seu potencial devido a problemas relacionados com a falta de neutralidade (O’Leary, 2003). Nesse sentido, foram desenvolvidos outros tipos de técnicas de IA, no âmbito das tarefas de auditoria.

Abdolmohammadi (1991) estudou 332 tarefas desempenhadas por auditores, observando que apesar do seu elevado número, nem todas seriam indicadas para a aplicação de técnicas de IA. Embora, algumas tarefas fossem estruturadas e rotineiras, existiam outras pouco estruturadas e dependentes de informações incertas e incompletas (por exemplo, decisões de continuidade de um cliente).

Por norma, em campos de contabilidade e auditoria, a IA é implementada através de algum dos diferentes tipos de tecnologia, seguidamente apresentadas (Zemánková, 2019): algoritmos/programação genética, utilizados maioritariamente para prever falências, conseguindo minimizar o risco de falência associado a outros modelos tradicionais (Lensberg et al., 2006), sendo também úteis para construir modelos de comportamento de um auditor em casos de decisões de fraude (Welch et al., 1998), e até mesmo em situações de decisão de continuidade (Baldwin et al., 2006); sistemas difusos, que oferecem a possibilidade de contabilizar os fatores qualitativos, e são úteis para efeitos de avaliação da materialidade pois permitem aos seus utilizadores avaliar a materialidade numa escala contínua entre 0 e 1, em vez de o fazerem numa decisão binária (Rosner et al., 2006); NN, uma técnica de IA que tenta simular um cérebro humano (Omoteso, 2012), fundamental ao nível do DL, estando associada, sobretudo, à avaliação de risco, uma vez que o permite fazer de forma mais sistemática e consistente, graças à sua capacidade de aprender, generalizar e categorizar os dados (Chiu & Scott, 1994); sistemas híbridos, resultantes da combinação das tecnologias anteriores, e são, por norma, utilizados quando tanto a análise qualitativa como quantitativa são relevantes e necessárias (Davis et al., 1997). Lenard et al. (1998), desenvolveram um sistema híbrido que combinava um modelo estatístico com um ES para prever decisões de continuidade. Os Sistemas Híbridos poderão ser apropriados neste tipo de casos, uma vez que algumas tarefas de auditoria envolvem a utilização de análise quantitativa a par de um julgamento qualitativo (Baldwin et al., 2006).

Ao longo de toda a evolução dos níveis de inteligência e das respetivas técnicas, o conhecimento foi sendo aprimorado, podendo ser decomposto em três grandes camadas (Figura 1). A IA como um todo, sendo o *Machine Learning* (ML), um subcampo desta, e mais recentemente, o *Deep Learning* (DL) como uma parte do ML.

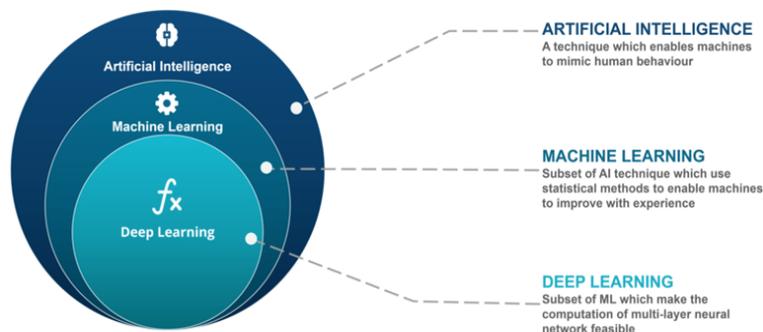


FIGURA 1 – Relação entre os três níveis de IA (Fonte: Aggarwal et al., 2022)

2.4. Machine Learning

ML é um subcampo fundamental da IA que surge da ideia de que máquinas poderiam ser programadas para aprender da mesma forma que os humanos o fazem, sendo um método computacional com capacidade para identificar padrões escondidos, baseado em dados, conseguindo, posteriormente, fazer previsões (Alpaydin, 2014), fazendo deste uma ferramenta utilizada na modelação preditiva (Shmueli, 2010). É uma técnica de IA que é bastante eficiente a trabalhar com conjuntos de dados de grande dimensão, requerendo um menor número de pressupostos subjacentes (Alpaydin, 2014; Bertomeu, 2020; Cecchini et al., 2010). Desta forma, assente num largo número de *inputs*, o computador consegue prever o *output* (Brown, 2021), e por esse motivo, o modelo será tanto melhor quanto mais *inputs* lhe forem fornecidos (Violante & Andrade, 2022). Os algoritmos de ML ao lerem os dados, detetam padrões complexos e identificam quais as melhores variáveis que conseguem explicar um dado resultado. Além disso, através destes algoritmos, são encontradas combinações adequadas para elaborar previsões precisas fora da amostra em estudo, daí que se considerem fundamentais para desbloquear fontes de dados financeiros, permitindo tomar melhores decisões (Bartomeu et al., 2021).

É de alta importância frisar que a inteligência do sistema depende fortemente da qualidade dos dados e dos exemplos a que é submetida previamente, uma vez que é sobre eles que vai produzir conhecimento, sendo necessário assegurar que os dados utilizados não contêm enviesamentos ou preconceitos, para que o sistema não só não aprenda com

eles, como não os perpetua durante o processo de aprendizagem e na aplicação a novos casos (Garcia, 2020). O ML pode apresentar algumas questões a ter em atenção. Um delas é o *overfitting*, ou seja, quando o computador capta idiosincrasias, isto é, padrões comportamentais nos dados, considerados peculiares, que não são representativas da realidade. Situações deste tipo podem resultar do facto do modelo ser testado com os mesmos dados utilizados para o treinar e contruir, uma vez que a sua sobreposição faz com que o sistema esqueça que as correlações estatisticamente significativas entre variáveis, não implicam, obrigatoriamente, uma relação causal. Opostamente, o fenómeno de *underfitting* ocorre quando o modelo criado não é suficientemente complexo para encontrar padrões nos dados. Por ambos os casos, continua a ser necessária a compreensão e julgamento humano, como complemento ao ML (Dickey et al., 2019).

Os *inputs* fornecidos aos sistemas de informação podem ser lidos segundo três linhas distintas de aprendizagem: Aprendizagem Supervisionada, Aprendizagem Não Supervisionada e Aprendizagem Reforçada. A Aprendizagem Supervisionada (Modelos Preditivos) consiste em, partindo de dados de treino (*inputs*), chegar a uma função que possa ser útil para prever um rótulo/valor, que caracterize um novo exemplo, baseado nos valores dos seus atributos de entrada (Gama et al., 2017). Pode ser classificado em dois tipos: Classificação (rótulo discreto) ou Regressão (rótulo contínuo) (Gama et al., 2017). Na Aprendizagem Não Supervisionada (Modelos Descritivos) não existem rótulos associados aos *inputs* fornecidos, sendo o objetivo principal encontrar um padrão nos dados recolhidos. Para tarefas deste género, os algoritmos utilizados não consideram os atributos de saída e podem ter três possíveis classificações (Gama et al., 2017): i) agrupamento, onde os dados se associam e agrupam pelo nível de equivalência; ii) sumarização, onde se tenta sintetizar e interpretar de forma simplista um determinado conjunto de dados; e iii) associação, onde se verificam padrões de ligações entre atributos de um conjunto de dados. Por fim, na Aprendizagem Reforçada existem interações de tentativa e erro num ambiente dinâmico, onde um sistema deve aprender e otimizar um comportamento (Kaelbling et al., 1996). O DL está bastante presente neste tipo de aprendizagem (Li, 2017).

Crê-se que, nos próximos anos, o ML terá a capacidade de revolucionar quase todas as indústrias, não sendo a profissão de auditoria uma exceção (Kokina & Davenport, 2017), podendo ser utilizado para prever fraudes (Bao et al., 2020; Cecchini et al., 2010;

Perols, 2011; Perols et al., 2017), falências (Gentry et al., 2002) reestruturações/dissoluções (Bertomeu et al., 2021; Dutta et al., 2017; Hunt et al., 2019) e estimativas contabilísticas (Ding et al., 2020).

As *Big4* têm investido, consideravelmente, em inovação tecnológica, especialmente em técnicas de ML (Kokina & Davenport, 2017). A KPMG destaca três pilares fundamentais para a inovação em auditoria: automação digital, análise preditiva e tecnologias cognitivas. A plataforma KPMG *Clara*, desenvolvida em colaboração com outras empresas que utilizam sistemas como o *Microsoft Azure* (uma nuvem de serviços computacionais baseada em ML e análise preditiva) e o IBM *Watson*, permite analisar extensos conjuntos de dados financeiros em tempo real, identificando informações inconsistentes, não dependendo de amostras limitadas (Barnes, 2015). A tecnologia cognitiva, conforme definida pela KPMG (2018), requer interpretação humana e julgamento cognitivo no processamento da informação sendo que, posteriormente, através de DL, ML e análise preditiva, formulam-se hipóteses que sustentam a tomada de decisão (KPMG, 2016).

No caso da EY, o investimento em IA centra-se, fundamentalmente, em DL, ML e automação (EY, s.d.), destacando-se as capacidades de análise e extração de informações de dados não estruturados (imagens, contratos e faturas), bem como a análise de grandes conjuntos de dados para identificar com precisão riscos e possíveis distorções decorrentes de casos fraudulentos (EY, s.d.). Para este efeito, o ML, inclui a programação neurolinguística (PNL) para revisões de documentos e extração de dados de contratos (Boillet, 2018). A EY é ainda responsável pelo desenvolvimento do EY *Helix* e do EY *Canvas* que, através da automação que oferecem, melhoram a eficiência da auditoria (EY, s.d.). O primeiro é uma plataforma global que orienta os auditores na análise de dados, e não na sua recolha. Na sua génese, começou por ser um sistema de ML sustentado por ES, que através da avaliação que faz aos *inputs* fornecidos pelos auditores, analisa-os e recomenda ações, sendo que, quanto mais forem as auditorias realizadas com recurso ao EY *Helix*, mais eficazes serão os seus algoritmos a detetar anomalias (EY, s.d.).

No que à *Deloitte* diz respeito, é utilizada uma plataforma global de auditoria chamada *Deloitte Ominia* (Deloitte, s.d. (a)), outro sistema baseado em ML. Para análise de provas de auditoria, a *Deloitte* emprega PNL, reconhecimento ótico de caracteres e ML (Deloitte,

s.d.(b)). Além disso, através do *Argus*, outra ferramenta da *Deloitte* baseada em algoritmos de ML, é possível ler documentos e contratos, identificando pontos chave, tendências e valores atípicos (Kepes, 2016).

No que concerne à *PricewaterhouseCoopers* (PWC), esta utiliza o *Halo* para analisar lançamentos contabilísticos, antecipando áreas potencialmente problemáticas e processos anormais relacionados com esses lançamentos (por exemplo: fontes duvidosas ou lançamentos incoerentes com os limites autorizados). Esta ferramenta permite aos auditores concentrarem-se em lançamentos de maior risco, melhorando a velocidade e qualidade da auditoria (Kokina & Davenport, 2017).

Além das plataformas mencionadas anteriormente, vão surgindo outros projetos e variantes dos algoritmos que as empresas integram nos seus processos de auditoria (Anexo 1) na tentativa de ganhar vantagem competitiva (Faggella, 2020), alargada a campos de contabilidade, declaração de impostos, consultoria, análise financeira e análise de risco (Ucoglu, 2020b).

2.5. *Aprendizagem Supervisionada*

Este tipo de aprendizagem preditiva traduz-se numa função onde, tendo um conjunto de exemplos rotulados, é construído um estimador. Os rótulos podem tomar valores dentro de um domínio conhecido, porém, segundo duas perspetivas distintas: se o domínio for um conjunto de valores nominais, está-se perante uma situação de classificação (gerando um estimador classificador), por outro lado, trabalhando num domínio de valores ordenados e infinito, existe um problema de regressão (originando um estimador de regressão). Em ambas as situações, os estimadores gerados são uma função, que pegando em exemplos não rotulados, têm capacidade de alocar esses exemplos a uma das classes ou valor já conhecidos (Dietterich, 1998).

A aprendizagem supervisionada apresenta-se como a técnica mais comum em problemas de classificação, uma vez que, na maioria dos casos, o objetivo é programar a máquina para aprender um determinado sistema de classificação previamente criado. A principal tarefa será prever o rótulo de um objeto através do conjunto das suas características. Desta forma, o algoritmo de aprendizagem tem em consideração os *inputs* que traduzem as características desse objeto, e compara o *output* previsto com a realidade (Nasteski, 2017). Num modelo simples de ML, o processo de aprendizagem é dividido

em duas etapas: treino, onde os dados de treino são lidos pelo algoritmo construindo um modelo de aprendizagem, e teste (Dhage & Raina, 2016).

Segundo Oladipupo (2010), os algoritmos de aprendizagem supervisionada que mais frequentemente lidam com problemas de classificação são: Regressão Linear, Regressão Logística, *Support Vector Machine*, *Decision Tree*, *Random Forest*, *K-Nearest Neighbour*, *Neural Networks*, *Stochastic Gradient Descendent*, *XGBoost*, *Naive Bayes*, *K-Means Clustering*, entre outros. Seguidamente, apresentar-se-á uma breve descrição dos algoritmos relevantes para este trabalho.

2.5.1. Algoritmos de Aprendizagem Supervisionada

Para resolver um problema de decisão, uma *decision tree* usa a estratégia de “dividir para conquistar”. Assim, um problema considerado complexo, é repartido em problemas mais simples, aos quais se aplicam estratégias adequadas. Para estes problemas mais simples, são encontradas soluções, que quando combinadas, poderão fornecer a solução para o problema complexo (Faceli et al., 2021). Deste modo, *decision trees* são classificadores que expressam ocorrências (instâncias) ordenadas, baseando-se em valores das suas características. Cada nó de uma árvore de decisão representa uma característica de uma ocorrência que será classificada e cada ramo representa o valor que um nó pode assumir (Osisanwo et al., 2017). As instâncias são classificadas partindo do nó de raiz (Kotsiantis et al., 2007), que por ser o inicial, não tem arestas de entrada (Maimon & Rokach, 2014), porém, todos os outros têm uma aresta de entrada. Se um nó tiver arestas de entrada e saída é chamado nó interno (ou de teste), e se apenas tiver nós de entrada, é chamado de folha. Numa *decision tree*, os nós de teste, dividem o espaço da ocorrência em dois ou mais subespaços. A cada folha (nó final) é atribuída uma classe que representa um valor-objetivo adequado. Com um classificador deste tipo, um analista poderá prever a resposta para uma determinada situação, tendo em consideração as características comportamentais de toda a amostra (Tan et al., 2013). O processo de aprendizagem neste tipo de algoritmo é utilizado como mecanismo de previsão, e partindo de observações sobre um determinado objeto, são tiradas conclusões acerca do seu valor-alvo (Osisanwo et al., 2017). Por norma, um decisor prefere *decision trees* menos complexas, uma vez que permitem uma abrangência maior (Nasteski, 2017).

No seguimento deste modelo, surgem os algoritmos de *random forest*, uma vez que se consideram como conjuntos de *decision trees*, calculando a média das suas previsões individuais. Analisar árvores individualmente apresenta maior facilidade de interpretação, porém, essa característica perde-se quando se fala na análise de *random forests*, devido ao facto de serem várias árvores agregadas. No entanto, este modelo, oferece um desempenho muito superior em tarefas de previsão (Schonlau & Zou, 2020), uma vez que a taxa de erro diminui à medida que a quantidade de árvores aumenta (Breiman, 2001b).

O *extreme gradient boosting (Xgboost)* é um sistema que tem vindo a receber reconhecimento numa série de problemas de ML e *data mining*, mais concretamente, por exemplo, ao nível de previsão de comportamentos de clientes, categorização de produtos, previsão de vendas, classificação de eventos, entre outras atividades de previsão. O fator que mais força dá ao uso de *Xgboost*, é a sua característica de escalabilidade em vários cenários, permitindo executar mais de dez vezes mais rápido que as outras soluções disponíveis, devido às suas otimizações, e pode ser direcionado para um enorme número de exemplos (Chen & Guestrin, 2016).

3. CONTEXTO DE INVESTIGAÇÃO

Nesta secção, será contextualizado o tema na organização, aprofundando o campo orçamental e destacando o objeto de estudo, com recurso às respostas obtidas na primeira entrevista realizada².

3.1. Quadro Normativo Geral

A FAP, segundo a Diretiva Estratégica da Força Aérea (2022, p. 8), tem por missão “participar de forma integrada, na defesa militar da República, nos termos da Constituição e da lei, sendo fundamentalmente vocacionada para a geração, preparação, aprontamento e sustentação de forças e meios da componente operacional do sistema de forças”. De acordo com o artigo 1.º do Decreto-Lei 187/2014, de 29 de dezembro, que estabelece a Lei Orgânica da FAP (LOFA), é um ramo das Forças Armadas, dotado de autonomia administrativa que, através do Ministério da Defesa Nacional (MDN), se integra na

² Tal como será referenciado no capítulo seguinte, o presente trabalho contou com duas entrevistas ao chefe da Sub-Repartição de Planeamento e Controlo Orçamental (Capitão João Malico), sendo esta uma delas.

administração direta do Estado. Adicionalmente, segundo o disposto na Lei de Bases da Contabilidade Pública (LBCP), Lei n.º 8/90, de 20 de fevereiro, mais concretamente no n.º 1 do artigo 2.º, a autonomia administrativa nos serviços e organismos da Administração Central, no qual se inclui a FAP, manifesta-se, em regra, na competência de autorizar a realização de despesa e respetivos pagamentos por parte dos dirigentes, em atos de gestão corrente. Confrontando o artigo 3.º da LBCP com o artigo 5.º da LOFA, os serviços e organismos deste regime contam com créditos do Orçamento de Estado (OE). Assim, a FAP tem ao seu dispor receitas atribuídas no OE, e por isso, tem a obrigação de prestação de contas a determinadas entidades.

A função de monitorização é assegurada sob duas dimensões: a interna e a externa. Na perspetiva interna, o Serviço de Inspeção e Auditoria Financeira e Patrimonial (SIAFP)³ tem como missão executar ações de inspeção, auditoria e controlo, nomeadamente, auditar as contas das Unidades/Órgãos/Serviços (UOS) da FAP, bem como as contas consolidadas, com o fim de garantir a sua situação financeira e patrimonial com a correta conformidade legal e regularidade financeira, e posterior prestação de contas ao Tribunal de Contas (TC) (RFA 303-10 (A) - Organização e normas de funcionamento da DFFA). Paralelamente, a nível interno, a função de controlo na FAP é também assegurada pela Inspeção Geral da Força Aérea. A nível externo, o controlo é exercido pela Inspeção Geral da Defesa Nacional, Inspeção Geral da Administração Interna, Inspeção Geral das Finanças e Tribunal de Contas.

O Regulamento das Auditorias de Administração Financeira e Patrimonial da DFFA, é ditado pelo RFA 425-3, que tem como objetivo estabelecer a doutrina e os procedimentos gerais que devem ser adotados e tidos em consideração aquando da realização de uma auditoria na alçada da DFFA. Este documento pretende dar ferramentas e linhas orientadoras ao auditor para que possa expressar o seu parecer sobre se as demonstrações financeiras da FAP estão a ser realizadas em conformidade legal, tributária e com regularidade financeira.

³ O SIAFP está na dependência da Direção de Finanças da Força Aérea (DFFA) que é a unidade orgânica responsável pela administração dos recursos financeiros postos à disposição da FAP, de acordo com os planos e diretivas aprovadas pelo Chefe de Estado-Maior da Força Aérea (CEMFA) (artigo 16º da LOFA; parágrafo 201 da RFA 303-10 (A) - Organização e normas de funcionamento da DFFA).

Além do estabelecido nos regulamentos internos da FAP, os auditores devem seguir também, as Normas e Boas Práticas reconhecidas e utilizadas por entidades de Controlo Nacionais e Internacionais, como é o caso de diretrizes da *International Organization of Supreme Audit Institutions*, as Normas Internacionais de Auditoria do *International Auditing and Assurance Standards Board*, as Normas Técnicas de auditoria da Ordem dos Revisores Oficiais de Contas e as diretrizes do *Committee of Sponsoring Organizations of the Treadway Commission* (RFA 425-3 - Regulamento das Auditorias de Administração Financeira e Patrimonial, parágrafo 204).

As tendências emergentes da tecnologia irão repercutir-se nas Forças Armadas nacionais, influenciando a forma de combater e o processo de organização e gestão das forças. Na Diretiva Estratégica da Força Aérea 2022-2025 é referido que a Ciência e Tecnologia apresentam um ritmo de evolução rápido e disruptivo, obrigando as organizações a inovar, procurando formas de introduzir sistemas suportados por IA e ML, assentes em sistemas com elevado grau de processamento e armazenamento. A nível interno, no que à Governança e Tomada de Decisão diz respeito, identificam-se alguns fatores que afetam a colaboração entre Ministério da Defesa Nacional (MDN) e Estado-Maior-General das Forças Armadas (EMGFA), prendendo-se fundamentalmente com a complexidade do processo de tomada de decisão e com ferramentas de gestão desadequadas (CEMFA, 2022). Pelo descrito no Objetivo Estratégico 4 – Otimizar a gestão da organização com processos simples e eficazes suportados em sistemas de informação atuais e resilientes – pretende-se atingir uma tomada de decisão mais simples e assente em tecnologias ágeis (Linha de Ação 4.1), baseado num processo de transição digital, com o intuito de alcançar a transformação digital da organização, aumentando a sua produtividade e eficiência dos recursos existentes (CEMFA, 2022).

Seguindo esta linha de ideias, o facto de a documentação de auditoria poder ser registada em papel ou em meios eletrónicos (RFA 425-3 - Regulamento das Auditorias de Administração Financeira e Patrimonial, parágrafo 206), aliado a que auditorias externas solicitem, cada vez mais, todos os elementos dos processos de despesa em formato digital num curto espaço de tempo, levou o Serviço Administrativo e Financeiro a emitir a Instrução nº01/2022, no sentido de seguir a tendência da Administração Pública (AP) da desmaterialização documental com recurso a meios eletrónicos, que se poderá tornar bastante relevante na melhoria da capacidade de resposta da FAP a entidades

externas, no âmbito de inspeções, auditorias ou investigações e na aplicação de tecnologias de IA.

3.2. *Envolvente da Gestão Orçamental*

De acordo com o Despacho n.º 52/2008 de 30 de setembro, que determina o Ciclo Anual de Planeamento e Orçamento (CAPO), o planeamento de atividades da FAP está sujeito a um enquadramento legal específico que regula a estrutura organizacional, o sistema de gestão e os recursos financeiros disponíveis. Assim, o enquadramento das atividades assenta em duas poderosas ferramentas de administração: o Plano Anual de Atividades (PAA) e o Relatório Anual de Atividades (RAA).

Considerando o constante no Anexo B ao Despacho n.º 52/2008, de 30 de setembro, todo o processo orçamental (Anexo 2) começa no ano N-2, aquando da revisão por parte da Divisão de Planeamento (DIVPLAN) dos Objetivos Estratégicos e da Diretiva de Planeamento. Mediante coordenação da DIVPLAN, a DFFA solicita às diversas UOS a inclusão e quantificação das despesas previstas para N+1. Recolhidas todas as Propostas de Orçamento, estas são consolidadas e submetidas à Secretaria-Geral do MDN, sendo posteriormente comunicados os *plafonds* atribuídos. Em função das necessidades estabelecidas pela macroestrutura e das limitações impostas pela tutela, o PAA é submetido para análise, eventuais ajustamentos e submetido a despacho de S. Exa. o General CEMFA. Em setembro de N-1 a sua versão final é gravada em sistema, constituindo-se como documento orientador na execução das Atividades. Até dezembro de N-1, caso o Orçamento sofra alterações, são efetuados acertos às prioridades do PAA e do Projeto de Orçamento. Por sua vez, em N+1, é elaborado o RAA, que descreve o desempenho efetuado, apontando os desvios, avaliando resultados e também, fornecendo informação relevante para que a melhoria e busca de qualidade sejam constantes.

No que ao PAA diz respeito, este é o documento onde a FAP define os objetivos a alcançar, programas a realizar e quais os recursos necessários. O cumprimento deste PAA poderá tornar-se ambicioso se os recursos financeiros necessários para a sua persecução se revelarem superiores aos orçamentados (Plano Anual de Atividades 2023). O PAA deve coordenar os esforços das diferentes entidades integrantes do planeamento para traduzir um cumprimento coerente relativamente ao planeado (Pimentel, 2006). De acordo com Malico (2023), “(...) o PAA é alimentado pelas diversas UOS que espelham

todas as necessidades existentes. É primordial para obter a devida fundamentação dos valores a incluir na proposta do orçamento”.

Partindo de uma visão genérica e de nível estratégico para um âmbito mais específico, o PAA pode-se decompor por quatro níveis hierárquicos organizados de forma descendente, isto é: os Objetivos, as Atividades, ambas da responsabilidade do CEMFA, as Ações e os Elementos de Ação (EA), da responsabilidade dos Órgãos e Serviços da Macroestrutura (Pimentel, 2006).

O PAA é desagregado em quatro níveis (...): Objetivos, Atividades, Ações e EA. Os dois primeiros são definidos pela Diretiva Estratégica da Força Aérea. As ações e EA são criados pela entidade responsável pela execução dos centros financeiros e têm de ser enquadrados dentro dos Objetivos e Atividades existentes.

In Malico (2023).

A hierarquia anteriormente descrita revela-se importante na identificação de onde se encontra a ser executado o orçamento da FAP, permitindo quantificar a expressão orçamental de cada um dos Objetivos e Atividades.

Só os EA é que possuem dotação orçamental atribuída, sendo através deles que se consegue chegar ao valor executado. Um EA só está associado a uma única ação, a uma única atividade e a um único Objetivo. O EA deve refletir o montante de despesa previsto.

In Malico (2023).

3.2. Objeto de Estudo

De acordo com Pimentel (2006), o SIG é um sistema visto como elemento importante a nível estratégico devido ao poder de integração das diferentes componentes da organização, que tem como fim máximo a otimização e equilíbrio de forma dinâmica dos recursos da FAP. Uma das grandes inovações deste sistema foi a integração e envolvimento das diferentes áreas, tais como a área do planeamento e orçamentação (Pereira, 2010). O entrevistado acrescenta que “o SIG é a principal ferramenta no planeamento orçamental (...) através dos dados carregados em SIG, é possível analisar, quantificar e mensurar as necessidades previstas da FAP”.

O SIG, enquanto sistema de toda organização, tem a capacidade de efetuar validações/bloqueios de forma automática nas diversas funções que nele se podem realizar. No entanto, sempre que é elaborado um processo de contratação com o respetivo

Número de Processo de Despesa (NPD) associado, pertencente a um EA, mesmo que este vá exceder o valor máximo previsto para esse EA, o SIG deixa prosseguir, o que põe em causa o planeamento previamente elaborado, uma vez que “(...) deveria ser dado um aviso ao utilizador. Desta forma o utilizador ficaria ciente de que o planeamento não está ajustado à previsão de execução (...) O montante dos EA deve acompanhar a previsão da despesa” (Malico, 2023).

Executar o planeamento conforme o que é planeado é a situação ideal. Porém, quer por razões inopinadas, ou até pela própria natureza da organização, a gestão do orçamento deverá ser sempre adaptada ao contexto real, sendo necessária flexibilidade para que se obtenham os melhores resultados possíveis.

O PAA é dinâmico e vai sendo ajustado conforme as necessidades reais. Por exemplo, durante a execução do orçamento surgem despesas inopinadas que não se encontravam contempladas no PAA. Esta despesa inopinada vai ter impacto em pelo menos um outro EA, ou seja, o valor anteriormente previsto vai ter de ser reduzido ou anulado. Caso um EA ultrapasse o montante inicialmente previsto é porque um ou mais EA vão deixar de ser financiados ou pelo menos sofrer reduções. Quando situações destas acontecem, na minha opinião, a decisão deve ser casuística, ou seja, deve ser feita uma avaliação das prioridades existentes e no momento tomar a decisão que se julgue mais vantajosa. Um PAA atualizado e fidedigno é uma ferramenta bastante útil no apoio à tomada de decisão”

In Malico (2023).

A adoção de técnicas de IA, como ferramentas de complemento/ajuda no trabalho dos militares nesta área, isto é, na melhor gestão do estado dos EA, bem como na otimização da capacidade de previsão das necessidades de cada EA, poderá ser tida como uma vantagem a nível da gestão e do controlo da mesma.

Já existem ferramentas que permitem acompanhar o estado de execução dos EA, que poderão ser melhoradas (...) existem ferramentas que possibilitam prever e estimar o financiamento adequado para os EA. Eventualmente, poderá ser desenvolvido algum mecanismo que possibilite uma análise mais célere à informação já existente. Creio que os principais fatores para planeamentos menos realistas são a escassez de tempo e de recursos humanos. Todas as ajudas/complementos que se revelem benéficas, são de aceitar.

In Malico (2023).

Em suma, nunca retirando importância ao facto de possuir um planeamento flexível, mas numa busca constante por aperfeiçoamento e planeamento cada vez mais próximo,

refletindo a realidade da organização, o propósito deste trabalho será a aplicação de um método de ML para prever que EA terão maior propensão para entrar em desvio, isto é, apresentar maior execução do que o que estava previamente planeado, mostrando que as tecnologias de IA emergentes poderão ser uma ferramenta útil, quer para gestão orçamental da FAP, quer para o seu próprio controlo.

4. METODOLOGIA E AMOSTRA

Neste capítulo será feita uma descrição e explicação do método de recolha de dados, descrevendo esses mesmos dados, e uma explicação do método de análise prático aplicado. A metodologia utilizada foi a *action research* (Williamson, 2002), que tem o propósito de gerar mudanças práticas, criando simultaneamente conhecimento, tornando-se útil para pesquisas exploratórias com o objetivo de implementar melhorias na prática ou propor novas soluções para eventuais falhas existentes. McNiff (2013), refere-se a este molde de investigação como sendo um pensamento meticoloso sobre as práticas realizadas, sendo por isso, um tipo de investigação autorreflexiva, podendo ser realizada por qualquer pessoa em qualquer que seja o contexto.

4.1. Método de Recolha de Dados

Para recolha de dados do presente trabalho utilizou-se uma abordagem mista (quantitativa e qualitativa), através da realização de duas entrevistas, e de uma aplicação prática de técnicas de ML aos dados recolhidos na organização. O objetivo das entrevistas foi o de reforçar quer a viabilidade de aplicação de sistemas de IA no controlo do planeamento orçamental da FAP (identificando possíveis oportunidades para a sua utilização), quer os resultados obtidos da análise quantitativa, dando-lhes assim robustez. O guião das entrevistas pode ser solicitado via e-mail⁴.

Numa fase inicial, foi realizada uma entrevista não estruturada, num âmbito exploratório, para melhor entender de que forma se poderia inserir esta temática na organização, e de que maneira poderia ser uma mais-valia a nível da eficiência dos seus processos, colmatando uma eventual necessidade ou melhorando processos existentes, tendo em vista a otimização do controlo interno da organização. A entrevista foi realizada ao chefe da Sub-Repartição de Planeamento e Controlo Orçamental⁵, e por restrições

⁴ popalmas@academiafa.edu.pt

⁵ À data do presente trabalho, trata-se do Capitão de Administração Aeronáutica João Malico.

temporais e de agenda, foi realizada via e-mail. Tendo em vista a consolidação e robustez de resultados e conclusões, foi ainda realizada outra entrevista numa fase final do trabalho à mesma entidade, também esta não estruturada, realizada presencialmente, com a duração de, aproximadamente, uma hora, tendo sido gravada e, posteriormente, transcrita.

4.2. Descrição da Amostra

Os dados destinados à análise prática focaram-se no período compreendido entre 2020 e 2022, inclusive, tendo sido extraídos do SIG, mais concretamente, através dos mapas de Execução por NPD, que permitem obter informação acerca dos parâmetros de cada processo de contratação (de bens e serviços) da FAP e Execução por EA, que fornece uma imagem da informação geral dos EA e da sua execução. Posteriormente, este conjunto de dados foi aprimorado e tratado no sentido de se construir um único mapa que relacionasse e combinasse a informação de forma completa e organizada para o fim pretendido e para a análise através do software *Anaconda*, uma plataforma de análise de dados e computação na linguagem *Python*, mais propriamente com recurso ao ambiente de desenvolvimento integrado *Spyder*.

De todos os parâmetros possíveis de serem extraídos do sistema, filtraram-se aqueles considerados relevantes para este tipo de análise. Assim, após organizado, o mapa resultante permitia observar todos os processos realizados nos anos em questão, onde para cada um deles, havia informação do respetivo NPD, da sua data de criação, da forma de adjudicação do procedimento, a económica de despesa, o valor dos seus cabimentos, compromissos e pagamentos e do EA a que correspondiam com a respetiva descrição. Paralelamente, para cada EA associado, foi adicionada informação acerca do valor “teto” suposto, da soma dos cabimentos, compromissos e despesa processada dos processos nele inserido, bem como do valor não processado (dado pela diferença do que seria suposto ser o teto, com o que efetivamente foi executado).

Após o processo de tratamento e limpeza de dados provenientes do sistema da FAP, foi adicionada uma coluna correspondente a uma variável *target* binária, isto é, que para cada linha de dados, apenas poderia assumir o rótulo “Sim/Não”, consoante o sinal da despesa não processada correspondente. Se para um dado EA existia um valor de desvio negativo (entre o limite previsto do EA e o real), a variável assumia o rótulo “Sim”. Caso contrário, se o desvio apresentado fosse positivo, a variável assumia o rótulo “Não”.

Depois de limpos e tratados os dados, foram contabilizados (Anexo 3) um total de 56.056 processos, de entre os quais: 11 formas de adjudicação distintas, onde o Ajuste Direto foi a mais observada; 505 económicas de despesa, onde a económica “02.01.21.17” referente a outros bens de vida corrente e funcionamento normal (Decreto-Lei nº26/2002 de 14 de fevereiro) foi a com maior representatividade; 3265 EA, nos quais o mais utilizado foi o correspondente a “FCC - Aquisição de material diverso”; 7 anos de criação de NPD diferentes, na qual o ano mais frequente foi 2021; 12 meses, com preponderância para o mês de novembro; 7 dias, apresentando uma maior frequência na quarta-feira; 2 variáveis *target*, com maior frequência no rótulo “Não”, ou seja, os dados apresentaram mais desvios positivos.

Além das variáveis categóricas, as variáveis numéricas utilizadas foram referentes aos cabimentos realizados e aos desvios, explicados anteriormente. A diferença observada entre as observações dos cabimentos (56.048) e as observações das restantes variáveis deveu-se ao facto de que em toda a amostra, em 8 processos, verificou-se a inexistência desse campo (Anexo 4).

4.3. Método de Análise

Após a preparação dos dados para aplicações de ML, na aprendizagem supervisionada, é necessário dividi-los em conjuntos de treino e teste (Joseph, 2022; Liu & Cocea, 2017). Baseado numa análise estatística que avalia diferentes divisões de dados e o seu impacto no desempenho dos modelos de ML, concluiu-se que a proporção de 70/30 é a mais adequada para o treino e validação dos modelos (Nguyen et al., 2021). Por essa razão, adotou-se essa divisão, aleatoriamente, onde 70% corresponde ao conjunto de treino para ensinar o algoritmo e 30% ao conjunto de teste, para fazer as previsões. Partindo dos resultados das previsões, estes são comparados com as ocorrências reais para que se percebam e avaliem os modelos testados (Joseph, 2022).

A avaliação de performance de classificadores que foi tida em consideração, tendo em conta a literatura, baseou-se na *Confusion Matrix* (Figura 3). Através desta matriz pode entender-se a relação entre as observações reais e esperadas, percebendo quais foram ou não classificadas corretamente: TP são o número de casos positivos classificados corretamente como positivos; TN são o número de casos negativos classificados corretamente como negativos; FP são o número de casos negativos classificados

erradamente como positivos (erro tipo I); FN são o número de casos positivos classificados de forma errada como negativos (erro tipo II).

N = % teste da Amostra (N = 16.815)		Valores Reais	
		Positivo	Negativo
Valores Previstos	Positivo	Positivo Verdadeiro (TP)	Positivo Falso (FP)
	Negativo	Negativo Falso (FN)	Negativo Verdadeiro (TN)

FIGURA 2 – Representação *Confusion Matrix* (Adaptado de Visa et al., 2011)

Partindo dos fatores subjacentes à matriz, apresentam-se, seguidamente, as três principais métricas que poderão ser calculadas (Wei & Dunbrack, 2013, Strauss et al., 2022).

$$(1) \quad Accuracy = \frac{\text{Número de previsões corretas}}{\text{Número total de previsões}} = \frac{TP+TN}{TP+TN+FP+FN}$$

A *accuracy*, que mede a frequência com que um modelo de ML consegue prever corretamente os valores verdadeiros, refletindo a sua capacidade de classificar corretamente os dados, e naturalmente, quanto maior for o valor, melhor a performance do modelo.

$$(2) \quad Precision = \frac{\text{True Positives}}{\text{Total de positivos previstos}} = \frac{TP}{TP+FP}$$

Relativamente à *precision*, é uma métrica que avalia a frequência de acertos do modelo na classe positiva verdadeira (Strauss et al., 2022), isto é, quanto mais frequentemente o modelo prevê de forma correta a variável *target*, mais perto de 1 se encontrará este fator.

$$(3) \quad Recall = \frac{\text{True Positives}}{\text{Total de positivos reais}} = \frac{TP}{TP+FN}$$

Por último, através da medida dada pela *recall*, é medida, efetivamente, a frequência de previsões positivas corretas, de entre todas as ocorrências positivas reais (Strauss et

al., 2022). É medido numa escala entre 0 e 1, e quanto maior for o seu valor, melhor será o modelo.

Baseado nas 3 equações de medição, o objetivo foi avaliar estas métricas sobre 3 modelos distintos (*decision tree*, *random forest* e *Xgboost*), comparando-os posteriormente para entender qual teria o melhor rendimento. Além disso, foram criados dois cenários distintos, diferindo na variável explicativa “EA”, por forma a entender o peso da inclusão ou não da mesma.

5. ANÁLISE DE RESULTADOS

Seguidamente, nesta secção, serão apresentados separadamente ambos os cenários criados, bem como descritos os resultados obtidos.

5.1. Cenário 1 da Previsão

No primeiro cenário, o objetivo consiste em perceber o comportamento da variável *target* (desvio: sim / não) em função do dia semana, mês, ano, forma de adjudicação e cabimentos.

TABELA I

RESULTADOS DE PERFORMANCE DOS TRÊS MODELOS (CENÁRIO 1)

	Previsão <i>Decision Tree</i>		Previsão <i>Random Forest</i>		Previsão <i>Xgboost</i>	
	Não desvio	Desvio	Não desvio	Desvio	Não desvio	Desvio
Não desvio real	8085	2361	7911	2535	9360	1086
Desvio real	3864	2505	3618	2751	4599	1770
<i>Accuracy</i>	0,63		0,63		0,66	
<i>Precision</i>	0,51		0,52		0,62	
<i>Recall</i>	0,39		0,43		0,28	

Fonte: *outputs* do *Spyder*

De acordo com o extraído do sistema (Tabela I): para o modelo de *decision tree*, o modelo previu de forma correta a existência de 2505 desvios (TP) e de 8085 não desvios (TN), e de forma incorreta a existência de 2361 desvios (FP) e de 3864 não desvios (FN); para o modelo de *random forest*, o modelo previu de forma correta a existência de 2751 desvios (TP) e de 7911 não desvios (TN), e de forma incorreta a existência de 2535 desvios (FP) e de 3618 não desvios (FN); para o modelo de *xgboost*, o modelo previu de forma correta a existência de 1770 desvios (TP) e de 9360 não desvios (TN), e de forma incorreta a existência de 1086 desvios (FP) e de 4599 não desvios (FN).

Partindo da informação fornecida pela Tabela I, e utilizando as equações de medição, obtiveram-se os seguintes parâmetros: (1) *Accuracy* = 63% para o modelo *decision tree* e *random forest*, e 66% para o modelo *xgboost*, valores esses que representam a percentagem de previsões corretas dos valores verdadeiros, não se revelando significativos, apesar da ligeira melhoria no terceiro modelo; (2) *Precision* = 51% para o modelo *decision tree*, 52% para o modelo *random forest* e 62% para o modelo *xgboost*, valores cujo significado reflete a taxa de acertos na classe positiva verdadeira, apresentando um melhor resultado no último modelo, no entanto, ainda insatisfatório; (3) *Recall* = 39% no modelo *decision tree*, 43% no modelo *random forest* e 28% no modelo *xgboost*, medidas estas que fornecem informação acerca da taxa de acerto efetiva na classe positiva, isto é, na previsão da existência de desvios, e que por isso, não se revelam resultados sólidos e convincentes, não se apresentando nenhum deles acima dos 50%.

Em jeito comparativo, neste primeiro cenário, aquele que teve uma *accuracy* e *precision* superiores foi o *xgboost* (66% e 62%, respetivamente), no entanto, no que toca a falar do parâmetro *recall*, este modelo foi o que apresentou pior resultado (28%). Quanto aos modelos de *decision tree* e *random forest*, de forma geral, apresentaram rendimentos semelhantes entre si, ligeiramente abaixo do *xgboost*, apesar dos valores de *recall* mais favoráveis.

Por fim, para cada um dos cenários foi realizada uma análise acerca dos pesos de cada variável no resultado da previsão da variável *target*, para o modelo considerado mais adequado (que neste caso foi o *xgboost*, pelas razões explicadas anteriormente), que permitiu observar quais variáveis são mais influentes, isto é, quais das características de um processo melhor conseguem explicar o *output* da previsão. Assim, para uma análise onde se procura explicar e prever a deteção de desvios, tendo por base as variáveis dia, mês, ano, forma de adjudicação e cabimentos, concluiu-se que (Anexo 5) as variáveis explicativas com maior preponderância seriam: o mês de julho, destacando-se das demais, com uma importância relativa de, aproximadamente, 22,1%, seguindo-se os meses de agosto e janeiro, com uma influência de cerca de 8,6% e 7,4%, respetivamente. O ano com maior interferência nos resultados, seria o ano de 2020, com cerca de 4,8%.

5.2. Cenário 2 da Previsão

No segundo cenário, o objetivo consiste em perceber o comportamento da variável *target* (desvio: sim / não), tal como no cenário anterior, mas desta vez, em função do dia, mês, ano, forma de adjudicação, cabimentos e elemento de ação. Analisando os resultados obtidos através do *software* utilizado, é possível extrair as seguintes informações (Tabela II): no modelo *decision tree*, este previu de forma correta a existência de 6074 desvios (TP) e de 10.370 não desvios (TN), e de forma incorreta a existência de 76 desvios (FP) e de 295 não desvios (FN); para o modelo de *random forest*, o modelo previu de forma correta a existência de 5800 desvios (TP) e de 10.424 não desvios (TN), e de forma incorreta a existência de 22 desvios (FP) e de 569 não desvios (FN); no modelo de *xgboost*, previu-se de forma correta a existência de 4318 desvios (TP) e de 10.438 não desvios (TN), e de forma incorreta a existência de 8 desvios (FP) e de 2051 não desvios (FN).

TABELA II

RESULTADOS DE PERFORMANCE DOS TRÊS MODELOS (CENÁRIO 2)

	Previsão <i>Decision Tree</i>		Previsão <i>Random Forest</i>		Previsão <i>Xgboost</i>	
	Não desvio	Desvio	Não desvio	Desvio	Não desvio	Desvio
Não desvio real	10.370	76	10.424	22	10.438	8
Desvio real	295	6074	569	5800	2051	4318
<i>Accuracy</i>		0,98		0,96		0,88
<i>Precision</i>		0,99		1,00		1,00
<i>Recall</i>		0,95		0,91		0,68

Fonte: *outputs* do *Spyder*

Partindo da informação fornecida pela Tabela II, e utilizando as equações de medição, obtiveram-se os seguintes parâmetros: (1) *Accuracy* = 98% para o modelo *decision tree*, 96% para o modelo *random forest* e 88% para o modelo *xgboost*, valores esses que representam a percentagem de previsões corretas dos valores verdadeiros, revelando-se resultados bastante significativos, apesar do decréscimo no terceiro modelo; (2) *Precision* = 99% para o modelo *decision tree*, 100% para o modelo *random forest* e 100% para o modelo *xgboost*, valores cujo significado reflete a taxa de acertos na classe positiva verdadeira, apresentando resultados, aparentemente, perfeitos nos dois últimos modelos, e muito semelhante no primeiro modelo; (3) *Recall* = 95% no modelo *decision tree*, 91% no modelo *random forest* e 68% no modelo *xgboost*, medidas estas que fornecem informação acerca da taxa de acerto efetiva na classe positiva, isto é, na previsão da

existência de desvios, e que por isso, se revelam resultados significativos nos dois primeiros modelos, e irrelevante no modelo *xgboost*.

Combinando os três modelos, para o segundo cenário, foi possível entender que, neste caso, os modelos de *decision tree* e *random forest* foram aqueles onde a *accuracy* se destacou pela positiva, com 98% e 96%, respetivamente. No que à *precision* diz respeito, os três modelos apresentaram valores muito próximos entre si, sendo que aquele onde o valor foi inferior foi a *decision tree* com 99%, tendo os restantes modelos alcançado valores de 100%. Concluindo, ao nível da *recall*, o modelo *xgboost* foi o que teve pior performance (68%), sendo que, nos restantes, os valores foram significativamente superiores, com o modelo *random forest* a alcançar resultados de 91%, e 95% para o modelo de *decision tree*. Em suma, pelas características descritas anteriormente, considerou-se que o modelo mais adequado e que apresentava melhor performance de classificação no conjunto dos três parâmetros era o modelo de *decision tree*.

Para finalizar, foi realizada, tal como no cenário anterior, uma análise que permitisse perceber o peso de cada variável na previsão da variável *target*, utilizando o modelo que se considerou mais adequado (*decision tree*) neste segundo cenário, que difere do primeiro pela inclusão dos EA. Posto isto, para uma análise desta natureza, com o intuito de prever a existência de desvios, considerando as variáveis dia, mês, ano, forma de adjudicação, cabimentos e EA, foi possível aferir que (Anexo 6) as variáveis explicativas de maior notoriedade e que maior peso explicativo poderiam ter na classificação da existência ou não de desvios foi o ano de criação dos processos, em que a criação de NPDs nos anos de 2022 e 2021 teriam um peso respetivo de, aproximadamente, 8,1% e 6,2%. Ainda assim, na grande maioria, o que melhor poderá explicar a ocorrência de desvios serão os próprios elementos de ação.

Da observação da Tabela III, pode depreender-se a presença significativa de EA correspondentes a bens e serviços para funcionamento corrente das UOS (FCC), que combinados, apresentam um peso preditivo de, aproximadamente, 9,33%.

É possível verificar que existem EA que são relevantes e explicativos, mesmo que em diferentes centros financeiros (...) por exemplo, neste caso, observa-se que o EA tido como um dos mais relevantes, com o descritivo FCC, destinado a uso generalizado e material diverso, encontra-se em diferentes centros financeiros.

In Malico (2023).

TABELA III

TOP10 DOS EA COM MAIOR PESO EXPLICATIVO NA PREVISÃO DE OCORRÊNCIA DE DESVIOS

EA	Descrição do EA	Peso Explicativo
4050118014	FCC – Assegurar bens de uso generalizado	3,89%
4060116043	MTO – Aquisição de Material Diverso	3,20%
4060116044	FCC – Aquisição de Material Diverso	2,68%
4110114007	MEQ – Fornecimento de bens inerentes à manutenção e funcionamento das infraestruturas	1,96%
4101516008	PCME – CA - Geral	1,60%
4060119007	FCC – Aquisição de Material Diverso	1,39%
4050118008	EPO – Manutenção preventiva ou inopinada das infraestruturas	1,38%
4030417040	FCC – Aquisição de outros materiais para o regular funcionamento	1,37%
4101516002	PCME – VCEMFA - GERAL	1,26%
4031117001	FND – MINUSMA - Mali	1,16%

Fonte: elaboração própria

Devido ao facto de na Tabela III estarem refletidos dois EA do mesmo centro financeiro que, aparentemente, se destinam ao mesmo uso, tendo surgido em duplicado no ano de 2021, considera-se que isto constitui um erro a assinalar.

O “4” indica que o código é referente a um EA, o “0601” indica o centro financeiro, o “16” representa o ano de criação e “044” representa o número sequencial (...) O que aparentemente poderá ter acontecido, uma vez que são iguais no mesmo centro financeiro (BA6), terá sido um deles já estar criado, e em 2019, criou-se outro com o mesmo fim, tendo ficado os dois a ser utilizados em simultâneo no ano de 2021, o que não é suposto.

In Malico (2023).

Assinalável é também a importância que os materiais e equipamentos oficinais e de laboratório, incluindo serviços externos (MTO), poderão ter no cumprimento ou não do orçamento estabelecido, uma vez que, de forma individual, apresentam um peso explicativo na variável *target* de cerca de 3,2%.

É ainda possível destacar, como potenciais EA propensos a entrar em desvio, os relativos à aquisição de mobiliário e equipamentos de bens diversos (MEQ), e os relativos ao plano de cursos e missões no estrangeiro (PCME), quer do Comando Aéreo, quer do Vice-CEMFA. Relativamente aos relativos ao PCME, entende-se a sua presença no TOP10 devido ao facto de que não existe um planeamento para estes espelhado em

sistema, pelo que tudo o que seja executado, surge como ultrapassando o seu limite, o que, naturalmente, originará um desvio.

Não se tem dotação prevista no tocante a assuntos do PCME (...) o PCME é um centro financeiro específico, uma vez que é um plano de cursos a ser autorizado pelo General CEMFA, onde se acaba por utilizar dotação do ano anterior, e onde poderá haver alguma oscilação, relativamente a cada centro. Tanto o PCME e o PCN (plano de cursos nacionais) não estão planeados. De todo o *plafond* que é dado à FAP, não é distribuído na íntegra às direções e unidades (...) parte dessa dotação fica numa conta que é a Previsional do CEMFA que é gerida pela DFFA, e essa dotação nasce daí, e acaba por não estar refletida no sistema.

In Malico (2023).

Além dos acima referidos, pelo histórico registado, os fundos destinados a missões no Mali, fazem deste EA um alvo a ter em conta aquando da análise da ocorrência de desvios. Porém, a sua presença neste leque dos mais explicativos, dever-se-á, também, ao facto de que à semelhança dos fundos para o PCME, este também não ser planeado, uma vez que segundo Malico (2023), “(...) a dotação é atribuída pelo EMGFA (Estado-Maior General das Forças Armadas) no decorrer do próprio ano e é atribuída a dotação à FAP consoante as missões que nos foram atribuídas. Portanto, não há qualquer tipo de planeamento nessas situações”.

5.3. Implicações na Gestão

Da Resolução do Conselho de Ministros n.º 55/2020, de 31 de julho de 2020, é referido que é necessário proceder a alterações na forma como a AP trabalha, dando lugar a novas ideias, defendendo que a exploração da tecnologia e inovação são chave na melhoria dos seus processos, garantindo respostas rápidas. Neste seguimento, da Resolução do Conselho de Ministros n.º 131/2021, de 10 de setembro de 2021, surge a Estratégia para a transformação Digital da Administração Pública 2021-2026, que vem estabelecer linhas estratégicas no sentido de alcançar uma AP mais inteligente, eficiente e transparente, através do potencial das tecnologias digitais e da utilização inteligente dos dados. Os resultados obtidos no estudo evidenciam a utilidade de IA na previsão de erros, reforçando o constante na literatura acerca da sua capacidade de resolução de problemas de forma célere e incisiva, melhorando o controlo interno e tornando a gestão mais efetiva e sustentável (Zhou, 2021).

6. CONCLUSÕES, LIMITAÇÕES E PISTAS DE INVESTIGAÇÃO FUTURA

Nesta última secção, serão tecidas as devidas conclusões do estudo, identificadas quais as limitações e entraves à realização do mesmo, e por consequência destas, sugeridas as possíveis linhas de investigação para trabalhos futuros.

6.1. Conclusões

O estudo utilizou três modelos de aprendizagem supervisionada para avaliar a utilidade da IA na fase específica do planeamento orçamental da FAP. O objetivo era identificar os EA com maior probabilidade de desvio com base no seu histórico e características, contribuindo para o controlo interno e otimização da distribuição de recursos, alinhando-os o melhor possível com as necessidades da organização.

Os dois cenários de previsão apresentam performances notoriamente diferentes. Para o cenário 1, o melhor modelo foi o *xgboost*, com uma *accuracy* de 66%, uma *precision* de 62% e um *recall* de 28%. Por oposição, no cenário 2, o melhor modelo foi a *decision tree*, com uma *accuracy* de 98%, uma *precision* de 99% e um *recall* de 95%. A diferença entre os dois cenários deve-se à inclusão da variável "EA", que aumentou significativamente a capacidade preditiva da análise. Esse aumento é natural, pois o EA é a variável que está mais diretamente relacionada com os desvios registados. Assim, a inclusão desta variável resultou num aumento de 32% na *accuracy*, indicando a capacidade de previsão correta de desvios e não desvios; um aumento de 37% na *precision*, representando a melhoria na deteção de desvios, de entre os desvios previstos e um aumento de 67% no *recall*, refletindo a melhoria mais significativa, traduzindo-se na capacidade de o modelo prever corretamente os desvios, de entre todos os desvios reais.

Além do objetivo do trabalho, é vital considerar a realidade da organização. Sendo uma instituição militar sujeita a fatores externos imprevisíveis, é utópico prever com perfeição as suas necessidades futuras e elaborar planeamentos exímios. Portanto, ter uma ferramenta como um PAA dinâmico e flexível é fundamental para se adaptar às necessidades decorrentes de fatores incontroláveis, tal como reforçado pelo entrevistado: “deve-se destacar a importância de tentar prever com cada vez mais precisão, no entanto, poder ter a ferramenta de conseguir alterar as previsões conforme as necessidades”. Até hoje, a escassez de dados foi um obstáculo ao desenvolvimento da IA. No entanto, no

mundo digital atual, os dados são abundantes nas organizações, não sendo a FAP uma exceção, impulsionando a IA a atingir o seu potencial. Conforme mencionado por Butz (2021), sistemas de inteligência deste nível poderão recomendar planos flexíveis e adaptáveis para alcançar as metas das instituições.

Além de EA destinados a campos onde o planeamento não é espelhado, denotou-se uma forte presença de EA referentes a despesas mais gerais e de funcionamento corrente das UOS.

Todos eles são EA bastante latos, onde encaixam muitos artigos. Existem prioridades nas unidades, e tendo um orçamento para gerir ao longo do ano, não se vai comprometer tudo muito tempo antes do fim do período. Normalmente é nos últimos meses que as unidades fazem os últimos ajustes e confirmam que há dotação para executar (...) Poderá estar relacionado com o facto de que este tipo de materiais, e estes EA, tendo em conta apenas estas informações, eventualmente, poderiam ser consumidos mais nessa altura do ano.

In Malico (2023).

Contudo, para todas as despesas do normal funcionamento corrente da organização, devem-se mitigar ao máximo os desvios registados, procurando ter cada vez mais proximidade e assertividade no estabelecimento daqueles que são os recursos destinados a cada EA, onde o entrevistado acrescenta,

Esta análise aplicar-se-ia muito bem, ou ajudaria mais ao nível das unidades. (...) conseguir-se-ia ter um planeamento mais ajustado para o ano seguinte, num nível micro, talvez ao nível de uma unidade, onde existe uma estrutura montada e em que a realidade não foge muito à normalidade. A um nível macro, surgem processos inesperados e de grande dimensão (compra de aeronaves, por exemplo), e onde se tem de reservar orçamento para essas situações (...) Numa unidade tem-se um orçamento para manter a unidade e o seu normal funcionamento, o que vai de encontro aos EA mais diversos.

In Malico (2023).

Conforme indicado na literatura, a aplicação de técnicas de IA na auditoria supera os modelos tradicionais (Zhou, 2021), melhorando a sua eficácia e a eficiência (Chen, 2020). Isso resulta em resoluções mais rápidas e precisas, reduzindo a carga de trabalho e o tempo necessários, proporcionando uma melhoria notável no controlo interno das organizações (Zhou, 2021). O entrevistado aponta que, atualmente,

Para saber a previsão para anos seguintes, tem de se pegar no histórico, no âmbito daquilo que se quer analisar. (...) Os mapas extraídos do sistema dão muita informação e o próprio sistema também, no entanto, são números que apenas dão uma ideia, sendo um método rudimentar de previsão (...) outro problema é a falta de meios e recursos humanos, pois, ainda que rudimentar, requer tempo e pessoas empenhadas.

In Malico (2023).

Neste caso concreto, no cenário 1, o sistema apenas precisou de, aproximadamente, 10 segundos para fazer as suas previsões, e relativamente ao cenário 2, com a inclusão da variável “EA”, que naturalmente tornou as previsões mais complexas, o sistema apenas precisou de cerca de 3 minutos, levando a crer que a sua aplicação poderia ser uma mais-valia, indo ao encontro de alguns problemas apontados. Perante o exposto acerca do funcionamento e apresentação de uma solução desta natureza, a visão do entrevistado, suportando a utilidade de modelos preditivos aplicados na FAP, é de que:

Tendo por base o tipo de tecnologias abordadas, creio que as mesmas são úteis para fazer o acompanhamento da execução orçamental, uma vez que, consoante várias variáveis, tais como, o tipo de procedimento adotado, o estado em que o processo de despesa se encontra, previsão de entrega dos bens ou prestação de serviço, entre outros, seria obtido o grau de probabilidade de ocorrer a execução orçamental pretendida. Na prática, a sua aplicação poderia ser traduzida para os seguintes fins: (...) dar prioridade a ações necessárias a nível interno (despacho da informação de início de procedimentos, despacho da informação de adjudicação, assinatura de contrato, remessa ao TC de um contrato para fiscalização prévia, entre outros); não iniciar um processo de despesa com execução para o próprio ano⁶ onde um grau de probabilidade de execução seja manifestamente baixa traduzindo-se em ineficácia; agilizar perante o fornecedor a entrega dos bens ou a prestação de serviços.

In Malico (2023).

Segundo Garcia (2020), a qualidade dos dados é crucial para o desempenho de um sistema, pois é através deles que se identificam padrões e gera conhecimento. Portanto, antes de usar um código de ML, é fundamental realizar uma preparação rigorosa dos dados para evitar enviesamentos ou preconceitos de quem os realiza, a fim de garantir que o código não aprende com esses erros e não os perpetua nos resultados da aplicação em novos casos. No contexto da FAP, o principal desafio não seria a aplicação de

⁶ O princípio orçamental da anualidade, presente na FAP (e AP), dita que a execução do orçamento tem de ocorrer no próprio ano, não sendo possível a transição de saldos para anos seguintes (exceto em programas orçamentais plurianuais).

algoritmos de ML, mas sim a preparação dos dados. Na organização, existem profissionais qualificados para tarefas deste tipo, e até mesmo para tarefas mais complexas no mesmo âmbito, que em colaboração com *players* de auditoria e planeamento orçamental, teriam capacidade suficiente para esta tipologia de análises. Quanto aos custos, contando com um computador funcional e acesso a *softwares* de programação, não haveria despesas adicionais, pois esses *softwares* estão disponíveis *online*, e dependendo das necessidades, podem ser instalados sem custos. O verdadeiro desafio reside na preparação dos dados para serem usados pelos algoritmos. Isso envolve todo o processo, desde a extração até a disponibilização dos dados para serem corridos por algoritmos. É essencial que os critérios de preenchimento dos dados sejam rigorosos e representem fielmente a realidade, sem lacunas, falhas de informação ou erros. Para alcançar isso, é crucial manter as equipas comprometidas (Newmark et al., 2018) e motivadas na adoção da IA, ano após ano.

No seguimento da ideia anterior, será importante salientar que este estudo terá sempre de ser aplicado com cautela e analisado à luz da conjuntura em que é realizado, pois devido a alterações estruturais no PAA, poderia originar-se repetição de EA, caso fosse realizada uma análise que incluísse os anos de 2023 e 2024, por exemplo, dado que

Os EA, vêm da Diretiva Estratégica da FAP. Devido às recentes alterações, a nova estrutura do PAA já foi utilizada para fazer o carregamento da Proposta Orçamental para 2024 (...) se fosse realizada uma análise que incluísse os anos pré e pós 2024, iria verificar-se a existência de EA em duplicado, devido à mudança de estrutura.

In Malico (2023).

6.2. Limitações

Apesar de ser um campo em desenvolvimento com várias abordagens e ferramentas, a aplicação à FAP representa o primeiro desafio, pois a informação necessária é específica e deve ser interpretada de acordo com as necessidades da organização. Além disso, a literatura existente abrange, principalmente, assuntos mais amplos ou aplicáveis ao setor privado. O presente trabalho visava testar a aplicação de técnicas de IA na gestão financeira e no controlo interno da FAP. A seleção do campo de aplicação foi desafiadora, devido à natureza dos dados disponíveis, restrições de tempo e à necessidade de uma base de dados substancial para treinar e testar modelos de ML. O estudo concentrou-se em dados internos da FAP, o que limitou o objeto de estudo. Para treinar um modelo de ML,

é crucial ter dados que incluam tanto casos corretos como anómalos, a fim de ensinar o algoritmo. Dado que o SIG já realiza as suas validações em muitos pontos de controlo, o campo de estudo escolhido teria de apresentar ocorrências não expectáveis, evitando, assim, um trabalho redundante. Por outro lado, a falta de variáveis explicativas pode introduzir enviesamento nos resultados. Outra possível limitação está nas entrevistas realizadas. Embora o foco fosse na aplicação prática dos dados por meio de um modelo ML estabelecido, entrevistar mais intervenientes no processo, com diferentes perspetivas, poderia enriquecer o trabalho. No entanto, questões logísticas e de tempo, impediram a implementação desse plano.

6.3. Pistas de Investigação Futura

Devido às limitações anteriores, surgem questões a explorar. Primeiro, considerando o trabalho já realizado, seria interessante analisar como a inclusão de mais variáveis afetaria o desempenho dos modelos, verificando se os fatores mais influentes se manteriam ou mudariam. O estudo abrangeu três anos, mas uma análise futura incluindo mais anos, ajudaria a validar os resultados atuais, verificando se as variáveis mais importantes para prever desvios / não desvios permaneceriam constantes ou sofririam alterações. Em relação às entrevistas realizadas, como mencionado anteriormente, seria relevante, além da aplicação prática, compreender e comparar as perspetivas de diferentes intervenientes em vários níveis hierárquicos no processo. Por fim, se os dados da organização o permitirem, seria benéfico para a FAP estudar e aplicar modelos de IA em outras áreas, como é o caso dos vencimentos. Conforme sugerido pelo entrevistado, uma previsão que poderia ser feita e que não é carregada em PAA, recairia sobre os vencimentos. Sabendo os vencimentos, as progressões, as promoções, as caducidades dos contratos, saídas e incorporações e passagens à reforma, poderia ser construído um modelo sustentado por IA para suporte do planeamento dos mesmos.

REFERÊNCIAS

- Abdelraheem, A., Hussaien, A., Mohammed, M., & Elbokhari, Y. (2021). The effect of information technology on the quality of accounting information. *Accounting*, 7(1), 191-196.
- Abdolmohammadi, M. J. (1991). Factors affecting auditors' perceptions of applicable decision aids for various audit tasks. *Contemporary Accounting Research*, 7(2), 535-548.
- Afeng, X., Xuemei, T., Ruifeng, P. (2017). Reflections on the accounting industry in the era of artificial intelligence [J]. *Accounting and accounting studies*, (10), 112-112.
- Aggarwal, K., Mijwil, M. M., Al-Mistarehi, A. H., Alomari, S., Gök, M., Alaabdin, A. M. Z., & Abdulrhman, S. H. (2022). Has the future started? The current growth of artificial intelligence, machine learning, and deep learning. *Iraqi Journal for Computer Science and Mathematics*, 3(1), 115-123.
- AICPA. (2020). The Data-Driven Audit: How Automation and AI are Changing the Audit and the Role of the Auditor. Disponível em: <https://www.aicpa.org/content/dam/aicpa/interestareas/frc/assuranceadvisoryservices/downloadabledocuments/the-data-driven-audit.pdf>.
- Alpaydin, E. (2014). Introduction to Machine Learning.
- Arnold, V., Collier, P. A., Leech, S. A., & Sutton, S. G. (2004). Impact of intelligent decision aids on expert and novice decision-makers' judgments. *Accounting & Finance*, 44(1), 1-26.
- Baldwin-Morgan, A. A., & Stone, M. F. (1995). A matrix model of expert systems impacts. *Expert Systems with Applications*, 9(4), 599-608.
- Baldwin, A. A., Brown, C. E., & Trinkle, B. S. (2006). Opportunities for artificial intelligence development in the accounting domain: the case for auditing. *Intelligent Systems in Accounting, Finance & Management: International Journal*, 14(3), 77-86.
- Bao, Y., Ke, B., Li, B., Yu, Y. J., & Zhang, J. (2020). Detecting accounting fraud in publicly traded US firms using a machine learning approach. *Journal of Accounting Research*, 58(1), 199-235.
- Barnes, J. (2015). *Microsoft Azure essentials Azure machine learning*. Microsoft Press
- Baryannis, G., Dani, S., & Antoniou, G. (2019). Predicting supply chain risks using machine learning: The trade-off between performance and interpretability. *Future Generation Computer Systems*, 101, 993-1004.
- Bertomeu, J. (2020). Machine learning improves accounting: Discussion, implementation and research opportunities. *Review of Accounting Studies*, 25(3), 1135-1155.
- Bertomeu, J., Cheynel, E., Floyd, E., & Pan, W. (2021). Using machine learning to detect misstatements. *Review of Accounting Studies*, 26, 468-519.
- Boillet, J. (2018). How artificial intelligence will transform the audit. *Earnest & Young Reporting*.

- Borana, J. (2016). Applications of artificial intelligence & associated technologies. *Science [ETEBMS-2016]*, 5(6).
- Bostrom, N. (2014). Get ready for the dawn of superintelligence. *New Scientist*, 223(2976), 26-27.
- Breiman, L. (2001a). Statistical modeling: The two cultures (with comments and a rejoinder by the author). *Statistical science*, 16(3), 199-231.
- Breiman, L. (2001b). Random forests. *Machine learning*, 45, 5-32.
- Brennan, B., Baccala, M., & Flynn, M. (2017). Artificial intelligence comes to financial statement audits. *CFO Newsletters*, 2.
- Brown, S. (2021). *Machine learning, explained*. MIT Sloan management.
- Butz, M. V. (2021). Towards strong AI. *KI-Künstliche Intelligenz*, 35(1), 91-101.
- Canadian Public Accountability Board (CPAB). (2021). Technology in the audit. Disponível em: https://www.cpab-ccrc.ca/docs/default-source/thought-leadership-publications/2021-technology-audit-en.pdf?sfvrsn=f29b51ce_14.
- Carlson, E. D. (1983). An approach for designing decision support systems. In A. Abdolmohammadi, Decision support and expert systems in auditing: A review and research directions, 1987. Accounting and Business Research, 173–185.
- Cecchini, M., Aytug, H., Koehler, G. J., & Pathak, P. (2010). Detecting management fraud in public companies. *Management Science*, 56(7), 1146-1160.
- Chen, G. F., & Ni, H. (2020). Application prospect of blockchain technology in water resources management. *J. Water conservancy and Hydropower Technology*, 6, 11-16.
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- Chiu, C. T., & Scott, R. (1994). An intelligent forecasting support system in auditing: expert system and neural network approach. In *1994 Proceedings of the Twenty-Seventh Hawaii International Conference on System Sciences*.
- Cohen, M., & Rozario, A. (2019). Exploring the use of robotic process automation (RPA) in substantive audit procedures. *The CPA Journal*, 89(7), 49-53.
- Cordeschi, R. (2007). AI turns fifty: revisiting its origins. *Applied Artificial Intelligence*, 21(4-5), 259-279.
- DARPA. (2016). Broad Agency Announcement Explainable Artificial Intelligence (XAI). Disponível em: <https://www.darpa.mil/attachments/DARPA-BAA-16-53.pdf>.
- Davenport, T. H., & Kirby, J. (2016). Just how smart are smart machines?.
- Davis, E., & Marcus, G. (2015). Commonsense reasoning and commonsense knowledge in artificial intelligence. *Communications of the ACM*, 58(9), 92-103.

- Davis, J. T., Massey, A. P., & Lovell II, R. E. (1997). Supporting a complex audit judgment task: An expert network approach. *European Journal of Operational Research*, 103(2), 350-372.
- Decreto-lei n.º 187/2014, de 29 de dezembro - Lei Orgânica da Força Aérea, Diário da República: Série I.
- Decreto-Lei nº26/2002 de 14 de fevereiro
- Deloitte. (2022). Deloitte Wins 2022 'Digital Innovation of the Year' for its Omnia ESG Module at the International Accounting Forum and Awards. Disponível em: <https://www2.deloitte.com/cn/en/pages/audit/articles/deloitte-wins-2022-digital-innovation-of-the-year.html>
- Deloitte. (s.d.(a)). Deloitte Omnia. Disponível em: <https://www2.deloitte.com/us/en/pages/audit/solutions/deloitte-omnia-unifying-people-processes-and-technology-in-auditing.html>
- Deloitte. (s.d.(b)). Blockchain and financial reporting. Disponível em: <https://www2.deloitte.com/us/en/pages/audit/articles/blockchain-financial-reporting.html>
- Despacho nº52/2008 de 30 de setembro, que determina o ciclo anual de planeamento e orçamento (CAPO)
- Dhage, S. N., & Raina, C. K. (2016). A Review on Machine Learning Techniques. *International Journal on Recent and Innovation Trends in Computing and Communication*, 4(3).
- Dickey, G., Blanke, S., & Seaton, L. (2019). Machine learning in auditing. *The CPA Journal*, 89(6), 16-21.
- Dietterich, T. G. (1998). Approximate statistical tests for comparing supervised classification learning algorithms. *Neural computation*, 10(7), 1895-1923.
- Ding, K., Lev, B., Peng, X., Sun, T., & Vasarhelyi, M. A. (2020). Machine learning improves accounting estimates: Evidence from insurance payments. *Review of accounting studies*, 25, 1098-1134
- Dutta, I., Dutta, S., & Raahemi, B. (2017). Detecting financial restatements using data mining techniques. *Expert Systems with Applications*, 90, 374-393.
- Eining, M. M., Jones, D. R., & Loebbecke, J. K. (1997). Reliance on decision aids: An examination of auditors' assessment of management fraud. *Auditing: A Journal of practice & theory*, 16(2).
- Elliot, V. H., Paananen, M., & Staron, M. (2020). Artificial intelligence for decision-makers. *Journal of Emerging Technologies in Accounting*, 17(1), 51-55.
- Ernst & Young. (s.d.). Audit Innovation. Disponível em: https://www.ey.com/en_gl/audit/innovation
- Eulerich, M., Pawlowski, J., Waddoups, N. J., & Wood, D. A. (2022). A framework for using robotic process automation for audit tasks. *Contemporary Accounting Research*, 39(1), 691-720.
- EY. (2018). Robotics and intelligent automation - Combining the power of human and machine (p. 32).
- EY. (2019). Multimillion-dollar investment in EY Blockchain Analyzer delivers new upgrades for blockchain and cryptocurrency audit and tax services. Disponível em:

https://www.ey.com/en_gl/news/2019/04/multimillion-dollar-investment-in-ey-blockchain-analyzer-delivers-new-upgrades-for-blockchain-and-cryptocurrency-audit-and-tax-services

EY. (2022). EY announces US\$1b investment in a next generation technology platform to facilitate trust, transparency and transformation through assurance services. Disponível em: **https://www.ey.com/en_gl/news/2022/06/ey-announces-us-1b-investment-in-a-next-generation-technology-platform-to-facilitate-trust-transparency-and-transformation-through-assurance-services#:~:text=LONDON%2C%20JUNE%202022,settlers%2C%20audit%20committees%20and%20boards**

EY. (2023). EY announces the fourth generation of the EY Blockchain Analyzer: Reconciler with new features for blockchain and cryptocurrency audit services. Disponível em: **https://www.ey.com/en_gl/news/2023/02/ey-announces-the-fourth-generation-of-ey-blockchain-analyzer-reconciler-with-new-features-for-blockchain-and-cryptocurrency-audit-services**

Faceli, K., Lorena, A. C., Gama, J., Almeida, T. A. D., & Carvalho, A. C. P. D. L. F. D. (2021). Inteligência artificial: uma abordagem de aprendizado de máquina.

Faggella, D. (2020). AI in the accounting big four—comparing Deloitte, PwC, KPMG, and EY. *Emerj, The AI Research and Advisory Company*. Disponível em: **<https://emerj.com/ai-sector-overviews/ai-in-the-accounting-big-four-comparing-deloitte-pwc-kpmg-and-ey/>**(Retrieved December 7, 2021).

Força Aérea (2016). *RFA 425-3. Regulamento das Auditorias de Administração Financeira e Patrimonial da Direção de Finanças da Força Aérea*. Alfragide: Força Aérea.

Força Aérea Portuguesa (2013). *RFA 303-10 (A). Organização e normas de funcionamento da Direção de Finanças da Força Aérea*. Alfragide: Força Aérea.

Força Aérea Portuguesa (2022). Diretiva de Planeamento Estratégico da Força Aérea 2022-2025.

Força Aérea Portuguesa (2022). Instrução n.º 1 do Serviço Administrativo e Financeiro.

Força Aérea Portuguesa (2022). Plano Anual de Atividades 2023.

Gama, J., Carvalho, A. D. L., Faceli, K., Lorena, A. C., & Oliveira, M. (2017). Extração de Conhecimento de Dados.

Garcia, A. C. (2020). Ética e inteligência artificial. *Computação Brasil*, (43), 14-22.

Gartner. (2019). Gartner Survey Shows 37 Percent of Organizations Have Implemented AI in Some Form. Disponível em: **<https://www.gartner.com/en/newsroom/press-releases/2019-01-21-gartner-survey-shows-37-percent-of-organizations-have>**

Gentry, J. A., Shaw, M. J., Tessmer, A. C., & Whitford, D. T. (2002). Using inductive learning to predict bankruptcy. *Journal of Organizational Computing and Electronic Commerce*, 12(1), 39-57.

- Goertzel, B. (2007). Human-level artificial general intelligence and the possibility of a technological singularity: A reaction to Ray Kurzweil's The Singularity Is Near, and McDermott's critique of Kurzweil. *Artificial Intelligence*, 171(18), 1161-1173.
- Gotthardt, M., Koivulaakso, D., Paksoy, O., Saramo, C., Martikainen, M., & Lehner, O. (2020). Current state and challenges in the implementation of smart robotic process automation in accounting and auditing. *ACRN Journal of Finance and Risk Perspectives*.
- Greenman, C. (2017). Exploring the impact of artificial intelligence on the accounting profession. *Journal of Research in Business, Economics and Management*, 8(3), 1451.
- Hunt, E., J. & Richardson, V. (2019). Predicting Accounting Misstatements Using Machine Learning. Mississippi State University. Working paper.
- Iansiti, M., & Lakhani, K. R. (2020). *Competing in the age of AI: Strategy and leadership when algorithms and networks run the world*. Harvard Business Press.
- IBM Cloud Education. (2020). Strong AI. Disponível em: <https://www.ibm.com/cloud/learn/strong-ai>
- IDC. (2023). Future of Intelligence. Disponível em: https://www.idc.com/eu/events/70563-idc-future-of-intelligence#section_7
- IDC. (2023). IDC FutureScape: *Worldwide Artificial Intelligence and Automation 2023 Predictions*. IDC FutureScape
- IEEE. (2019). IEEE Position Statement – Artificial Intelligence. Disponível em: <https://globalpolicy.ieee.org/wp-content/uploads/2019/06/IEEE18029.pdf>
- INE. (2021). Inquérito à Utilização de Tecnologias da Informação e da Comunicação nas Empresas. Disponível em: https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_destaques&DESTAQUESdest_boui=473557706&DESTAQUESmodo=2
- Institute for Robotic Automation and Artificial Intelligence. (s.d.). Definition and Benefits. Retrieved from: <https://irpaa.com/definition-and-benefits/>
- Janvrin, D., Bierstaker, J., & Lowe, D. J. (2008). An examination of audit information technology use and perceived importance. *Accounting horizons*, 22(1), 1-21.
- Joseph, V. R. (2022). Optimal ratio for data splitting. *Statistical Analysis and Data Mining: The ASA Data Science Journal*, 15(4), 531-538.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business horizons*, 62(1), 15-25.

- Kennedy, K. – Namee, B.M. – Delany, S.J. (2013): Using Semi-Supervised Classifiers for Credit Scoring. *The Journal of Operational Research Society*, 64(4): 513–529.
- Kepes, B. (2016). Big four accounting firms delve into artificial intelligence. *Computerworld*, 3.
- Kokina, J., & Davenport, T. H. (2017). The emergence of artificial intelligence: How automation is changing auditing. *Journal of emerging technologies in accounting*, 14(1), 115-122.
- Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160(1), 3-24
- KPMG. (2016). Intelligent Automation: How cognitive technology can sustain audit quality in the digital age. Disponível em: <https://home.kpmg/content/dam/kpmg/us/pdf/2016/11/us-audit-CognitiveFactSheet.pdf>
- KPMG. (2018). KPMG Clara: A smart audit platform. Disponível em: <https://assets.kpmg/content/dam/kpmg/xx/pdf/2017/05/kpmg-clara-a-smart-audit-platform.pdf>
- Kurzweil, R. (2014). *The singularity is near* (pp. 393-406). Palgrave Macmillan UK.
- Lacity, M. C., Willcocks, L. P., Craig, A. (2016, janeiro). Robotic process automation at telefónica O2. The Outsourcing Unit Working Research Paper Series, 15(02), 1-19.
- Lake, B. M., Ullman, T. D., Tenenbaum, J. B., & Gershman, S. J. (2017). Building machines that learn and think like people. *Behavioral and brain sciences*, 40, e253.
- Law, K., & Shen, M. (2020). How does artificial intelligence shape the audit industry. *Available at SSRN*.
- Lei n.º 8/90, de 20 de fevereiro - Lei de Bases da Contabilidade Pública, Diário da República: Série I.
- Lenard, M. J., Madey, G. R., & Alam, P. (1998). The design and validation of a hybrid information system for the auditor's going concern decision. *Journal of Management Information Systems*, 14(4), 219-237.
- Lensberg, T., Eilifsen, A., & McKee, T. E. (2006). Bankruptcy theory development and classification via genetic programming. *European Journal of operational research*, 169(2), 677-697.
- Levesque, H. J. (2017). *Common sense, the Turing test, and the quest for real AI*. mit press.
- Li, Y. (2017). Deep reinforcement learning: An overview. *arXiv preprint arXiv:1701.07274*.
- Lipton, Z. C. (2018). The mythos of model interpretability: In machine learning, the concept of interpretability is both important and slippery. *Queue*, 16(3), 31-57.
- Liu, H., & Cocea, M. (2017). Semi-random partitioning of data into training and test sets in granular computing context. *Granular Computing*, 2, 357-386.
- Loten, A. (2023). PricewaterhouseCoopers to Pour \$1 Billion Into Generative AI. *The Wall Street Journal*. Disponível em: <https://www.wsj.com/articles/pricewaterhousecoopers-to-pour-1-billion-into-generative-ai-cac2cedd>

- Maimon, O. Z., & Rokach, L. (2014). *Data mining with decision trees: theory and applications* (Vol. 81). World scientific.
- Martens, D. – Van Gestel, T. – De Backer, M. – Haesen, R. – Vanthienen, J. – Baesens, B. (2010): Credit Rating Prediction Using Ant Colony Optimization. *The Journal of Operational Research Society*, 61(4): 561–573.
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- McNiff, J. (2013). *Action research: Principles and practice*. Routledge.
- Minsky, M. (2007). *The emotion machine: Commonsense thinking, artificial intelligence, and the future of the human mind*. Simon and Schuster.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b*, 4, 51-62.
- Newmark, R. I., Dickey, G., & Wilcox, W. E. (2018). Agility in audit: Could scrum improve the audit process?. *Current Issues in Auditing*, 12(1), A18-A28.
- Nguyen, Q. H., Ly, H. B., Ho, L. S., Al-Ansari, N., Le, H. V., Tran, V. Q., ... & Pham, B. T. (2021). Influence of data splitting on performance of machine learning models in prediction of shear strength of soil. *Mathematical Problems in Engineering*, 2021, 1-15.
- O'Leary, D. E. (2003). Auditor environmental assessments. *International Journal of Accounting Information Systems*, 4(4), 275-294.
- Oladipupo, T. (2010). Types of machine learning algorithms. *New Advances in Machine Learning*.
- Omoteso, K. (2012). The application of artificial intelligence in auditing: Looking back to the future. *Expert Systems with Applications*, 39(9), 8490-8495.
- Osisanwo, F. Y., Akinsola, J. E. T., Awodele, O., Hinmikaiye, J. O., Olakanmi, O., & Akinjobi, J. (2017). Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138.
- Pereira, E. D. B. A. (2010). *O papel da Orçamentação na Força Aérea Portuguesa: Diferenças e semelhanças com o sector privado* (Doctoral dissertation, Instituto Superior de Economia e Gestão)
- Perols, J. (2011). Financial statement fraud detection: An analysis of statistical and machine learning algorithms. *Auditing: A Journal of Practice & Theory*, 30(2), 19-50.
- Perols, J. L., Bowen, R. M., Zimmermann, C., & Samba, B. (2017). Finding needles in a haystack: Using data analytics to improve fraud prediction. *The Accounting Review*, 92(2), 221-245.
- Pimentel, J. M. S. (2006). *O novo modelo orçamental da Força Aérea*.
- Public Company Accounting Oversight Board (PCAOB). (s.d.). AS 1105, Audit Evidence.
- Raphael, J. (2017). Rethinking the audit. *Journal of Accountancy*, 223(4), 29-32.

- Resolução do Conselho de Ministros n.º 131/2021, de 10 de setembro (2021). *Aprova a Estratégia para a transformação Digital da Administração Pública 2021-2026 e o respetivo Plano de Ação Transversal para a legislatura*. Diário da República, 1.ª série, 177.
- Resolução do Conselho de Ministros n.º 55/2020, de 31 de julho (2020). *Aprova a Estratégia para a Inovação e Modernização do Estado e da Administração Pública 2020-2023*. Diário da República, 1.ª série, 148.
- Rosner, R. L., Comunale, C. L., & Sexton, T. R. (2006). Assessing materiality. *The CPA Journal*, 76(6), 26.
- Russell, S., & Norvig, P. (2002). *Artificial Intelligence: A Modern Approach*.
- Sabouret, N. (2020). *Understanding artificial intelligence*. CRC Press.
- Schmidt, P. J., Church, K. S., & Riley, J. (2020). Clinging to Excel as a security blanket: Investigating accountants' resistance to emerging data analytics technology. *Journal of Emerging Technologies in Accounting*, 17(1), 33-39.
- Schonlau, M., & Zou, R. Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal*, 20(1), 3-29.
- Shift, D. (2015, September). Technology tipping points and societal impact. In *World Economic Forum Survey Report*. Disponível em: http://www3.weforum.org/docs/WEF_GAC15_Technological_Tipping_Points_report_2015.pdf (last accessed 20.08.2018).
- Shmueli, G. (2010). To explain or to predict?.
- Solaimani, R., Mohammed, S., Rashed, F., & Elkelish, W. (2020). The impact of artificial intelligence on corporate control. *Corporate Ownership & Control*, 17(3), 171-178.
- Strauss, E., Júnior, M. V. B., & Ferreira, W. L. L. (2022). A importância de utilizar as métricas adequadas de avaliação de performance em modelos preditivos de machine learning. *Projectus*, 7(2), 52-62.
- Sun, T. (2019). Applying deep learning to audit procedures: An illustrative framework. *Accounting Horizons*, 33(3), 89-109.
- Taborda, P. (2017). Lei de Benford–Aplicação à Força Aérea Portuguesa. *Academia da Força Aérea*, 167.
- Tan, P. N., Steinbach, M., & Kumar, V. (2013). Data mining cluster analysis: basic concepts and algorithms. *Introduction to data mining*, 487, 533.
- Ucoglu, D. (2020a). Effects of artificial intelligence technology on accounting profession and education. *Pressacademia*, 11(1), 16-21.
- Ucoglu, D. (2020b). Current machine learning applications in accounting and auditing. *PressAcademia Procedia*, 12(1), 1-7.

- Violante, A., & Andrade, A. (2022). O potencial da inteligência artificial na gestão. *Gestão e Desenvolvimento*, (30), 439-479.
- Virág, M., & Nyitrai, T. (2014). Is there a trade-off between the predictive power and the interpretability of bankruptcy models? The case of the first Hungarian bankruptcy prediction model. *Acta Oeconomica*, 64(4), 419-440.
- Visa, S., Ramsay, B., Ralescu, A. L., & Van Der Knaap, E. (2011). Confusion matrix-based feature selection. *Maics*, 710(1), 120-127.
- Wei, Q., & Dunbrack Jr, R. L. (2013). The role of balanced training and testing data sets for binary classifiers in bioinformatics. *PloS one*, 8(7), e67863.
- Welch, O. J., Reeves, T. E., & Welch, S. T. (1998). Using a genetic algorithm-based classifier system for modeling auditor decision behavior in a fraud setting. *Intelligent Systems in Accounting, Finance & Management*, 7(3), 173-186
- Williamson, K. (2002). *Research methods for students, academics, and professionals: Information management and systems*. Elsevier.
- Wright, K. (2019). KPMG and Microsoft have signed a five-year agreement. Disponível em: <https://kpmg.com/xx/en/home/media/press-releases/2019/12/kpmg-expands-microsoft-alliance-to-accelerate-professional-services-transformation.html>
- Zemánková, A. (2019). Artificial intelligence and blockchain in audit and accounting: Literature review. *wseas Transactions on Business and Economics*, 16(1), 568-581.
- Zhou, G. (2021, March). Research on the problems of enterprise internal audit under the background of artificial intelligence. In *Journal of Physics: Conference Series* (Vol. 1861, No. 1, p. 012051). IOP Publishing.
- Zhu, Y., Gao, T., Fan, L., Huang, S., Edmonds, M., Liu, H., ... & Zhu, S. C. (2020). Dark, beyond deep: A paradigm shift to cognitive ai with humanlike common sense. *Engineering*, 6(3), 310-345.

ANEXOS

Anexo 1 – Plataformas/ferramentas desenvolvidas pelas *Big4*

	EY	PwC	Deloitte	KPMG
Tax & Legal			Sonar	
Audit	Canvas	GL.ai	Argus	Clara
	Helix	Cash.ai	Optix	
	Blockchain Analyzer	Halo	Signal	
			Cortex	
			Reveal	
			Omnia DNAV	
Consulting			GRAPA	
Risk Advisory			HR Agent Edgy	
Financial Advisory			DocQMiner	
			Eagle Eye	
			BrainSpace	

Fonte: Ucoglu, 2020

Anexo 2 – Ciclo Anual de Planeamento Orçamental

CICLO ANUAL DE PLANEAMENTO E ORÇAMENTO							
Objectivos Estratégicos	Directiva de Planeamento	Plano Anual de Actividades	Proposta de Orçamento			Directiva Objectivos de Gestão	Relatório Anual de Actividades
Revisão	Revisão	Elaboração	Elaboração			Revisão	Elaboração
DIVPLAN	DIVPLAN	Macro-estrutura	DFFA	GT EMFA / SIG	Macro-estrutura	DIVPLAN	GT EMFA / SIG
31 OUT N-2	15 DEZ N-2	31 MAR N-1	Proposta de Orçamento despesas Pessoal 31 MAR N-1 Propostas de Orçamentos despesas Pessoal - Versões MDN 15 MAIN-1 Consolida Propostas de Orçamento JUN N-1	Proposta de Orçamento 15 ABR N-1 Atribuição de macro prioridades ao Plano de Actividades 31 MAIN-1 Plano Anual Actividades por Objectivos Sectoriais e Subunidade 15 JUL N-1 Gravar no SIG e ajustar o Plano Anual de Actividades SET a DEZ N-1	Definição de financiamento e atribuição prioridades ao Plano Anual de Actividades 31 MAIN-1 Lançamento do financiamento das actividades no SIG (coordenação DFFA)	15 DEZ N-1	31 MAR N-1

Fonte: Anexo B ao Despacho n.º 52/2008, de 30 de setembro

Anexo 3 – Descrição das variáveis categóricas

	count	unique	top	freq
Forma de Adjudicação	56056	11	Ajuste directo	41981
Económica Despesa	56056	505	02.01.21.17	3725
Elemento_Acção	56056	3265	4050118014	1269
Descrição da Acção	56056	3108	FCC - Aquisição de material diverso	1595
Target	56056	2	Não	35037
Ano	56056	7	2021	19066
Mes	56056	12	11	6597
Dia_da_semana	56056	7	Wednesday	11991

Fonte: *Output Spyder*

Anexo 4 – Estatística descritiva das variáveis numéricas e observações ausentes

	Cabimentos	Desvio		
count	56048.0	56056.0	Forma de Adjudicação	0
mean	28096.7	-235815.1	Económica Despesa	0
std	695943.8	6956021.6	Cabimentos	8
min	-15842.7	-219669067.8	Elemento_Acção	0
25%	55.8	-2976.2	Descrição da Acção	0
50%	213.6	0.7	Desvio	0
75%	913.0	320.4	Target	0
max	70840562.9	13556877.0	Ano	0
			Mes	0
			Dia_da_semana	0

Fonte: *Output Spyder*

Anexo 5 – Comparativo de pesos (%) das 20 variáveis explicativas mais importantes no melhor modelo de classificação (*XGBoost*) no Cenário 1

	Score (%)
Mes_7	22.072136
Mes_8	8.627127
Mes_1	7.441363
Mes_5	5.984522
Mes_12	5.088457
Ano_2020	4.808932
Mes_3	3.482062
Dia_da_semana_Sunday	3.396567
Mes_4	3.172402
Mes_10	2.880383
Dia_da_semana_Saturday	2.264265
Mes_11	2.116763
Forma de Adjudicação_Acordo Quadro	2.056478
Dia_da_semana_Thursday	1.927537
Forma de Adjudicação_Não atribuído	1.858541
Mes_2	1.835918
Ano_2019	1.819808
Dia_da_semana_Monday	1.768577
Mes_6	1.755673
Mes_9	1.725907

Fonte: *Output Spyder*

Anexo 6 – Comparativo de pesos (%) das 20 variáveis explicativas mais importantes no melhor modelo de classificação (*Decision Tree*) no Cenário 2

	Score (%)
Ano_2022	8.104498
Ano_2021	6.178043
Elemento_Acção_4050118014	3.887894
Elemento_Acção_4060116043	3.203361
Elemento_Acção_4060116044	2.675886
Elemento_Acção_4110114007	1.963596
Elemento_Acção_4101516008	1.604490
Elemento_Acção_4060119007	1.388094
Elemento_Acção_4050118008	1.375398
Elemento_Acção_4030417040	1.366089
Elemento_Acção_4101516002	1.264515
Elemento_Acção_4031117001	1.161540
Elemento_Acção_4102012011	1.145654
Ano_2020	1.117959
Elemento_Acção_4101516003	1.116620
Elemento_Acção_4031216007	1.032028
Elemento_Acção_4060116007	0.807114
Elemento_Acção_4050118007	0.783627
Elemento_Acção_4110114017	0.781395
Elemento_Acção_4031122001	0.737451

Fonte: *Output Spyder*